



Universidad Autónoma de Querétaro
Facultad de Ingeniería

Arquitectura FPGA para estimaciones espectrales de orden superior

Tesis

Que como parte de los requisitos para obtener el grado de Doctor en Ingeniería

Presenta

M. en I. David Camarena Martínez

Dirigido por:

Dr. Arturo García Pérez
Dr. Roque Alfredo Osornio Ríos

CU, Querétaro, Qro. Mayo 2015



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Ingeniería

Arquitectura FPGA para Estimaciones Espectrales de Orden Superior

Tesis

Que como parte de los requisitos para obtener el Grado de
Doctor en Ingeniería en Mecatrónica

Presenta:

M. en I. David Camarena Martínez

Dirigido por:

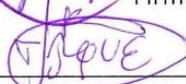
Dr. Arturo García Pérez
Dr. Roque Alfredo Osornio Ríos

SINODALES

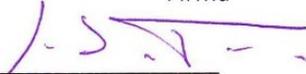
Dr. Arturo García Pérez
Presidente


Firma

Dr. Roque Alfredo Osornio Ríos
Secretario


Firma

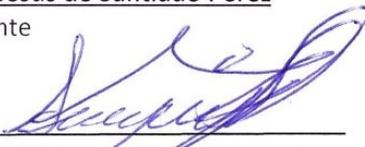
Dr. René de Jesús Romero Troncoso
Vocal


Firma

Dr. Luis Morales Velázquez
Suplente


Firma

Dr. J. Jesús de Santiago Pérez
Suplente


Firma
Dr. Aurelio Domínguez González
Director de la Facultad
Dra. Ma. Guadalupe Flavia Loarca Piña
Directora de Investigación y Posgrado

RESUMEN

Hoy en día, muchos investigadores han sido atraídos por el tema del monitoreo de máquinas eléctricas debido a una gran variedad de fallos que están presentes cuando la máquina eléctrica se encuentra en funcionamiento, estos fallos pueden ser eléctricos o mecánicos, los cuales pueden afectar drásticamente el comportamiento de la máquina . En este trabajo, se proponen y desarrollan nuevas metodologías con el fin de conocer la condición de la máquina eléctrica, dichas metodologías están basadas en el análisis de espectral de alto orden; y principalmente se centran en la reciente técnica llamada Empirical Mode descomposición (EMD), que en la actual literatura reportada ha demostrado buenos resultados, estas metodologías propuestas se usan en la detección de las fallas individuales y combinados, ya sea reportado en la literatura. Además, se ha utilizado como plataforma la tecnología FPGA para implementar las metodologías propuestas, este instrumento o es sistema automático utilizando la técnica de EMD que es capaz de en la supervisión en línea de máquinas eléctricas, además puede tratar con señales no lineales y no estacionarias, lo cual lo hace adecuado para señales de corriente de un motor. Los resultados obtenidos de esta investigación fueron publicados en dos artículos en revistas indexadas.

Palabras clave: Condition Monitoring, Motor análisis de la firma actual, empírica Modo de descomposición, FPGA

SUMMARY

Nowadays, many researchers have been attracted by the topic of monitoring of electric machines due to a great variety of faults that are present when the electric machine is in operation, these faults could be electrical or mechanical, which can affect drastically the behavior of the machine. In this work, different methodologies based on high order analysis spectral are proposed and developed in order to know the condition of the electric machine; they are mainly focused on the recent technique called Empirical Mode Decomposition (EMD), which perform reported in the present literature had proven good results, as well the different methodologies proposed are used in the detection of single and combined faults, either reported in literature. Also, an FPGA has been used as technology platform to implement the aforementioned methodologies in order to develop a monitoring instrument. On the other hand, this instrument has the advantage of being an automatic on line system and uses the EMD technique, which is capable of monitoring of the electric machine, this implementation can deal with nonlinear a non-stationary signals, which is suitable for motor current signals and other industrial application. The obtained results of this investigation was published on two papers in indexed journals.

Keywords: Condition Monitoring, Motor current signature analysis, Empirical Mode Decomposition, FPGA

DEDICATORIA

“A mi madre y a mi padre que hicieron posible este logro

“A mis hermanas por estar siempre conmigo”

AGRADECIMIENTOS

A mis padres y hermanas por el apoyo incondicional que me han dado durante todo este tiempo, siendo mi principal motivación para seguir avanzando y salir adelante.

A mis asesores, el Dr. Arturo García Pérez, el Dr. René de Jesús Romero Troncoso y el Dr. Roque Alfredo Osornio Ríos, por confiar en mí y darme dirección en mis estudios doctorales, por sus invaluable consejos y enseñanzas durante mi formación profesional.

A todos mis compañeros de trabajo, que me dieron su apoyo y me acompañaron durante el doctorado, en especial a: Carlitos, Lieberman, Pablo, Rooney, Armando, Marco, Uriel, Arturo, Benigno, Carlos, Irving, Paquito, José Luis, y Basurto.

A todos los integrantes del grupo HSPdigital por el apoyo y amistad que me han brindado haciendo que lo difícil sea fácil.

A todos mis alumnos de la Universidad Autónoma de Querétaro por todas las experiencias vividas dentro y fuera del aula de clases.

A todos los colegas y personal de trabajo de la Universidad Autónoma de Querétaro que ayudaron, facilitaron y brindaron su ayuda laboral y personal.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por otorgarme la beca (329800) para realizar mis estudios doctorales en la Universidad Autónoma de Querétaro.

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	14
1.1. ANTECEDENTES	14
1.1.1 Análisis Espectral en Máquinas Eléctricas.....	17
1.1.2 Antecedentes del grupo de investigación HSP y la Universidad Autónoma de Querétaro	20
1.2. OBJETIVOS	21
1.2.1 Objetivo general.....	21
1.2.2 Objetivos Específicos:	21
1.3 DESCRIPCIÓN DEL PROBLEMA	22
1.4 JUSTIFICACIÓN	23
1.5 PLANTEAMIENTO GENERAL.....	26
2. REVISIÓN DE LA LITERATURA	28
2.1 TRANSFORMADA HILBERT HUANG.....	29
2.2 DESCOMPOSICIÓN EMPÍRICA DE MODOS	30
2.3 VARIACIONES A LA DESCOMPOSICIÓN EMPÍRICA DE MODOS	34
2.3.1 Descomposición empírica en modos por conjuntos.....	34
2.3.2 Descomposición empírica en modos por conjuntos complementarios	36
2.3.3 Descomposición parcial empírica en modos por conjuntos	38
2.4 RED LINEAL ADAPTIVA	40
2.5 LAS REDES NEURONALES ARTIFICIALES	43
2.6 DIAGNÓSTICO EN MÁQUINAS ELÉCTRICAS ROTATORIAS	45
2.7 FALLAS EN MÁQUINAS ELÉCTRICAS ROTATORIAS.....	46
2.7.1 Falla de barra rota	47
2.7.1.1Causas de la rotura de barras.....	47
2.7.1.2 Detección de rotura de barras.....	48
2.7.2 Falla de desbalance en un motor.....	49
2.7.2.1 Causas de desbalance en un motor.....	49
2.7.3 Falla en baleros	49
2.7.3.1 Componentes principales de los rodamientos.....	49

2.7.3.2 Causas de fallas en los Rodamientos	50
2.8 LOGICA PROGRAMABLE.....	52
3. METODOLOGÍA.....	54
3.1 SISTEMAS DE MONITOREO DE MÁQUINAS ELÉCTRICAS	55
3.2 CASOS DE ESTUDIO.....	59
3.2.1 Caso de estudio 1. Metodología basada en EMD-MUSIC para la detección de fallas múltiples en motores eléctricos.	59
3.2.1.1 Condiciones de falla.....	61
3.2.2 Caso de estudio 2. Implementación del algoritmo emd en fpga para la detección de fallas en motores de inducción.	62
3.2.2.1 Procesador basado en FPGA	64
3.2.2.2 Estructura digital EMD.....	67
3.2.2.3 Módulo de Identificación de extremos.....	68
3.2.2.4 Módulo de interpolación Spline cúbica.....	68
3.2.2.5 Estructura ADALINE digital	71
3.2.2.6 FFNN.....	72
3.2.3 Caso de estudio 3. Metodología basada en EEMD-MUSIC para la obtención de las frecuencias naturales en estructuras civiles.....	75
3.2.3.1 Señal sintética.....	76
3.2.3.2 Excitación artificial.....	77
3.2.3.3 Excitación natural.....	83
4. RESULTADOS	84
4.1 CASO DE ESTUDIO 1. METODOLOGÍA BASADA EN EMD-MUSIC PARA LA DETECCIÓN DE FALLAS MÚLTIPLES EN MOTORES ELÉCTRICOS.....	84
4.2 CASO DE ESTUDIO 2. IMPLEMENTACIÓN DEL ALGORITMO EMD EN FPGA PARA LA DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN.	89
4.3 CASO DE ESTUDIO 3. METODOLOGÍA BASADA EN EEMD-MUSIC PARA LA OBTENCIÓN DE LAS FRECUENCIAS NATURALES EN ESTRUCTURAS CIVILES	94
4.3.1 Señal sintética	94
4.3.2 .Excitación artificial	96
5. CONCLUSIONES.....	102
6. REFERENCIAS	104

ANEXO A: Artículo indizado (Caso de estudio 1)
ANEXO B: Artículo indizado (Caso de estudio 2)
ANEXO C: Artículo indizado (Caso de estudio 3)
ANEXO D: Artículo indizado
ANEXO E: Artículo congreso internacional
ANEXO F: Artículo congreso internacional

ÍNDICE DE FIGURAS

FIGURA 1.1 a) Sistema de monitoreo clásico. b) Sistema de monitoreo propuesto	23
FIGURA 1.2 Planteamiento general.....	26
FIGURA 1.3 Estructura del instrumento.....	28
FIGURA 2.1 Respuesta en Fase del Sistema Transformador de Hilbert	29
FIGURA 2.2 Diagrama de flujo del método EMD	32
FIGURA 2.3 Señal en tiempo $x(t)$	34
FIGURA 2.4 a) Distribución tiempo frecuencia de la señal $x(t)$ usando la STFT b) usando la HHT	34
FIGURA 2.5 Diagrama de flujo del método EEMD.....	36
FIGURA 2.6 . Diagrama de flujo del método CEEMD	38
FIGURA 2.7 Diagrama de flujo del método PEEMD	40
FIGURA 2.8 Estructura de bloque ADALINE para la estimación de frecuencias	42
FIGURA 2.9 Arquitectura de una FFNN.....	43
FIGURA 2.10 Incremento de la amplitud de las componentes frecuenciales laterales debido a la falla BRB. (Garcia-Ramirez et al., 2012).....	48
FIGURA 2.11 Componentes de un balero (Reincos S.A. de C.V., 2015).....	50
FIGURA 2.12 Fallas en el balero: a) disco exterior, b) disco interior, c) tren del balero y d) balines. (Vibratech, 2015)	52
FIGURA 3.1 Diagrama general de la metodología seguida.	55
FIGURA 3.2 Sistema de monitoreo eléctrico basado en FPGA.	56
FIGURA 3.3 Sistema de monitoreo de máquinas eléctricas FPGA.....	57
FIGURA 3.4 Diagrama a bloques de los sistemas de monitoreo	57
FIGURA 3.5 Instrumentación de sensores de corriente.....	58
FIGURA 3.6 Tarjeta para la etapa de acondicionamiento de señales.....	58
FIGURA 3.7 Diagrama de bloques del sistema propuesto múltiple combinado para los motores de inducción.	60
FIGURA 3.8 Banco de prueba para la detección de fallas múltiples y combinadas del motor.	60
FIGURA 3.9 Fallas generadas artificialmente. a) Una barra rota (1BB). b) Defecto en el disco exterior del balero (BD), C) desbalance (UNB).	61
FIGURA 3.10 Combinaciones de las fallas múltiples	62
FIGURA 3.11 Propuesta de metodología para diagnóstico de falla en los motores de inducción.....	64
FIGURA 3.12 Procesador basado en FPGA.....	65
FIGURA 3.13 Metodología propuesta para el diagnóstico de la condición de un motor de inducción en buen estado.	65
FIGURA 3.14 Contenido de frecuencia para cada IMF de un motor de inducción Equipo de Alto Nivel, a) Primera IMF, b) Segunda IMF, c) Tercera IMF, y d) Cuarta IMF	66

FIGURA 3.15 Diagrama de bloques del enfoque EMD propuso	67
FIGURA 3.16 Diagrama de bloques del módulo de identificación de los extremos	68
FIGURA 3.17 Diagrama de bloques del módulo de interpolación spline cúbica	69
FIGURA 3.18 a) y b) Diagrama de bloques del módulo de Matriz Tridiagonal.....	71
FIGURA 3.19 Diagrama de bloques del módulo ADALINE	72
FIGURA 3.20 Componentes de frecuencia de estimación hasta ADALINE por diferentes faltas.....	74
FIGURA 3.21 Diagrama a bloques del módulo FFNN, a) capa oculta, b) capa de salida	74
FIGURA 3.22 Metodología para la extracción de frecuencias naturales	75
FIGURA 3.23 Señal sintética	77
FIGURA 3.24 a) IMFs de la señal sintética, b) DCs de la señal sintética.....	78
FIGURA 3.25 (a) Estructura de barras articuladas. (b) Elementos de la estructura	80
FIGURA 3.26 Obtención de señales de aceleración obtenidas de la estructura tipo truss	81
FIGURA 3.27 Banco de pruebas.....	82
FIGURA 3.28 Medición de la aceleración vertical	82
FIGURA 3.29 Puente analizado	83
FIGURA 4.1 Espectros obtenidos del motor en estado sano y con fallas individuales a) IMF2 HLT, b) IMF1 HLT, c) IMF2 1BB, d) IMF1 1BB ,e) IMF2 BD, f) IMF1 BD, g) IMF2 UNB, h) IMF1 UNB.....	86
FIGURA 4.2 Espectros obtenidos por un análisis de diferentes combinaciones de fallas. a) IMF2 BD-UNB, b) IMF1 BD-UNB, c) IMF2 1BB-UNB, d) IMF1 1BB-UNB, e) IMF2 1BB-BD, f) IMF1 1BB-BD, g) IMF2 1BB-BD-UNB, h) IMF1 1BB-BD-UNB.	86
FIGURA 4.3 IMFs resultantes de la implementación de hardware EMD, a) del motor en buen estado, b) del motor defectuoso con dos barras del rotor rotas	91
FIGURA 4.4 Resultados obtenidos por (a) EEMD-HT (b) DWT-HT, (c) EEMD-FFT, (d) DWT-FFT, (e) EEMD-MUSIC, y (f) DWT-MUSIC.....	95
FIGURA 4.5 IMFs obtenidas mediante EEMD de la señal de aceleración vertical.	97
FIGURA 4.6 Pseudo-espectros de diferentes analizó IMF.....	98
FIGURA 4.7 a) Medición de la aceleración vertical y b) su densidad espectral de potencia.....	99
FIGURA 4.8 IMFs obtenidas a través de EEMD para la aceleración de vibración ambiental.....	100
FIGURA 4.9 Pseudo- espectros de las IMFs analizadas	101

ÍNDICE DE TABLAS

TABLA 3.1 Componentes de frecuencia seleccionados para cada IMF	66
TABLA 4.1 La detectabilidad en decibelios para el análisis de fallos combinados múltiples.....	88
TABLA 4.2 Resultados de la ejecución basado en FPGA.....	89
TABLA 4.3 Porcentaje de eficacia de la metodología propuesta	90
TABLA 4.4 Recursos usados de la FPGA.....	90
TABLA 4.5 Principales características de los trabajos anteriores y de la obra propuesta.	93
TABLA 4.6 Identificación de frecuencias naturales.	96
TABLA 4.7 Comparación de las frecuencias naturales obtenidas.....	98
TABLA 4.8 Frecuencias naturales obtenidas.	101

1. INTRODUCCIÓN

La estimación espectral de una señal digital tiene por objeto la descomposición de dicha señal en sus diversas componentes dentro del dominio de la frecuencia. El análisis espectral puede ser llevado por un conjunto de técnicas diferentes y su aplicación es utilizada en varias especialidades de ingeniería, ciencias aplicadas, y procesamiento de datos. Una tarea muy común en el análisis espectral es tratar de encontrar frecuencias características importantes que den información de utilidad proveniente de una determinada señal que está contaminada por otras, por ejemplo ruido. Las frecuencias más significativas sirven para explicar diversos fenómenos, estacionalidad o características estadísticas generales del proceso aleatorio. Aunque contiene la misma información que el análisis en el dominio del tiempo, el análisis en el dominio de la frecuencia puede facilitar la comprensión de un fenómeno.

EL análisis espectral ha ido progresando y nuevas técnicas denominadas de “*orden superior*” cuentan con mejor desempeño que las técnicas de análisis espectral clásicas basadas en la transformada de Fourier (*Fourier Transform, FT*) y ayudan a encontrar información de una señal de manera más eficiente; estas técnicas requieren de alto número de operaciones lógicas y matemáticas, sin embargo, los resultados justifican su fiabilidad, para solucionar este problema se concentró en implementar algoritmos y arquitecturas con el mínimo de recursos, computacionalmente eficientes a través de su implementación en hardware, de esta manera no sólo se pueden implementar complejos algoritmos en tiempo real si no también presentar soluciones SoC (*System on a Chip; sistema en un chip*).

En este trabajo se desarrolla e implementan metodologías en base al uso de técnicas de procesamiento de orden superior aplicadas al monitoreo y clasificación de fallas que afectan a las máquinas eléctricas rotatorias.

1.1. ANTECEDENTES

La estimación espectral consiste en estimar la densidad espectral de potencia de una señal en el dominio del tiempo, con el fin de caracterizar el contenido en frecuencia de la

señal. Tradicionalmente las técnicas para el análisis espectral de las señales están basadas en el uso de la FT, la cual sirve para caracterizar la distribución de energía en las frecuencias que conforman la señal. Sin embargo, esta técnica sólo pueden ser utilizadas cuando las propiedades estadísticas de la señal no varían con el tiempo, por lo cual terminan siendo inadecuadas para señales no estacionarias de corta duración, que suele ser los casos comunes en las aplicaciones en el mundo real (Huang et al, 1998).

En los últimos años se ha dado una expansión en las técnicas de estimación espectral; las cuales han sido esenciales en muchas aplicaciones, tales como las comunicaciones, sonar, radar, procesamiento de voz e imagen, geofísica, estructuras civiles, procesamiento de señales biomédicas y en la detección de fallas de equipo industrial. Una de las desventajas de la FT es que supone que la señal es estacionaria, algo que no sucede comúnmente puesto que las señales presentan características no estacionarias, debido a que hay cambios de corta duración. Para contrarrestar esta deventaja se ha usado la Transformada Corta de Fourier (*Short Time Fourier Transform, STFT*) para hacer frente al problema de las señales no estacionarias la cual es utilizada ampliamente debido a su fácil implementación. Como ejemplo, Zhang et al. (2006) desarrollaron un procesador en línea en hardware basado en la Transformada Corta de Fourier Discreta, aplicado al análisis espectral en tiempo real. Sin embargo, la STFT, cuenta con varias desventajas como son la baja resolución espectral y temporal, además de la incapacidad de manejar las características no lineales de una señal, ya que esta técnica considera que el sistema físico tiene una función de transferencia lineal, es decir, que la respuesta del sistema a múltiples entradas, se obtiene mediante la observación de cada entrada en forma individual, y posteriormente se suman cada uno de los resultados individuales; así que a menudo los sistemas son representados por ecuaciones lineales, sin embargo, el comportamiento no lineal de las señales reales, hacen no adecuadas el uso de estas técnicas.

Otra técnica de análisis espectral es la Transformada Wavelet (*Wavelet Transform, WT*), también usada para el análisis tiempo-frecuencia, la cual ha resultado ser útil para el análisis de señales no estacionarias, por lo cual ha sido ampliamente utilizada. Como en

clasificación de audio (Chien-Chang L. et al., 2005), procesamiento de imágenes, monitoreo de máquinas eléctricas (Lau y Ngan, 2010), monitoreo de la calidad de la energía (Erişti y Demir, 2012), detección de patologías en señales biomédicas (Labate, et al., 2013), etc. Sin embargo, la WT tiene como desventaja que utiliza ventanas de corta duración para altas frecuencias y de larga duración para bajas frecuencias, proporcionando una alta resolución en frecuencia (a bajas frecuencias) y una alta resolución en tiempo (a altas frecuencias); lo cual limita la capacidad de análisis frecuencial de la Transformada Wavelet.

La distribución Wigner-Ville (*Wigner-Ville Distribution, WVD*) es otra técnica de análisis tiempo-frecuencia de señales no estacionaria, la cual ha resultado ser efectiva en la descomposición tiempo-frecuencia; su resolución es mayor comparada con la resolución entregada por técnicas lineales como la STFT. Como ejemplo, Rajagopalan et al. (2006) presentaron un estudio para la detección de fallas de rotor en motores de inducción operando en condiciones no estacionarias. Sin embargo, la distribución Wigner-Ville también presenta una gran desventaja, el “cruce de frecuencias” (*cross-terms*) que dificultan la interpretación de los resultados. Recientemente han aparecido nuevas técnicas para la estimación espectral aparte de las convencionales basadas en la FT, estas nuevas técnicas cuentan con un gran desempeño en la estimación de las componentes espectrales, entre las técnicas se encuentran el Análisis Espectral de Orden Superior (*High Order Spectral Analysis, HOSA*), la Clasificación Múltiple de Señales (*Multiple Signal Classification, MUSIC*) y la Transformada Hilbert-Huang (*Hilbert-Huang Transform, HHT*), las cuales han resultado efectivas para el análisis espectral de señales no lineales de corta duración. El problema de estas técnicas es el requerimiento de una gran capacidad de cómputo, por lo que la necesidad del diseño y desarrollo de arquitecturas que permitan el procesamiento en tiempo real de dichas técnicas es una necesidad actual para su uso. Una posible solución a este problema es la utilización de dispositivos Arreglo de Compuertas Lógicas Programables en Campo (*Field Programmable Gate Arrays, FPGA*), los cuales gracias a su capacidad de procesamiento en paralelo permiten realizar varias operaciones al mismo tiempo, logrando sistemas aptos para su funcionamiento en tiempo real.

1.1.1 Análisis Espectral en Máquinas Eléctricas

El diagnóstico de máquinas eléctricas se enfrenta al problema de que la mayoría de los fenómenos naturales cuentan con un comportamiento no lineal y a la vez no estacionario, es decir que las características de las señales como lo son el voltaje y la corriente, van cambiando con el tiempo y es difícil predecir su comportamiento en cada momento. El método más extendido para el diagnóstico de fallas en máquina industriales se basa en la transformación rápida de Fourier (FFT) para el análisis en frecuencia de las señales (Schien et al., 1997; Cabanas, et al., 1999), el cual proporciona resultados robustos cuando la máquina opera bajo un cierto nivel de carga y bajo un régimen estacionario perfecto, sin embargo presenta algunos inconvenientes importantes cuando se aplica para diagnosticar el estado de las máquinas sin carga o con poca carga, máquinas que manejan cargas de par variable (por ejemplo, los motores de los molinos de conducción, compresores, reductores, etc), o las máquinas que son alimentadas con tensiones fluctuantes (Antonino-Daviu et al., 2006). Algunos métodos basados en el estudio de los procesos transitorios de la máquinas eléctricas y, más concretamente, en el transitorio de arranque (Zhang, et al., 2003), se han desarrollado recientemente. La base implícita o explícita de estas técnicas consiste en la detección del armónico de la banda lateral izquierda (LSH), asociado a la falla, durante la ocurrencia del estado transitorio en el arranque de la máquina eléctrica en donde la evolución característica de esta componente constituye una prueba fiable de la presencia de la rotura de la barra del rotor. Un método basado en la aplicación de la DWT de la corriente de arranque del estator se ha introducido recientemente por Antonino-Daviu, et al. (2007), en el cual se encontraron patrones que hacen posible el diagnóstico de la falla, incluso en casos en que el análisis de Fourier no lleva a corregir el diagnóstico.

A pesar de los resultados satisfactorios del método DWT, algunos problemas persisten, entre ellos se encuentra la selección de la Wavelet madre para la aplicación de la DWT la cual se realiza de una manera arbitraria, ya que no hay reglas claras para la selección de la Wavelet madre óptima para cierta aplicación específica (Antonino-Daviu et al. 2009), otro problema es la poca inmunidad que presenta la DWT a señales ruidosas lo cual evita la extracción correcta de información de una señal (Bhende et al., 2008).

Actualmente técnicas como el HOSA y HHT, han logrado hacer frente al problema de la no estacionabilidad y la no linealidad de las señales, por lo cual han empezado a ser ampliamente utilizadas en varias aplicaciones. En lo que respecta a las técnicas de Análisis Espectral de Orden Superior, Suiren, et al. (2003) combinaron dicha técnica con el uso de la DWT para el estudio de imágenes de ultrasonido de piel humana. Chua, et al. (2007) analizaron señales de encefalograma (*EEG*) para la detección de epilepsia. Acharya, et al. (2011) utilizaron la técnica de HOSA en imágenes de nervio óptico para la detección temprana de glaucoma.

Recientemente Huang et al. Propusieron una nueva técnica llamada Transformada Hilbert-Huang, la cual posee la ventaja de poder analizar señales no estacionarias y no lineales. La transformada Hilbert Huang se compone de dos partes, la descomposición empírica de modos (*Empirical Mode Decomposition, EMD*) y la Transformada Hilbert (*Hilbert Transform, HT*), EMD así como la HHT han sido aplicadas ampliamente en los diferentes campos de la ciencia, demostrando ser una herramienta de gran ayuda y efectividad en el análisis de señales. Zhang, et al. (2010) utilizaron la HHT para la evaluación de distensión arterial. En el campo de la ingeniería civil se ha utilizado para la detección de defectos en imágenes de estructuras de concreto (Tong, et al., 2010). La transformada Hilbert-Huang también ha tenido aplicaciones en el sector industrial. Ruqiang & Gao (2006) presentaron una metodología basada en la HHT para el análisis de vibraciones aplicada al monitoreo de máquinas, demostrando que es eficaz para lograr la detección de deterioro de un rodamiento en motores de corriente continua. Xiang, et al. (2007) afirmaron que el análisis de maquinaria eléctrica a través de la HHT logra tener un mejor desempeño para análisis tiempo-frecuencia en comparación al uso de la WT o la WVD. Xiang, et al. (2008) propusieron un nuevo método basado en la HHT para el diagnóstico de fallas en el devanado del estator de motores de inducción. Ying et al. (2009) presentaron una técnica nueva de procesamiento de señales para identificar fallas en rodamientos del motor. Antonino-Daviu, et al. (2009) mostraron una comparación en el uso de Transformada Wavelet con la Transformada Hilbert-Huang para la detección de fallas en una o dos barras rotas en motores de inducción. Kalvoda, et al. (2010) presentaron un análisis para el monitoreo de procesos no estacionarios y no

lineales en maquinaria industrial a través del uso de la HHT. Wang et al. (2010) desarrollaron un nuevo método para el diagnóstico de fallas en motores diésel basado en el análisis del espectro marginal obtenido con la HHT, Liu Z. & Zhang, (2010) usaron la HHT para la descomposición y análisis de señales de motores, Lei & He (2011) también propusieron un método a través del análisis del espectro Hilbert-Huang para el diagnóstico de fallas en maquinaria eléctrica. Xu, et al. (2011) aplicaron un análisis de vibraciones en el rotor de motores de avión usando la transformada Hilbert Huang. Shen, et al (2012) aplicaron el método EMD para la identificación de fallas en cajas de engranes. Zamanian & Ohadi (2011) hicieron el análisis estadístico de la descomposición de las señales de vibración hecha por EMD para el diagnóstico de fallas en engranes. Lei, et al. (2008) combinaron la EMD con algoritmos genéticos para detección de defectos en los baleros en motores de inducción. También Lei et al. (2009) usaron la EMD por conjuntos para la detección de fallas en el rotor. Lei (2012) utilizó la EMD para la identificación y monitoreo de fallas múltiples en máquinas rotatorias. A pesar de la gran aplicabilidad de estas técnicas, la mayoría de estos estudios; el procesamiento es realizado en computadoras, y en virtud a la gran capacidad de cómputo que demandan las técnicas de orden superior, generan un sistema lento que no es aplicable para el análisis en tiempo real.

Lo anterior muestra la existencia de varias y diferentes metodologías para el monitoreo de máquinas eléctricas, sin embargo, estas están fuertemente limitadas al ser realizadas en software, lo que conlleva a un monitoreo fuera de línea y a otras desventajas propias de la tecnología software; por otro lado, las pocas implementaciones en hardware utilizan diseños específicos y por lo tanto estructuras no reconfigurables. Las limitantes de las técnicas actuales hacen pensar en la posibilidad de generar un gran campo de investigación y aplicación en metodologías hardware para el monitoreo de la máquinas eléctrica. La tecnología actual a través del uso de dispositivos reprogramables como las FPGAs, permiten desarrollar nuevas arquitecturas con el fin de acelerar algoritmos que no pueden ser implementados en computadoras para aplicaciones en tiempo real; ya que normalmente estas aplicaciones requieren de un gran número de operaciones, por lo que su implementación en un FPGA es considerada necesaria; principalmente por que

el FPGA es un dispositivo con la capacidad de desarrollar computo en paralelo haciéndolo idóneo en aplicaciones que requieran operar en línea. Como ejemplo de ello, Yang et al. (2007) realizaron un sistema FPGA en tiempo real para el monitoreo, transmisión y diagnóstico de señales de electrocardiograma (ECG). Morales et al. (2010) mostraron el diseño de una arquitectura abierta FPGA con funciones reconFigurables de control y monitoreo en tiempo real para máquinas CNC. Bartzoudis et al. (2011) presentaron un diseño e implementación FPGA de un transceptor de WiMAX móvil en tiempo real. Por lo cual se puede decir con certeza, que el uso de la tecnología FPGA brinda la posibilidad de implementar las técnicas propuestas de análisis espectral de orden superior para ser usadas en aplicaciones que requieran análisis en tiempo real.

1.1.2 Antecedentes del grupo de investigación HSP y la Universidad Autónoma de Querétaro

Entre los antecedentes que se tienen dentro de la universidad está el trabajo de Ordaz-Moreno, et al. (2008), que presentaron un algoritmo para el diagnóstico y detección automática en línea de barras rotas en motores de inducción usando la Transformada Wavelet Discreta (*Discrete Wavelet Transform, DWT*). Por otro lado, Franco, et al. (2006) desarrollaron un sistema para el monitoreo de la señal de corriente en los servomotores para determinar los daños o desgaste en la maquinaria CNC; este trabajo fue desarrollado utilizando la transformada Wavelet para encontrar las frecuencias originadas por la fuerza de corte de la máquina, los algoritmos diseñados fueron implementados en hardware para poder realizar el monitoreo en línea y fueron probados en una máquina CNC Baker-422 bajo distintas condiciones de corte. García-Perez et al.(2011) usaron análisis espectral de alta resolución basado en la técnica MUSIC para poder identificar barra rota en el transitorio de arranque. García-Ramírez et al. (2012) presentaron una metodología basada en la FFT y redes neuronales para la detección de fallas múltiples en motores con variador de frecuencia, la cual fue implementada en FPGA para ser usado como sensor inteligente.

Como se podrá observar en los trabajos citados aún falta mucho por explorar sobre técnicas de análisis espectral. Principalmente el desarrollo de arquitecturas

hardware genéricas que apliquen estas técnicas sin importar la aplicación a la cual vayan a ser destinadas ya que la mayoría de las arquitecturas hardware son de propósito específico y no permiten el desarrollo de sistemas más grandes.

1.2. OBJETIVOS

1.2.1 Objetivo general

Desarrollar una arquitectura en hardware aprovechando el diseño y paralelismo en FPGA para optimizar el tiempo de cómputo al implementar la Transformada Hilbert-Huang y el Análisis Espectral de Orden Superior.

1.2.2 Objetivos Específicos:

1. Integrar y desarrollar tecnología para el monitoreo de la condición de máquinas eléctricas para la detección temprana de fallas que nos permitan proponer un mantenimiento predictivo y preventivo.
2. Desarrollar una metodología para la detección y clasificación de fallas en máquinas eléctricas basado en técnicas espectrales de orden superior.
3. Desarrollar e integrar nuevas arquitecturas en FPGA para la implementación de técnicas de estimación espectral avanzadas y con aplicación en la elaboración de instrumentos para el monitoreo de maquinaria industrial.
4. Comparar en cuanto a tiempo y recursos de cómputo la metodología desarrollada en software y la arquitectura desarrollada en hardware para evaluar la mejora del sistema propuesto.
5. Verificar la eficacia de las nuevas arquitecturas en FPGA con las técnicas de estimación espectral avanzadas implementadas en hardware con respecto a las metodologías hasta ahora reportadas en software para mostrar las mejoras de las nuevas arquitecturas desarrolladas.

1.3 DESCRIPCIÓN DEL PROBLEMA

El monitoreo de máquinas industriales es uno de los principales intereses en el sector industrial, el cual ayuda a garantizar el correcto desempeño del proceso de producción, ayudando a detectar fallas en diferentes equipos como lo son transformadores, generadores, motores y máquinas CNC. El problema generado por fallas en máquinas industriales es que éstas inicialmente no presentan síntomas evidentes, y requieren la aplicación de técnicas avanzadas de análisis espectral que puedan ayudar a la identificación temprana y correcta de las fallas, es por eso que el mantenimiento predictivo de maquinaria industrial llama la atención a muchas empresas debido a que contribuye en el ahorro de los altos costos causados por fallas inesperadas.

Comúnmente el uso de técnicas avanzadas de análisis espectral para el monitoreo de máquinas industriales consiste en el sensado y adquisición de datos que son transmitidos hacia una computadora, la cual almacena dichos datos y posteriormente realiza el análisis espectral fuera de línea mediante un software especializado y finalmente proporciona el diagnóstico como se puede observar en la Figura 1.1 a. La principal razón por la que se lleva este procedimiento se debe a la gran carga computacional que requieren estas técnicas, pero como consecuencia conlleva a un monitoreo lento y costoso. Por lo cual la presente investigación propone el diseño de una arquitectura hardware que permita el uso de diferentes técnicas de análisis espectral de orden superior, en donde la implementación se realizará en una tarjeta FPGA la cual proporciona la capacidad de implementar un sistema en línea y en tiempo real, lo que significa mayor rapidez y un diagnóstico totalmente automático. La Fig. 1 presenta una comparación entre un sistema de monitoreo tradicional y el sistema de monitoreo propuesto en esta investigación.

El desarrollo de un instrumento de monitoreo para alguna falla que afecte las máquinas o herramientas eléctricas, requerirá la implementación de la metodología revisada en la literatura para el monitoreo de esta misma falla, incluyendo bloques de instrumentación y bloques de pre-procesamiento. Cuidando que estas integraciones de hardware reúnan y mantengan las características y recursos necesarios para realizar el monitoreo en línea

y a un bajo costo. Como parte del problema y aportación científica, se debe diseñar y desarrollar una arquitectura eficiente en velocidad y en recursos hardware para el desarrollo arquitecturas FPGA que cumplan y satisfagan, de forma flexible y versátil cada una de las características y requerimientos propios de la técnica de estimación espectral.

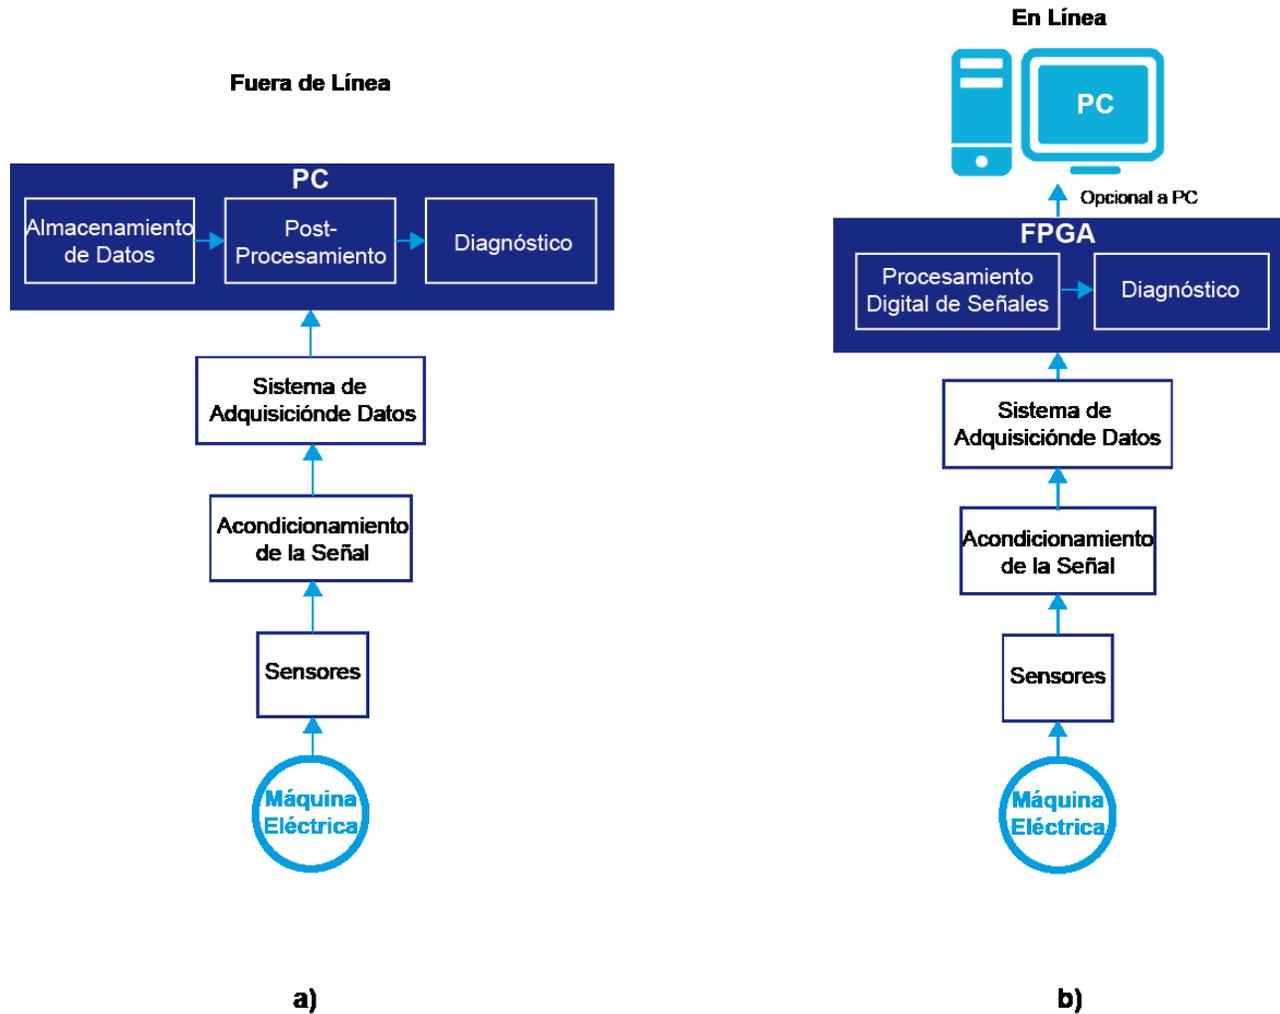


Figura 1.1 a) Sistema de monitoreo clásico. b) Sistema de monitoreo propuesto

1.4 JUSTIFICACIÓN

La principal motivación en la elaboración de esta investigación, consiste en que después de realizar una búsqueda en lo referente al estado del arte de las técnicas de estimación espectral, a la fecha no se ha encontrado el diseño de una arquitectura lineal, genérica

y flexible en hardware para la implementación de las técnicas de estimación espectral como son la Transformada Hilbert-Huang y el Análisis Espectral de Orden Superior. Por lo que en esta investigación se propone desarrollar nuevas arquitecturas para la implementación de estas técnicas de estimación espectral en un FPGA; ya que la única implementación encontrada en hardware de la HHT, fue desarrollada por Wang et al. (2010), para el análisis de señales de electrocardiograma ECG, donde la principal desventaja de esta implementación es que trabaja con señales de muy baja frecuencia, dando lugar a una aplicación en hardware muy limitada y específica para el campo de la medicina, evitando ser aplicada en otras áreas, donde el requerimiento de paralelismo, arquitectura genérica y flexible son necesarios como por ejemplo en análisis espectral en tiempo real. Por lo tanto, el diseño y desarrollo de nuevas arquitecturas aplicadas a la estimación espectral de orden superior; permitirán el procesamiento y análisis de señales no estacionarias y no lineales de una forma eficiente y versátil, con esto, la contribución para el campo de innovación en el desarrollo de instrumentos será muy grande. Una aplicación natural de esta investigación consiste en el análisis de máquinas industriales, que requieren un análisis espectral en tiempo real.

Las soluciones identificadas hasta ahora acerca del uso de técnicas de estimación espectral de orden superior en artículos reportados en congresos internacionales y revistas indexadas principalmente presentan metodologías que realizan las técnicas de análisis espectral en software, esto debido a la gran carga computacional que requieren. A pesar de las muchas aplicaciones que tiene el análisis espectral; el monitoreo y diagnóstico de máquinas industriales, es una de las principales aplicaciones de éste debido a los grandes beneficios que otorga al sector industrial, como por ejemplo, la detección de fallos repetitivos, la detección temprana de fallas, el ahorro en la compra de nuevos equipos, el incremento en la vida útil de los equipos, la disminución de costos por reparaciones, la detección de puntos débiles en la instalación y el ahorro en el consumo de energía, entre una larga lista de ventajas. Es por eso que la situación demanda sistemas en línea para el monitoreo de las máquinas industriales que indiquen de forma rápida y eficiente la condición actual de la maquinaria de forma flexible, versátil, con velocidad de diagnóstico y con mejor costo que las propuestas actuales. Por lo tanto en

este momento el problema se concentra en implementar algoritmos y arquitecturas con el mínimo de recursos computacionalmente para presentar plataformas de desarrollo como lo son los “sistemas en un solo chip” (*SoC, System on a Chip*), sistemas reconFIGurables, plataformas con sistemas embebidos, etc.

En el ámbito tecnológico una implementación basada en un dispositivo de alto desempeño como los circuitos FPGA se justifica de la siguiente forma: los dispositivos FPGAs permiten bajo una arquitectura de procesamiento paralelo una alta velocidad de cómputo, además el desarrollo de cualquier aplicación en estos dispositivos es descrita bajo un lenguaje de descripción en hardware que hace al diseño portable en una plataforma en hardware independiente. Permiten desarrollar soluciones tipo SoC que han estado ganando mercado recientemente, ya que en éstos dispositivos se pueden integrar unidades de procesamiento que son definidas por el usuario, así como los periféricos lógicos relacionados en hardware. Se combinan arquitecturas abiertas que no dependen de algún fabricante o plataforma específica, en este caso de otros módulos del sistema desarrollados en otras investigaciones. Este tipo de dispositivos además proporcionan al diseñador la libertad suficiente para lograr una tarea específica desarrollando un nivel de arquitectura que también representa una unidad única de bajo costo. El arreglo de los bloques lógicos dentro del FPGA y la característica que le permite al usuario definir su interconectividad lo convierten en un dispositivo programable y conFIGurable en una arquitectura completamente abierta. Por otra parte, la velocidad y el tamaño de esta tecnología son comparables con los circuitos integrados de aplicación específica, pero con mayor flexibilidad. La portabilidad del diseño basado en FPGA le confiere a los desarrollos la inmunidad a la obsolescencia, problema tan recurrente en aplicaciones industriales. Finalmente, como conclusión se puede decir que esta investigación pretende desarrollar nuevas arquitecturas en hardware de estimaciones espectrales de orden superior y como ejemplo de aplicación al caso de monitoreo y diagnóstico de máquinas industriales las cuales sean versátiles a nuevas necesidades y proporcionen un resultado automático y confiable.

1.5 PLANTEAMIENTO GENERAL

El planteamiento general de la metodología seguida en este trabajo se muestra en la Figura 1.3, la cual consiste principalmente de cuatro módulos: (1) Diseño del banco de pruebas, (2) Desarrollo de un sistema de adquisición de datos, (3) Desarrollo e implementación de la metodología para el monitoreo de máquinas eléctricas y (4) pruebas y resultados para validar y probar las metodologías e instrumentos desarrollados.



Figura 1.2 Planteamiento general.

Una descripción más detallada de los bloques anteriores es la siguiente:

Diseño del banco de pruebas: En esta parte del desarrollo de este trabajo es necesario diseñar y planear las pruebas físicas donde serán probadas las metodologías e instrumentos desarrollados. Para esto, se utilizaron: (1) Señales sintéticas basadas en modelos matemáticos reportados en la literatura, (2) Señales reales de base de datos del IEEE disponibles en internet y (3) señales reales generadas a través de un banco de disturbios eléctricos compuesto de cargas monofásicas y trifásicas como motores, banco de capacitores, variadores de velocidad, entre otras.

Desarrollo del sistema de adquisición de datos: Esta etapa consiste principalmente en el desarrollo e integración de sensores de voltaje y corriente, así como la etapa de filtrado y acondicionamiento de estas señales. También, la programación del sistema de control de los convertidos analógico digital, y de la transmisión de datos.

Desarrollo e implementación de metodologías para el monitoreo de máquinas eléctricas Este etapa es la más importante en la cual se proponen nuevas metodologías que permitan monitorear y analizar de forma más eficiente la condición de las máquinas eléctricas.

Pruebas y resultados: finalmente en esta etapa, se valida y prueba las distintas metodologías e instrumentos desarrollados en los bancos de pruebas diseñados en la

primer etapa. También, los resultados obtenidos son comparados con las metodologías reportadas en la literatura para los distintos casos de estudio.

Una vez funcional el sistema anterior, los instrumentos para el monitoreo de la máquinas eléctricas tendrán la estructura mostrada la Figura 1.4.

Los bloques que componen la estructura del instrumento son:

- Sensor: El instrumento presentará sensores para monitoreo de corriente o vibración que nos permitan extraer información de la condición de la máquina eléctrica
- Sistema de adquisición de datos (*Data Acquisition System, DAS*) El sistema de adquisición contará con un módulo del controlador DAS el cual se encarga de obtener y acondicionar las señales provenientes de los sensores para su procesamiento
- Controlador DAS. Estará embebido dentro del FPGA, dicho módulo se encargará de controlar la entrada de las extraídas por el DAS.
- Procesador de Análisis Espectral: Este módulo realizará alguna técnica de análisis espectral con el fin de encontrar características esenciales que identifiquen el estado actual del sistema a monitorear. La elección de la técnica dependerá y se seleccionará acorde a la mejor metodología encontrada en la literatura para el monitoreo de algún parámetro en específico que afecte a la máquina eléctrica.
- Clasificador. Este módulo estará embebido en la FPGA y servirá para dar un resultado automático de la condición de la máquina eléctrica, estará basado ya sea en redes neuronales o sistemas difusos.
- Despliegado de Resultados. Este modulo finalmente mostrará el resultado obtenido de la condición de la máquina eléctrica; el resultado será mostrado en una pantalla LCD o será transmitido hacia una computadora para su registro.

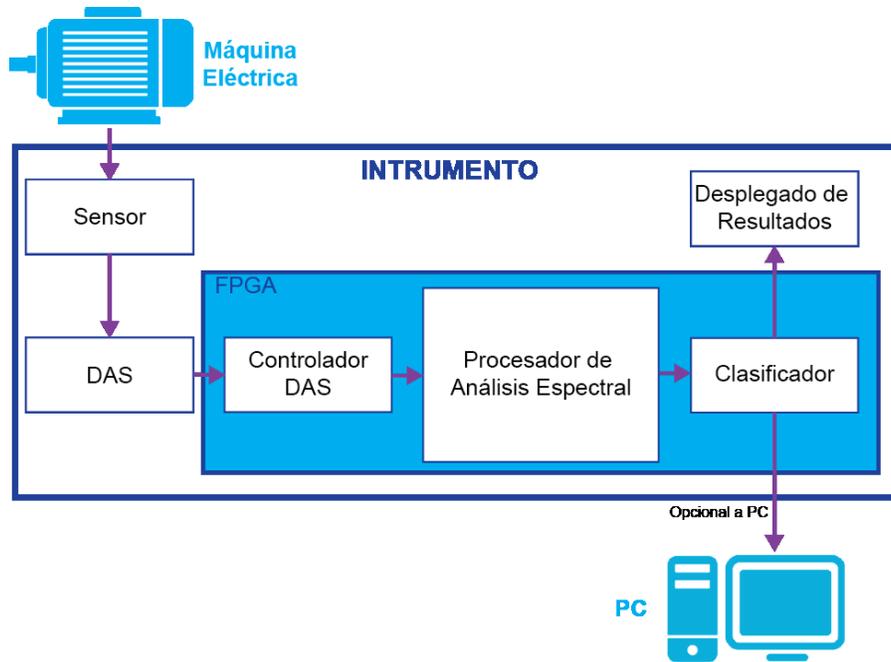


Figura 1.3 Estructura del instrumento.

2. REVISIÓN DE LA LITERATURA

En el mundo del mantenimiento mecánico, son de sobra conocidos los casos en los que la Transformada de Fourier no es capaz de evidenciar en forma clara, el proceso del fallo. Esto significa que a pesar de observar vibraciones, fatigas y fallos, la Transformada de Fourier no consigue determinar un patrón claro del fenómeno. Esta inexactitud de la Transformada de Fourier es una característica intrínseca de la propia Transformada, es decir es inevitable, debido a que es incapaz de tratar señales no estacionarias de corta duración (Huang et al, 1998). Así pues se busca una herramienta que sea capaz de determinar claramente fallas que puedan estar afectando a los mecanismos y estructuras de las máquinas industriales, para esto han surgido novedosas técnicas que cuenta con la capacidad de hacer frente a este problema, en esta investigación se estudiarán las técnicas de Análisis Espectral de Orden Superior, es la Transformada Hilbert-Huang.

2.1 TRANSFORMADA HILBERT HUANG

La Transformada de Hilbert es útil para calcular el contenido en frecuencia de una señal de energía o de potencia. La Transformada de Hilbert produce el efecto de desplazar la componente de frecuencias negativas de $+90^\circ$ y las parte de frecuencias positivas -90° . De esta forma, se pueden analizar y diseñar filtros selectivos en frecuencia para poder separar señales según su contenido en frecuencia.

Sea una serie de valores $x(t)$; la Transformada Hilbert $y(t)$ de esta secuencia puede expresarse en la ecuación (2.1):

$$y(t) = \frac{1}{\pi} \int \frac{x(\tau)}{(t-\tau)} d\tau \quad (2.1)$$

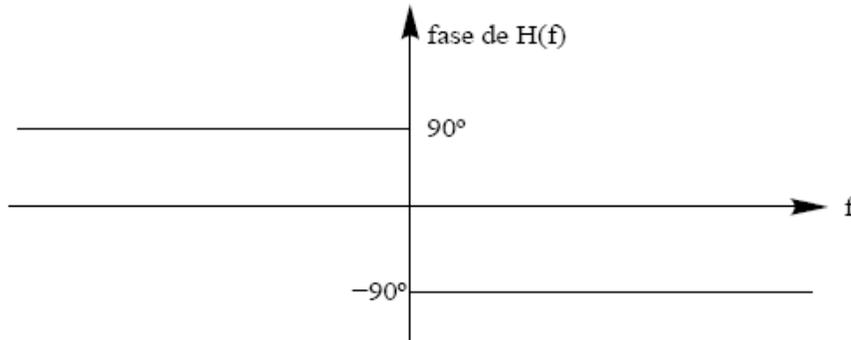


Figura 2.1 Respuesta en Fase del Sistema Transformador de Hilbert

La función $x(t)$ y su Transformada de Hilbert, $y(t)$, forman un par conjugado complejo, y por lo tanto es posible definir una señal analítica $z(t)$:

$$z(t) = x(t) + iy(t) = a(t)e^{i\theta(t)} \quad (2.2)$$

$$a(t) = \sqrt{x^2 + y^2} \quad (2.3)$$

$$\theta(t) = \tan^{-1}\left(\frac{y}{x}\right) \quad (2.4)$$

En las ecuaciones (2.3) y (2.4), la variable $a(t)$ representa la amplitud instantánea y $\theta(t)$ la función de fase instantánea. La frecuencia instantánea, única para un tiempo dado, es:

$$w_{\text{int}} = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (2.5)$$

Las ventajas de la HHT con respecto a la tradicional Transformada de Fourier: es la capacidad de analizar series cortas, no lineales y no estacionarias.

La aplicación práctica de la Transformada de Hilbert no es inmediata y por lo tanto requiere de un método numérico. El primer intento puede ser tratar de linealizar la integral y transformarla en un sumatoria, lo que obliga a adoptar un planteamiento lineal del proceso, y por consecuencia pierde una de las ventajas, que es su capacidad de analizar señales no lineales. EL proceso más exacto es el desarrollado por Huang o su método de descomposición, el cual es conocido como el método de la Transformada de Hilbert-Huang. Este método se le conoce como descomposición empírica de modos (EMD, empirical mode decomposition).

2.2 DESCOMPOSICIÓN EMPÍRICA DE MODOS

La descomposición de modo empírica es un método que ayuda a descomponer una señal en bandas de modos estrechas con el fin de aplicar la HT sobre cada descomposición de modo, a cada uno de estas descomposiciones de les conoce como función de modo intrínseca (IMF, *Intrinsic Mode Function*). Y el algoritmo de la EMD se puede explicar de la siguiente manera:

Primeramente se identifica los extremos de la señal, mínimos y máximos; una vez que los extremos se han identificado se unen los máximos con una la interpolación *spline cúbica* y lo mismo con los mínimos. De esta forma se envuelve la serie original entre ambas funciones llamadas envolvente máxima $e_{\text{max}}(t)$ y envolvente mínima $e_{\text{min}}(t)$. La

siguiente operación es hallar la media entre las dos envolventes y se denomina como $m(t)$. Se generará entonces $h(t)$ que se determina de la siguiente manera:

$$x(t) - m(t) = h(t) \quad (2.6)$$

Después la serie $h(t)$ es evaluada para conocer si es una IMF, para ello es necesario que cumpla con dos condiciones: que la media de $h(t)$ sea cercano a cero y que el número de máximos y el número de mínimos no sea mayor o menor a uno el número de cruces por cero. No siempre se pueden satisfacer estas dos condiciones a la perfección por eso existe el parámetro de desviación estándar o parámetro SD (*standard deviation*) para definir una IMF, el cual es obtenido mediante la ecuación dada a continuación:

$$SD = \sum_{t=0}^T \left[\frac{|h_{1(k-1)} - h_{1k}(t)|^2}{h_{1(k-1)}^2} \right] \quad (2.9)$$

La serie $h(t)$ sigue obteniéndose hasta que las condiciones de IMF sean verdaderas o que el parámetro SD tiene un valor menor a 0.3. Una vez alcanzado el valor límite de SD se identifica la última serie $h(t)$ como $IMF_k(t)$ donde k es el número de la IMF calculada; y se obtiene una nueva serie de la forma:

$$r(t) = x(t) - IMF_k(t) \quad (2.10)$$

A la serie $r(t)$ ahora se define como la nueva serie de entrada $x(t)$ y se le aplica todo el proceso inicial. Este proceso se repite hasta que la serie $r(t)$ es una serie monótona y en ese momento se da por terminado el proceso EMD.

Una vez descompuesta la señal original por el proceso EMD, en series ortogonales llamadas IMFs, se puede aplicar la Transformada Hilbert a cada una de las series unitarias, determinando para cada una de ellas la amplitud y la frecuencia instantánea (Messina y Vijay-Vittal, 2010). La Figura 2.2 muestra el algoritmo de la EMD para su mejor visualización. Si ahora se vuelve a reconstruir la serie en base a los resultados unitarios de las series $IMF_k(t)$; la señal puede representarse por la siguiente ecuación:

$$x(t) = \sum_1^n IMF_k(t) e^{i \int w_j(t) dt} \quad (2.13)$$

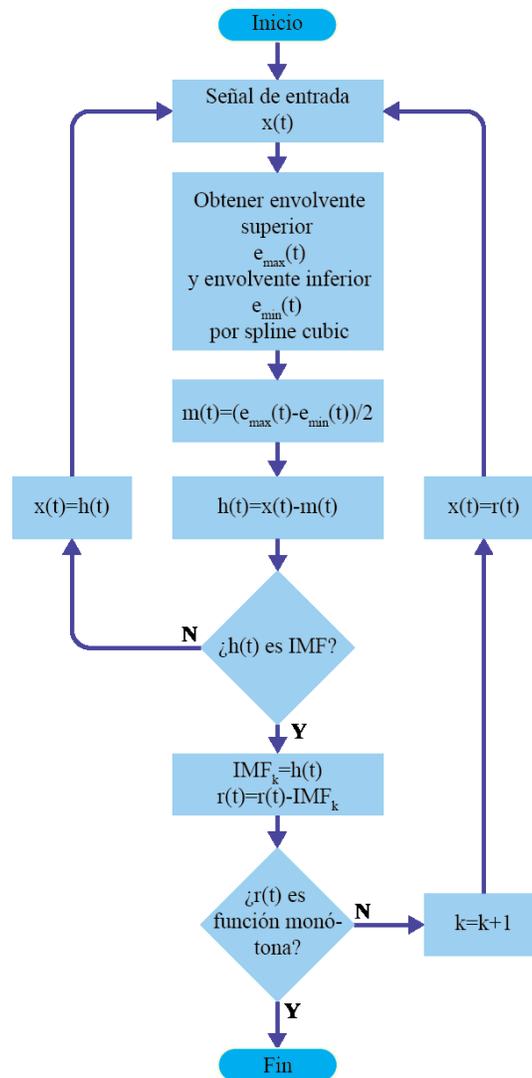


Figura 2.2 Diagrama de flujo del método EMD

La ventaja de la Transformada Hilbert, usando la ecuación (2.13), consiste en que puede ser representada en un gráfico en tres dimensiones, en el cual se representa la amplitud en función del tiempo y de la frecuencia instantánea. A esta representación gráfica es a la que se denomina espectro de Hilbert y se denomina como $H(w,t)$. Una vez definido el espectro de Hilbert se define el espectro marginal de Hilbert $h(w)$ como:

$$h(w) = \int_0^T H(w, t) dt \quad (2.14)$$

Este espectro marginal es la representación más parecida a la clásica Transformada de Fourier. La HHT tiene claras ventajas en comparación a otros métodos. Ming Li en el 2007 compara la STFT con la HHT, en la Figura 2.3 se muestra una señal en tiempo dada por la siguiente ecuación:

$$x(t) = [\cos(0.1\pi t) + \cos(0.4\pi t)][u(t) - u(t - 100)] \\ + [\cos(0.5\pi t) + \cos(0.9\pi t)][u(t - 200) - u(t - 300)] \quad (2.15)$$

La Figura 2.4 muestra la diferencia entre las distribuciones tiempo-frecuencia hechas por la STFT y con la HHT, en la cual se puede observar que la HHT tiene una resolución mucho mayor que la STFT, esto debido el mayor inconveniente de la STFT, el equilibrio que debe de existir entre la resolución de tiempo y frecuencia. La resolución en el tiempo y la frecuencia de la STFT será determinada por el ancho de la ventana que se utilice. Un ancho de la ventana grande proporciona una buena resolución en el dominio de la frecuencia, pero una pobre resolución en el dominio del tiempo. Por el contrario, un ancho de la ventana pequeña ofrece una buena resolución en el dominio del tiempo y una pobre resolución en el dominio de la frecuencia, siguiendo el principio de Heisenberg. Esta limitación de la STFT se derivan del uso de una sola ventana para todas las frecuencias y por lo tanto, la resolución de análisis es el mismo en todos los lugares en el plano de tiempo-frecuencia, en cambio con la HHT se muestra la frecuencia instantánea en cada momento, ajustándose completamente a las características locales de la señal, esto gracias a la descomposición que se hace a la señal, lo que genera un análisis adaptivo e ideal para el análisis de señales no estacionarias y no lineales (Huang et al, 1998).

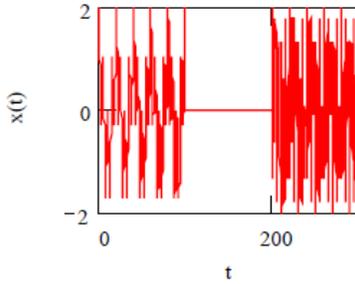


Figura 2.3 Señal en tiempo $x(t)$.

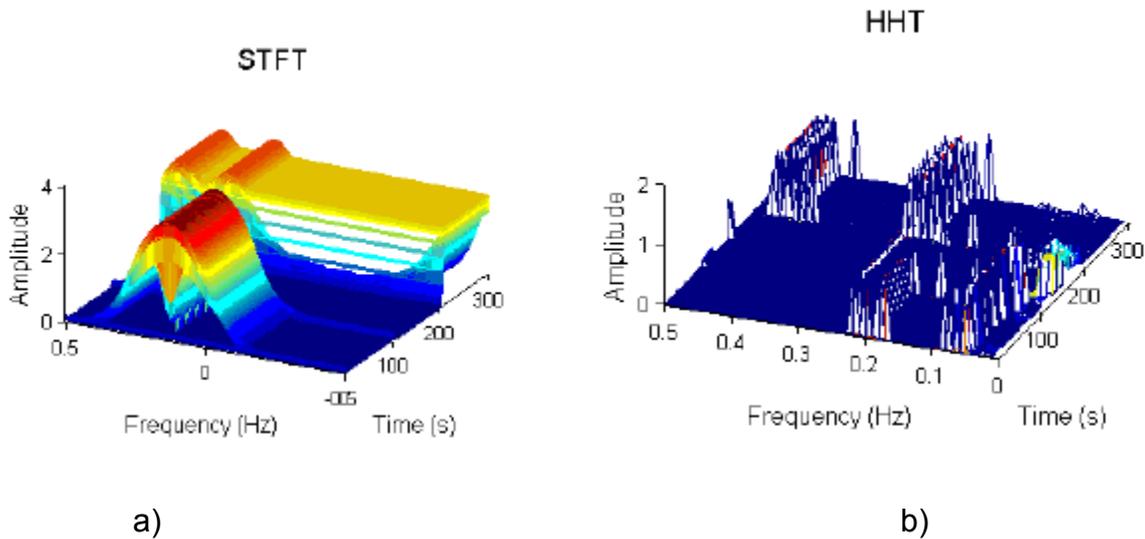


Figura 2.4 a) Distribución tiempo frecuencia de la señal $x(t)$ usando la STFT b) usando la HHT

2.3 VARIACIONES A LA DESCOMPOSICIÓN EMPÍRICA DE MODOS

Aunque la descomposición empírica de modos ha tenido varias aplicaciones, mostrando ser una técnica de alta efectividad, aún posee problemas para obtener una descomposición fiable para problemas de mayor índole, para esto, se han propuesto nuevos algoritmos que complementan a la EMD con el fin de mejorar las descomposiciones obtenidas. A continuación se describen las más importantes:

2.3.1 Descomposición empírica en modos por conjuntos

La descomposición empírica en modos por conjuntos (*Ensemble Empirical Mode Decomposition, EEMD*) tiene como objetivo la adición de ruido blanco para

homogeneizar su escala en el espacio tiempo-frecuencia, que permite que el banco de filtros natural de EMD pueda filtrar las oscilaciones locales intrínsecas de forma adaptiva a escalas adecuadas y restringir el problema de mezclar modos con éxito. Dado que las IMFs correspondientes de diferentes series de ruido no están relacionados entre sí, el ruido en cada ensayo se puede cancelar en el proceso de ensamble, siempre que las iteraciones sean las suficientes (Wu y Huang, 2009)

El algoritmo EEMD se puede describir brevemente como se muestra en la Figura 2.5.

(1) Añadir ruido blanco $\{w_j(t)\}(i = 1, 2, \dots, N)$ a la señal S dirigida (t)

$$x_i(t) = x(t) + w_i(t) \quad (2.16)$$

Donde N es el número de iteraciones.

(2) Descomponer la señal serie ruido agregado $x_i(t)$ mediante EMD, respectivamente, y en consecuencia la serie IMF_k^j puede derivarse, donde k significa la k ésima IMF de la i -ésimo señal de ruido añadido.

(3) Después sumar y promediar cada serie de IMFs de la siguiente manera:

$$IMF_k(t) = \frac{1}{N} \sum_{i=1}^N IMF_k^j \quad (2.17)$$

(4) La señal $x(t)$ se puede volver a conseguir usando la siguiente ecuación:

$$x(t) = \sum_{j=1}^n IMF_k(t) \quad (2.18)$$

Los ruidos blancos sumados casi pueden ser anulados si el conjunto de pruebas es el suficientemente grande. El número N del conjunto debe ser tan grande como sea posible para obtener un resultado fiable y, en general, N se ha encontrado que genera buenos resultados con valores alrededor de los pocos cientos (Huang et al., 2003). En realidad,

el residuo de agregados ruidos blancos debe disminuir siguiendo la regla estadística bien establecida, a saber,

$$\varepsilon_n = \frac{\varepsilon}{\sqrt{N}} \quad (2.19)$$

donde ε es la amplitud de ruido añadido y ε_n es la desviación estándar final de error, que se define como la diferencia entre los datos originales y los datos reconstruidos a través de las IMFs conjunto (Wu y Huang, 2009)

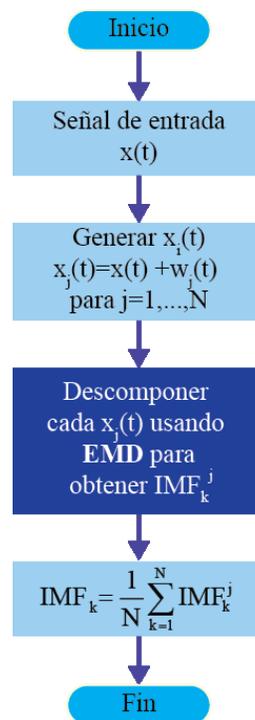


Figura 2.5 Diagrama de flujo del método EEMD

2.3.2 Descomposición empírica en modos por conjuntos complementarios

La descomposición empírica en modos por conjuntos complementarios (*Complementary Ensemble Empirical Mode Decomposition, CEEMD*) se propone principalmente con el objetivo de disminuir el error de reconstrucción causados por los ruidos blancos añadidos. A diferencia de EEMD, en la CEEMD se añaden los ruidos blancos de dos en

dos a los datos originales (es decir, uno positivo y otro negativo) para generar dos conjuntos de IMFs.

El algoritmo CEEMD descrito en (Yeh et al., 2010) se puede describir de la siguiente manera:

1. Añadir un par de series de ruido blanco $\{+w_i(t)\}(i = 1, 2, \dots, N)$ y $\{-w_i(t)\}(i = 1, 2, \dots, N)$ a la señal $x(t)$, donde a es la amplitud de ruido blanco añadido y N es los pares de ruidos agregados .

$$x_j^+(t) = x(t) + w_i(t) \quad (2.20)$$

$$x_j^-(t) = x(t) - w_i(t) \quad (2.21)$$

2. Descomponer la serie de datos con ruido añadido $x_j^+(t)$ y $x_j^-(t)$ utilizando EMD , respectivamente, se obtendrá $I_{jk}^+(t)$ y $I_{jk}^-(t)$ que representan las k-ésimas IMFs derivadas de los datos de ruido añadido j-ésimo con ruido positivo (o negativo) .
3. Las IMFs finales se pueden obtener por conjunto usando

$$IMF_k(t) = \frac{1}{2N} \sum_{k=1}^{Ne} [I_{jk}^+(t) + I_{jk}^-(t)] \quad (2.22)$$

4. A continuación, la señal de original puede reconstruirse por:

$$x(t) = \sum_{k=1}^n IMF_k(t) \quad (2.23)$$

CEEMD y EEMD tienen principalmente los siguientes problemas. En primer lugar, el proceso de ensamble consume mucho tiempo, especialmente cuando el número de iteraciones es grande. En segundo lugar, las IMFs derivadas de EEMD y CEEMD suelen incluir algunos componentes innecesarios, es decir, IMFs falsas y sin sentido y algunas de ellas ni siquiera cumplen las condiciones de definición de IMF. Esto es causado

principalmente por el hecho de que los diferentes datos de ruido añadido pueden generar un número diferente del IMFs, aunque la adición de ruido blanco sea del mismo tamaño.

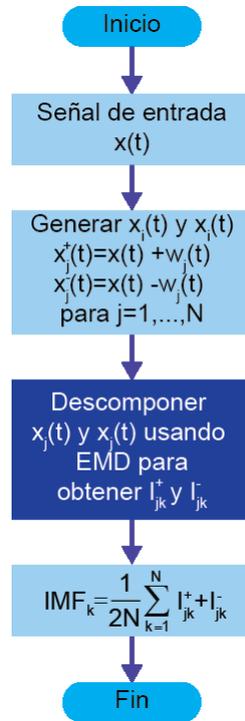


Figura 2.6 . Diagrama de flujo del método CEEMD

2.3.3 Descomposición parcial empírica en modos por conjuntos

Con el fin de superar los inconvenientes de EEMD y CEEMD, se propone el método de la Descomposición parcial empírica en modos por conjuntos (*Partly Ensemble Empirical Mode Decomposition, PEEMD*) es un método propuesto se describe como sigue (Zheng et al., 2014):

1. Poner $j=1$, y añadir un par de series de ruido blanco $\{+w_i(t)\}(i = 1, 2, \dots, N)$ y $\{-w_i(t)\}(i = 1, 2, \dots, N)$ a la señal $x(t)$ como

$$x_j^+(t) = x(t) + w_i(t) \quad (2.24)$$

$$x_j^-(t) = x(t) - w_i(t) \quad (2.25)$$

Donde a es la amplitud de ruido blanco añadido, para $j= 1 , 2 , \dots , N$, y N es el par de número de ruido blanco añadido.

2. Descomponer las dos señales $x_j^+(t)$ y $x_j^-(t)$ usando EMD para obtener el par j -ésimo de IMF, y definirlos como $I_{jk}^+(t)$ y $I_{jk}^-(t)$, definir los dos residuos como $r_{i,j+1}^+(t)$ y $r_{i,j+1}^-(t)$ los cuales se obtienen de la siguiente manera:

$$r_{i,j+1}^+(t) = x_j^+(t) - I_{jk}^+(t) \quad (2.26)$$

$$r_{i,j+1}^-(t) = x_j^-(t) - I_{jk}^-(t) \quad (2.27)$$

3. A través del algoritmo de ensamble se obtiene la última IMF de orden j , la cual puede ser derivada por:

$$IMF_k(t) = \frac{1}{2N} \sum_{k=1}^N [I_{jk}^+(t) + I_{jk}^-(t)] \quad (2.28)$$

4. Calcular el valor de entropía de la permutaciones (*permutation entropy*) de $I_j(t)$ y definirlo como P_j , seguir repitiendo los pasos (2) y (3) hasta que P_j sea menor a θ_0 .
5. Se separan las primeras $(j-1)$ -ésimas IMFs de la señal original y el residuo $r(t)$ se obtiene por:

$$r(t) = x(t) - \sum_{k=1}^{j-1} IMF_k(t) \quad (2.29)$$

6. Descomponer $r(t)$ por completo mediante el uso de EMD

$$r(t) = \sum_{k=1}^n c_k(t) + r_n(t) \quad (2.30)$$

7. $c_k(t)$ son vistas como las siguiente IMFs después de la (j-1)-ésima IMF. La señal inicial se forma usando:

$$x(t) = \sum_{k=1}^{j-1} IMF_k(t) + \sum_{k=1}^n c_k(t) + r_n(t) \quad (2.31)$$

PEEMD descompone usando CEEMD hasta la (j-1)-ésima IMF, si la entropía de las permutaciones tiene una valor menor a uno definido con anterioridad las siguientes IMFs son calculadas usando simplemente EMD.

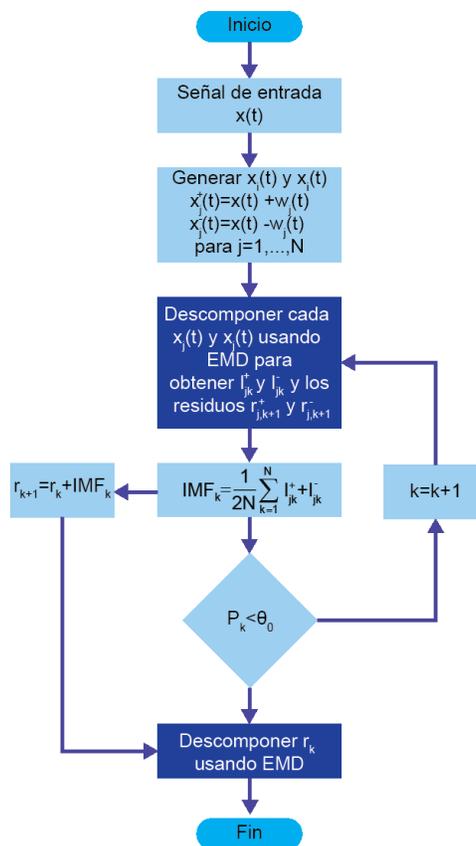


Figura 2.7 Diagrama de flujo del método PEEMD

2.4 RED LINEAL ADAPTIVA

La extracción de características esenciales de las fallas es un procedimiento que ayuda a la obtención de parámetros que representan la condición de motor de inducción con el fin de lograr una futura clasificación. Diferentes parámetros se pueden usar para

clasificar; por ejemplo, los parámetros estadísticos como la desviación estándar, los valores máximos y mínimos locales, la asimetría y los coeficientes de curtosis se han extraído de la corriente de entrada del motor (Ghate y Dudul, 2010)) Los espectros de frecuencia de vibración y señal de corriente s también se han calculado (Su et al, 2011), respectivamente; donde se extraen las amplitudes de algunos componentes de frecuencia. Sin embargo, en señales no estacionarias, algunos de los parámetros mencionados anteriormente, principalmente los componentes de frecuencia, puede cambiar a través del tiempo la producción de un resultado de clasificación errónea. Una solución adecuada para la estimación de componentes de frecuencia de las señales no estacionarias es el uso de una red neuronal lineal adaptativa (*Adaptive Linear Neural Network, ADALINE*) como se ha demostrado en (Valtierra et al, 2013) además, su rendimiento paralelo inherente hace que sea también atractivo para la implementación FPGA.

ADALINE es un filtro adaptativo utilizado para la extracción de características procedentes de señales en entornos ruidosos, para la identificación del modelo, así como para el seguimiento y la estimación de componentes de frecuencia. Por esta última aplicación se supone, en concordancia con la serie de Fourier, que una de la señal es la suma de todos los componentes de frecuencia con amplitudes y ángulos de fase desconocidos. Por lo tanto, la representación de una señal y es

$$\begin{aligned}
 y(k) &= \sum_{m=1}^M A_m \sin(2\pi f_m k\Delta t + \phi_m) \\
 &= \sum_{m=1}^M (A_m \cos \phi_m \sin 2\pi f_m k\Delta t + A_m \sin \phi_m \cos 2\pi f_m k\Delta t) \\
 &= \sum_{m=1}^M (a_m \sin \theta_m + b_m \cos \theta_m)
 \end{aligned} \tag{2.32}$$

donde A y ϕ_m son las amplitudes y ángulos de fase de m -ésima componente de frecuencia, respectivamente; M es el total de los componentes de frecuencia, $\theta_m = 2\pi f_m k\Delta t$, k es el índice de muestreo, Δt es el intervalo de muestreo, $a_m = A_m \cos \phi_m$, and $b_m = A_m \sin \phi_m$. Entonces la ecuaciones (2.32) se puede reescribir como

$$y(k) = \mathbf{w}^T(k) \cdot \mathbf{x}(k) \tag{2.33}$$

con

$$\mathbf{w}(k) = [a_1 \quad b_1 \quad \dots \quad \dots] \tag{2.34}$$

Para aplicaciones sobre la estimación de la frecuencia, ADALINE está dispuesto como se muestra en la Fig. 2.8 La estimación inicial de w es un vector cero; luego, sus elementos se ajusta durante cada muestra a través de una regla de actualización de peso para reducir al mínimo el error entre la salida y estimada y la real y_k . Al mismo tiempo, la amplitud A_m y ángulo de fase φ_m del m -ésimo componente de frecuencia se calculan como:

$$A_m = \sqrt{a_m^2 + b_m^2} \quad \varphi_m = \tan^{-1}\left(\frac{a_m}{b_m}\right) \quad (2.35)$$

donde $-\pi \leq \varphi_m \leq \pi$.

El error es igual a cero cuando todos los componentes de frecuencia de y_k son modelados por ADALINE.

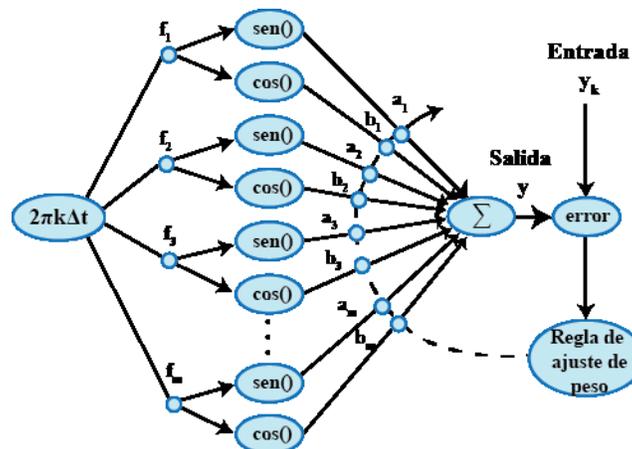


Figura 2.8 Estructura de bloque ADALINE para la estimación de frecuencias

La regla actualización de pesos que se utiliza para reducir al mínimo el error es a través del cuadrados mínimos medio (*Least Mean Squares, LMS*), que reduce el error cuadrático medio (*Mean Squared Error, MSE*) definidos por

$$E_k^2 = \frac{1}{2L} \sum_{k=1}^L \varepsilon_k^2 \quad (2.36)$$

donde L es el número de muestras analizadas y ε_k es la diferencia entre la salida de ADALINE y la salida deseada y_k , dada en (2.37).

$$\varepsilon_k = y_k - y \quad (2.37)$$

Finalmente, la modificación de los pesos se da en (2.38), donde α es una constante de proporcionalidad, conocida como la tasa de aprendizaje ADALINE.

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \alpha \varepsilon_k \mathbf{x}(k) \quad (2.38)$$

2.5 LAS REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales (*Artificial Neural Network, ANN*) son modelos computacionales que simulan la estructura neurológica del cerebro humano y su capacidad de aprender y resolver problemas a través de reconocimiento de patrones para aplicaciones industriales. Hay diferentes arquitecturas ANN como las redes de alimentación directa (*Feed-Forward Neural Networks, FFNN*), redes recurrentes, redes de realimentación, redes de funciones de base radial, y redes de auto-organización de mapa de Kohonen, entre otras. La arquitectura más popular para ANN es la FFNN ya que es simple y práctica en su labor como clasificador y porque requiere poca carga computacional. FFNN está caracterizada por tener una arquitectura en capas con las neuronas individuales o múltiples en cada capa (Cabal et al, 2012), como se muestra en la Figura 2.9. El modelo matemático que describe cada neurona se da en (2.39), donde y , ω_i , x_i , b , $f(\cdot)$ y I son la salida, los pesos, entradas, sesgos, función de activación y el total número de entradas, respectivamente.

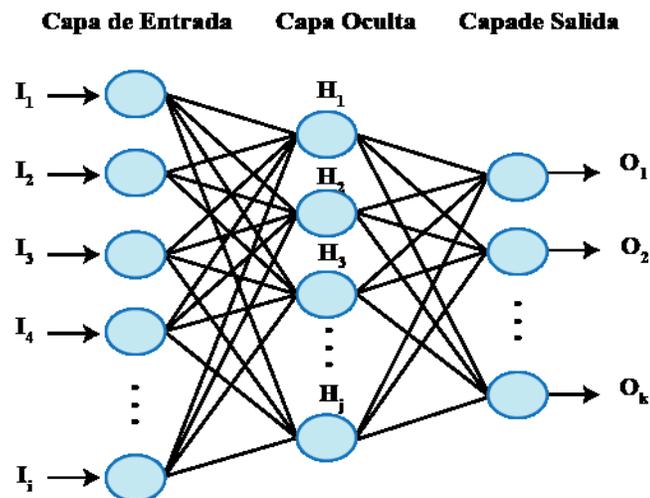


Figura 2.9 Arquitectura de una FFNN

El modelo FFNN consiste en la suma de productos entre las entradas y los multiplicadores asociados, comúnmente llamados pesos, además de un sesgo. Entonces, este resultado es evaluado por una función no lineal para proporcionar la red neuronal con la capacidad de modelar relaciones no lineales. En esta arquitectura, la información fluye en una sola dirección, desde la capa de entrada, a través de la capa oculta, hasta los nodos de salida. Para la caracterización de los pesos de la red, se presentan los pares de datos de entrada-salida; a continuación, se utiliza una regla de

entrenamiento para el ajuste de estos pesos. El proceso de formación minimiza el error entre la salida deseada y la salida calculada y se repite hasta que el error total sea aceptable.

$$y = f\left(\sum_{i=1}^I \omega_i x_i + b\right) \quad (2.39)$$

MUSIC

El algoritmo de Clasificación Múltiple de Señales (Multiple Signal Classification, MUSIC) es una técnica basada en el uso de subespacios. En general, los algoritmos de subespacio son conocidos como métodos de alta resolución debido a que pueden detectar frecuencias en señales cuya relación señal a ruido (SNR) es muy pequeña (Garcia-Perez et al., 2011). Estos métodos asumen que la señal discretizada en tiempo $x[n]$ puede ser representada por m señales senoidales complejas inmersas en ruido, $e[n]$, es decir:

$$x[n] = \sum_{i=1}^m \bar{B}_i e^{j2\pi f_i n} + e[n] \quad (2.40)$$

$$\bar{B}_i = |B_i| e^{j\phi_i} \quad (2.41)$$

donde N es el número de datos de la muestra y $n = 0; 1; 2 \dots; N$; B_i es la amplitud compleja de la i -ésima señal senoidal, f_i es la frecuencia de la señal senoidal y $e[n]$ es una secuencia de ruido blanco con media cero y varianza σ^2 . El siguiente paso consiste en la descomposición en eigenvectores de $x[n]$ para obtener dos subespacios ortogonales. La matriz de autocorrelación R de la señal inmersa en ruido $x[n]$ es la suma de ella misma con las matrices de autocorrelación del ruido (R_s y R_n , respectivamente):

$$R = R_s + R_n = \sum_{i=1}^p |B_i|^2 e^{j2\pi f_i n} e^{H}(f_i) + \sigma_n^2 I \quad (2.42)$$

donde p es el número de frecuencias, el exponente H denota la transpuesta Hermitiana, I es la matriz identidad y $e^H(f_i)$ es la señal vector dada por:

$$e^H(f_i) = [1 \quad e^{-j2\pi(1)f_i} \quad \dots \quad e^{-j2\pi(N-1)f_i}] \quad (2.43)$$

De la condición de ortogonalidad de ambos subespacios, el pseudoespectro MUSIC, Q , está dado por:

$$Q_{MUSIC}(f) = \frac{1}{|e(f)^H V_{m+1}|} \quad (2.44)$$

donde V_{m+1} es el eigenvector de ruido. Esta expresión muestra que los picos se ubican en las frecuencias exactas de las principales componentes senoidales donde el denominador es cero.

2.6 DIAGNÓSTICO EN MÁQUINAS ELÉCTRICAS ROTATORIAS

En esta línea, el mantenimiento correctivo de máquinas eléctricas es una práctica muy costosa, ya que implica paradas no programadas y los daños provocados por las fallas de los equipos. Las actuales exigencias de calidad consideran cada vez más necesaria la utilización de sistemas de monitoreo y detección de fallas, de modo de no interrumpir la producción. Los motores eléctricos de inducción son los responsables, en muchos casos, del correcto funcionamiento del sistema productivo. Existen hoy muchas técnicas publicadas y herramientas avaladas comercialmente de detección de fallas en motores de inducción, que pueden garantizar un mayor grado de confiabilidad en su funcionamiento. A pesar de esto, la mayoría de las industrias aún no utilizan técnicas de detección y monitoreo de máquinas eléctricas. A continuación se presentarán los principales métodos de detección de fallos. Existen diferentes métodos invasivos y no

invasivos para la detección de fallos utilizando técnicas de análisis de datos de origen eléctrico, mecánico o químico, entre los cuales se pueden resaltar los siguientes: análisis de vibraciones, análisis de temperatura, estimación de parámetros electromagnéticos del motor, análisis de partículas de aceite, análisis de señal de corriente del motor (Motor Current Signal Analysis, MCSA) (Baruch, 2013).

El motor de inducción es la máquina eléctrica más ampliamente usada en la industria debido a su sencilla construcción y gran robustez. Los tiempos inesperados de parada del Motor de Inducción causan, en la mayoría de los casos, pérdidas de producción e ingresos. Es por esto que cada vez cobra más importancia prevenir las paradas no programadas, lo cual ayuda no solo a reducir costos de mantenimiento sino que también genera mayores ingresos.

Los costos de mantenimiento representan la mayor parte de los costos totales de operación de todas las plantas de producción (industria). Dependiendo del tipo de industria, dichos costos pueden alcanzar entre el 15 y 60 por ciento del total de costos de producción (Electric Power Research Institute, 1985).

2.7 FALLAS EN MÁQUINAS ELÉCTRICAS ROTATORIAS

Estudios realizados por el Instituto de Investigación de Energía Eléctrica (*Electric Power Research Institute*, EPRI) muestran porcentajes de falla para un amplio rango de Motores de Inducción en donde los resultados indican un 37% de fallas en los motores fueron causadas por fallas en el devanado del estator, 10% por fallas en el rotor, 41% por fallas en cojinetes y rodamientos y 12% a fallas diversas (Electric Power Research Institute, 1985).

El análisis en el dominio de la frecuencia de la señal de las corrientes de la máquina refleja los efectos de las fallas al incrementarse el valor de ciertas componentes características de las fallas, para ello diferentes técnicas de análisis espectral son usadas como la FFT o la WT. Estas técnicas se han empleado desde hace varios años en el diagnóstico de motores para detectar fallas en el motor mediante el análisis de las corrientes en el dominio de la frecuencia, sin embargo nuevas técnicas han ido

apareciendo haciendo más confiable el diagnóstico. Entre las fallas que pueden ser detectadas por MCSA están la barra rota, el desalineamiento y los baleros.

2.7.1 Falla de barra rota

El 10% de las fallas que se presentan en el motor de inducción se relacionan con fallas en el rotor. Una de las fallas más frecuentes en el rotor es la rotura de barras. Una pieza que se rompa puede moverse a través del entrehierro y dañar la superficie de los devanados en el estator, ocasionando una falla súbita. Dicha falla puede representar elevados costos de reparación y tiempos muertos. Por lo anterior, la detección a tiempo de una rotura de barra es muy importante y ventajoso (Electric Power Research Institute, 1985)..

2.7.1.1 Causas de la rotura de barras

El rompimiento de una o varias barras puede ser causado por muchas razones, entre las cuales se encuentran (Baruch, 2013):

1. Estrés térmico debido a sobrecargas y desbalances, puntos calientes o pérdidas excesivas, chispas.
2. Estrés magnético causado por fuerzas electromagnéticas, atracción magnética desbalanceadas, ruido y vibración electromagnética.
3. Estrés residual debido a problemas de manufactura.
4. Estrés dinámico proveniente del eje de torsión, fuerzas centrifugas.
5. Estrés medioambiental causado por contaminación y abrasión del material del rotor debido a químicos o humedad.
6. Estrés mecánico debido a laminaciones sueltas, partes debilitadas, fallas en los cojinetes, etc.
7. Condiciones de operación: Cargas pulsantes las cuales ocasionan cambios en el torque del eje.

Los riesgos de falla en el rotor pueden minimizarse si se controlan las anteriores situaciones. El diseño, construcción e instalación, así como el mantenimiento se deben considerar y ejecutar adecuadamente para reducir posibles problemas.

2.7.1.2 Detección de rotura de barras

La falla de barra rota (*Broken Rotor Bar*, BRB) es posible detectarla mediante la localización de los componentes de frecuencia laterales a la frecuencia fundamental f_{BRB} , lo cual puede determinarse por la fórmula (Garcia-Perez et al., 2012):

$$f_{BRB} = \left[k \left(\frac{1-s}{p} \right) \pm s \right] f_s \quad (2.45)$$

donde f_s es la frecuencia de alimentación eléctrica, s es el deslizamiento del motor, p es el número de polos del motor, y $k = 1, 3, 5, \dots$ denota los valores característicos del motor. Cuando una rotura de la barra del rotor se lleva a cabo, las amplitudes de estos componentes se incrementan significativamente, haciendo viable el diagnóstico de la rotura.

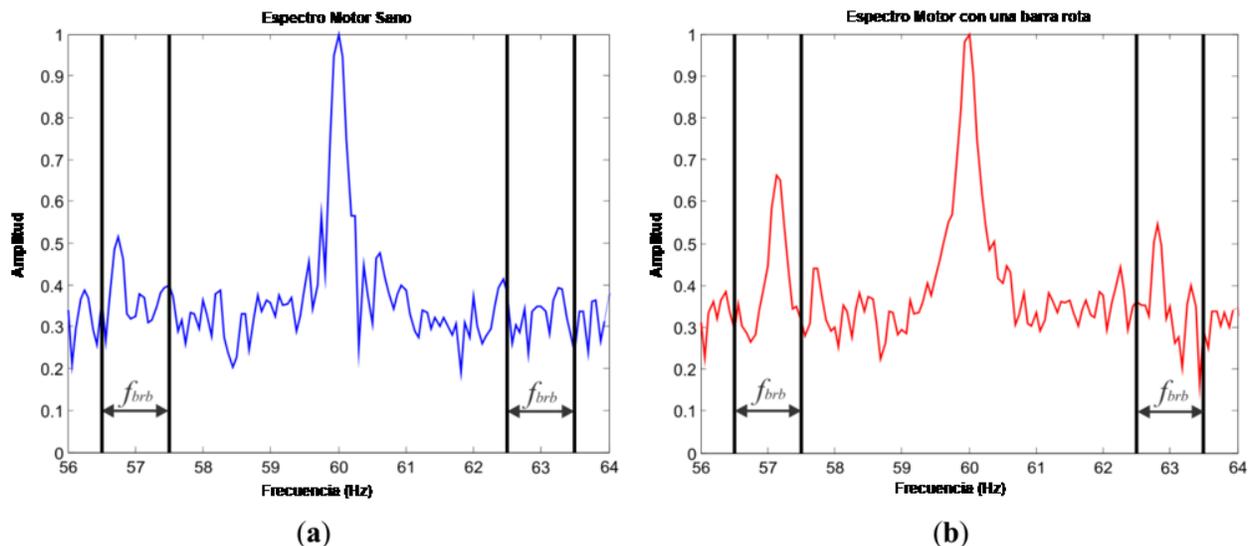


Figura 2.10 Incremento de la amplitud de las componentes frecuenciales laterales debido a la falla BRB. (Garcia-Ramirez et al., 2012)

2.7.2 Falla de desbalance en un motor

La falla de desbalance (*Unbalance*, UNB) está presente cuando la carga mecánica del motor de inducción no se distribuye uniformemente, es decir el centro de masa no se encuentra en el centro de rotación (MetAs & Metrolólogos Asociados, 2005)..

2.7.2.1 Causas de desbalance en un motor

La excentricidad estática puede ser causada por:

1. Un núcleo del estator con forma ovalada producto de defectos en la fabricación.
2. Desalineación de los rodamientos durante el montaje.
3. Desgaste de los rodamientos.
4. Acoples mecánicos desalineados.

2.7.3 Falla en baleros

Los baleros se utilizan para sostener el eje del rotor en el motor de inducción. Una falla en los baleros puede resultar en el incremento de las vibraciones y del nivel de ruido y ocasionar daños en los acoples mecánicos por lo que también es importante detectar este tipo de falla. (All test Pro, 2009)

2.7.3.1 Componentes principales de los rodamientos.

El anillo interior, tiene normalmente un ajuste muy justo en la flecha o eje. También es difícil prevenir el desgaste prematuro. El anillo interior normalmente gira con la flecha. El anillo exterior, normalmente se encuentra dentro del alojamiento de la máquina y es fijo, las tolerancias de montaje son muy cerradas, normalmente en micras μm . La jaula mantiene los elementos rotativos en su lugar. Los elementos de rotativos son rodillos, bolas, balines o algún otro dispositivo rodante, que permite la acción rodante entre los anillos interior y exterior. Los elementos rodantes reducen la fricción al deslizarse directamente en las pistas de rodadura y permiten movimiento relativo se los dos anillos. La lubricación de los rodamientos es muy importante para reducir la fricción y la

generación de calor entre los componentes. Los fabricantes de rodamientos cuentan con diferentes tipos de sellos laterales para evitar la contaminación hacia el interior los elementos y del lubricante (All test Pro, 2009).

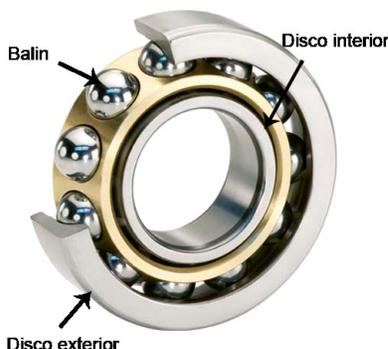


Figura 2.11 Componentes de un balero (Reincos S.A. de C.V., 2015).

2.7.3.2 Causas de fallas en los Rodamientos

Los principales fabricantes de rodamientos cuentan con estadísticas donde indican que cerca del 16% de las fallas que se dan en los rodamientos son el resultado del mal manejo de estos. Esto es causado por el almacenamiento, transportación e instalación inadecuada del rodamiento. El 84% restante son instalados libres de defectos. En este momento no hay indicadores de fallas en rodamientos. Si un indicador está presente durante la operación inicial del rodamiento, por lo general se trata de un ajuste en el rodamiento o problema de ensamblado. El 36% de las fallas en rodamientos son el resultado de una lubricación deficiente, es decir, sobrelubricación o sublubricación, en términos coloquiales lubricación inadecuada. El 34% son el resultado de la operación inadecuada de los rodamientos como pudiera ser el desbalance, excentricidad entre eje, des alineamiento de poleas o remplazo indicado por los programas de mantenimiento preventivo(All test Pro, 2009).

Generalmente, la mayoría de las máquinas eléctricas usan rodamientos de balín el cual consiste en dos anillos, uno interior y otro exterior. Los daños en este tipo de rodamiento se pueden categorizar en cuatro tipos como se muestra en la Figura 2.12. Las ecuaciones

que muestran la frecuencia relacionada a la falla por daño en balero se muestran a continuación:

1. Daño en el disco exterior: del balero su frecuencia de vibración (*Ball Pass Frequency of Outer ring*, f_{BPFO}) es ;

$$f_{BPFO} = \frac{N_B}{2} f_r \left(1 - \frac{D_b}{D_c} \cos \theta \right) \quad (2.46)$$

2. Daño en el disco interior del balero la frecuencia de vibración (*Ball Pass Frequency of Inner ring*, f_{BPIF}) es ;

$$f_{BPIF} = \frac{N_B}{2} f_r \left(1 + \frac{D_b}{D_c} \cos \theta \right) \quad (2.47)$$

3. Daño en el balón: la frecuencia de vibración (*Ball Spin Frequency*, f_{BSF}) es;

$$f_{BSF} = \frac{D_b f_r}{D_c} \left(1 - \left(\frac{D_b}{D_c} \cos \theta \right)^2 \right) \quad (2.48)$$

4. Daño en tren del balero la frecuencia de vibración (*Fundamental Train Frequency*, f_{FTF}) es;

$$f_{BPOF} = \frac{(f_r)^2}{2} \left(1 - \frac{D_b}{D_c} \cos \theta \right) \quad (2.49)$$

donde θ es el ángulo de contacto entre las superficies de apoyo, D_c es el diámetro de la jaula del cojinete y se mide a partir de un centro de la bola a la centro de la bola opuesta, D_b es el diámetro de la bola, y N_B es el número de bolas en el cojinete.

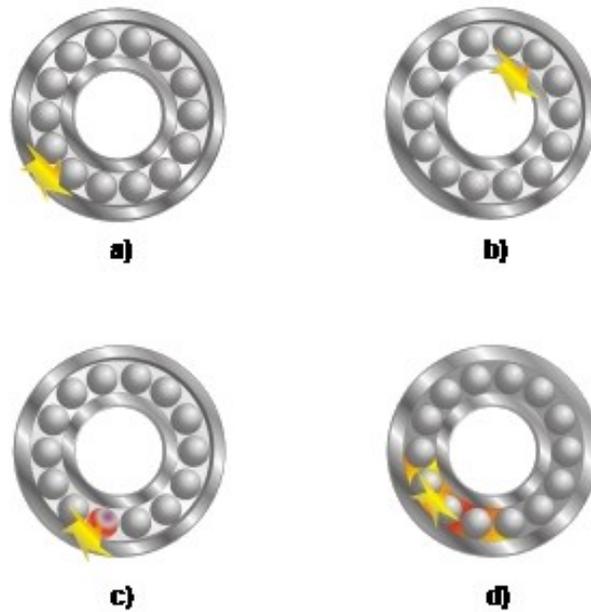


Figura 2.12 Fallas en el balero: a) disco exterior, b) disco interior, c) tren del balero y d) balines.
(Vibrattech, 2015)

2.8 LOGICA PROGRAMABLE.

Los dispositivos de lógica programable se pueden clasificar en dos tipos: volátiles y no volátiles. Los primeros dependen de la alimentación para conservar la información del programa y los no volátiles no mantienen la información del programa si no se encuentran alimentados.

Los primeros dispositivos lógicos programables fueron las Memoria de solo lectura (*Read Only Memory*, ROM) la desventajas de estas es que solo podían programarse una sola vez ya sea por el fabricante o el usuario, posteriormente surgieron las ROM borrable y programable (*Eraseable Programmable ROM*, EPROM) y las. ROM programable y borrable eléctricamente (*Electrically Eraseable Programmable ROM*, EEPROM), la principal característica de estas fue que el usuario podía borra y volver a programar estos dispositivos. Debido a la necesidad de contar con circuitos integrados en los cuales se

podieran sintetizar funciones combinacionales y funciones secuenciales, surgieron los Dispositivo lógico programable (*Programmable Logic Device, PLD*) a diferencia de las ROM, estos circuitos están hechos por muchas macro-celdas que cuentan con flipflop y lógica adicional que permiten la realización de funciones más complejas, también se puede encontrar los Dispositivos lógico programable complejos (*Complex Programmable Logic Device, CPLD*), la característica de estos es que podían integrar varios PLDs en el mismo circuito. Otro dispositivo que cuenta con mejores características que los anteriores son los Arreglo de compuertas programables en campo (*Field Programmable Gate Array, FPGA*) las característica de estos dispositivos es que están construidos por muchas celdas lógicas que tienen una mejor interconexión entre ellas.

La forma de programar este tipo de tecnología es mediante lenguaje de descripción de hardware (*Hardware Description Language, HDL*), Lenguaje de descripción de hardware), entre los más usados se encuentra VHDL, debido principalmente a que es un lenguaje estándar definido por la IEEE, con lo que se logra la portabilidad de los diseños lo que los hace independientes del fabricante de los dispositivos (Valtierra, 2013).

3. METODOLOGÍA

En este capítulo se describe en extenso la metodología seguida para la prueba y validación para el desarrollo exitoso del trabajo de investigación aquí presentado, así como se describe cada uno de los experimentos e instrumentos desarrollados. Primero, se muestran las especificaciones y características de los instrumentos desarrollados; segundo, se describen las metodologías planteadas para la detección, clasificación y cuantificación de disturbios eléctricos basados en redes neuronales, lógica difusa y sistemas neuro-difusos y finalmente se hace mención a los bancos de pruebas sugeridos para la validación de cada una de las metodologías planteadas en este trabajo

En este capítulo se describen en detalle todos los procedimientos y acciones seguidas para el desarrollo exitoso del trabajo de investigación aquí presentado. El diagrama de la Figura 3.1 muestra el diagrama general de la metodología seguida. En seguida se da una breve descripción de cada fase mostrada en la Figura y en los subtemas siguientes se describirán en detalle.

De acuerdo con el diagrama mostrado en la Figura 3.1, la primera etapa consiste en la búsqueda y análisis de la información relacionada con técnicas de análisis espectral de orden superior, esto con el fin de desarrollar una metodología que pueda ser aplicada en el monitoreo de máquinas eléctricas. La segunda etapa consiste en el diseño de la metodología para monitoreo de máquinas eléctricas basadas en análisis espectral de orden superior. La tercera etapa consiste en la elaboración del banco de pruebas en donde se realizarán las pruebas de funcionamiento de la metodología propuesta. La etapa cuatro es la implementación de la metodología desarrollada en software, la quinta etapa es el análisis de los resultados obtenidos en software. La etapa seis abarca diseño de las arquitecturas para la implementación en hardware de la metodología, y finalmente la etapa siete son las pruebas y el análisis y discusión de los resultados obtenidos.

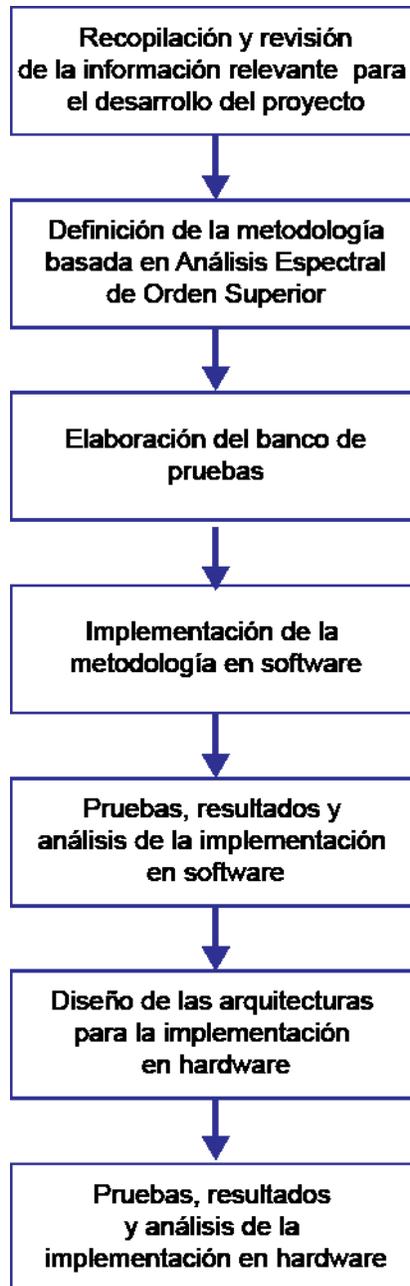


Figura 3.1 Diagrama general de la metodología seguida.

3.1 SISTEMAS DE MONITOREO DE MÁQUINAS ELÉCTRICAS

El monitoreo de variables eléctricas en los sistemas de potencia constituye una necesidad esencial para diversas aplicaciones industriales y científicas, tales como el monitoreo de la calidad de la energía, diagnóstico y monitoreo de máquinas eléctricas, sistemas de protección y control entre otros. Los equipos existentes en el mercado

desarrollados para este fin, realizan la interpretación de las variables eléctricas por medio de diversos algoritmos con el fin de cubrir las necesidades para cada aplicación; sin embargo, en muchas ocasiones cuentan con funciones que no son explotadas o no son usadas en su totalidad, lo cual por una parte contribuye a elevar su costo. Debido a la gran diversidad de aplicaciones existentes en el monitoreo de variables eléctricas, es de gran ayuda contar con sistemas de adquisición y procesamiento de señales eléctricas que permitan la reconFiguración en su arquitectura para poder adecuarse de manera específica a las diversas tareas a un bajo costo. En este trabajo se presenta un sistema reconFigurable para el monitoreo de variables eléctricas basado en tecnología FPGA de bajo costo. Este sistema es capaz de adquirir las señales de voltaje y corriente en cualquier sistemas trifásicos, además de contar con una capacidad de reconFigurabilidad para así poder utilizarse e integrarse con diversos algoritmos acorde a las necesidades particulares de cada aplicación.

En la Figura 3.2 y 3.3 se muestran los instrumentos utilizados en este trabajo. El mostrado en la Figura 3.2 es un instrumento realizado por Granados (2012) como elemento clave para su tesis doctoral; por otro lado, el sistema mostrado en la Figura 3.3 es un sistema desarrollado para este trabajo con un enfoque mayor hacia el monitoreo de máquinas eléctricas con características similares a un equipo comercial, como se puede apreciar por el uso de ganchos amperímetros i200 de la marca Fluke y las pinzas de voltaje. Al primer instrumento (Figura 3.2) se le agregó gracias a su reconFigurabilidad una pantalla LCD para el despliegado de resultados.

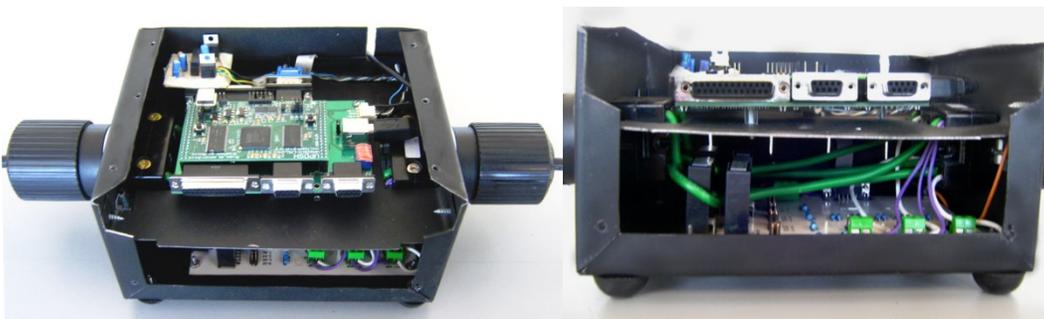


Figura 3.2 Sistema de monitoreo eléctrico basado en FPGA.



Figura 3.3 Sistema de monitoreo de máquinas eléctricas FPGA.

El sistema de monitoreo de máquinas eléctricas se puede describir a través del diagrama a bloques que se muestra en la Figura 3.4. Los sistemas de monitoreo constan de 4 sensores de efecto hall para el monitoreo de las corrientes de fase y la corriente del neutro. Los sensores de efecto hall presentan excelentes características de precisión, un ancho de banda grande así como la capacidad de sensado para corrientes tanto de AC como de DC.



Figura 3.4 Diagrama a bloques de los sistemas de monitoreo

En cuanto a los sensores de instrumentación, la Figura 3.5 muestra respectivamente los diagramas de los circuitos utilizados para las etapas de sensado y acondicionamiento de las corrientes. La instrumentación de los sensores de corriente es conformada por una etapa de ganancia con selección y un filtro antialiasing. Los filtros antialiasing son filtros butterworth de segundo orden con una frecuencia de corte de 3 KHz. La Figura 3.6 se muestra una fotografía de la tarjeta diseñada para el acondicionamiento de las señales de corriente.

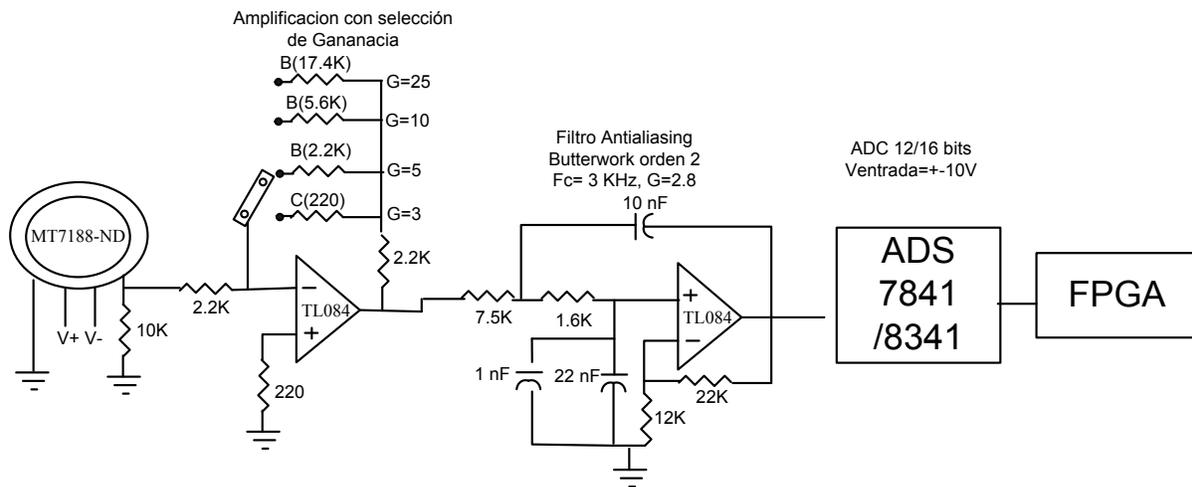


Figura 3.5 Instrumentación de sensores de corriente.

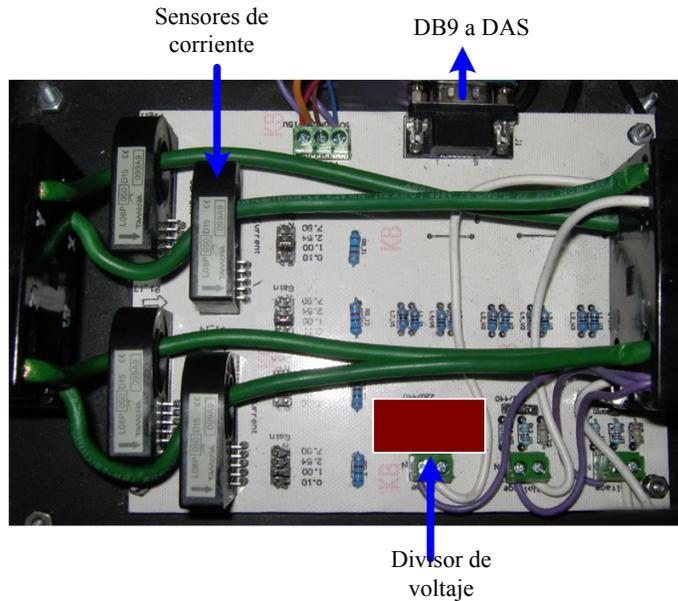


Figura 3.6 Tarjeta para la etapa de acondicionamiento de señales.

3.1.1 Adquisición de las señales.

La etapa de conversión digital analógica puede utilizar un convertidor analógico digital ADS7886 con una resolución de 12 bits o puede ser reemplazado por un ADS8341

de 16 bits. Este sistema es diseñado para obtener una tasa máxima de muestreo de 6000 muestra/s y cuenta con 20 MHz de transmisión serial para su procesamiento en una PC. El sistema de adquisición de datos (ADS) recibe una señal que determina la frecuencia de muestreo deseada, esta señal es proveniente de un controlador embebido en el FPGA. Posteriormente las señales digitales son multiplexadas y pueden ser almacenadas en memorias externas localizadas en la tarjeta que contiene el FPGA.

3.2 CASOS DE ESTUDIO

En esta sección se presentará los dos casos de estudios tratados en este proyecto de tesis, en el primer caso se propone una metodología combinando dos técnicas de análisis espectral, EMD y MUSIC, para el monitoreo de fallas múltiples y combinadas en motores eléctricos y en el segundo caso de estudio se realiza un sistema que combina las técnicas EMD y Adaline para extraer características esenciales para determinar la condición de motores, además se realiza una evaluación automática a través de redes neuronales.

3.2.1 Caso de estudio 1. Metodología basada en EMD-MUSIC para la detección de fallas múltiples en motores eléctricos.

En este caso de estudio se utiliza la señal de corriente del motor en estado estable para encontrar fallos combinados simples y múltiples, y clasificar las condiciones en la que se encuentra el motor. La señal de corriente puede proporcionar las características dinámicas del motor de inducción. La Figura 3.2 muestra el diagrama a bloques del sistema propuesto y la Figura 3.3 muestra la configuración experimental donde se utilizan varios motores de inducción trifásicos de 1 hp (modelo WEG 00136APE48T) para probar el rendimiento de la metodología propuesta. Los motores probados tienen dos polos y 28 barras y reciben una fuente de alimentación de 220 V CA a 60 Hz, y la carga mecánica aplicada es de un alternador normal. La señal de corriente se adquiere mediante el uso de un gancho de corriente alterna Fluke i200s. Después la señal entra a un sistema de adquisición de datos (*Data Acquisition System, DAS*) la cual transforma la entrada analógica a digital de 12 bits de cuatro canales a través de un convertidor analógico-

digital (ADS7841). El sistema de instrumentación utiliza una frecuencia de muestreo f_0 de 1500 Hz, y se obtienen 4096 muestras durante el estado estacionario del motor de inducción. Posteriormente de la etapa de DAS, la señal se descompone en IMFs por el método EMD, donde cada IMF es analizada por el algoritmo MÚSIC que identifica las frecuencias de fallas relacionadas y esta metodología se implementa en Matlab

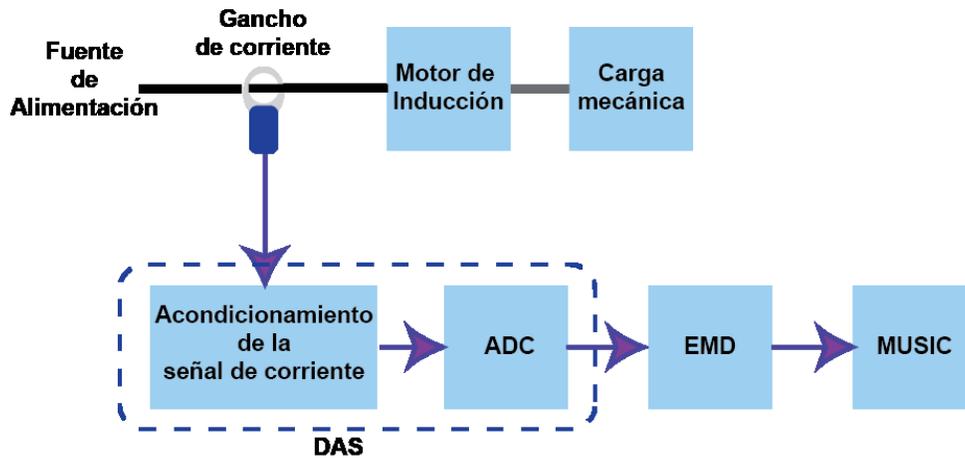


Figura 3.7 Diagrama de bloques del sistema propuesto múltiple combinado para los motores de inducción.

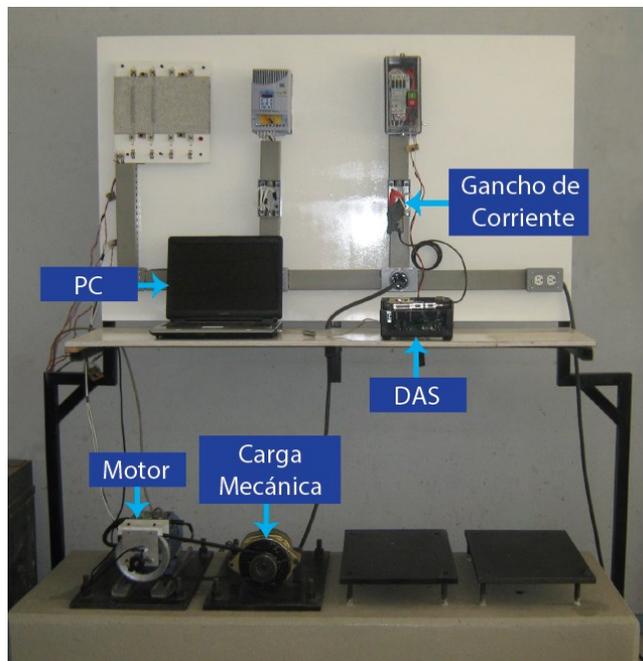


Figura 3.8 Banco de prueba para la detección de fallas múltiples y combinadas del motor.

3.2.1.1 Condiciones de falla

La condición de un rotor con barra rota (*one broken bar, 1BB*) se produce artificialmente a través de la perforación de un agujero de 7,938 mm de diámetro sobre una barra cuidando de no dañar el eje del rotor. La Figura 3.4. (a) muestra el rotor con una barra rota utilizado durante la experimentación. Para llevar a cabo el defecto del balero defectuoso (*bearing defect, BD*), el rodamiento está dañado artificialmente mediante la perforación de un agujero con 1,191 mm de diámetro exterior en su carrera usando un tungsteno broca. Figura 3.4. (b) muestra el modelo de balero 6203-2ZNR utilizado en este trabajo, el cual se muestra dañado artificialmente. Finalmente, para probar la condición de desbalance (*unbalance, UNB*) es producido por la perforación de un agujero de 8 mm en uno de los brazos de la polea, donde se inserta el tornillo y se fija con una tuerca como se muestra en la Figura.3.4. (c) La masa adicional (el tornillo y la tuerca) hace que el estado de desbalance.

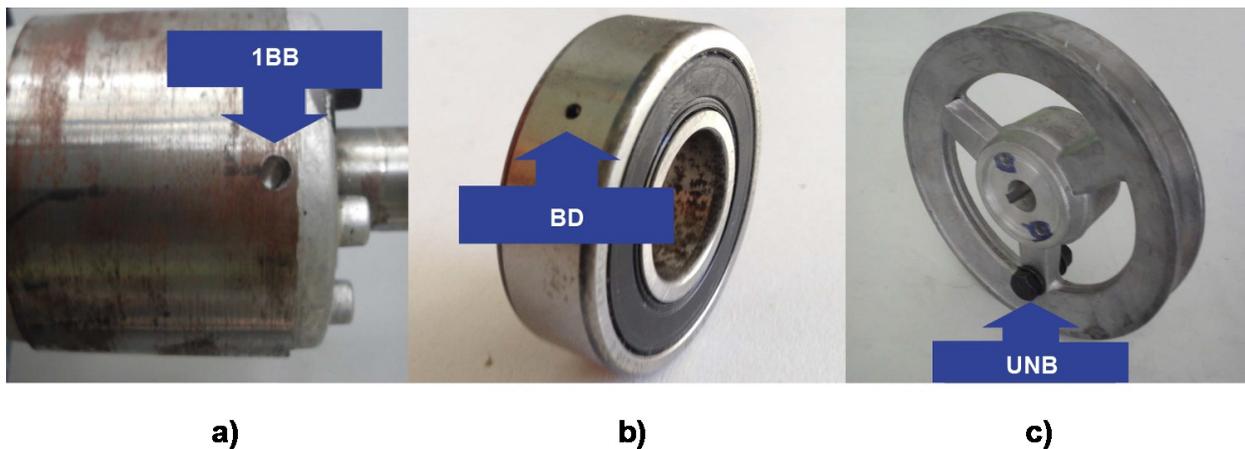


Figura 3.9 Fallas generadas artificialmente. a) Una barra rota (1BB). b) Defecto en el disco exterior del balero (BD), C) desbalance (UNB).

Las posibles combinaciones de múltiples condiciones defectuosas para el motor de inducción se obtuvieron mediante la mezcla de cada defecto con uno o dos de los fallos restantes. La Figura 3.5 muestra las diferentes combinaciones de las fallas tratadas.

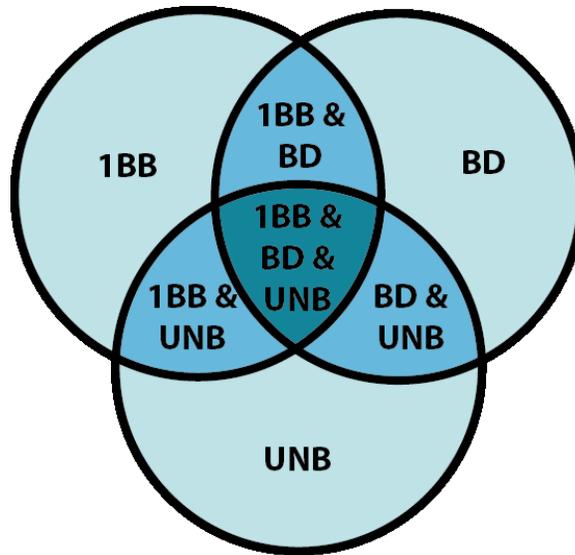


Figura 3.10 Combinaciones de las fallas múltiples

3.2.2 Caso de estudio 2. Implementación del algoritmo emd en fpga para la detección de fallas en motores de inducción.

La identificación y clasificación de las múltiples fallas en los motores de inducción es muy importante, ya que en la vida real las máquinas rotatorias pueden ser afectadas por varias fallas simultáneamente, donde el 50% de estas fallas están relacionadas con el estator, el 10% son fallas de rotor, y el desequilibrio está dentro del 12% de otras fallas (Hachemi Benbouzid, 2000). La identificación y clasificación automática de la condición del motor de inducción pueden ser proporcionadas por las técnicas de estimación frecuencial tales como la FFT, WT o más avanzadas como la HHT, que son herramienta poderosa en la identificación estado de la maquinaria rotatoria (Chen D y Wang WJ (2002)). La identificación condición a través de las redes neuronales de diferentes fallas también se ha presentado en diferentes trabajos como en (Su et al, 2011), donde presenta falla de cortocircuito en el devanado del estator y fallas de desequilibrio en la fuente de alimentación son analizadas a través de señales de vibración. Fallos relacionados con devanado del estator y excentricidad dinámica en el rotor se clasifican en (Ghate y Dudul, 2010). Ertuc *et al* (2013) usan las señales de corriente y vibraciones son analizadas con el fin de clasificar las diferentes fallas de baleros]. Otros fallos en el rotor también son clasificados a través de la extracción de características de la señal corriente en (Arabaci y Bilgin, 2010) Aunque RNAs se han aplicado con éxito para la identificación de la condición de los fallos de motor, la aplicación en línea se mantiene

como un reto ya que requiere de una técnica de tratamiento que le da la información pertinente con el fin de extraer las características relacionadas con las diferentes fallas; Por otra parte, si el número de características es grande, la complejidad clasificador puede aumentar. Como resultado, un compromiso debe establecerse entre el número de características que alimentan el clasificador y la carga computacional total requerido para la operación en línea.

Las señales de corriente de motor contienen componentes espectrales que varían con el tiempo, y las características de la falla se revelan a través de la distorsión de estas componentes. La firma característica de la falla de barra rota en el motor se extrajo en las bajas frecuencias mediante el uso de la amplitud instantánea de la corriente del estator (Kia *et al*, 2009), y la DWT se usa como un algoritmo de escala de tiempo eficiente, lo que da una precisión óptima de frecuencia en el ancho de banda de baja frecuencia (1,2 Hz - 9,6 Hz).

El indicador de fallo propuesto en este caso para la detección de fallos mecánicos y eléctricos en los motores de inducción se basa en la observación de la señal de corriente del motor den el transitorio de arranque que ese distorsiona en presencia de alguna falla. En consecuencia, los componentes espectrales registran un aumento de la corriente cuando se comparan con el espectro de un motor en buen estado. Por lo tanto, las variaciones de espectro actuales proporcionan la información suficiente para notar la presencia de alguna falla mecánica y eléctrica. Los cambios relativos en las frecuencias bajas ayudan para detectar cambios en la condición del motor de inducción.

La metodología general de este caso se muestra en la Figura 3.6. En primer lugar, el sistema utiliza una pinza de corriente para medir una de la fases de la corriente del estator, y un sistema de adquisición de datos (*Digital Acquisition System, DAS*) es usado para acondicionar y cuantizar la señal. A continuación, la señal discreta se hace pasar a través del procesador basado en FPGA para lograr un diagnóstico automático; donde una unidad de control general coordina las siguientes acciones: el *Control DAS* para adquisición de datos, la unidad de procesamiento de *EMD*, la unidad *ADALINE* para la extracción de características, y, finalmente, la unidad que lleva a cabo la clasificación hecha a través de una *FFNN*, y el control de la pantalla *LCD*. Entonces finalmente, el resultado de la condición del motor de inducción se muestra al usuario a través de una *LCD*.

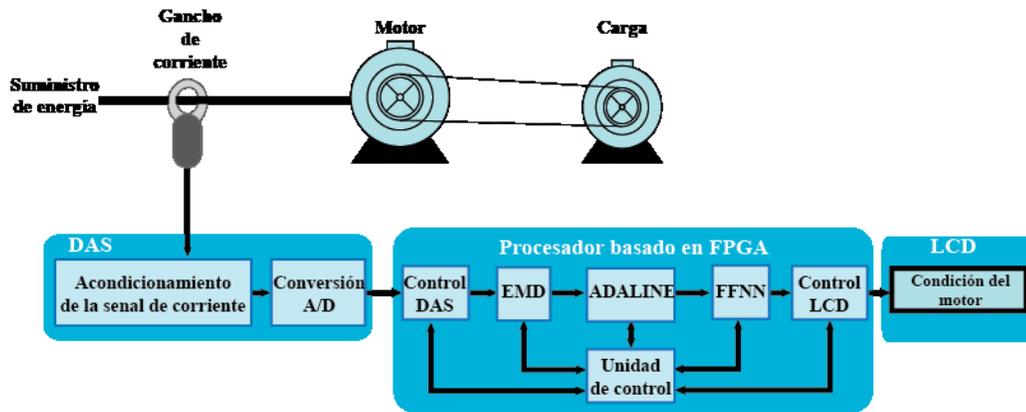


Figura 3.11 Propuesta de metodología para diagnóstico de fallos en los motores de inducción

3.2.2.1 Procesador basado en FPGA

El procesador basado en FPGA se compone de tres etapas: *Procesamiento EMD*, *Extracción de características por ADALINE* y *Clasificación por FFNN* como se muestra en la Figura 3.7 y el flujo del procesamiento de una señal real de un motor de inducción en buen estado se representa en la Figura 3.8. En primer lugar, la señal de entrada se descompone por el módulo de *EMD* a fin de obtener las primeras cuatro IMFs. Nótese que para esta aplicación, la primera IMF tiene información irrelevante para la metodología propuesta, ya que contiene la componente de frecuencia de la señal fundamental de 60 Hz, y la presencia de las componentes de frecuencia relacionadas con los fallos de motor es indetectable en este ancho de banda. Por lo tanto, se usan la segunda, tercera y cuarta IMFs, que se muestra en las Figuras 3.9 (b), 3.9 (c), 3.9 (d) respectivamente, las cuales pueden contener las componentes de frecuencia relacionadas con las fallas del motor. La información dentro de los rangos de ancho de banda que se encuentran en estas IMFs nos pueden indicar la condición del motor, estos valores se muestran en la Tabla 3.1. Las señales *RDD* y *EOD* supervisan los datos entrantes a la unidad *EMD*, la cual calcula las IMFs de manera secuencial y, a continuación, transfiere el resultado a la unidad de *ADALINE*. La estimación de componentes frecuenciales se realiza por *ADALINE* para la segunda (H_IMF_2), tercera (H_IMF_3) y cuarta (H_IMF_4) IMF, una por una seleccionadas por la señal *IMF_Sel*, de ahí se extraen doce componentes de frecuencia (cuatro por cada IMF), almacenados en la unidad de registros llamada *Registros de características*. Posteriormente, la unidad de *Clasificación por FFNN* realiza la clasificación mediante el uso de estos componentes de frecuencia que indica a través de cinco salidas la condición del motor como: HLT, 1BB, 2BB, UNB, y BD.

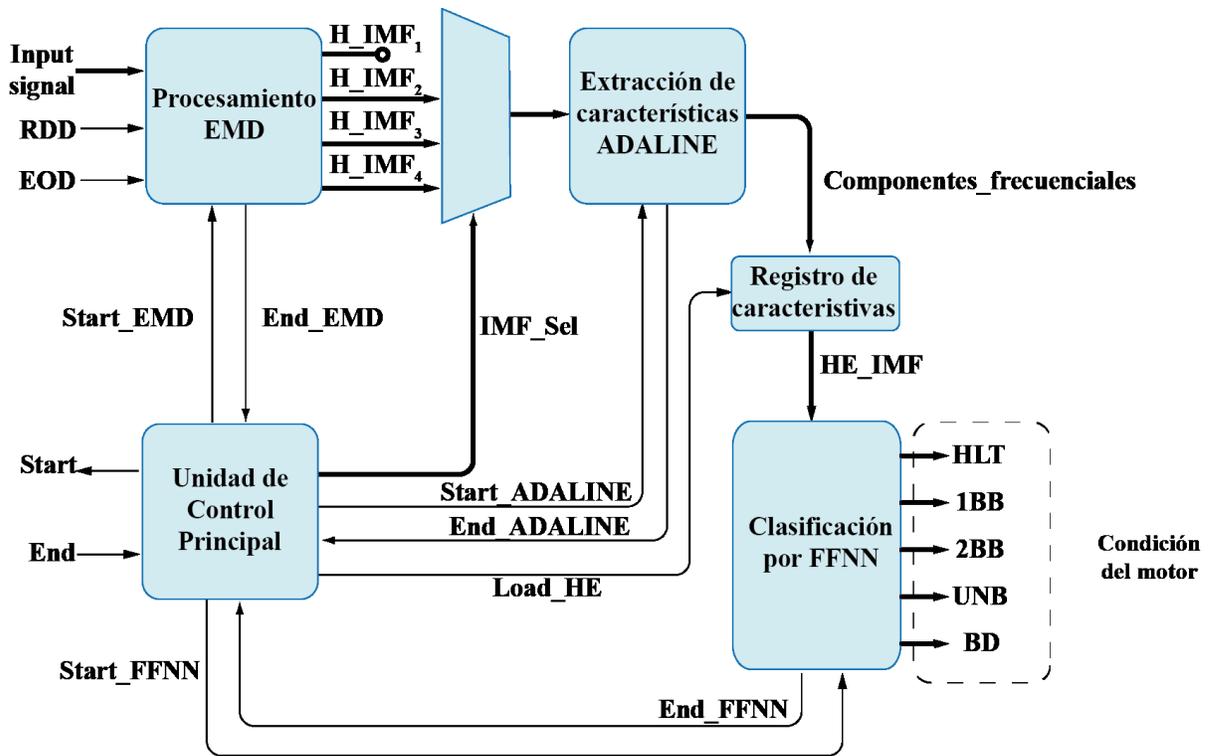


Figura 3.12 Procesador basado en FPGA

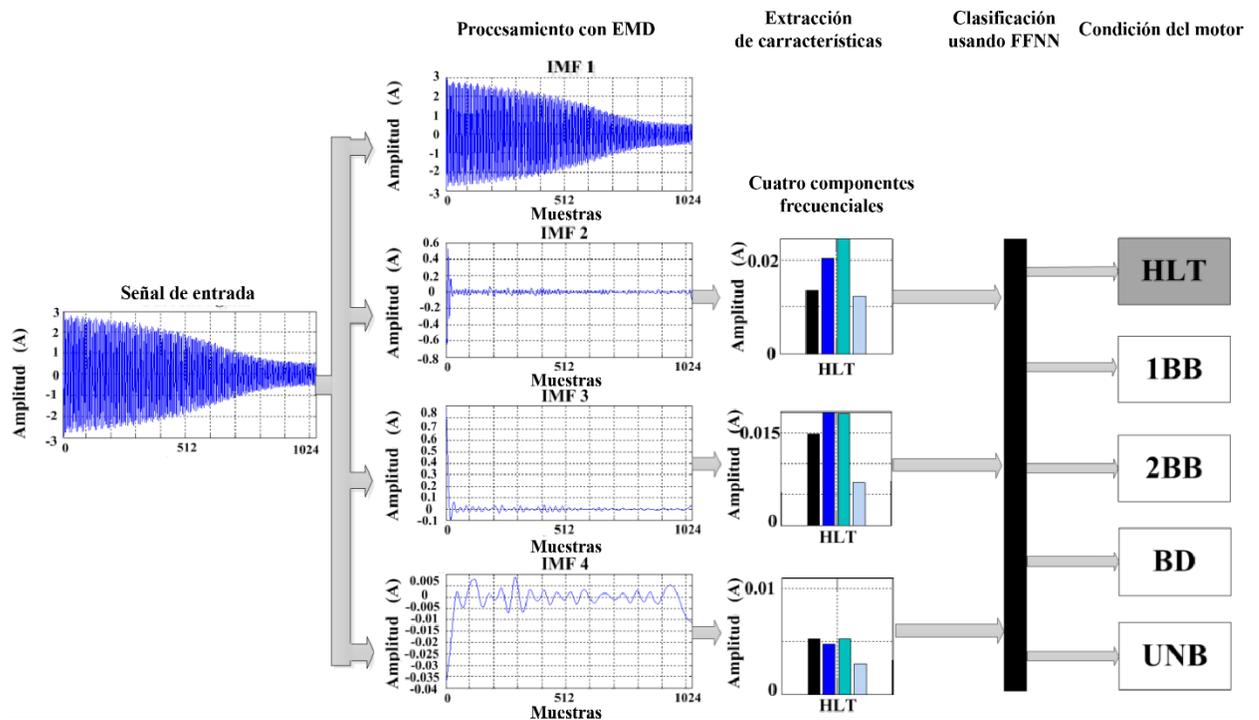


Figura 3.13 Metodología propuesta para el diagnóstico de la condición de un motor de inducción en buen estado.

Tabla 3.1 Componentes de frecuencia seleccionados para cada IMF

IMF	Ancho de banda analizado (Hz)	Componentes de frecuencia seleccionada (Hz)
2	0-40	10, 20, 30, 40
3	0-20	5, 10, 15, 20
4	0-10	2.5, 5, 7.5, 10

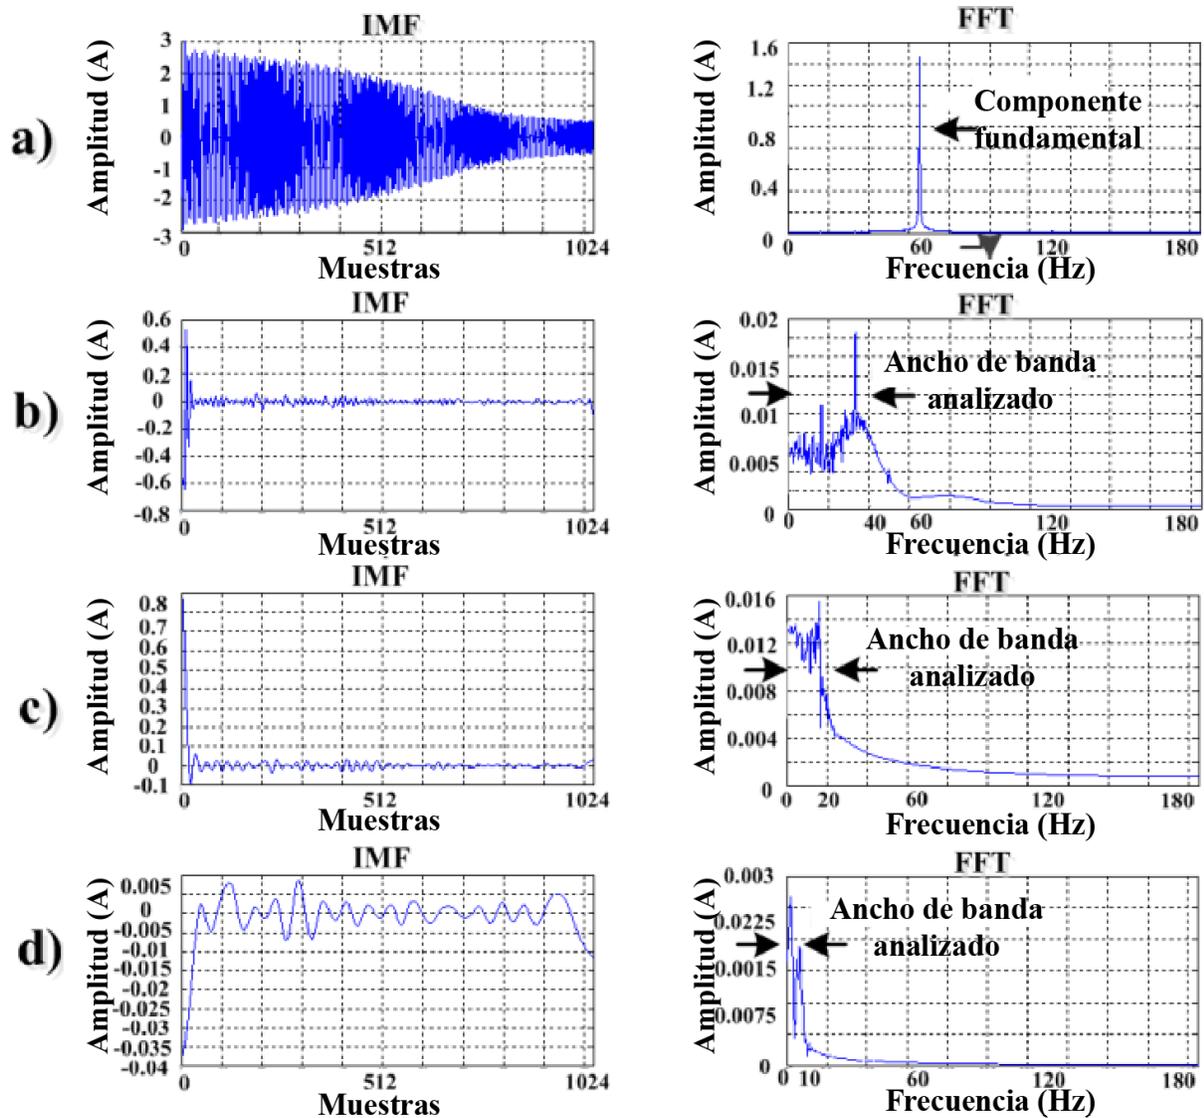


Figura 3.14 Contenido de frecuencia para cada IMF de un motor de inducción Equipo de Alto Nivel, a) Primera IMF, b) Segunda IMF, c) Tercera IMF, y d) Cuarta IMF

3.2.2.2 Estructura digital EMD

La Figura 3.10 muestra los pasos necesarios para implementar el método EMD en hardware. En primer lugar, la *Señal de entrada* se almacena en un bloque de memoria RAM interna como x_i , donde $i = 1, 2, 3 \dots 1024$; y luego se envía al módulo *Identificación de extremos*, donde se identifica los extremos de la señal (x_{max_j} y x_{min_k}) y sus respectivas posiciones (p_{max_j} y p_{min_k}). El módulo de *Spline Cubic* recibe x_{max_j} y x_{min_k} para calcular las envolventes superior e inferior (S_u y S_l). El módulo *Promedio de las envolventes* calcula la media de las envolventes superior e inferior y asigna la señal con el nombre de m_i . Luego, en el módulo de *IMF Candidato* calcula la diferencia entre la señal x_i y la señal de m_i con el fin de obtener el h_i señal, que representa una posible IMF. El criterio de desviación estándar se utiliza para determinar si h_i es una verdadera IMF, y si no la señal h_i se convierte en la señal de entrada y los pasos 1-4 se repiten. Cuando h_i es una verdadera IMF, la señal h_i se almacena y se convierte en la señal c_i , entonces la diferencia de las señales x_i y c_i se define como r_i . Finalmente, se revisa el número de las IMFs calculadas para decidir si termina el proceso. Si el proceso continúa, la señal r_i convierte en la nueva señal de entrada y el proceso se repite.

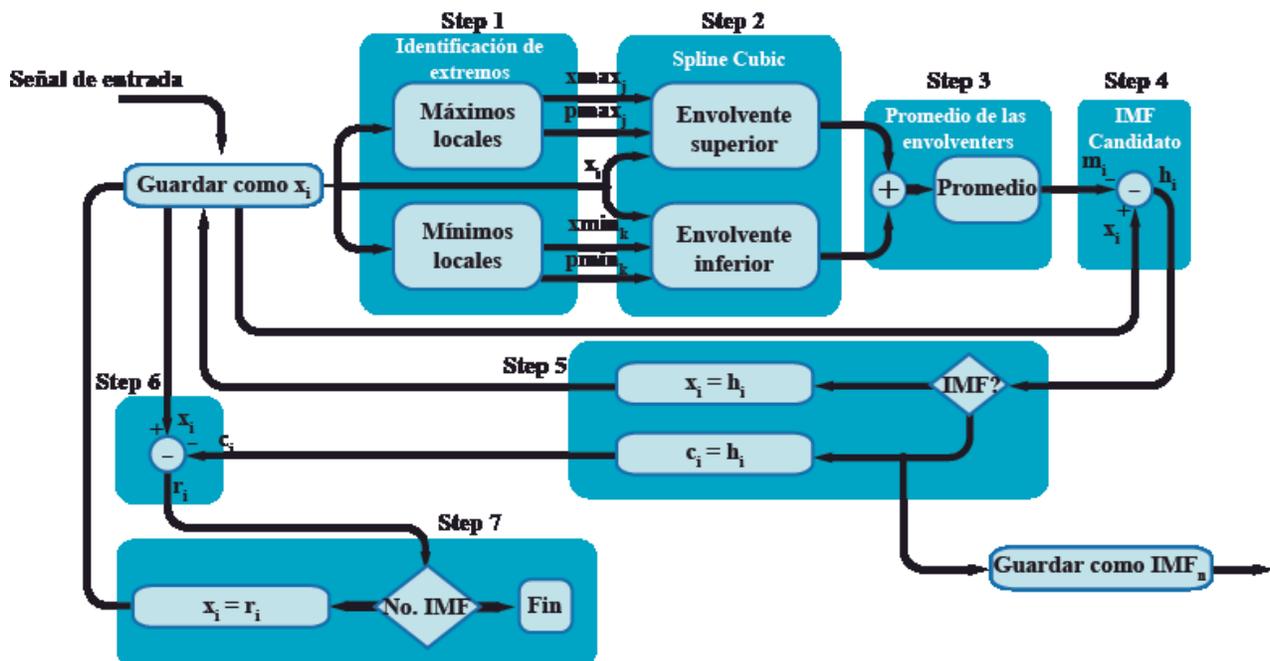


Figura 3.15 Diagrama de bloques del enfoque EMD propuesto

3.2.2.3 Módulo de Identificación de extremos

De acuerdo a la Figura 3.11, primero, de entrada x_i se envía a un registro pipeline 2-nivel, para almacenar x_{i-1} en el *Registro A*, y x_{i-2} en el *Registro B*. La señal x_{i-1} se compara con x_i y x_{i-2} por dos comparadores, cuyos resultados atraviesan una compuerta *AND*. Si x_{i+1} es el valor mayor referencia, éste se define como un máximo, que se coloca en el *Registro M* como x_{max_j} . La salida de la puerta *AND* habilita los registros *Registro M*, *Registro R* y *Registro P*. La señal *RDmax* indica cuando aparece un nuevo máximo. Al mismo tiempo, un *contador* se incrementa en uno cada que entra un nuevo dato, en lo que el *Registro P* almacena la posición del máximo (P_{max_j}). El mismo proceso se usa para calcular los mínimos, pero en este caso los comparadores se establecen para detectar cuando x_{i-1} es menor que x_i y x_{i-2} .

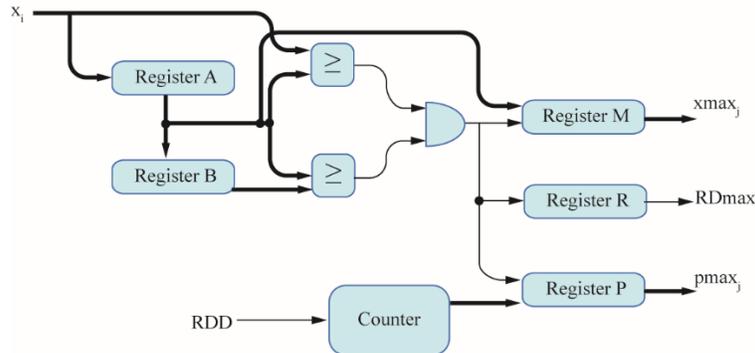


Figura 3.16 Diagrama de bloques del módulo de identificación de los extremos

3.2.2.4 Módulo de interpolación Spline cúbica

El algoritmo de la interpolación *spline* cúbica requiere un número determinado de datos para obtener una interpolación suave, en este diseño el tamaño del conjunto de datos seleccionado es 1024. Después de que se capturó el conjunto de datos, es posible calcular una interpolación adecuada. En la Figura 3.12 se describe el módulo de *spline* cúbica para el cálculo de la envolvente superior. Un procedimiento similar se utiliza para calcular la envolvente inferior.

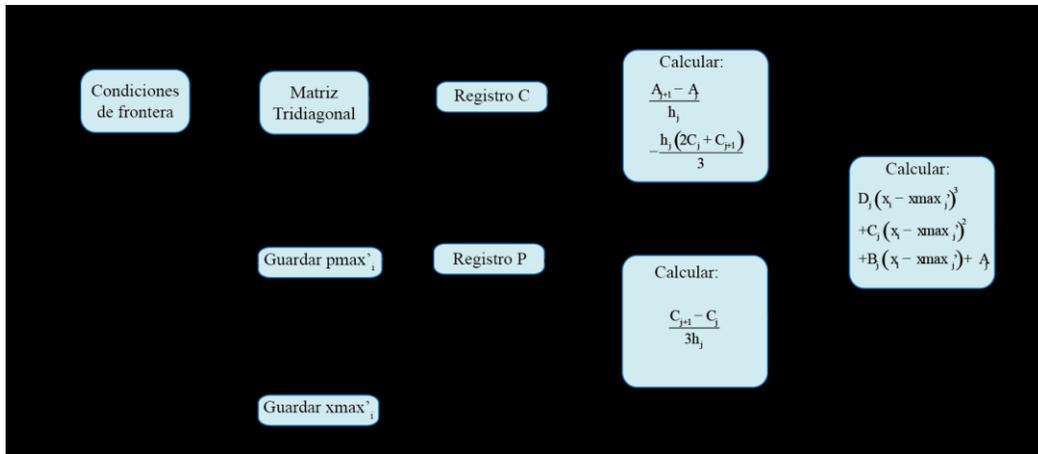


Figura 3.17 Diagrama de bloques del módulo de interpolación spline cúbica

De acuerdo a la Figura 3.12, las entradas $xmax_j$ y $pmax_j$, pasan a través del módulo de *Condiciones de frontera*, que adhiere a las condiciones de borde en el comienzo y el final de la serie de datos de máximos. El $RDmax$ señal indica la llegada de un nuevo máximo y EOD el fin del conjunto de datos. Estas condiciones se utilizan para calcular los valores en los bordes de la señal en el proceso de interpolación. Los nuevos conjuntos de datos ($xmax'_i$ y $pmax'_i$) con la condición de borde generadas se almacenan y se envían al módulo *Matriz Tridiagonal* con sus respectivas señales de control ($Rmax$ y EOD).

El algoritmo de la interpolación spline cúbica de acuerdo con (3.1) es

$$S(x) = \{S_j(x), x \in [x_j, x_{j+1}], j \in \{0 \dots n-1\}\} \quad (3.1)$$

donde

$$S_j(x) = D_j(x - xmax_j)^3 + C_j(x - xmax_j)^2 + B_j(x - xmax_j) + A_j \quad (3.2)$$

Para obtener el parámetro C_j , el módulo *Matriz Tridiagonal* resuelve un sistema tridiagonal para n número de máximos para la condición natural de spline cúbica, que está definida por (3.3) y (3.4), y la implementación de estas ecuaciones se muestran en la Figura 3.13,

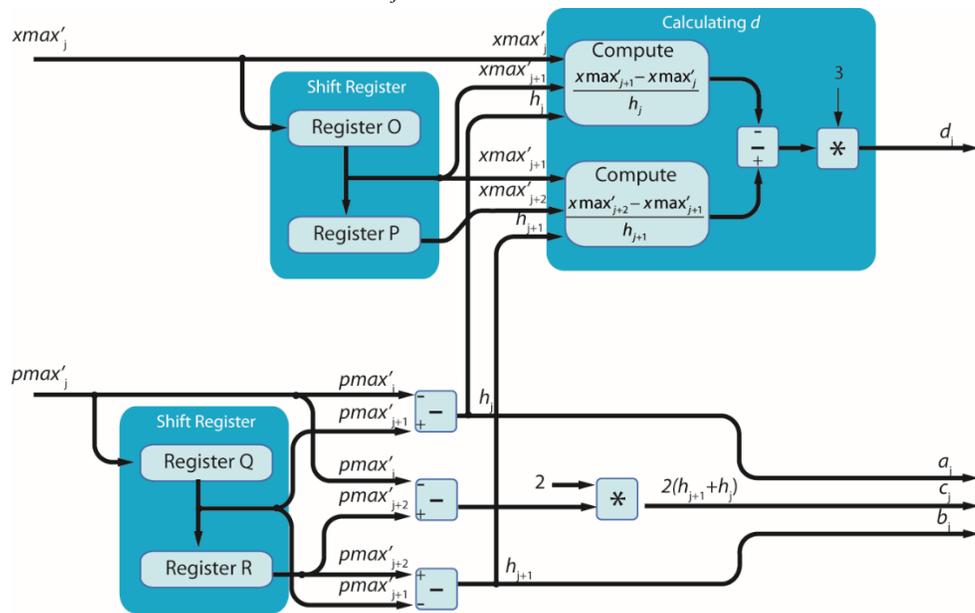
$$\begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 \\ h_0 & 2(h_0 + h_1) & h_1 & 0 & & \\ 0 & h_1 & 2(h_0 + h_1) & h_2 & & \\ \vdots & & \ddots & \ddots & \ddots & \\ 0 & \dots & & h_{n-2} & 2(h_{n-2} + h_{n-1}) & h_{n-1} \\ 0 & \dots & & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} C_0 \\ C_1 \\ \vdots \\ C_{n-1} \\ C_n \end{bmatrix} = \begin{bmatrix} 0 \\ 3(\lambda_1 - \lambda_0) \\ 3(\lambda_2 - \lambda_1) \\ \vdots \\ 3(\lambda_{n-1} - \lambda_{n-2}) \\ 0 \end{bmatrix} \quad (3.3)$$

donde

$$\begin{aligned}
 A_j &= pmax'_j, \\
 B_j &= \frac{A_j - A_{j-1}}{h_j} - \frac{h_j(2C_j + C_{j-1})}{3}, \\
 D_j &= \frac{C_j - C_{j-1}}{3h_j}
 \end{aligned}
 \tag{3.4}$$

Después de obtener el valor del coeficiente C , es posible encontrar los valores del coeficiente de s A , B y D siguientes (3.5) y haciendo posible calcular la envolvente

$$\begin{aligned}
 A_j &= pmax'_j, \\
 B_j &= \frac{A_j - A_{j-1}}{h_j} - \frac{h_j(2C_j + C_{j-1})}{3}, \\
 D_j &= \frac{C_j - C_{j-1}}{3h_j}
 \end{aligned}
 \tag{3.5}$$



a)

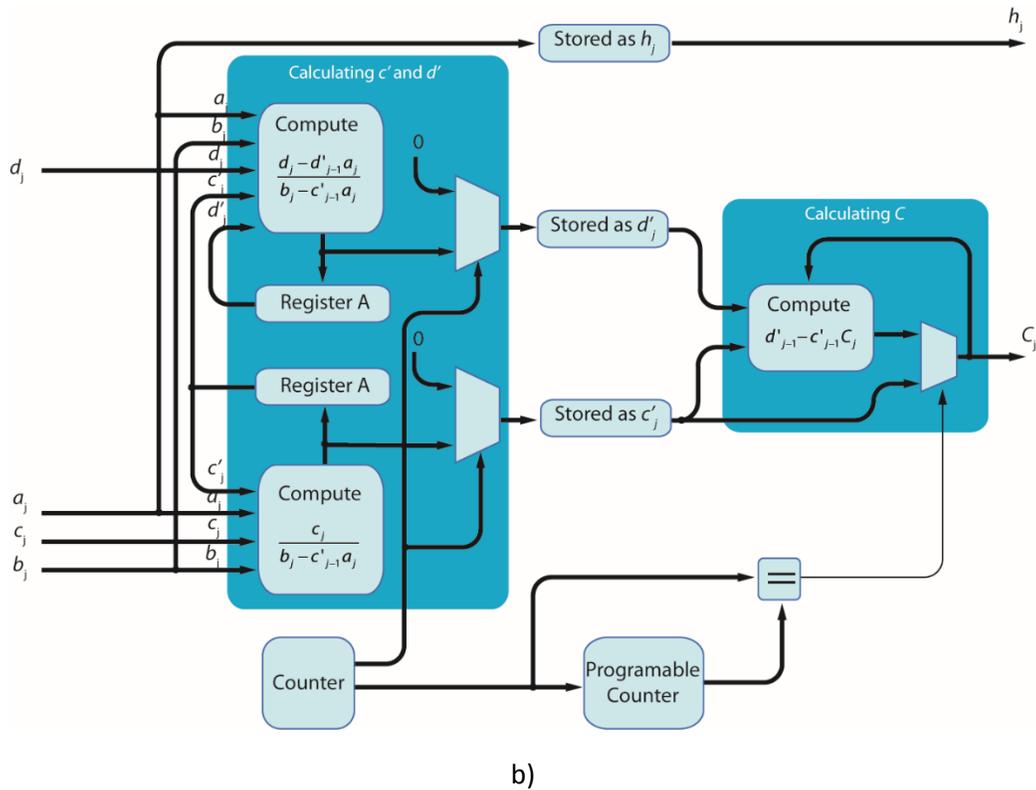


Figura 3.18 a) y b) Diagrama de bloques del módulo de Matriz Tridiagonal

3.2.2.5 Estructura ADALINE digital

Este módulo realiza la estimación de frecuencia para la segunda (IMF_2), tercera (IMF_3), y la cuarta IMF (IMF_4) de acuerdo con la señal C_IMF como se muestra en la Figura 3.14. El módulo *Control Maestro ADALINE* proporciona la sincronización global para calcular (2.34), (2.36), (2.37) y (2.38) para ADALINE ($Start_ADALINE/End_ADALINE$), LMS ($Start_ADALINE/End_ADALINE$), y CORDIC (S_C/E_C). En primer lugar, la sección ADALINE de la Figura 3.14 realiza (8) de la siguiente manera: los valores seno y el coseno para un solo período los doce componentes de frecuencia se almacenan en la una Tabla de consulta (*Lookup table, LUT*) como *LUT sin* y *LUT cos*, respectivamente; después, se multiplican y se añaden por los pesos almacenados en los registros W_i para $i = 0 \dots 8$, ya que hay cuatro componentes de frecuencia y cada uno de ellos requiere los coeficientes a y b de acuerdo con (9). En segundo lugar, la sección LMS calcula (13) el error entre la salida de la sección ADALINE y la salida deseada y_k . Para ello, el error en (12) se calcula primero

y se multiplica por α ; en la metodología propuesta se utiliza $\alpha = 0.01$. Posteriormente, los pesos modificados se almacenan en el registro X_i para $i = 0 \dots 8$ a través de la multiplicación y la suma con S , C , y W_i ; que son los valores de seno, coseno, y pesos, respectivamente. Por último, la sección del método digito por digito, en ingles llamado *Coordinate Rotation Digital Computer (CORDIC)* calcula la amplitud y fase de acuerdo con (10) (Meher *et al*, 2009). Éste se utiliza en el modo de vectorización, donde se toman los pesos en pares, W_k y W_{k+1} . Con el fin de obtener los doce componentes de frecuencia ($H1_IMF_2, H2_IMF_2, H3_IMF_2, H4_IMF_2, \dots, H4_IMF_4$), todo el proceso general se repite para los tres IMF's. Las señales I_i y L_i para $i = 1, 2$, y 3 controlan los multiplexores y la habilitación de los registros, respectivamente.

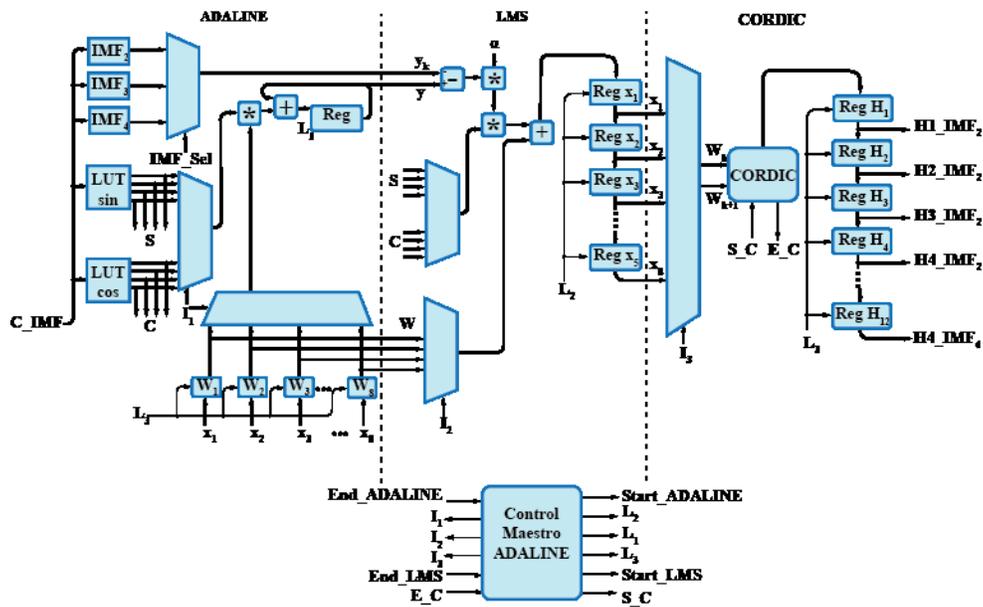


Figura 3.19 Diagrama de bloques del módulo ADALINE

3.2.2.6 FFNN

Este módulo se desarrolla y entrena primeramente en Matlab para ser implementado posteriormente en la FPGA. Por lo tanto, el módulo FFNN está previamente entrenado usando el algoritmo de Levenberg-Marquardt para identificar una condición HLT en el motor de inducción o la presencia de múltiples fallos individuales. Para ello, veinte señales reales de prueba se llevan a cabo en cada condición motor. Los conjuntos de entrenamiento y la validación se establecen para cada condición sintéticamente mediante la producción al azar de 100 valores, 70 para la formación y 30 para la validación, de cada componente de frecuencia dentro del rango $(\mu + \sigma, \mu - \sigma)$, donde μ es la media y la σ es la desviación estándar de la magnitud componentes de

frecuencia a partir de los veinte señales reales en la muestra, como se muestra en la Figura 3.15. El conjunto de pruebas está compuesto por sólo señales reales. La arquitectura FFNN tiene 12 entradas (cuatro componentes de frecuencia para cada IMF), 10 neuronas en la capa oculta, y 5 salidas (una por cada estado), que funcionan como banderas para indicar el estado del motor de inducción. El número de 10 neuronas en la capa oculta fue seleccionado de forma experimental para obtener el mínimo error en la clasificación general. Después del entrenamiento, validación y pruebas, los pesos finales y los sesgos de cada capa de neuronas se utilizan para la implementación FPGA de acuerdo a la estructura digital que se muestra en la Figura 3.16, que calcula (14) para cada neurona. Allí, los módulos de *Control de la capa oculta* y *Control de la capas de salida* proporcionan las señales de sincronización que regulan el intercambio de información entre las unidades de control para la capa oculta y de salida a través de *StartH / EndH* y *StartO / EndO*, respectivamente; además, las señales I_i y L_i para $i = 1$ y 2 de control de los multiplexores y la carga de registros. La capa oculta se muestra en la Figura 3.16 (a) tiene 10 neuronas y recibe los cuatro componentes de frecuencia para cada IMF. Ellos son ponderadas por los correspondientes valores W_1, W_2, \dots, W_{10} . Cada k registro W contiene 12 valores ponderados diferentes, una para cada entrada. Los valores ponderados para cada componente de frecuencia se resumen a n d añadió secuencialmente a un valor de polarización almacenado en un LUT (*LUT Bias*). El resultado de esta operación se utiliza para el disparo en la salida respectiva Y_i a través de una función de transferencia -sigmoid log (LS), que se implementa como una LUT (*LUT log-sig*). El mismo proceso se repite en la capa de salida se muestra en la Figura 3.16 (b), que utiliza las salidas y_1, y_2, \dots, y_{10} de la capa oculta como insumos para sus cinco neuronas que obtengan la salidas Z_1, Z_2, \dots, Z_5 que definir s HLT, 1BB, 2BB, UNB, y la condición BD a través de una comparación de umbral de 0,5. Finalmente, se da la condición de motor de inducción de acuerdo con la clasificación hecha por la red neuronal.

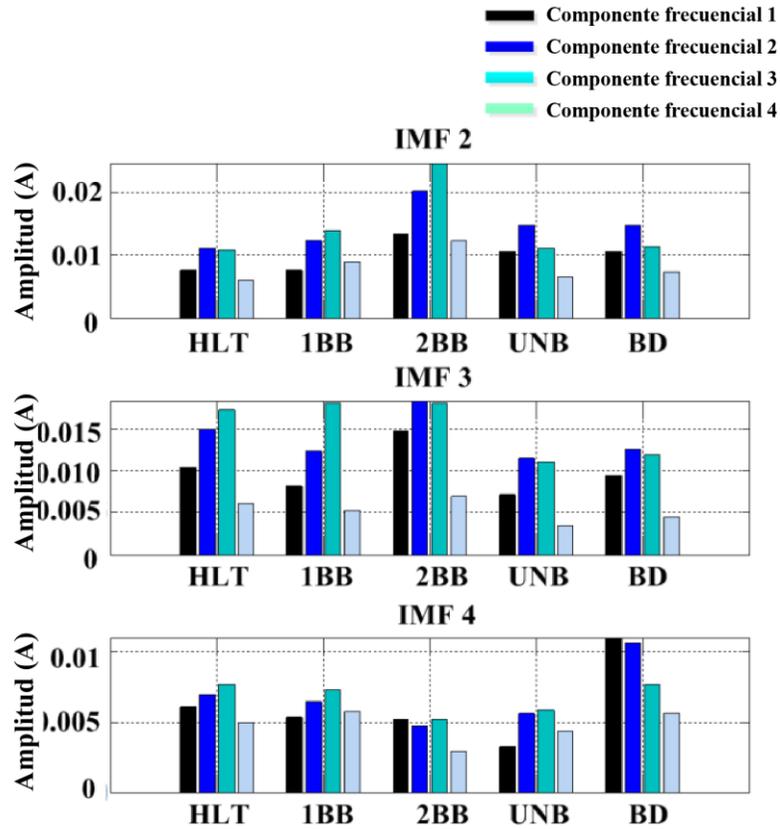


Figura 3.20 Componentes de frecuencia de estimación hasta ADALINE por diferentes faltas

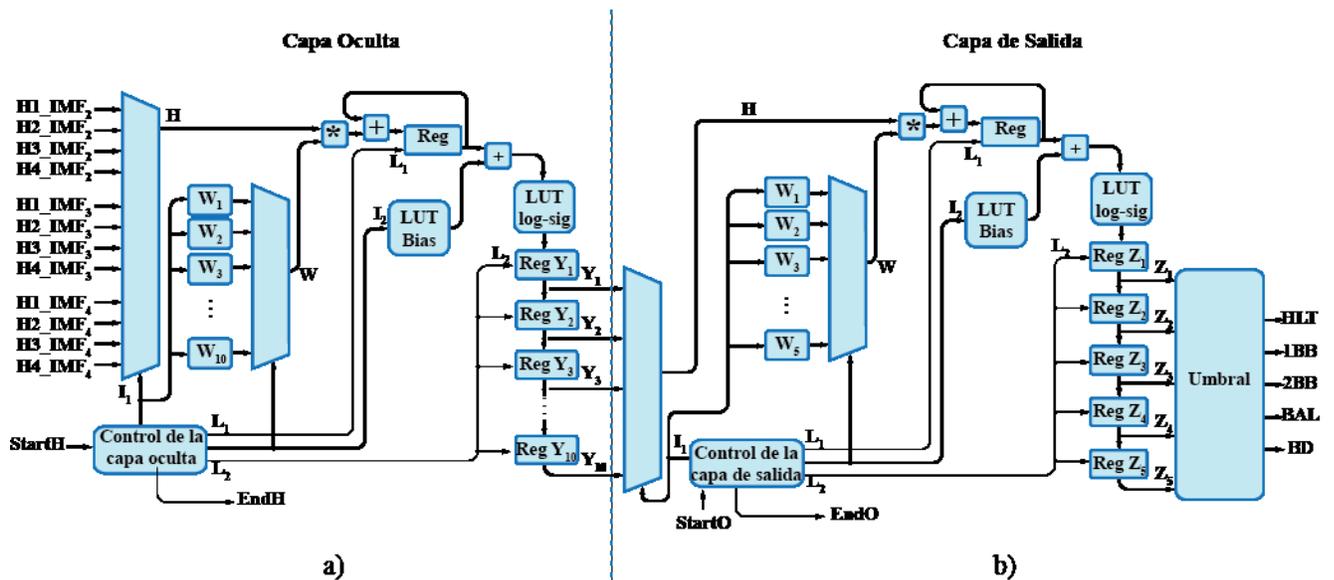


Figura 3.21 Diagrama a bloques del módulo FFNN, a) capa oculta, b) capa de salida

3.2.3 Caso de estudio 3. Metodología basada en EEMD-MUSIC para la obtención de las frecuencias naturales en estructuras civiles.

Las estructuras civiles juegan un papel importante en diferentes áreas de la ingeniería, dado que éstas tienen como papel principal soportar elementos y adaptarse a cambios repentinos de excitación, los cuales pueden llegar a producir daños en la estructura o bien, el colapso de la misma. Diversas construcciones en el mundo; desde las primeras edificaciones, hasta modernos edificios de alta ingeniería, guardan una relación íntima entre su diseño y dinámica. Naturalmente, no sólo las edificaciones han ido evolucionando, los avances en tecnología estructural y de materiales han permitido la construcción de estructuras civiles a gran y pequeña escala, lo cual se traduce en el desarrollo de la sociedad.

La Figura 3.22 muestra el diagrama de flujo de la metodología basada EEMD-MUSIC propuesto para la identificación de frecuencias modales de señales de vibración libres y ambientales producidos por una artificial o una excitación natural. El primer paso es la adquisición de la señal de vibración de la estructura. En segundo lugar, la señal de vibración muestreada se pasa a través de un filtro de paso de banda, con el fin de extraer el ancho de banda de interés relacionado con las frecuencias naturales s , así como para ayudar a resolver la mezcla de modo. En tercer lugar, la señal de vibración filtrada se descompone en su FMI utilizando el EEMD. Finalmente, el algoritmo MUSIC se aplica a cada IMF para calcular las frecuencias naturales de la estructura.

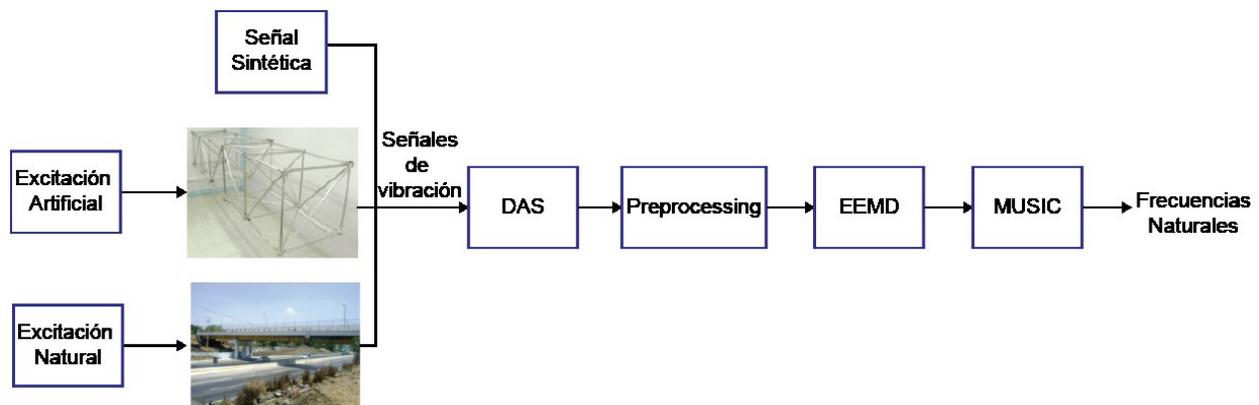


Figura 3.22 Metodología para la extracción de frecuencias naturales

La utilidad de la metodología propuesta se prueba en tres experimentos. El primer experimento se centra en el uso de una señal sintética para validar la precisión e inmunidad al ruido de la metodología propuesta (Figura 3.22). En el segundo experimento, la metodología propuesta es probada en una estructura tipo cercha escala situada en un laboratorio, donde se controlan las condiciones de excitación. Finalmente, el tercer experimento se lleva a cabo para mostrar la eficacia de la metodología propuesta en condiciones de funcionamiento reales. Para esto se analiza una estructura real (un puente), en el que se utiliza la excitación natural.

3.2.3.1 Señal sintética

Con el fin de validar el rendimiento metodología propuesta, se presenta una comparación entre los diferentes enfoques y la propuesta. Para ello, una señal sintética con valores conocidos *a priori* es utilizada, la cual corresponde a una respuesta de vibración libre amortiguada de 4 grados de libertad del sistema como sigue:

$$i(t) = \sum_{j=1}^4 A_j e^{-2\pi\zeta_j f_j t} \sin(2\pi f_d_j t + \theta_j) + \omega(t) \quad (3.4)$$

w aquí A_j , θ_j , f_j , $f_d_j = f_j \sqrt{1 - \zeta_j^2}$, y ζ_j son la amplitud, fase, frecuencia natural no amortiguada, frecuencia natural amortiguada, y factor de amortiguamiento del modo j -ésimo, respectivamente, mientras que $\omega(t)$ es una secuencia de ruido blanco. Los valores numéricos utilizados son $f_1=0.61$ Hz, $f_2=0.73$ Hz, $f_3=1.56$ Hz, $f_4=4.35$ Hz, $\zeta_j=0.01$, $A_j=1.0$ y $\theta_j=0$ for $j=1, \dots, 4$, con una frecuencia de muestreo y el tiempo de muestreo de 50 Hz y 11 s, respectivamente. Además, un nivel de ruido de 30% para una SNR = 7.4 dB se utiliza para probar la eficiencia y la inmunidad de los nicas tecnología a entornos ruidosos. La metodología a seguir es analizar la señal sintética través de varias metodologías para hallar las frecuencias naturales. En primer lugar, se descompone la señal sintética, como se muestra en la Figura 3.23, por el método EEMD y la transformada wavelet discreta (DWT), que también descompone una señal en bandas de frecuencia nombrados descomposiciones (DCs). Luego, algunas IMFs y DCs se eligen para que se analiza. En cuanto a las IMFs. Los primeros dos niveles dla IMF se descartan ya que contienen los componentes de ruido y de alta frecuencia; por lo tanto,

sólo la IMF_{3,4} IMF, y la IMF₅ se consideran para identificar los modos naturales. On otro lado, y según la DCs (Véase la Figura 3.24b), las dos primera descomposiciones, DC₁ y DC₂, se descartan ya que contienen las bandas de alta frecuencia; en consecuencia, el DC₃ (3,125 a 6,25 Hz), DC₅ (0,781 a 1,5625 Hz), y DC₆ (0,390 a 0,781 Hz) se analizan para identificar las frecuencias naturales ya que además, contienen las frecuencias de interés.

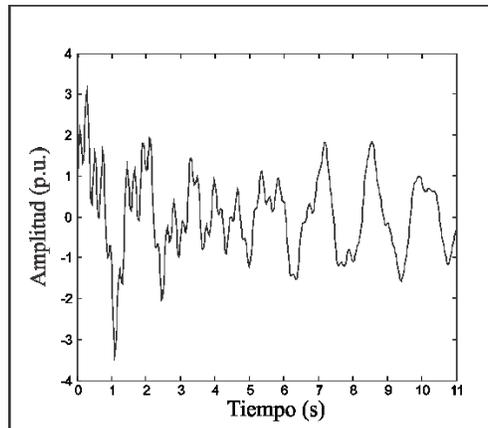


Figura 3.23 Señal sintética

3.2.3.2 *Excitación artificial*

Las estructuras de barras articuladas son las más empleadas en el diseño de la infraestructura civil ya que son fáciles de ensamblar, existe un ahorro de material en comparación a otros diseños de estructuras, su rápida instalación, su peso ligero y permiten un espacio accesible para su mantenimiento. Por lo tanto, las estructuras de barras articuladas juegan un papel importante en la economía teniendo aplicaciones en el diseño de puentes, torres, grúas, techos, esqueletos de edificios, entre otras. En arquitectura y en ingeniería estructural, una estructura de barras articuladas (Truss) es una estructura que comprende una o varias unidades triangulares construidas con elementos rectos cuyos extremos están conectados a las articulaciones llamadas nodos. Las fuerzas externas y reacciones a dichas fuerzas se considera que actúan solo en los nodos resultando en compresión o tensión en los miembros de la estructura.

30% de nivel de ruido

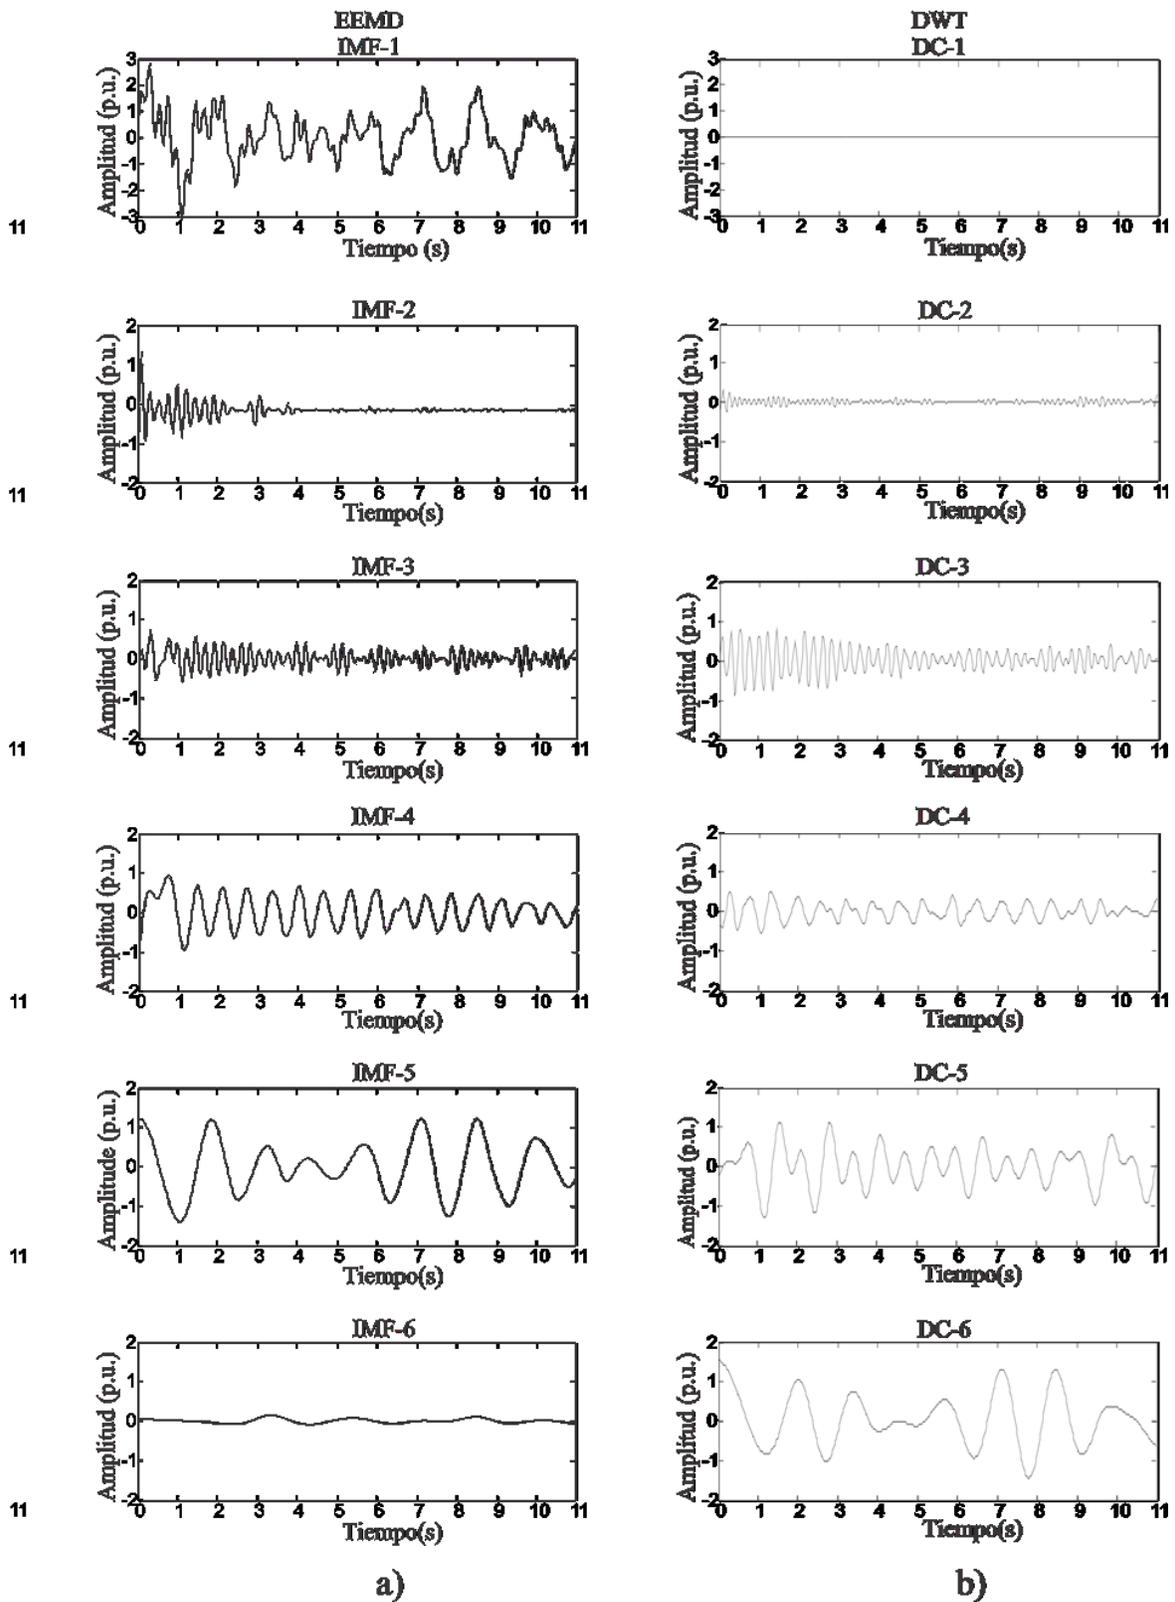


Figura 3.24 a) IMFs de la señal sintética, b) DCs de la señal sintética

La estructura empleada en este trabajo de tesis consta de cinco cubos hechos de aluminio, la cual esta empotrada en una pared de concreto. Cada cubo mide 0.707 de lado de manera que las barras diagonales son de 1 m de longitud. Los nodos tienen una masa de 0.2Kg, miden 0.055m de lado y están conectados por medio de un tornillo con las barras. Los elementos que conforman la estructura se diseñan a partir de estas dimensiones y a la topología mostrada en la Figura 3.25a. La Figura 3.25b muestra el ensamble de la barra con el nodo.

En arquitectura y en ingeniería estructural, una estructura de barras articuladas (Truss) es una estructura que comprende una o varias unidades triangulares construidas con elementos rectos cuyos extremos están conectados a las articulaciones llamadas nodos. Las fuerzas externas y reacciones a dichas fuerzas se considera que actúan solo en los nodos resultando en compresión o tensión en los miembros de la estructura. La estructura empleada en este trabajo de tesis consta de cinco cubos hechos de aluminio, la cual esta empotrada en una pared de concreto. Cada cubo mide 0.707 de lado de manera que las barras diagonales son de 1 m de longitud. Los nodos tienen una masa de 0.2Kg, miden 0.055m de lado y están conectados por medio de un tornillo con las barras. Los elementos que conforman la estructura se diseñan a partir de estas dimensiones y a la topología mostrada en la Figura 3.24a. La Figura 3.24b muestra el ensamble de la barra con el nodo.

El diagrama esquemático del sistema de monitoreo esta mostrado en la Figura 3.26, en el cual el sistema implementado consiste de cinco unidades: generador de señales, sintetizador digital de formas de onda, actuador primario, sistema de instrumentación, el cual está conformado por el sensor primario, el acondicionador de señales, y sistema de adquisición de datos, y un algoritmo programado en MATLAB para el análisis de señales. La unidad de generador de señales genera y modifica la señal que será empleada para excitar la estructura.

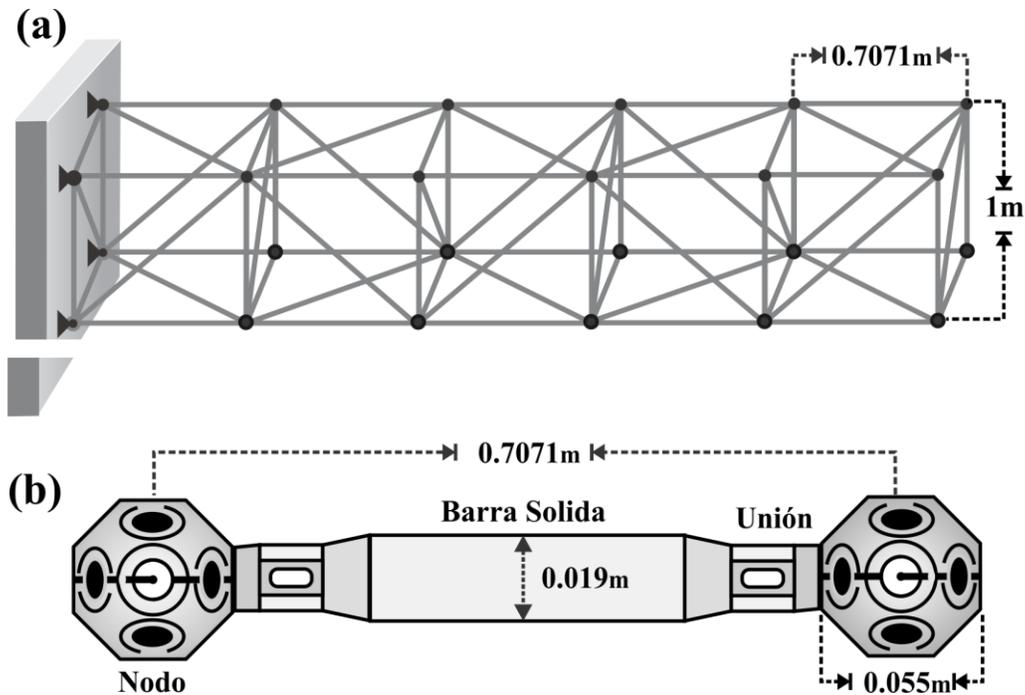


Figura 3.25 (a) Estructura de barras articuladas. (b) Elementos de la estructura

La unidad sintetizador digital de formas de onda está basada en FPGA y se encarga de guardar y reproducir la señal generada por la unidad de generador de señales. La unidad AP incluye un amplificador lineal comercial, el cual recibe y acondiciona la señal generada por la unidad de sintetizador digital de formas de, y un shaker electrodinámico, el cual es alimentado por la señal acondicionada para excitar la estructura. El sistema emplea múltiple acelerómetros como sensor primario para monitorear las aceleraciones en uno o varios puntos de la estructura simultáneamente. Finalmente, el sistema de adquisición de datos, el cual está basado en FPGA, adquiere y almacena todas las señales medida por los sensores, acondicionadas y amplificadas por la unidad de acondicionador de señales; luego, estas señales son enviadas a la PC para su análisis con el fin de estimar la condición de la estructura, localizar la falla y la severidad de la misma.

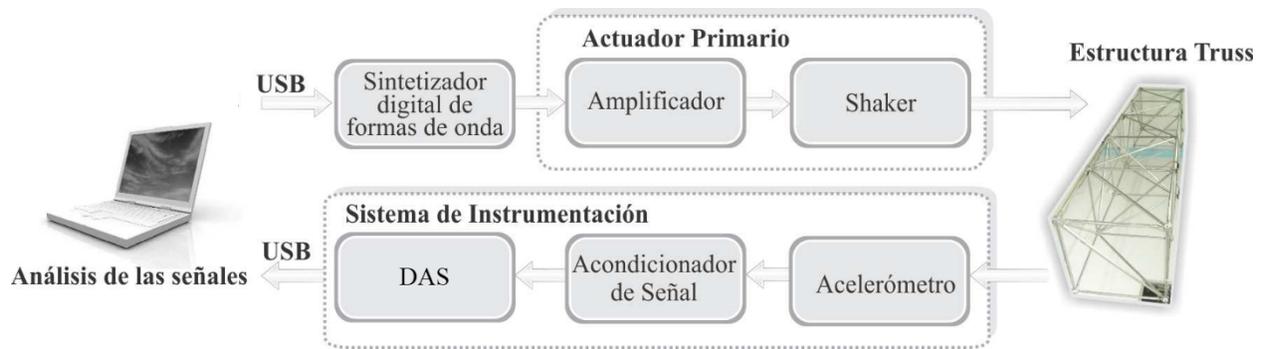


Figura 3.26 Obtención de señales de aceleración obtenidas de la estructura tipo truss

En la Figura 3.27 se muestra el banco de pruebas de la estructura tridimensional en escala de tipo truss, utilizada para la extracción de las frecuencias naturales por medio de una excitación artificial. La prueba modal se realiza con una masa que cuelga de 14 kg como fuente de excitación. La masa está atada en el primer-nodo con el fin de tener el máximo desplazamiento de la estructura; a continuación, el cable que sujeta la masa se corta para inducir una vibración libre en la estructura. La señal de vibración se adquiere usando un acelerómetro MEMS tri-axial modelo LIS3L02AS4 de STMicroelectronics colocado en la parte superior del tercer nodo como se muestra en la Figura 5 (a). El acelerómetro tiene una escala completa seleccionable por el usuario de $\pm 19,6 \text{ m/s}^2$ / $\pm 58,8 \text{ m/s}^2$ con una resolución de $50 \times 10^{-4} \text{ m/s}^2$ a más de 100 Hz. La información se digitaliza usando un acelerómetro usando un ADC ADS7841 de 12-bit y 4-canales de Texas Instruments, con un máximo de muestreo de 200 kHz en cada canal como se muestra en la Figura 3.26b. Las señales del sistema de adquisición de datos (DAS) se envían a una computadora personal a través del protocolo de bus serial universal (Universal Serial Bus, USB) como se muestra en la Figura 27b. El DAS utiliza una frecuencia de muestreo de 3,2 kHz para la obtención de 22,400 muestras durante una ventana de tiempo de 7 s. La señal de vibración libre vertical, se muestra en la Figura 3.28, la cual se utiliza para identificar las frecuencias naturales de la estructura.

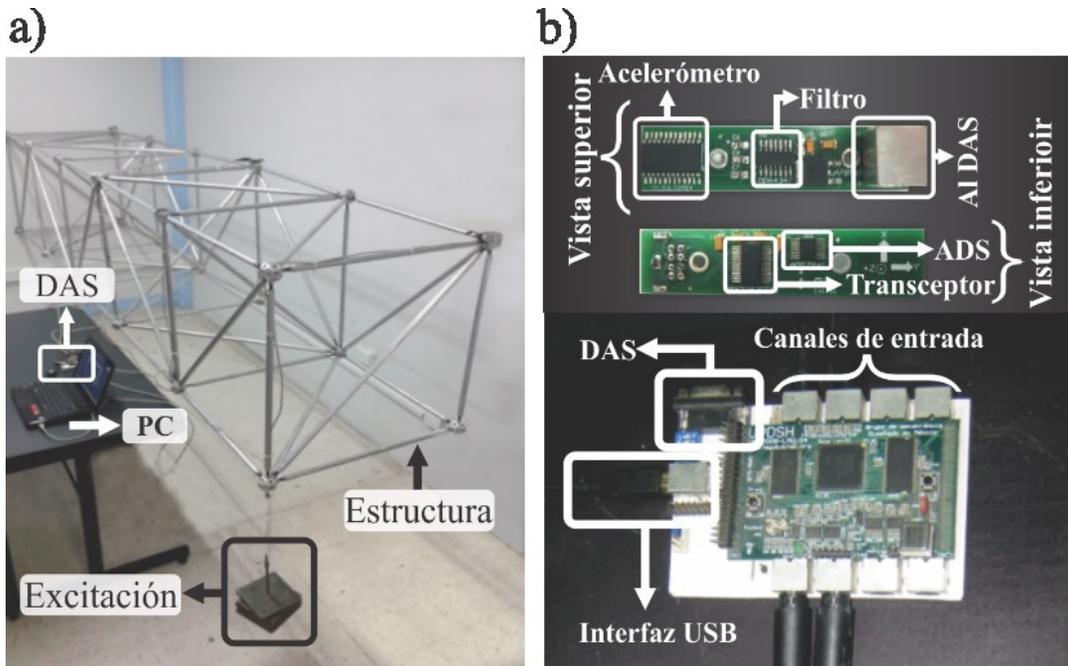


Figura 3.27 Banco de pruebas

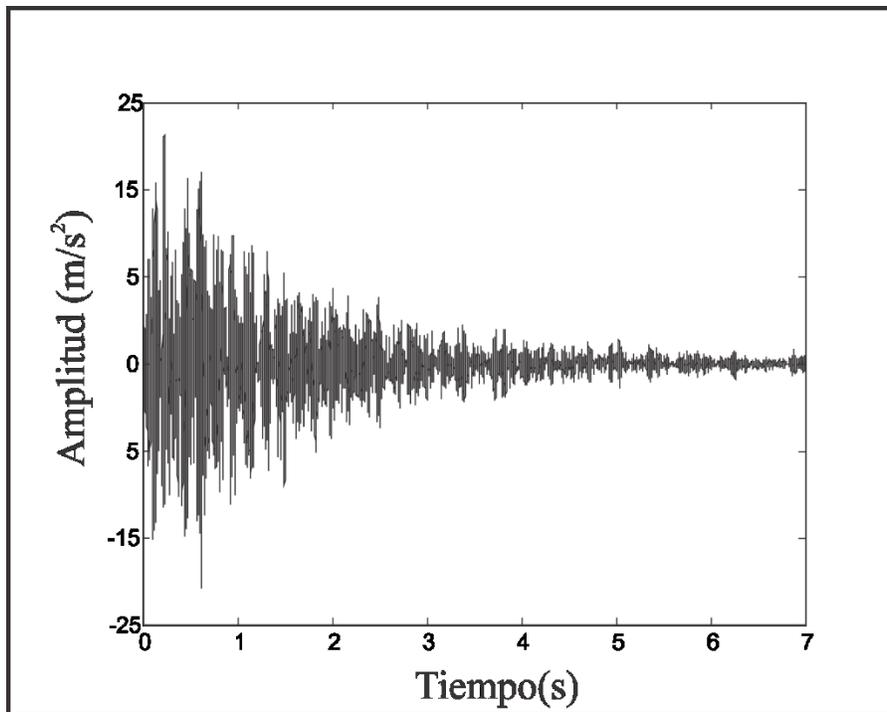


Figura 3.28 Medición de la aceleración vertical

3.2.3.3 Excitación natural

En esta prueba se analizan las señales obtenidas de la instrumentación de un puente de concreto reforzado, ubicado en la autopista México-Querétaro (veáse Figura 3.29a)Éste es utilizado para que personas puedan cruzar la autopista con total seguridad.



Figura 3.29 Puente analizado

El puente es excitado mediante el viento y el tráfico que cruza por debajo de él y es monitoreado en línea usando un acelerómetro tri-axial montado en la mitad del puente (como se muestra en la Figura 3.29b).

El puente se utiliza tanto para el tráfico vial y peatonal. Como se muestra en la Figura 29a. La vibración ambiental causada por el tráfico es monitorizada en línea-a través de un acelerómetro tri-axial montado en el medio del puente. Las señales obtenidas desde el acelerómetro se almacenan en el DAS y enviado a PC por el protocolo USB. El DAS utiliza un frecuencia de muestreo de 160 Hz para obtener 32,000 muestras durante una ventana de tiempo de 200 s.

4. RESULTADOS

En este capítulo se analizan y discuten los resultados obtenidos en los dos casos de estudio presentados en ese trabajo. Estos resultados discuten en comparativa con otras técnicas, estándares y normativas internacionales. Además, se describen las ventajas que ofrecen la implementación en FPGA en el uso del método de descomposición empírica de modos.

4.1 CASO DE ESTUDIO 1. METODOLOGÍA BASADA EN EMD-MUSIC PARA LA DETECCIÓN DE FALLAS MÚLTIPLES EN MOTORES ELÉCTRICOS.

La aplicación de la metodología propuesta se verifica en varias condiciones de falla (1BB, BD y UNB) o combinaciones de ellas presentes en el motor. La metodología se analiza para todos los posibles casos ya sea motor en buen estado o con alguna falla o combinación de éstas, donde la señal de corriente en el estado estacionario del motor es primeramente procesada por el algoritmo EMD y sólo los dos de las IMFs se utilizan para analizar la señal con el algoritmo MUSIC, debido a que en estas regiones se pueden encontrar información de interés para identificar la falla; la primera IMF da información de las fallas de 1BB y UNB, y la segunda IMF indica la BD. Los espectros obtenidos por el algoritmo MUSIC de las dos primeras IMFs se muestran en las Figuras 4.1 y 4.2 El orden del algoritmo MUSIC utilizado en este trabajo es 8, y es importante remarcar que este es un orden bajo e implica un menor tiempo de cálculo para obtener los resultados. El algoritmo MUSIC por sí mismo es incapaz de detectar las frecuencias relacionadas cuando se utiliza un bajo orden de 8, usando un orden superior de 18 y un previo filtrado el algoritmo se ha reportado que es capaz de detectar fallas simples o combinadas (Gao, 2005); pero esto implicaría un mayor tiempo de cálculo para obtener los resultados.

En la Figura 4.1 (a-h) considera los espectros del motor en estado sano y de las tres fallas individuales tratadas en este trabajo. Figura 4.1 (a-b) muestra el espectro del IMF para un motor sano. La Figura 4.1 (c) se muestra el espectro de la barra rota donde se identifica las bandas laterales que aparecen alrededor de la frecuencia fundamental. Estas bandas laterales se encuentran en 56 y 64 Hz respectivamente. La presencia de la frecuencia relacionada a BD de acuerdo con (2.41) se encuentra en 114 Hz, pero

debido al comportamiento empírico del método EMD, esta frecuencia no aparece en el espectro de frecuencia. Sin embargo, es posible identificar el segundo armónico esta frecuencia ($2x f_{BPOF}$) en 228 Hz; que aparece en el espectro de la primera IMF (Figura 4.1 (f).), donde se detecta claramente la identificación de fallo BD. El espectro para el fallo de UNB se presenta en la Figura 4.1 (g), y puede ser detectados por un aumento en la frecuencia fundamental en comparación con la condición del motor en buen estado. Figura 4.2 considera el espectro de la combinación de las tres fallas simples tratadas en este trabajo.

La combinación del UNB-BD es detectada por un aumento de la frecuencia fundamental en 60 Hz (UNB) en el espectáculo espectro IMF2 en la Figura 4.2 (a) en comparación con la frecuencia fundamental en 60 Hz para el caso sano (Figura 4.1 (a)) y el componente de 228 Hz de frecuencia (BRN) en el espectro IMF1 presentado en la Figura 4.2 (b). El caso de 1BB-UNB se ilustra en la Figura. 4.2 (c) cuando la banda lateral izquierda (1BB) es observable, apareciendo en 51 Hz y un aumento de la frecuencia fundamental (UNB) también es visto;

También en la Figura 4.2 (d), el espectro IMF1 muestra la presencia de la banda lateral izquierdo en el quinto armónico. En la Figura 4.2 (e) muestra el espectro de un motor con las fallas de 1BB- BD; que se detecta por la presencia de los componentes de frecuencia en 54 Hz y 66 que aparecen en el espectro de la IMF2 y el BD se detecta por la presencia de la componente de frecuencia 228 Hz en el espectro IMF1 (Figura. 4.2 (f)).

El espectro en el caso de las tres fallas combinadas 1BB-UNB-BD, se muestra en la Figura. 4.2 (g-h), particularmente en la Figura 4.2 (g) se encuentra la presencia de la banda lateral izquierda en 55 Hz así como el aumento de la amplitud de la frecuencia fundamental, y la Figura 4.2 (h) muestra la presencia de la componente de frecuencia en 228 Hz en el espectro IMF1.

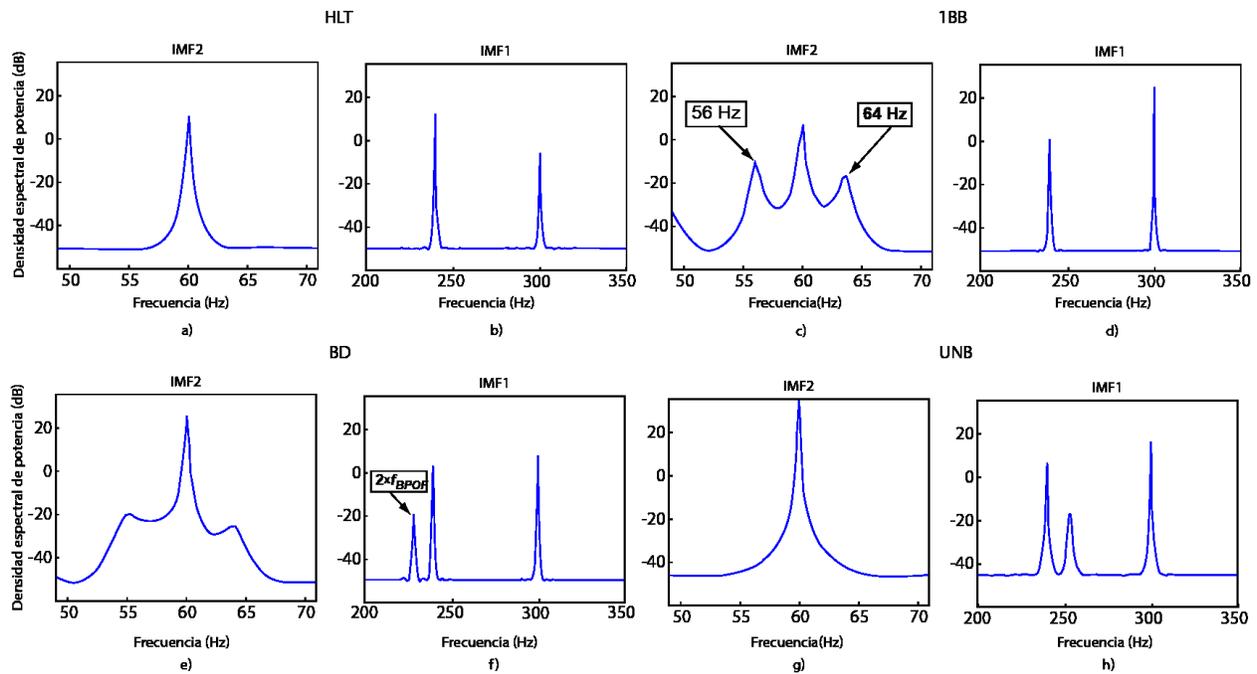


Figura 4.1 Espectros obtenidos del motor en estado sano y con fallas individuales a) IMF2 HLT, b) IMF1 HLT, c) IMF2 1BB, d) IMF1 1BB, e) IMF2 BD, f) IMF1 BD, g) IMF2 UNB, h) IMF1 UNB.

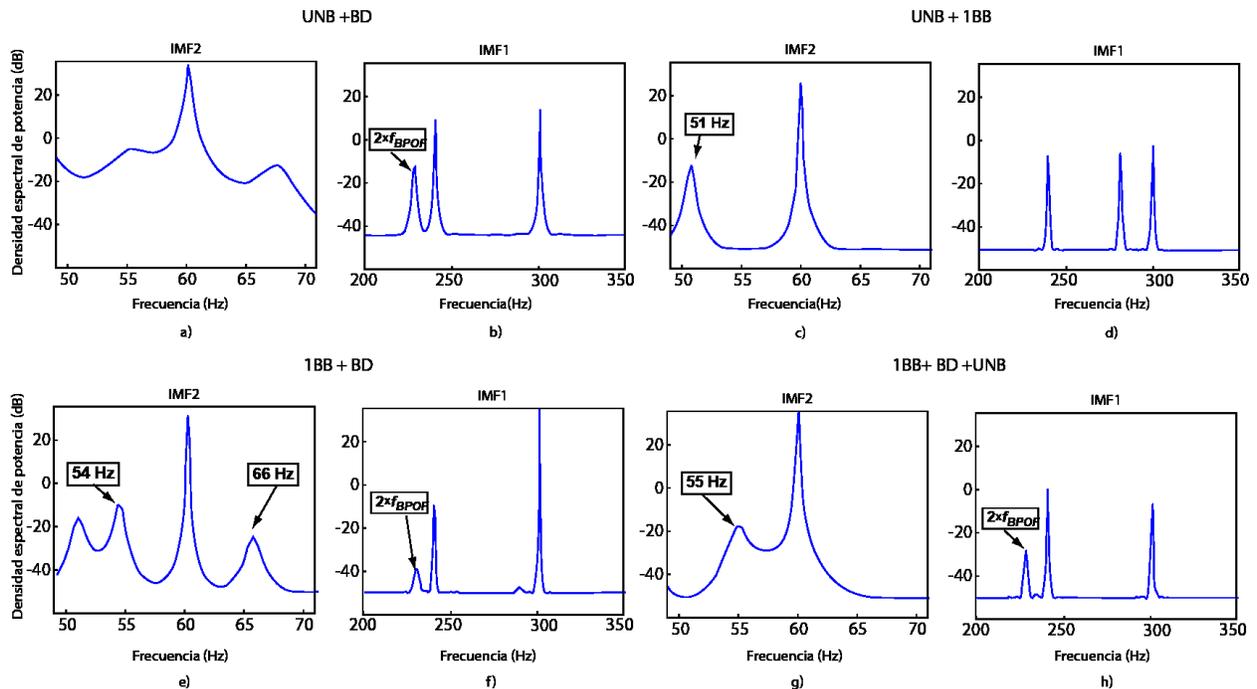


Figura 4.2 Espectros obtenidos por un análisis de diferentes combinaciones de fallas. a) IMF2 BD-UNB, b) IMF1 BD-UNB, c) IMF2 1BB-UNB, d) IMF1 1BB-UNB, e) IMF2 1BB-BD, f) IMF1 1BB-BD, g) IMF2 1BB-BD-UNB, h) IMF1 1BB-BD-UNB.

En la Tabla 5.1 se obtiene se muestra una comparación de la metodología propuesto (EMD-MUSIC) en decibelios en contra de la tradicional FFT y con la metodología propuesta en (García-Pérez *et al*, 2011) del algoritmo MUSIC con alto orden. La detectabilidad se calcula como la proporción de la amplitud (en decibelios) entre las condiciones defectuosas y saludables. Los valores de detectabilidad se obtienen de la Figura 4.1 y 4.2, y se calculan de la siguiente manera: con respecto a los casos con una barra rota;. el valor de pico de la banda lateral izquierda (D_f) se compara con el valor en decibelios de la frecuencia en el motor sano (D_h), para el caso de la frecuencia 1BB la banda lateral izquierda es de -2 dB y el valor de la amplitud en la condición saludable es de -50 dB; Por lo tanto, el valor de detectabilidad ($D_v = D_f - D_h$) es de 48 dB. El caso de la condición de falla BD se utiliza el valor de la amplitud de la frecuencia en 228 Hz. Para el caso de la falla de BD el valor del pico de la amplitud es de -22 dB en 228 Hz mientras que en la condición sana es de -50 dB, de modo el valor detectabilidad es 28 dB. Los casos en los que hay un error de UNB, se miden los incrementos de frecuencia fundamental, por lo tanto la detectabilidad se calcula comparando la amplitud del pico de frecuencia fundamental, de esta manera, el caso UNB muestra el valor del pico de frecuencia fundamental es de 35 dB y en la condición sana es 11 dB, por lo tanto, la detectabilidad es 24 dB.

Haciendo referencia a los casos de múltiples fallos combinados, en la comparación de las diferentes amplitudes de las frecuencias de errores relativos a, por ejemplo, para el caso de BD-UNB, la frecuencia fundamental se compara con una amplitud de 35 dB y la frecuencia de 228 Hz con una amplitud de -18 dB, con la amplitud respectiva en tales frecuencias en la condición sana, por lo tanto, los detectabilities calculados de ambos picos son 24 dB y 32 dB, por lo que se calcula la media, y la capacidad de detección resultante es 28 dB. Ahora, para el caso de 1BB-UNB el valor de amplitud de la frecuencia de banda lateral izquierdo es -11,5 dB y la amplitud de la frecuencia fundamental es de 29 dB, siguiendo el mismo proceso por encima de la detectabilidad es de 33,5 dB. En el caso 1BB-BD tiene un valor de -9 dB en la frecuencia de banda lateral izquierdo y en el pico de 228 H z la amplitud es de -30 dB, por lo que la detectabilidad es 30,5 dB. Por último, para el caso 1BB-BD-UNB las tres frecuencias a

se utilizan para calcular la detectabilidad, la amplitud del pico de frecuencia fundamental es de 35 dB, en la frecuencia de banda lateral izquierda es -15 dB y en el pico en 228 Hz es -28 dB, por lo tanto tiene una detectabilidad promedio de 27 dB.

El método FFT puede detectar algunas fallas individuales y combinadas. El algoritmo MUSIC con orden bajo muestra algunos valores con 0 dB de detectabilidad, lo cual representa que no puede detectar las fallas con esta técnica. Usando un orden superior el algoritmo MUSIC puede detectar todas las fallas individuales y combinadas, sin embargo, comparando contra la metodología EMD-MUSIC; la tecnología propuesta mejora los valores de detectabilidad para todos los casos y también disminuye la tiempo de cálculo para obtener los resultados. Por lo tanto, de acuerdo con los resultados obtenidos, el valor de la detectabilidad muestra un claro indicador para detectar fallas simples y combinadas.

Tabla 4.1 La detectabilidad en decibelios para el análisis de fallos combinados múltiples

Condición	FFT	MÚSICA		EMD-MUSIC Bajo-orden (8)
		Bajo-orden (8)	De alto orden (18)	
1BB	8	0	19	48
BD	0	0	21	28
UNB	18	19	20	24
BD-UNB	0	0	10	28
1BB-UNB	16	5	32	33.5
1BB-BD	7	0	15	30.5
1BB-BD-UNB	14	0	8	27

4.2 CASO DE ESTUDIO 2. IMPLEMENTACIÓN DEL ALGORITMO EMD EN FPGA PARA LA DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN.

El sistema basado en FPGA utiliza 18 bits en punto fijo, que generan errores de redondeo y truncamiento. Con el fin de evaluar el rendimiento general de la implementación FPGA desarrollada, los resultados de punto fijo se comparan contra los de punto flotante obtenidos en simulaciones en Matlab para los mismos conjuntos de datos adquiridos. La Tabla 4.2 presenta la media (μ), la desviación estándar (σ), y el pico (P) de errores relativos para comparar los resultados en punto fijo (FPGA) y en punto flotante (Matlab) de los 20 conjuntos de datos experimentales bajo cada condición de motor. Los peores valores se indican en negrita, siendo condición 1BB.

Tabla 4.2 Resultados de la ejecución basado en FPGA

Estado del motor de inducción	Error relativo (%)		
	La media (μ)	La desviación estándar (σ)	Error de pico (P)
HLT	0.4291	0.0743	0.5638
1BB	0.6146	0.0960	0.7902
2BB	0.1780	0.0564	0.3083
BD	0.4025	0.0803	0.5706
UNB	0.2091	0.0768	0.3518

La Tabla 4.3 muestra los resultados de la clasificación, así como el porcentaje de eficacia de la metodología propuesta. El conjunto de pruebas compuesta por 100 juicios reales, 20 para cada condición de motor de inducción, se clasifica de la siguiente manera: de las 20 pruebas con la condición HLT, el sistema clasifica en condición HLT las 20 prueba; por lo tanto, tiene una eficacia del 100%. Por otra parte, de la condición 1BB, el sistema clasifica una prueba como HLT, 18 como 1BB, y una como 2BB; por lo tanto, tiene una eficacia del 90%. Todas las clasificaciones correctas se localizan en la diagonal de la Tabla 5.3. En particular, la Figura 4.3 muestra los resultados de la implementación de hardware EMD para las condiciones HLT y 2BB.

La Tabla 4.4 resume los recursos de implementación en hardware de la metodología propuesta. Se presenta particularmente el número de ciclos de reloj usados por las principales módulos para llevar a cabo su cálculo se presenta también, donde es importante decir que el número de ciclos que se muestran para el módulo EMD es el promedio de las pruebas, ya que la duración de la EMD depende de la complejidad de la señal. La implementación se realizó en una FPGA Spartan 3E XCS1600 funcionando a 48 MHz.

Tabla 4.3 Porcentaje de eficacia de la metodología propuesta

	HLT	1BB	2BB	BRN	UNB	Eficacia (%)
HLT	20	0	0	0	0	100
1BB	1	18	1	0	0	90
2BB	0	0	20	0	0	100
BD	0	0	0	20	0	100
UNB	0	0	0	0	20	100

Tabla 4.4 Recursos usados de la FPGA

La utilización de recursos	EMD	ADALINE	FFNN	Total usado	Disponible	Edad Porcentaje
Lógico Programable	3, 731	3, 198	1, 582	8, 511	29, 504	28.85
STUI	11, 211	7, 437	4, 795	23, 443	29, 504	79.45
Multiplicadores	30	4	2	36	36	100
Ciclos de reloj	984, 564	84, 340	237	Total	1 '069, 141	

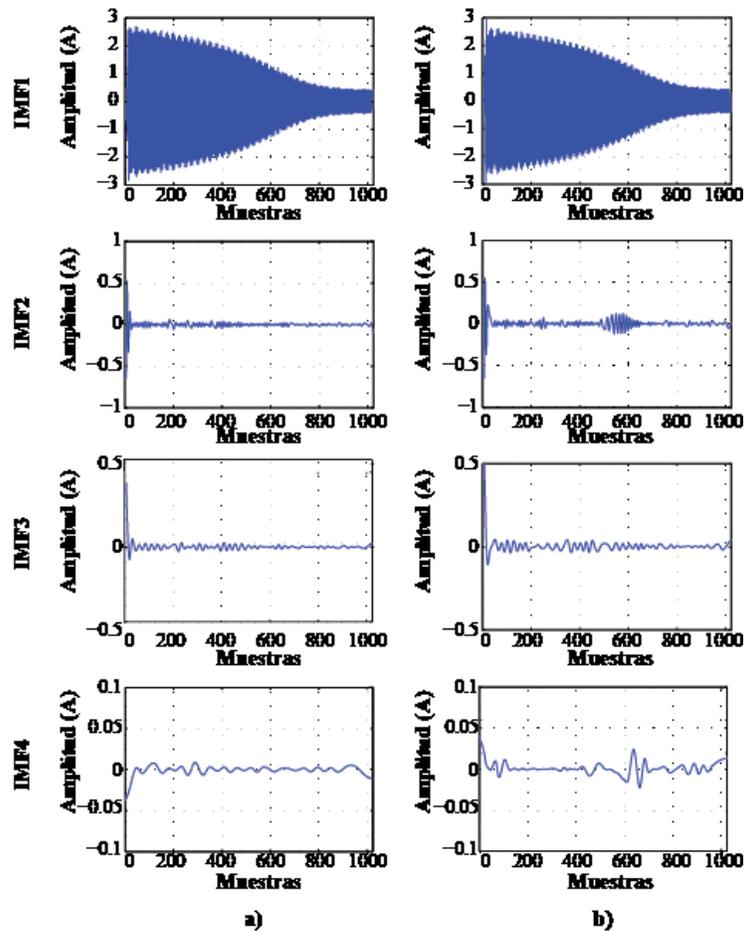


Figura 4.3 IMFs resultantes de la implementación de hardware EMD, a) del motor en buen estado, b) del motor defectuoso con dos barras del rotor rotas

El tiempo de cálculo de la implementación EMD se puede estimar por el número de ciclos de reloj necesarios para calcular un total de datos de entrada con N muestras. En este diseño para calcular, el algoritmo cúbico spline necesita que el conjunto de datos esté totalmente adquirido, y luego calcular la interpolación de estos datos. Esto necesita $2NT_m$ ciclos de reloj para calcular una IMF candidata, donde T_m es el número de ciclos de reloj necesarios para calcular cada muestra. El mínimo valor de T_m está determinado por dos operaciones de división consecutivas que consumen 56 ciclos de reloj, entonces para esta implementación, la estructura digital EMD puede trabajar a un máximo de 857 kHz de frecuencia de muestreo para un reloj maestro de 48 MHz. Este diseño utiliza un conjunto de datos de 1024 puntos que tendrían 114,688 ciclos de reloj para calcular una candidato IMF, o quiere decir 2.38 ms a 48 MHz. Huang *et al* (2003) menciona que

normalmente, se requiere de 3 a 4 interacciones para obtener una IMF, por lo que el peor de los casos para el cálculo de cuatro IMFs requerirá 16 interacciones que se lleva a 1'835,008 ciclos de reloj, o 38.22 ms a 48 MHz.

Los resultados muestran que la implementación de hardware de la metodología propuesta tiene 100% de efectividad en la detección de las condiciones de HLT, BD, UNB y 2BB. Para la condición 1BB, el porcentaje de una identificación correcta es 90%, dado que en dos resultados se equivoca con las condiciones HLT y 2BB.

Los valores bajos para la desviación estándar y el error de de los resultados presentados en la Tabla 4.4, muestran la viabilidad de la aplicación FPGA propuesta, teniendo en cuenta que los cálculos se realizan en punto fijo en la estructura digital. El uso de recursos presentado en la Tabla 4.4 muestra que es posible la implementación de complejos algoritmos en estructuras hardware (EMD, Adaline, y FFNN) así como su fusión en una solución SoC de bajo costo para el diagnóstico de motor de inducción. Además, la metodología propuesta basada en FPGA toma 1 '069, 141 ciclos de reloj, lo que equivale a 22,27 ms a 48 MHz, para la estimación de la condición del motor de inducción, lo cual es 38 veces más rápida que la aplicación Matlab que tiene 815,53 ms en un 2,2 GHz Intel Core i7 usando la metodología propuesta. Otra característica importante es que la estructura digital de EMD propuesta puede soportar velocidades de muestreo de hasta 857 kHz, lo que implica la posibilidad de nuevas implementaciones de hardware para aplicaciones en línea como el procesamiento de bio -señales, estimación de la calidad eléctrica, acústica y análisis sísmico, cuyas señales trabajar por debajo de esta tasa de muestreo.

Finalmente la Tabla 4.5 muestra una comparación de las características principales entre los trabajos reportados en la literatura y en la metodología propuesta. En cuanto a la implementación de hardware, la mayoría de los trabajos son realizados en computadoras, lo que puede comprometer la operación en línea, y sólo pocos trabajos presentan una solución en línea (García-Ramírez et al, 2012, Contreras-Medina et al, 2010); sin embargo, la propuesta es capaz de procesar señales estacionarias y transitorias a diferencia de los trabajos antes mencionadas, en condición de anuncios

que no necesita un diseño previo desde EMD es una técnica de adaptación y sin supervisión. Además, tiene la opción de enviar los datos para el post-procesamiento de un ordenador. Por otro lado, el número de fallos que puede ser detectada a través de la metodología propuesta es mayor que los otros que también utilizan la técnica de EMD.

Tabla 4.5 Principales características de los trabajos anteriores y de la obra propuesta.

Trabajo	Fallos	Metodología Residencia en	Requiere diseño A <i>priori</i>		Señal		Hardware	
			Sí	No	E	NE	PC	FPGA
Peng <i>et al</i> (2005)	Baleros	EMD		X	X	X		X
Niu y Yang (2003)	Barra rota	EMD		X	X	X		X
Gai (2006)	Excentricidades Rotor	EMD		X	X	X		X
García-Ramírez <i>et al</i> (2012)	Barra rota Desequilibrio desalineación	FFT	X			X		X
Metodología propuesta	Barra rota Baleros Desbalance	EMD		X	X	X		X

E: Estacionaria, NE: No estacionaria

4.3 CASO DE ESTUDIO 3. METODOLOGÍA BASADA EN EEMD-MUSIC PARA LA OBTENCIÓN DE LAS FRECUENCIAS NATURALES EN ESTRUCTURAS CIVILES

Para este caso de estudio como se mencionó en el capítulo tres consistió de tres experimentos para la validación de la metodología propuesta; señal sintética, excitación artificial a una estructura tipo truss y finalmente excitación ambiental a un puente. Los resultados se muestran a continuación.

4.3.1 Señal sintética

Las IMFs y DCs seleccionadas para el análisis mostradas en la Figura 3.24 son procesadas por la HT, la FFT, y el método MUSIC. Los resultados se muestran en la Figura 4.4. A partir de estas figuras, es posible observar que el método EEMD-HT (véase la Figura 4.4a) y el método DWT-HT (véase la Figura 4.4b) sólo detectan tres modos debido a: (i) la EEMD y DWT no pueden separar frecuencias cercanas y (ii) la HT sólo puede identificar una frecuencia por cada IMFo DC. Del mismo modo, la EEMD-FFT (Ver Figura 4.4c) y la DWT-FFT (Ver Figura 4.4d) no puede identificar cercanos modos debido a los componentes de frecuencia superpuestas y a la resolución de la FFT. Por otro lado, el EEMD-MUSIC (Ver Figura 4.4e) y la DWT-MUSIC (Ver Figura 4.4f) identificar claramente los cuatro modos naturales; Sin embargo, los resultados para las frecuencias naturales obtenidos por DWT-MUSIC se degradan en entornos ruidosos a diferencia del método EEMD-MUSIC. Todos los resultados mencionados anteriormente se presentan en una forma normalizada para una mejor presentación y comprensión

Por último, la Tabla 4.6 muestra la comparación numérica entre los valores de referencia de la señal sintética y los valores obtenidos a través de la EEMD-HT, la EEMD-FFT, la DWT-HT, la DWT-FFT, la DWT-MUSIC y el método EEMD-MUSIC propuesto. Como resultado de las capacidades de la EEMD-HT, la DWT-HT, la EEMD-FFT, y los métodos DWT-FFT; los modos naturales más cercanos de la señal sintética, f_1 y f_2 , se mezclan y, por lo tanto, se obtiene un único valor de ellos. Por otro lado, el método EEMD-MUSIC propuesto demostró ser capaz de extraer los cuatro modos naturales con mayor precisión que DWT-MUSIC ya que los resultados se ven afectados por el nivel de ruido

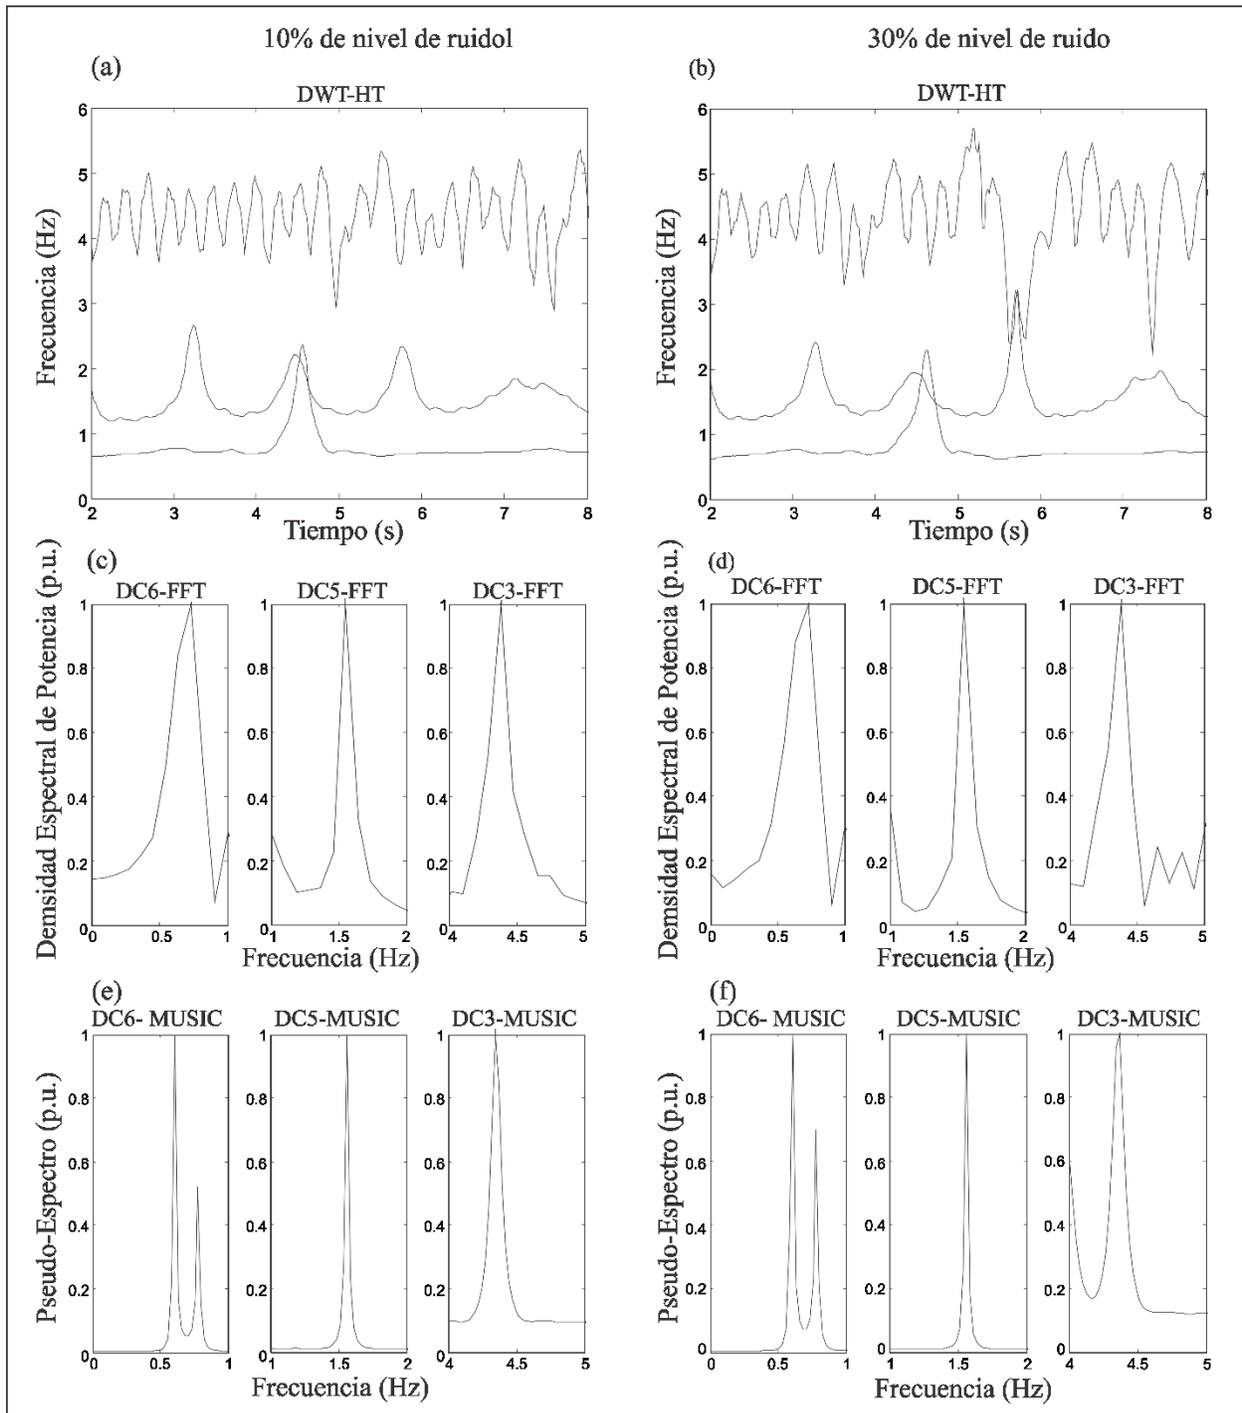


Figura 4.4 Resultados obtenidos por (a) EEMD-HT (b) DWT-HT, (c) EEMD-FFT, (d) DWT-FFT, (e) EEMD-MUSIC, y (f) DWT-MUSIC.

Tabla 4.6 Identificación de frecuencias naturales.

Valores de referencia	EEMD			DWT		
	HT	FFT	MUSIC	HT	FFT	MUSIC
$f_1 = 0,61$	0,72 *	0,68 *	0.61	0,70 *	0,72 *	0.61
$f_2 = 0,73$			0.73			0.78
$f_3 = 1,56$	1.54	1.52	1.56	1.31	1.55	1.56
$f_4 = 4,35$	4.38	4.30	4.34	4.41	4.38	4.37

4.3.2 .Excitación artificial

La Figura 4.5 muestra las primeras siete IMFs obtenidas de las señales de respuesta de vibración libres. La IMF₁ y la IMF₂ contienen ruido y componentes de alta frecuencia fuera del rango de frecuencias de interés. Por otro lado, a partir de IMF₃ a IMF₆ se utilizan para el análisis con el método MUSIC debido a que contienen las frecuencias naturales de la estructura de tipo truss. El resto de las IMFs se descartan ya que no contienen la información pertinente para su análisis. La Figura 4.6 muestra el pseudo-espectro normalizado obtenido a partir de las IMFs seleccionadas, donde cada una de las frecuencias naturales se observa. Los resultados obtenidos de la FEA, la metodología propuesta, y el método DWT-MUSIC se presentan en la Tabla 4.7. Cabe notar que sólo la DWT-MUSIC se utiliza como técnica comparativa ya que es la única que mostró mejor rendimiento para propósitos comparativos, como se comprobó en el caso de estudio anterior. La metodología propuesta identifica los valores de las frecuencias naturales muy cercanos a los encontrados de forma analítica por FEA. Evidentemente, las pequeñas diferencias pueden deberse a una serie de condiciones reales que no son considerados o completamente representados en el FEA. Por el contrario, el método DWT-MUSIC tiene un error más grande en la identificación de las frecuencias naturales debido a la verdadera ambiente ruidoso.

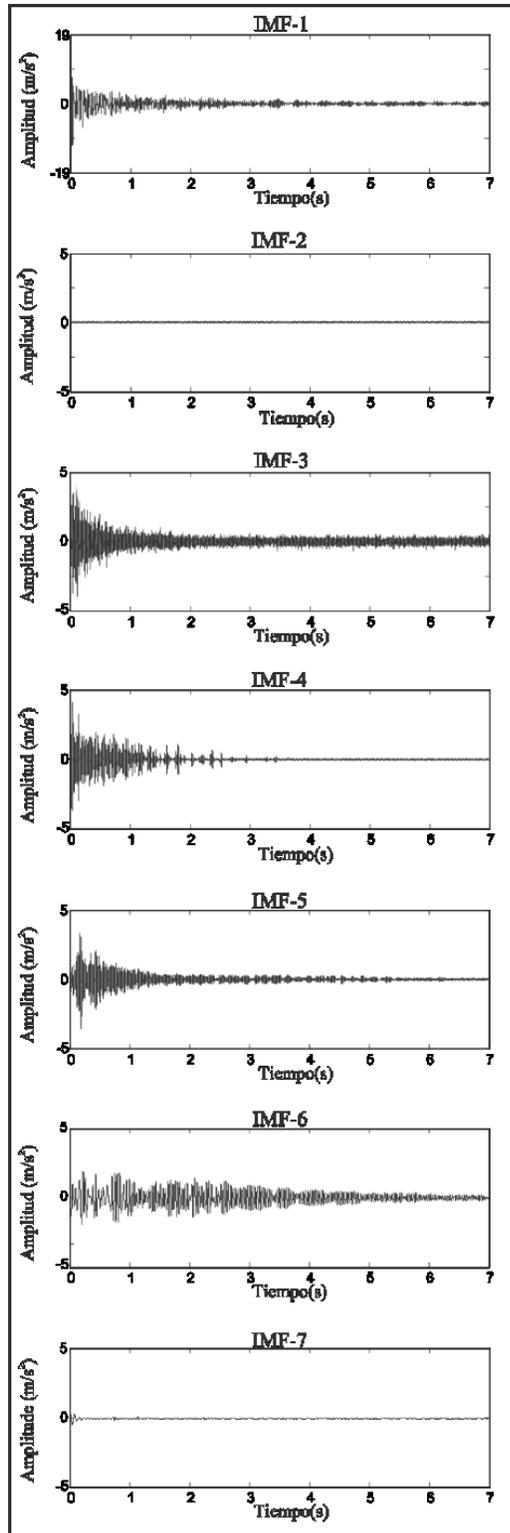


Figura 4.5 IMFs obtenidas mediante EEMD de la señal de aceleración vertical.

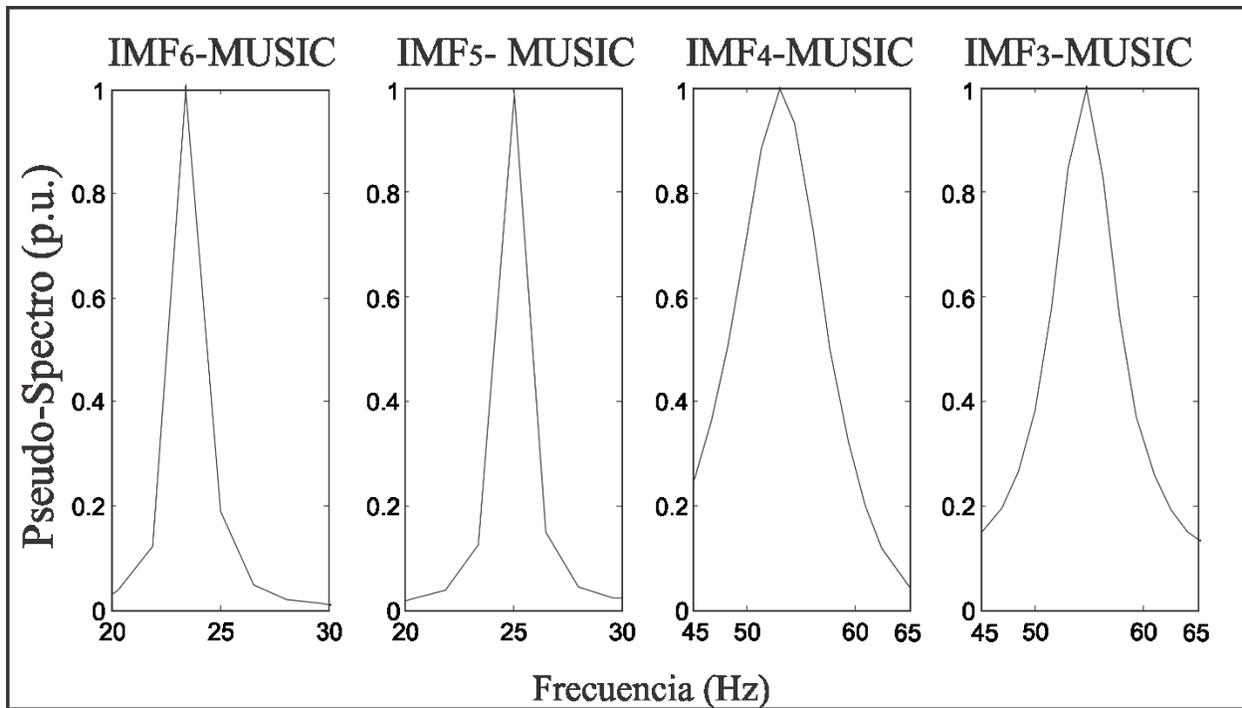


Figura 4.6 Pseudo-espectros de diferentes analizó IMF.

Tabla 4.7 Comparación de las frecuencias naturales obtenidas.

Modos	Análisis de elementos finitos	Metodología propuesta	DWT - MUSIC
Frecuencia Natural (Hz)			
1	24.48	23.44	21.88
2	25.50	25.00	26.56
3	52.57	51.56	50.00
4	54.65	54.69	53.13

Excitación Natural

Primeramente como se mencionó en la metodología se grafica la densidad espectral de potencia de la señal de aceleración vertical (Véase Figura 4.7a) obtenida a través de la FFT para conocer la región donde se encuentran las frecuencias naturales (Véase Figura 4.7b). Una vez que se establece la región de análisis, la señal filtrada se analiza a través del método EEMD, y los resultados se muestran en la Figura 4.8. Las IMF_3 a IMF_6 se seleccionan para obtener las frecuencias naturales ya que contiene el rango de frecuencia de interés el puente. La figura 4.9 muestra el pseudo-espectro normalizado de las IMFs seleccionadas, donde se observa cada una de las frecuencias naturales (2.539Hz, 5.313Hz, 9.814Hz, 14.55Hz). La Tabla 4.8 muestra los valores obtenidos de la metodología propuesta y por el método DWT-MUSIC. La metodología propuesta encuentra las tres frecuencias naturales estimadas por el método FFT (Figura 4.7b); además, encuentra otra frecuencia natural existente que no se identifica por la FFT (Véase Figura 4.9). Del mismo modo, el método DWT-MUSIC detecta las cuatro frecuencias naturales.; sin embargo, su precisión se espera inferior debido al ruido, ya que los datos de vibración ambiente están incrustado en el ruido de alto nivel.

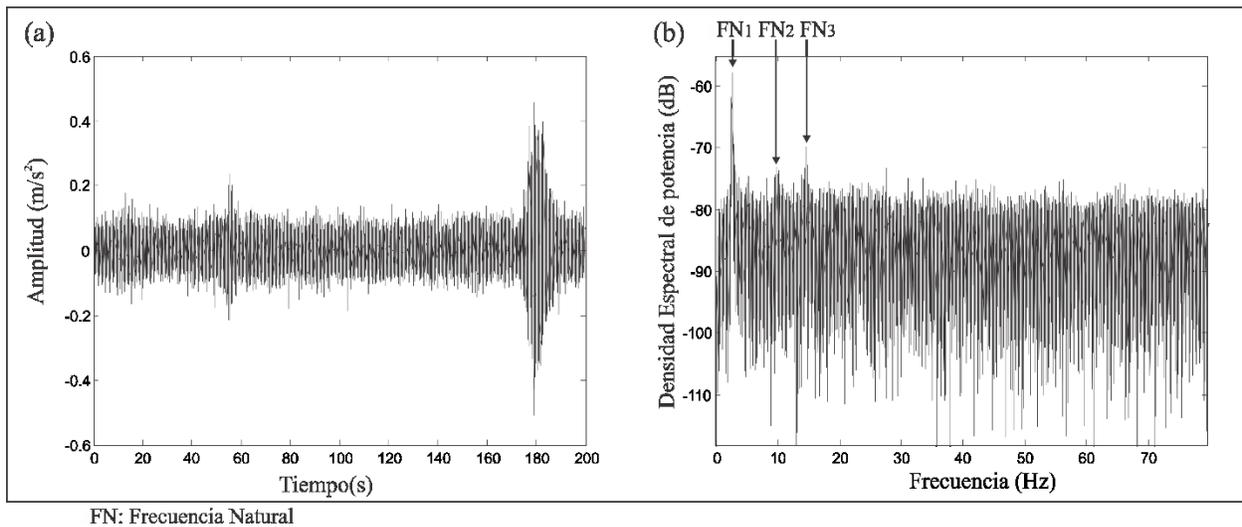


Figura 4.7 a) Medición de la aceleración vertical y b) su densidad espectral de potencia.

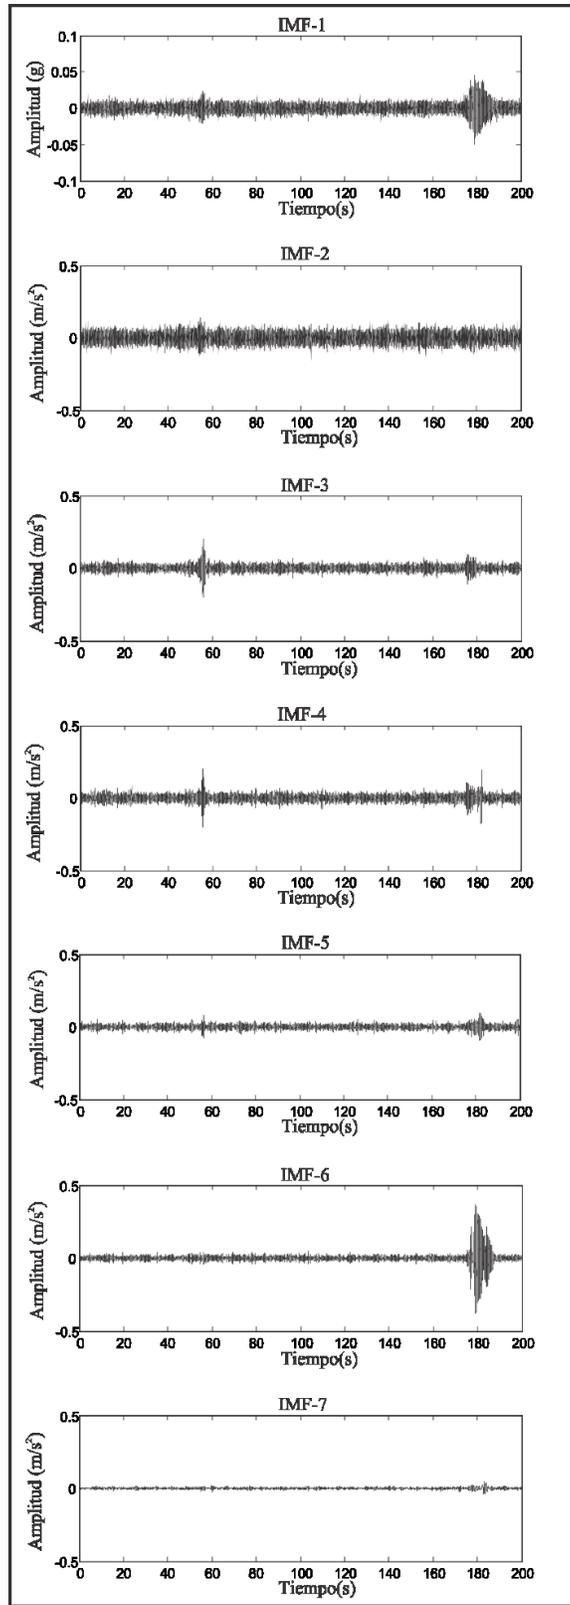


Figura 4.8 IMFs obtenidas a través de EEMD para la aceleración de vibración ambiental.

Tabla 4.8 Frecuencias naturales obtenidas.

Modos	Metodología	DWT-MUSIC
	propuesta	
Frecuencias Naturales (Hz)		
1	2,539	2.50
2	5,313	5.15
3	9,814	10.00
4	14.55	14.69

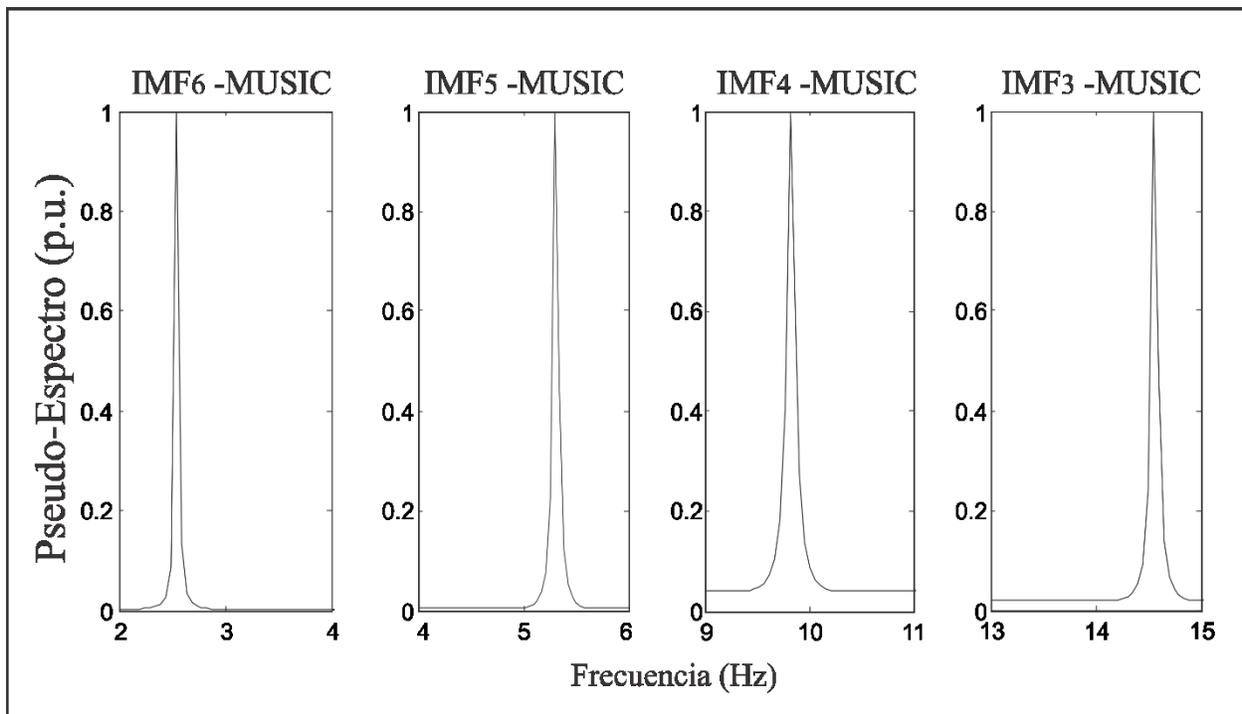


Figura 4.9 Pseudo- espectros de las IMFs analizadas

5. CONCLUSIONES

De la elaboración de esta tesis se obtuvo el desarrollo de nuevas metodologías así como un prototipo de sistema de monitoreo y análisis de motores de inducción, el cual permite analizar sus diferentes condiciones adecuándose a las necesidades que se tienen en la industria.

Referente al primer caso estudiado se obtuvo una nueva metodología para identificar múltiples fallas combinadas en motores de inducción a través de una combinación del método EMD y el algoritmo MUSIC. La combinación de estas técnicas permite resultados satisfactorios para la difícil tarea de identificar la condición de un motor a través del análisis de la densidad espectral de potencia de las IMFs obtenidas de la señal de corriente del estado de estable del motor de inducción. El método EMD proporciona una manera automática para descomponer la señal, y la combinación con un método de análisis espectral de alta resolución (algoritmo MUSIC) se obtiene una metodología adecuada para detectar fallas múltiples y combinadas en los motores de inducción. Los resultados muestran un alto acuerdo con la frecuencia de fallos analíticamente predeterminada para fallos individuales e incluso bajo el efecto de dos o tres fallos combinados.

En el segunda caso estudiado se presenta la estructura digital para implementar el método EMD en FPGA utilizando la interpolación spline cúbica. Esta nueva estructura para el cálculo de la EMD se combina con un estimador de frecuencia basado en ADALINE y un clasificador ANN en la misma FPGA para proporcionar una metodología inteligente para el diagnóstico de fallos múltiples en los motores de inducción. La aplicación global metodología en una FPGA permite un instrumento que opera en línea, gracias a sus capacidades de paralelismo y de alto rendimiento como una solución (SoC) system-on-a-chip, a diferencia de otras obras donde los resultados deben ser analizados posteriormente en una computadora fuera de línea.

Por otro lado, la alta precisión y uso mínimo de recursos de las estructuras digitales propuesto y desarrollado las hacen atractivas para muchas otras aplicaciones, destacando la nueva estructura digital de EMD utiliza la función spline cúbica completa

y no sólo es una aproximación lineal, esto evita la presencia de problemas de componentes de alta frecuencia, por lo que es más adecuado para el procesamiento en tiempo-frecuencia de señales no estacionarias en las aplicaciones industriales, por lo tanto la implementación EMD realizada es posible utilizarla para otras aplicaciones industriales

6. REFERENCIAS

Acharya R. Chua K. C., Chandran V., Lim C. M., (2007) Higher Order Spectral (HOS) Analysis Of Epileptic EEG Signals, International Conference of the IEEE on Engineering in Medicine and Biology.

Antonino-Daviu J. A., Riera-Guasp M., Pineda-Sanchez M., Pérez R. B. , (2009) A Critical Comparison Between DWT and Hilbert–Huang-Based Methods for the Diagnosis of Rotor Bar Failures in Induction Machines, IEEE Transactions On Industry Applications, Vol. 45, 1794-1806.

Arabaci H., Bilgin O. (2010) Automatic detection and classification of rotor cage faults in squirrel cage induction motor. Neural Computing Applications 19(5): 713-723.

Bhende, C. N.; Mishra, S.; Panigrahi, B. K.(2008) Detection and classification of power quality disturbances using S-transform and modular neural network. Electric. Power System Research. Vol 78, 122-128.

Baruch Vera A. E. (2013).Diagnóstico de Fallas en Motores Eléctricos de Inducción Trifásicos tipo jaula de ardilla usando Redes Neuronales Artificiales. (Tesis Licenciatura). Universidad Veracruzana.

Cabal-Yepez E., Valtierra-Rodriguez M., Romero-Troncoso R. J., Garcia-Perez A., Osornio-Rios R. A., Miranda-Vidales H., Alvarez-Salas R (2012) FPGA-based entropy neural processor for online detection of multiple combined faults on induction motors. Mechanical Systems and Signal Processing Vol. 30(1), 123-130.

Chen D, Wang W. J. (2002) Classification of wavelet map patterns using multilayer neural networks for gear fault detection. Mechanical System Signal Processing Vol 16(4): 695–704.

Chien-Chang L.; Shi-Huang C.; Trieu-Kien T.; Yukon C., (2005). Audio Classification and Categorization Based on Wavelets and Support Vector Machine, IEEE Transactions on Speech and Audio Processing, Vol. 13(5), 644-651.

Chua K., Chandran V., Acharya R. y Lim C. M., (2008), Automatic identification of epilepsy by HOS and power spectrum parameters using EEG signals: A comparative study, International Conference of the IEEE on Engineering in Medicine and Biology.

Contreras-Medina L. M., Romero-Troncoso R. J., Cabal-Yepez E., Rangel-Magdaleno J. J., Millan-Almaraz J. R. (2010) FPGA-based multiple-channel vibration analyser for industrial applications in induction motor failure detection. IEEE Transactions Instrument and Measurement Vol 59(1): 63-71.

Electric Power Research Institute. 2008. Descargado de <http://my.epri.com/portal/server.pt?open=512&objID=382&&PageID=225644&mode=2> (consulta hecha el 13 de febrero de 2015).

Espinosa A. G. , Rosero J. A. , Cusidó, J. , Romeral L.,Ortega, J. A., (2010) , Fault Detection by Means of Hilbert-Huang Transform of the Stator Current in a PMSM With Demagnetization, IEEE Transactions on Energy Conversion, Vol. 25(2), 312-318.

Erişti, H.; Demir, Y, (2012) "Automatic classification of power quality events and disturbances using wavelet transform and support vector machines," Generation, Transmission & Distribution, Vol.6 (10), 968-976.

Gai G. H., (2006) The processing of rotor startup signals based on empirical mode decomposition Mechanical System Signal Processing, Vol. 20 (1):222–235.

Gao Q., (2005) Detecting damage of rolling bearings using EMD, Key Engineering Materials, Damage Assessment of Structures, Vol. 293, 753-760.

Garcia-Espinosa A., Rosero J. A., Romeral L., Ortega J. A., (2010) Fault Detection by Means of Hilbert–Huang Transform of the Stator Current in a PMSM With Demagnetization, IEEE Transactions On Energy Conversion, Vol. 25, No. 2, 312-318

Garcia-Perez A., Romero-Troncoso R. J., Cabal-Yepez E., Osornio-Rios R. A., (2011) The Application of High-Resolution Spectral Analysis for Identifying Multiple Combined Faults in Induction Motors, IEEE Transactions On Industrial Electronics, Vol. 58, 2002-2010.

Garcia-Perez, A. ,Romero-Troncoso, R. J. ; Cabal-Yepez, E. ; Osornio-Rios, R.A. ; Rangel-Magdaleno, J. ;Miranda, H. (2011) Startup Current Analysis of Incipient Broken Rotor Bar in Induction Motors using High-Resolution Spectral Analysis IEEE Symposium on Diagnostics for Electric Machines, Power Electronics & Drives (SDEMPED), 657 - 663

Garcia-Ramirez A. G., Osornio-Rios R. A., Granados-Lieberman D., Garcia-Perez A., Romero-Troncoso R. J. (2012) Smart Sensor for Online Detection of Multiple-Combined Faults in VSD-Fed Induction Motors. Sensors, Vol, 12, 11989-12005.

Ghate V. N., Dudul S. V. (2010) Optimal MLP neural network classifier for fault detection of three phase induction motor. Expert Syst Appl 37(4): 3468-3481.

Hachemi-Benbouzid M. (2000) A review of induction motors signature analysis as a medium for faults detection. IEEE Transaction on Industrial Electronics, Vol. 47(5), 984-993.

Huang N. E., Wu M. C., Long S. R., Shen S. P., Qu W., Gloersen P., Fan K. L. (2003) A confidence limit for the empirical mode decomposition and Hilbert spectrum analysis. Proceedings of. Real Society of London at Mathematics and Physic Sciences, Vol. 459 (2037):, 2317–2345.

Huang N. E. , Zheng S., Steven R., Manli C., Wu L, Hsing H., Zheng Q., Yen N.C., Tung C. C. , Liu H. (1998) The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. Proceedings of. Real Society of London at Mathematics and Physic Sciences, Vol. 454 (1971), 2317–2345.

Kalvoda TA, Hwang Y, (2010) Analysis of signals for monitoring of nonlinear and non-stationary machining processes, Sensors and Actuators A: Physical, Vol. 161, 39-45.

Lau ECC; Ngan HW, (2010) Detection of Motor Bearing Outer Raceway Defect by Wavelet Packet Transformed Motor Current Signature Analysis," IEEE Transactions on Instrumentation and Measurement, Vol. 59(10), 2683-2690.

Lei R., He D., (2012) Rotational machine health monitoring and fault detection using EMD-based acoustic emission feature quantification, IEEE Transaction in Instrumentation and Measurement Vol.61 990–1001.

Lei Y (2011) Machinery fault diagnosis based on improved Hilbert-Huang transform, Journal of Mechanical Engineering, Vol. 47, 71-77.

Lei Y.G., He Z.J.& Zi Y.Y., (2009) Application of the EEMD method to rotor fault diagnosis of rotating machinery, Mechanical Systems and Signals Processings.Vol.23, 1327–1338.

Li, H., Zhang, Y.a & Zheng, H.b, (2009) Hilbert-Huang transform and marginal spectrum for detection and diagnosis of localized defects in roller bearings, Journal of Mechanical Science and Technology, Vol. 23, 291-301

Liu Z. & Zhang W., (2010) Operation mode identification for induction motors based on HHT method, Electric Power Automation Equipment, Vol. 30, 55-57.

Meher PK, Valls J, Juang TB, Sridharan K, Maharatna K (2009) 50 years of CORDIC: algorithms, architectures, and applications. IEEE Transaction on Circuit Systems. Vol. 56(9): 1893-1907.

Messina R. & Vijay-Vittal, (2010) Nonlinear, Non-Stationary Analysis of Interarea Oscillations via Hilbert Spectral Analysis, IEEE Transactions On Power Systems, Vol. 21, 1234 1241

MetAs & Metrológos Asociados. (2005). Manual de curso de balanceo Dinámico. Descargado de <http://www.immp.com.mx/PDF/BDI.pdf> (Consulta el 1 de Marzo del 2015)

Ming L, Xue-Kang G. & Shen-Shen Y.Hilbert-Huang Transform Based Time-Frequency Distribution and Comparisons with Other Three, International Journal Of Circuits, Mechanical Systems And Signal Processing, Vol. 1(2), 155-160

Morales-Velazquez L., Romero-Troncoso R.J., Osornio-Rios R.A., Herrera-Ruiz G. & Cabal-Yepez E., (2010) Open architecture system based on a reconFigurable hardware–

software multi-agent platform for CNC machines. *Journal of Systems Architecture*. Vol. 56(9). 407-418.

Motor Reliability Working Group, "Report of Large Reliability Survey of Industrial and Commercial Installations, Part I and II", *Transactions on Industrial Applications*, IEEE, Vol. IA-21, No. 4, July/August 1985

Niu F., Huang J., Yang J. (2003) Rotor broken-bar fault diagnosis of induction motor based on HHT of the startup electromagnetic torque. *Electric and Electronic Engineering of China*, Vol 1(2), 188-193.

Ordaz-Moreno A., Romero-Troncoso R. J., Vite-Frias J. A., Rivera-Gillen J. R. & Garcia-Perez A., (2008) Automatic Online Diagnosis Algorithm for Broken-Bar Detection on Induction Motors Base on Discrete Wavelet Transform for FPGA Implementation. *IEEE Transactions on industrial Electronics*. Vol.55 (5). 2193-2202.

Peng ZK, Tse PW, Chu FL (2005) A comparison study of improved Hilbert–Huang transform and wavelet transform: application to fault diagnosis for rolling bearing. *Mechanical Systems and Signal Processing* Vol. 19(5), 974–988.

Reincos S.A. de C.V. Descargado de: <http://paginas.seccionamarilla.com.mx/representaciones-industriales-reincos-sa-de-cv/mangueras-y-conexiones-hidraulicas/coahuila/torreon/-/-/baleros-y-filtros/>. Consulta hecha el 1 de marzo del 2015)

Ruqiang Y, Gao R. X., (2006) Hilbert–Huang Transform-Based Vibration Signal Analysis for Machine Health Monitoring, *IEEE Transactions On Instrumentation And Measurement*, Vol. 55, 2320-2329.

Shen Z. J., Chen X. F., Zhang X .L., et al. (2012) A novel intelligent gear fault diagnosis model based on EMD and multi-class TSVM ,*Measurement*. Vol. 45, 30–40.

Su H., Chong K. T., Kumar R. R. (2011) Vibration signal analysis for electrical fault detection of induction machine using neural networks. *Neural Comput Applicat* 20(2): 183-194.

Tong J. H., Chiu C. L., Wang C. Y.,(2010) Improved Synthetic Aperture Focusing Technique by Hilbert-Huang Transform for Imaging Defects Inside a Concrete Structure, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, Vol. 57, 2512-2521.

Valtierra-Rodriguez M. (2013) Arquitectura de procesador neuro-difuso para el desarrollo de instrumentos de la calidad de la energía. (Tesis de doctorado). Universidad Autónoma de Querétaro.

Valtierra-Rodriguez M., Osornio-Rios R. A. , Garcia-Perez A., Romero-Troncoso R. J. (2013) FPGA-based neural network harmonic estimation for continuous monitoring of the power line in industrial applications. *Electronic Power Systems*, Vol. 98: 51-57.

Vibratech. Descargado de: <http://www.vibratech.com.ve/texto/serviciosDiagnostico-vibraciones.html>. (Consulta hecha el 1 de marzo de 2015).

Wang C. , Lu, J. (2010) Fault diagnosis of diesel engine based on HHT marginal spectrum, *Journal of Vibration, Measurement and Diagnosis*, Vol. 30, 465-468.

Wang L., Vai M. I. , Mak P. & leong C. I. ,(2010) Hardware-accelerated Implementation of EMD Hardware and Software Co-design Evaluation for HHT, *International Conference on Biomedical Engineering*.

Wu Z. & Huang N., (2009) Ensemble empirical mode decomposition a noise assisted data analysis method, *Advances in Adaptive Data Analysis*. Vol. 1, 1–41.

Xiang L., Hu A. & Tang G., (2008) Non-stationary vibration signal analysis based on Hilbert-Huang transform, *Journal of Information and Computational Science*, Vol. 5, 41-47.

Xiang L., Zhu Y. L. & Tang G.-J., (2007) Application of Hilbert-Huang transform method in vibration faults diagnosis for rotor system, *Proceedings of the Chinese Society of Electrical Engineering*, Vol. 27, 84-89.

Xu K.-J., Qin, H.-Q. Jiang & L.-P., (2011) Rotor-case vibration signal analysis of an aero engine based on EMD and HHT, *Journal of Vibration and Shock*.

Yang, W.X., (2008) Interpretation of mechanical signals using an improved Hilbert-Huang transform, *Mechanical Systems and Signal Processing*, Vol. 22, 1061-1071.

Yeh J.R., Shieh J.S., (2010) Complementary Ensemble Empirical Mode Decomposition: a noise enhanced data analysis method, *Advances in Adaptive Data Analysis Vol 2 (2)* 135–156.

Zamanian, A. & Ohadi, Gear fault diagnosis based on Gaussian correlation of vibrations signals and wavelet coefficients, *Appl. Soft Comput.* 11 (2011) 4807–4819.

Zhang S.A, Yang Y., Han Q., Qu Y., (2010) Experimental study on a rotor system with rub-impact at fixed limiter based on HHT, Vol. 29, 121-125.

Zhang S., Yu D. & Sheng S., (2006) A Discrete STFT Processor for Real-time Spectrum Analysis. *IEEE Circuits and Systems. IEEE Asia Pacific Conference*. 1943-1946.

Zhang Y. P., Huang S., Hou J., Shen Tao & Liu W., (2006) Continuous wavelet grey moment approach for vibration analysis of rotating machinery. *Mechanical Systems and Signal Processing*, Elsevier. Vol.20. 1202-1220.

Zhang Y., Su N., Li Z., Gou Z., Chen Q. & Zhang Y., (2007) Assessment of Arterial Distension Based on Continuous Wave Doppler Ultrasound with an Improved Hilbert-Huang Processing, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, Vol. 57, 203-213

Zheng J., Cheng J, Yang Y. (2014) Partly ensemble empirical mode decomposition: An improved noise-assisted method for eliminating mode mixing. *Signal Processing*, Vol. 96 (1) 362–374