



**INSTITUTO POLITÉCNICO NACIONAL**  
**CENTRO DE INVESTIGACIÓN EN COMPUTACIÓN**



**Modelo computacional para el diagnóstico de fallas incipientes en un tren de engranes tipo aerogenerador**

## **TESIS**

Para obtener el grado de:

**MAESTRÍA EN CIENCIAS EN INGENIERÍA DE CÓMPUTO CON  
OPCIÓN EN SISTEMAS DIGITALES**

Presenta:


**Ing. Edgar Alan Valdés Iglesias**

Directores de tesis:

**Dr. Luis P. Sánchez Fernández**  
**Dr. José J. Carbajal Hernández**

México, D.F.

Diciembre de 2014



# INSTITUTO POLITÉCNICO NACIONAL SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

## ACTA DE REVISIÓN DE TESIS

En la Ciudad de México, D.F. siendo las 10:00 horas del día 12 del mes de mayo de 2014 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del:

**Centro de Investigación en Computación**

para examinar la tesis titulada:

**"Modelo computacional para el diagnóstico de fallas incipientes en un tren de engranes tipo aerogenerador"**


Presentada por el alumno:


<b>Valdés</b> Apellido paterno	<b>Iglesias</b> Apellido materno	<b>Edgar Alan</b> Nombre(s)							
		Con registro:	B	1	2	1	1	0	3

aspirante de: **MAESTRÍA EN CIENCIAS EN INGENIERÍA DE CÓMPUTO CON OPCIÓN EN SISTEMAS DIGITALES**

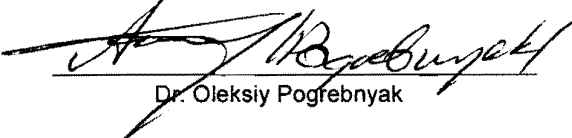
Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

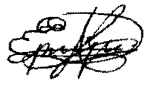
### LA COMISIÓN REVISORA Directores de Tesis

  
\_\_\_\_\_  
Dr. Luis Pastor Sánchez Fernández

  
\_\_\_\_\_  
Dr. José Juan Carbajal Hernández

  
\_\_\_\_\_  
Dr. Sergio Suárez Guerra


  
\_\_\_\_\_  
Dr. Oleksiy Pogrebnyak

  
\_\_\_\_\_  
M. en C. Pablo Manrique Ramírez

  
\_\_\_\_\_  
Dr. José Medel Juárez



PRESIDENTE DEL COLEGIO DE PROFESORES  
\_\_\_\_\_  
Dr. Luis Alfonso Villa Vargas  
INSTITUTO POLITÉCNICO NACIONAL  
CENTRO DE INVESTIGACION  
EN COMPUTACION  
DIRECCION



**INSTITUTO POLITÉCNICO NACIONAL**  
**SECRETARÍA DE INVESTIGACIÓN Y POSGRADO**

**CARTA CESIÓN DE DERECHOS**

En la Ciudad de México, Distrito Federal; el día 13 de Noviembre de 2014, el que suscribe **Edgar Alan Valdés Iglesias** alumno del Programa de **Maestría en Ciencias en Ingeniería de Cómputo con opción en sistemas digitales** con número de registro **B121103**, adscrito al **Centro de Investigación en Computación**, manifiesta que es autor intelectual del presente trabajo de Tesis bajo la dirección del Dr. Luis P. Sánchez Fernández y del Dr. José J. Carbajal Hernández y cede los derechos del trabajo intitulado “**Modelo computacional para el diagnóstico de fallas incipientes en un tren de engranes tipo aerogenerador**”, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección **edgar\_alan15@hotmail.com**. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

---

Edgar Alan Valdés Iglesias

# Agradecimientos

*A mis padres por darme la vida, una excelente formación contagiándome de todo su amor y entregándome la posibilidad de cumplir con este logro.*

*A mis hermanos por todas sus preocupaciones, alientos y alegrías estando conmigo siempre.*

*A todos mis amigos y a mí novia por todo su aliento dedicándome su tiempo, paciencia y comprensión.*

*Al Dr. Luis Pastor Sánchez Fernández y al Dr. José J. Carbajal Hernández por su apoyo en la realización de esta tesis.*

*Al Centro de Investigación en Computación, por darme la oportunidad de formar parte de su colectivo y brindarme todo lo necesario para mi desarrollo a lo largo de mi estadía.*

*Al Dr. Enrique Baeyens, al Dr. Lázaro Gorostiaga y al Dr. Anibal Reñones del centro tecnológico CARTIF por sus consejos y colaboración en el desarrollo del trabajo.*

*Al CONACYT y PIFI por el apoyo económico recibido.*

*A dios por brindarme la oportunidad de vivir cada día.*

# Resumen

En este trabajo se presenta un modelo computacional para la identificación de fallas en un tren de engranes con la configuración de un aerogenerador comercial. Las señales utilizadas para el desarrollo del modelo fueron tomadas de un banco de pruebas realizado por el centro tecnológico CARTIF, para medir las vibraciones se utilizaron cuatro acelerómetros piezoeléctricos y un módulo de adquisición de datos de National Instruments. Dos reductoras acopladas simulan al tren de engranes en la plataforma de pruebas, por lo tanto los acelerómetros fueron colocados de manera ortogonal en la etapa paralela y planetaria de las reductoras.

Las diferentes condiciones simuladas en el banco de pruebas fueron sin fallo, desbalance, desalineamiento y un fallo conjunto con los máximos valores de desbalance y desalineamiento.

Para la extracción de rasgos de las diferentes condiciones mecánicas, el modelo computacional cuenta con dos opciones de procesamiento, una mediante el uso de coeficientes de predicción lineal (LPC) mientras que la segunda opción hace uso de los coeficientes cepstrales.

Los análisis por medio de los coeficientes LPC y el cepstrum han sido utilizados para el diagnóstico de fallas incipientes de máquinas rotatorias. Sin embargo, actualmente no se han reportado trabajos de investigación que hagan uso de ellos para valores de velocidad y carga variables como los empleados. La principal motivación del trabajo se enfoca en el empleo de estos métodos para poder comprobar su efectividad ante este tipo de condiciones y poder disminuir el tiempo de procesamiento que tienen otros enfoques reportados en la literatura.

Haciendo uso de MATLAB<sup>®</sup> se realizó el procesamiento de señales con los diferentes métodos y las pruebas con los modelos neuronales, para posteriormente hacer una comparación de los diferentes métodos estudiados tanto en tiempo de procesamiento como en el porcentaje de clasificación de los diferentes modelos neuronales; un perceptrón multicapa y una red artificial de base radial para los LPC y el Cepstrum respectivamente.

Con el software de ambiente gráfico LabVIEW<sup>™</sup> se generaron instrumentos virtuales que permiten realizar la lectura de las señales de vibraciones de la base de datos utilizada, para emitir un diagnóstico de las condiciones actuales de la etapa del engranaje analizado.

# Abstract

This work presents a computational model for fault identification in a gearbox setup of a commercial wind turbine. The signals used for model development were taken from a test conducted by the technology center CARTIF, to measure vibrations four piezoelectric accelerometers and a data acquisition module from National Instruments were used. Two coupled reducers simulate the gearbox on the test platform, therefore the accelerometers were placed orthogonally in parallel and planetary stage of the reducers.

The different conditions simulated in the test-bed were without fault, unbalance, misalignment and a failure with the maximum values of unbalance and misalignment.

To extract features of different mechanical conditions, the computational model has two processing options, the first option is using linear prediction coefficients (LPC) and the second one makes use of the cepstral coefficients.

The analysis by LPC coefficients and the cepstrum have been used for the diagnosis of incipient failures in rotary machines. However, actually there have been no reported research that makes use of them for values of variable speed and load as the employed ones. The main motivation of this work focuses on the use of these methods in order to test their effectiveness in this type of conditions and to reduce the processing time which have other approaches reported in the literature.

Signal processing was performed using MATLAB<sup>®</sup> with different methods and tests of the neural models, for the posterior comparison of the different studied methods both in processing time and the percentage of classification of different neural models, a multilayer perceptron and radial basis artificial network for LPC and cepstrum, respectively.

With the graphical environment software LabVIEW<sup>™</sup>, virtual instruments that allow reading the vibration signals from the used database to diagnose the actual conditions of the analyzed gearbox were generated.

# Índice general

<b>Resumen</b>	<b>i</b>
<b>Abstract</b>	<b>ii</b>
<b>Índice general</b>	<b>iii</b>
<b>Índice de figuras</b>	<b>vii</b>
<b>Índice de tablas</b>	<b>x</b>
<b>Glosario</b>	<b>x</b>
<b>1 Introducción</b>	<b>1</b>
1.1 Antecedentes . . . . .	1
1.2 Problemas a resolver . . . . .	2
1.3 Justificación . . . . .	2
1.4 Hipótesis . . . . .	3
1.5 Objetivos . . . . .	4
1.5.1 Objetivo general . . . . .	4
1.5.2 Objetivos particulares . . . . .	4
1.6 Alcances del trabajo . . . . .	4
1.7 Contribuciones . . . . .	4
1.8 Método de investigación y desarrollo utilizado . . . . .	5
1.9 Estructura de la tesis . . . . .	5
<b>2 Estado del arte</b>	<b>7</b>
2.1 Energía eólica . . . . .	7
2.2 Aerogenerador . . . . .	9
2.2.1 Descripción de los componentes de un aerogenerador . . . . .	9
2.2.2 Diseño de aerogeneradores . . . . .	12

2.3	Mantenimiento predictivo . . . . .	13
2.3.1	Mantenimiento en aerogeneradores . . . . .	14
2.4	Maquinaria funcionando bajo condiciones de velocidad y carga variables . . . . .	17
2.4.1	Análisis en el dominio del tiempo . . . . .	17
2.4.2	Análisis en el dominio de la frecuencia . . . . .	19
2.4.3	Análisis en el dominio tiempo-frecuencia . . . . .	20
2.5	Modelos computacionales neuronales híbridos . . . . .	22
2.6	Conclusiones del capítulo . . . . .	23
<b>3</b>	<b>Marco teórico</b>	<b>24</b>
3.1	Medición . . . . .	24
3.1.1	Unidades de frecuencia . . . . .	24
3.1.2	Frecuencia de Nyquist . . . . .	25
3.2	Procesamiento digital de señales . . . . .	27
3.2.1	Transformada de Fourier . . . . .	28
3.2.2	Modelo auto regresivo (LPC) . . . . .	29
3.2.3	Cepstrum . . . . .	31
3.2.4	Redes neuronales artificiales . . . . .	33
3.3	WPT . . . . .	35
3.4	Interpolación de Hermite . . . . .	36
3.5	Filtros IIR . . . . .	37
3.6	Conclusiones del capítulo . . . . .	37
<b>4</b>	<b>Descripción del banco de pruebas</b>	<b>39</b>
4.1	Banco de pruebas . . . . .	39
4.1.1	Fallos simulados . . . . .	40
4.2	Sistema de control . . . . .	42
4.3	Sistema de medición . . . . .	44
4.3.1	Arquitectura del sistema de medición . . . . .	45
4.3.2	Adquisición de las vibraciones . . . . .	46



4.4	Medición de la velocidad del eje lento . . . . .	48
4.5	Conclusiones . . . . .	49
<b>5</b>	<b>Procesamiento y análisis de datos</b>	<b>51</b>
5.1	Análisis mediante la FFT . . . . .	51
5.2	Ventaneo . . . . .	53
5.3	Perfiles de velocidad y par . . . . .	54
5.4	LPC . . . . .	55
5.5	Cesptrum . . . . .	59
5.6	WPT . . . . .	62
5.6.1	Wavelet . . . . .	62
5.7	Conclusiones . . . . .	64
<b>6</b>	<b>Reconocimiento de patrones y redes neuronales artificiales</b>	<b>66</b>
6.1	Metodología del reconocimiento de patrones . . . . .	66
6.2	Extracción de patrones . . . . .	67
6.2.1	Patrones LPC . . . . .	67
6.2.2	Patrones Cepstrum . . . . .	68
6.2.3	Patrones WPT . . . . .	68
6.3	Redes neuronales artificiales utilizadas . . . . .	69
6.3.1	Arquitectura del MLP . . . . .	71
6.3.2	Arquitectura de la red de base radial . . . . .	73
6.4	Entrenamiento . . . . .	75
6.4.1	Búsqueda del orden apropiado del los LPC . . . . .	76
6.5	Conclusiones . . . . .	76
<b>7</b>	<b>Resultados y discusiones</b>	<b>78</b>
7.1	Desempeño en tiempo de procesamiento de las técnicas estudiadas . . . . .	80
7.2	Programación e integración del modelo computacional . . . . .	81
7.3	Experimentación con un modelo en paralelo . . . . .	82
7.4	Conclusiones . . . . .	83

<b>8 Conclusiones y trabajo futuro</b>	<b>85</b>
8.1 Conclusiones . . . . .	85
8.2 Trabajo futuro . . . . .	86
8.3 Trabajo enviado para arbitraje . . . . .	86
<b>Referencias</b>	<b>87</b>
<b>Anexos</b>	<b>92</b>
Anexo A . . . . .	92
Anexo B . . . . .	92
Anexo C . . . . .	94
Patrones obtenidos con LPC y Cepstrum . . . . .	94
Anexo D . . . . .	98

# Índice de figuras

Figura 2.1:	Crecimiento de la energía eólica en el mundo . . . . .	8
Figura 2.2:	Componentes básicos de un aerogenerador de eje horizontal . . . . .	10
Figura 2.3:	Porcentaje de fallos de los componentes básicos de un aerogenerador . . . . .	15
Figura 2.4:	Fallos de los componentes de un aerogenerador y su tiempo de reparación . . . . .	15
Figura 3.1:	Componentes básicos de un acelerómetro piezoeléctrico . . . . .	25
Figura 3.2:	Ejemplo de aliasing . . . . .	27
Figura 3.3:	Algoritmo para calcular los coeficientes cepstrales . . . . .	33
Figura 3.4:	Arbol binario de un WPT . . . . .	36
Figura 4.1:	Banco de pruebas . . . . .	40
Figura 4.2:	Desbalance y desalineamiento en el banco de pruebas . . . . .	42
Figura 4.3:	Diagrama del sistema de control . . . . .	43
Figura 4.4:	NI USB-6009 . . . . .	43
Figura 4.5:	Sistema de control . . . . .	44
Figura 4.6:	Sistema de medición . . . . .	45
Figura 4.7:	NI 9233 . . . . .	47
Figura 4.8:	Tacómetro con el uso del sensor fotoeléctrico OJ5058 . . . . .	49
Figura 4.9:	NI 9423 . . . . .	49
Figura 5.1:	FFT de una señal sin fallo mecánico . . . . .	52
Figura 5.2:	FFT de la señal decimada por 2 . . . . .	53
Figura 5.3:	Señal multiplicada por una ventana de Hanning . . . . .	54
Figura 5.4:	Perfil de velocidad y carga . . . . .	55
Figura 5.5:	Coeficientes para diferentes valores de velocidad y carga . . . . .	56
Figura 5.6:	Coeficientes LPC para los 500 patrones con desalineamiento . . . . .	57
Figura 5.7:	Respuesta en frecuencia para diferentes ordenes del modelo AR . . . . .	58
Figura 5.8:	Respuesta en frecuencia de los LPC para 80 % de carga y 1700 rpm . . . . .	58

Figura 5.9:	Etapas del algoritmo para calcular al Cepstrum . . . . .	59
Figura 5.10:	Cepstrales para diferentes valores de $N$ . . . . .	60
Figura 5.11:	Cepstrales velocidad constante - carga variable . . . . .	61
Figura 5.12:	Cepstrales carga constante - velocidad variable . . . . .	61
Figura 5.13:	Daubechies wavelet de orden 4 . . . . .	63
Figura 5.14:	Calculo de la desviación estándar de los coeficientes de un WPT . . . . .	64
Figura 6.1:	Estudio comparativo del modelo AR para las condiciones simuladas . . . . .	67
Figura 6.2:	Estudio comparativo del Cepstrum para las condiciones simuladas . . . . .	68
Figura 6.3:	Topología del perceptrón multicapa . . . . .	73
Figura 6.4:	Topología de la red neuronal de base radial . . . . .	75
Figura 6.5:	Errores de entrenamiento de las RNA's para cada método de procesamiento . . . . .	75
Figura 6.6:	Desempeño de entrenamiento al incrementar los coeficientes de los LPC . . . . .	76
Figura 7.1:	Desempeño de las RNA's . . . . .	78
Figura 7.2:	Matriz de confusión . . . . .	79
Figura 7.3:	Tiempo de procesamiento para el Cepstrum, LPC, WPT y PCHI . . . . .	80
Figura 7.4:	Interfaz del modelo computacional en LabVIEW . . . . .	81
Figura 7.5:	Diagrama a bloques de la Interfaz del modelo computacional . . . . .	82
Figura 7.6:	Módulo de decisión de 8 y 4 RNA's en paralelo . . . . .	83
Figura A.1:	Patrones LPC desbalance . . . . .	94
Figura A.2:	Patrones LPC desalineamiento . . . . .	94
Figura A.3:	Patrones LPC desbalance contra desalineamiento . . . . .	95
Figura A.4:	Patrones LPC desbalance + desalineamiento . . . . .	95
Figura A.5:	Patrones Cepstrum desbalance . . . . .	96
Figura A.6:	Patrones Cepstrum desalineamiento . . . . .	96
Figura A.7:	Patrones Cepstrum desbalance contral desalineamiento . . . . .	97
Figura A.8:	Patrones Cepstrum desbalance + desalineamiento . . . . .	97
Figura A.9:	Módulo de lectura de archivos . . . . .	98

Figura A.10: Diagrama a bloques módulo de lectura de archivos . . . . .	99
Figura A.11: Módulo de lectura procesamiento de señal . . . . .	100
Figura A.12: Diagrama a bloques módulo procesamiento de señal . . . . .	100
Figura A.13: Diagrama a bloques cálculo de coeficientes . . . . .	101
Figura A.14: Diagrama a bloques red neuronal en el programa principal . . . . .	101
Figura A.15: Propagación RNA . . . . .	102
Figura A.16: Diagrama a bloques propagación RNA . . . . .	102

# Índice de tablas

Tabla 2.1:	Técnicas de monitoreo y análisis en aerogeneradores . . . . .	16
Tabla 4.1:	Especificaciones de las reductoras . . . . .	41
Tabla 4.2:	Tipos de fallos . . . . .	41
Tabla 5.1:	Medidas estadísticas para diferentes valores de $N$ . . . . .	60
Tabla 6.1:	Desviación estándar promedio de las diferentes condiciones simuladas .	69
Tabla 6.2:	Número de patrones utilizados por las RNA's . . . . .	70
Tabla 6.3:	Comparación de las diferentes arquitecturas del MLP . . . . .	72
Tabla 6.4:	Resultados de entrenamiento de la RBF . . . . .	74
Tabla 7.1:	Errores RBF . . . . .	84
Tabla A.1:	Tarjetas de adquisición de datos . . . . .	93
Tabla A.2:	Sensores . . . . .	93

# Glosario

## **época**

Ciclo en el que se adquieren y procesan por completo los datos de entrada a una red neuronal durante su entrenamiento.

## **Acelerómetro**

Elemento transductor que se sujeta a la superficie que vibra y convierte el movimiento mecánico en una señal eléctrica equivalente.

## **ADC**

Conversor análogo digital.

## **BackPropagation**

Algoritmo de entrenamiento para redes neuronales multicapa. Utiliza una metodología de aprendizaje de gradiente descendiente para actualizar los pesos a través de la topología.

## **dB**

Es una unidad logarítmica utilizada en acústica para representar los niveles de presión sonora y otros indicadores.

## **DFT**

Discrete Fourier Transform – Transformada discreta de Fourier.

## **FFT**

Fast Fourier Transform – Transformada rápida de Fourier.

## **FT**

Fourier Transform – Transformada de Fourier.

## **Hz**

Unidad utilizada para medir la frecuencia.

## **IDFT**

Inverse Discrete Fourier Transform – Transformada inversa discreta de Fourier.

## **IEPE**

Sensor de circuito integrado piezoeléctrico.

**IFT**

Inverse Fourier Transform – Transformada inversa de Fourier.

**LabVIEW**

Laboratory Virtual Instrument Engineering Workbench.

**LPC**

Codificación predictiva lineal.

**MATLAB**

Matrix Laboratory.

**muestreo**

Operación de crear una secuencia de números o muestras, a partir de una señal analógica en la que cada valor equivale a la magnitud de la misma en un instante de tiempo.

**NASA**

National Aeronautics and Space Administration.

**RNA**

Red neuronal artificial.

**SI**

Sistema Internacional de Unidades.

**topología**

Estructura en la que las neuronas son conectadas en una red neuronal artificial.

**WPT**

-Wavelet Packet Transform- Transformada de un paquete wavelet.



# Capítulo 1

## Introducción

### 1.1 Antecedentes

Los sistemas rotatorios pueden verse inmersos en una variedad de aplicaciones desde sistemas muy sencillos hasta algunos de gran complejidad, los principales sistemas rotatorios que se pueden encontrar son: los generadores, los motores, los sistemas de transmisión y de engranaje.

Los sistemas de engranajes son mecanismos utilizados para transmitir potencia de un engranaje a otro, mediante una configuración de engranes es posible incrementar o reducir el valor de velocidad de un eje rotatorio. Los engranajes están formados en su forma básica por dos ruedas dentadas, de las cuales a la menor se le conoce como piñón y a la mayor corona.

En los aerogeneradores un sistema rotatorio de gran importancia es el tren de engranes o multiplicadora. Esta máquina se encarga de aumentar la velocidad del viento adquirida por las aspas, para posteriormente transmitir al generador la energía mecánica de alta velocidad obtenida, la cual es empleada para la producción de energía eléctrica.

La energía eólica en la actualidad se considera como una excelente fuente alternativa de energía, debido a que no genera contaminación y no daña al medio ambiente. Los parques eólicos se instalan en áreas abiertas donde existe una buena velocidad del viento, el cual produce la rotación de grandes aspas en los aerogeneradores y permite transformar este movimiento mecánico en electricidad con el uso de un generador eléctrico.

Aunque este tipo de energía solo produce aproximadamente el 1% de la energía eléctrica mundial, es la alternativa renovable más sólida y eficaz para dar respuesta a una creciente demanda energética, ante el previsible agotamiento de los recursos fósiles y el calentamiento global generado en gran parte por la quema de combustibles fósiles, los cuales producen la mayor cantidad de emisiones de CO<sub>2</sub> en el mundo [1].

Al estar los aerogeneradores trabajando bajo condiciones de carga variable producidas por los cambios en el flujo del viento, sus componentes sufren un desgaste considerable a lo largo de su vida útil. El tren de engranes de un aerogenerador es uno de los componentes más costosos y que reciben la mayor cantidad de desgaste producto de la carga variable producida por los cambios en la dirección e intensidad del aire.

El porcentaje de fallos del tren de engranes se encuentra entre los más bajos. No obstante, el tiempo que se necesita para poder hacer una reparación es de cinco a siete días, ocupando

en tiempo perdido el segundo lugar entre los componentes principales de un aerogenerador, motivo por el cual en años recientes se están realizando investigaciones para poder diagnosticar fallas incipientes en esta maquinaria [2, 3].

El mantenimiento predictivo es una herramienta empleada para poder identificar un estado incipiente de fallo, este tipo de mantenimiento es utilizado en aerogeneradores en la actualidad para tratar de reducir los costos generados por fallos inesperados. Existen muchos métodos y procedimientos para el mantenimiento predictivo, de los cuales destacan el análisis de vibraciones como uno de los más utilizados por la cantidad de información que produce con respecto al estado de una máquina rotatoria.

El análisis de vibraciones ha sido un tema muy estudiado e implementado en máquinas rotatorias durante los últimos años y actualmente es aceptado como una de las mejores herramientas para el mantenimiento predictivo y el monitoreo de condiciones de operación en los sistemas [4]. El propósito principal de la medición y análisis de las vibraciones mecánicas, es el control y prevención de daños para poder disminuir los fallos inesperados, los posibles accidentes generados por el desconocimiento del estado actual de las máquinas y los costos generados por reparaciones.

## 1.2 Problemas a resolver

- No existe suficiente información sobre los sistemas de monitoreo en el tren de engranes en aerogeneradores.
- Es complicado obtener mediciones de fallos en un aerogenerador en funcionamiento, por el tiempo necesario para que se produzcan y el difícil acceso a los mismos.
- Pocos trabajos en la literatura emplean perfiles de velocidad y carga variable.
- La mayoría de los trabajos de investigación realizan perfiles de los principales valores de velocidad y carga, sin considerar los efectos que existen en las vibraciones mecánicas para todos los rangos posibles.
- Reducir el tiempo de procesamiento que presentan métodos reportados en la literatura, lo cual es relevante si la arquitectura del sistema de reconocimiento de patrones utiliza procesamientos en paralelo o en serie.

## 1.3 Justificación

Para poder obtener rasgos característicos de las vibraciones de un tren de engranes es necesario considerar los efectos que tienen la velocidad y la carga variable en la maquinaria rotatoria.

Muchos métodos de procesamiento de señales han caracterizado eficientemente las vibraciones mecánicas de máquinas que trabajan bajo estas condiciones. No obstante, la necesidad de remuestrear la señal, la complejidad de algunos métodos, el poco trabajo que existe en la literatura con este tipo de perfiles y el tiempo de procesamiento que requieren algunas de las metodologías reportadas en la literatura. Generan la posibilidad de explorar distintos métodos que puedan encontrar rasgos de las vibraciones en un menor tiempo y con resultados de clasificación que puedan igualar o superar a las metodologías reportadas.

El uso de técnicas de procesamiento de señales como son los modelos auto regresivos y el Cepstrum para obtener rasgos de vibraciones mecánicas han demostrado tener buenos resultados en trabajos de investigación previos [5, 6, 7]. No obstante, no se han utilizado en perfiles de velocidad y carga variable como el utilizado en el trabajo de investigación.

Debido al incremento de la complejidad que presenta la multiplicadora de un aerogenerador, ha surgido la necesidad de utilizar herramientas de diagnóstico no convencionales para poder realizar una clasificación efectiva de fallos incipientes o estados de deterioro en sus engranes. Los modelos computacionales son uno de los métodos no convencionales más utilizados por su capacidad de trabajar con problemas que tienen soluciones no lineales; como ejemplos de ellos se encuentran las redes neuronales y la lógica difusa [8], las cuales han tenido muy buenos resultados en la clasificación de este tipo de problemas.

El análisis de las vibraciones y el procesamiento de señales se realiza con el uso de MATLAB, por ser un programa que cuenta con un entorno poderoso para el cálculo numérico, la visualización y la programación. Entre otras de las funcionalidades es posible analizar datos y desarrollar algoritmos utilizando las herramientas y las funciones matemáticas incorporadas.

El modelo computacional propuesto se desarrolla principalmente en la plataforma y entorno de desarrollo LabVIEW, el cual trabaja con programación visual gráfica, siendo un programa enfocado hacia la instrumentación virtual que además permite una fácil integración con tarjetas de adquisición de datos, técnicas de procesamiento de señales y puede trabajar simultáneamente con MATLAB.

### 1.4 Hipótesis

Es posible desarrollar un modelo computacional para identificar las diferentes condiciones mecánicas simuladas en el engranaje paralelo de un banco de pruebas con la configuración de un aerogenerador comercial. Con resultados que igualan a los reportados en la literatura, empleando a diferencia de trabajos previos condiciones de funcionamiento similares a las presentes en un aerogenerador real y comparando el tiempo de procesamiento con respecto a la desviación estándar de los coeficientes de un paquete wavelet.

## 1.5 Objetivos

### 1.5.1 Objetivo general

Desarrollar un modelo computacional para la identificación de fallos del engranaje paralelo de un banco de pruebas con la configuración de un aerogenerador comercial.

### 1.5.2 Objetivos particulares

1. Conocer las características del banco de pruebas, así como los sistemas de medición y control utilizados.
2. Obtener un perfil de señales de vibraciones con velocidad y carga variables.
3. Realizar el análisis de vibraciones.
4. Obtener los rasgos de las condiciones mecánicas, utilizando técnicas de procesamiento de señales como son los LPC y el Cepstrum.
5. Comparar el procesamiento de señales empleado contra un método de la literatura que utiliza la desviación estándar de los coeficientes de un paquete wavelet.
6. Identificar los estados de fallo mediante el uso de un modelo neuronal.

## 1.6 Alcances del trabajo

En esta investigación el modelo computacional desarrollado incluye las siguientes características:

- Realiza el análisis en el engranaje paralelo, debido a que en esta etapa del banco de pruebas, las vibraciones que se presentan son de mayor intensidad que en la etapa planetaria.
- Utiliza solo un banco de pruebas para la detección de fallos.
- Analiza fallos en las reductoras del banco de pruebas que no consideran defectos en sus engranes.

## 1.7 Contribuciones

Con base en las características del procesamiento, los métodos de clasificación empleados y la tecnología actual para el diseño de instrumentación virtual, las contribuciones obtenidas en

el trabajo de investigación son las siguientes:

- Un modelo computacional para la clasificación de fallas incipientes del engranaje paralelo de un banco de pruebas con la configuración de un aerogenerador comercial, con resultados que mejoran a los reportados en la literatura en cuanto a tiempo de procesamiento; lo que ofrece la posibilidad de aplicar la metodología a un de reconocimiento de patrones con varias redes neuronales, en una estructura híbrida (serie paralela) ampliando el campo de aplicación a otro tipo de configuraciones de banco de engranes.

## 1.8 Método de investigación y desarrollo utilizado

La metodología utilizada para solucionar la problemática de la investigación consiste en:

- Documentación del análisis de vibraciones en un tren de engranes que opera bajo condiciones de velocidad y carga variable
- Conocer los sistemas de medición y de control utilizados en el banco de pruebas.
- Generar un perfil de datos con todas las condiciones de par y velocidad a partir de una base de datos que se realizó en un trabajo previo en el banco de pruebas, el cual evaluó la calidad de las mediciones bajo las condiciones en la que la simulación fue desarrollada.
- Utilizar métodos de procesamiento digital de señales para el análisis de vibraciones.
- Obtener rasgos característicos de las distintas condiciones mecánicas simuladas en el modelo físico mediante el uso del Cepstrum, los LPC y la desviación estándar de los coeficientes de un paquete wavelet.
- Diagnosticar las condiciones mecánicas simuladas mediante redes neuronales artificiales con la mejor arquitectura posible.
- Evaluar los resultados de las fases anteriores y desarrollar un instrumento virtual que realice el procesamiento y clasificación de las diferentes condiciones mecánicas.

## 1.9 Estructura de la tesis

La tesis se encuentra conformada por los siguientes capítulos:

**Capítulo 1. Introducción.-** Se especifican objetivos y se propone la hipótesis que orientará el desarrollo de este trabajo, las aportaciones realizadas al término del mismo y el alcance que tendrá el proyecto.

**Capítulo 2. Estado del Arte.-** Se revisa el estado actual del conocimiento de las técnicas usadas hasta el momento para el análisis de vibraciones y la identificación de fallos en maquinaria que opera bajo carga y velocidad variables.

**Capítulo 3. Marco teórico.-** Se se presentan los fundamentos teóricos para el procesamiento de señales y el reconocimiento de patrones.

**Capítulo 4. Descripción del banco de pruebas.-** Se describe al banco de pruebas utilizado en el trabajo, el sistema de control para generar los perfiles de velocidad y carga variable y el sistema de adquisición de las vibraciones mecánicas.

**Capítulo 5. Procesamiento y análisis de datos.-** Se describe el análisis realizado por medio de un modelo auto regresivo y el Cepstrum para la obtención de los rasgos de las distintas condiciones mecánicas del sistema. De igual forma se explica un método de la literatura que hace uso de la desviación estándar de los coeficientes de un paquete wavelet, el cual sirve para comparar el desempeño de los métodos utilizados en el trabajo.

**Capítulo 6. Reconocimiento de patrones y red neuronal artificial.-** Se indica la forma en que se obtienen los patrones de las distintas condiciones mecánicas con las técnicas de procesamiento de señales y los modelos neuronales estudiados.

**Capítulo 7. Resultados y discusiones.-** Se analizan los resultados obtenidos y se realiza una comparación con los trabajos reportados en la literatura .

# Capítulo 2

## Estado del arte

En este capítulo se realiza un estudio de las principales fuentes bibliográficas relacionadas con la identificación de fallas incipientes en maquinaria rotatoria con características de operación y diseño como el tren de engranes de un aerogenerador. De igual forma se incluye una descripción general de los conceptos básicos de un aerogenerador y las principales técnicas utilizadas en el mantenimiento predictivo.

### 2.1 Energía eólica

En la actualidad debido a los problemas de contaminación y la crisis que ha ocurrido con el petróleo, se ha visto en la necesidad de disminuir la dependencia que se tiene de los recursos no renovables; estas medidas han estimulado el estudio de fuentes de energía alternativas como la energía eólica [9]. Instituciones privadas y agencias gubernamentales como la NASA en Estados Unidos, dedican parte de sus recursos al desarrollo de grandes aerogeneradores, así como al mejoramiento de las tecnologías empleadas en su fabricación para aumentar la potencia que pueden proveer. Asimismo se han desarrollado mapas eólicos en las regiones que son óptimas para la instalación de parques eólicos y con ello cuantificar el potencial eólico disponible para suministrar la energía generada a una red eléctrica [10, 11].

En años recientes, el uso de energía eólica ha aumentado en países de la unión europea como son Alemania, Dinamarca, España, Inglaterra y Holanda, en gran medida por los incentivos establecidos para este tipo de energía y también por el desarrollo en la tecnología de fabricación de los componentes del aerogenerador. Entre los países líderes en la producción eólica en el mundo se encuentran Estados Unidos, Alemania y España, siendo España el país que mayor cantidad de energía eólica genera en Europa anualmente.

De acuerdo con la asociación mundial de energía eólica, la capacidad global de instalación de aerogeneradores aumentó un 23 % entre los años de 2007 al 2011. Un ejemplo del crecimiento de la capacidad de potencia es el de tiene Estados Unidos (60,000 MW) que se encuentra como el país con mayor capacidad mundial con 282,275 MW [12, 13]. La figura 2.1 muestra el crecimiento de la energía eólica mundial en los últimos años.

En México actualmente la capacidad instalada de energía eólica es de aproximadamente 1000 MW y 1500 MW que se encuentran en proceso de construcción o por iniciar obra. Para el consumo anual de energía en el país superior a los 230,000 GW el nivel de aportación al




Figura 2.1: Crecimiento de la energía eólica en el mundo

suministro eléctrico es mínimo y además comparado con los países líderes, es una producción muy pequeña [14].

En el territorio mexicano la región de Oaxaca presenta localizaciones con gran potencial para el desarrollo del recurso eólico, contando también con regiones del país con alto potencial como son los estados del norte, San Luis Potosí y Chiapas [15]. Por estas razones el gobierno ha aumentado el interés en la inversión y expansión de la energía eólica en el país, con el objetivo de aminorar costos de la energía eléctrica y también disminuir la cantidad de emisiones de CO<sub>2</sub> del país.

En resumen, las ventajas y desventajas de la energía eólica son las siguientes:

### Ventajas

- Fuente de energía segura y renovable que ahorra el uso de combustibles fósiles y diversifica el suministro energético.
- La instalación de un aerogenerador es fácil de desmontar y recuperar rápidamente la zona natural utilizada.
- El tiempo de construcción de un aerogenerador es rápido.
- Beneficio económico para los municipios con parques eólicos.
- Instalaciones amigables con otros usos del suelo.
- Limita la emisión de gases contaminantes a la atmósfera y no genera residuos líquidos o sólidos.
- No utiliza agua.

### Desventajas



- Incapacidad de asegurar un suministro de energía regular o permanente debido a la gran variabilidad y fluctuación tanto en la velocidad como en la dirección del viento.
- Impacto visual por el cambio en el paisaje producido.
- Impacto sobre la fauna y la flora (migración y nidificación).
- Impacto sonoro por la generación de un ruido constante de baja frecuencia y un nivel de intensidad pequeño.
- Puede producir interferencia electromagnética.

Por las ventajas mencionadas anteriormente, la energía eólica recibe un alto nivel de aceptación social, únicamente cuestionado en la población por el ruido generado por los aerogeneradores, por la intrusión en el paisaje y la interferencia electromagnética generada, no obstante eso no ha disminuido la cantidad de parques eólicos instalados [16, 17].

## 2.2 Aerogenerador

Un aerogenerador o generador eólico es una máquina capaz de extraer la energía cinética del viento y transformarla en energía mecánica, la energía mecánica se puede utilizar para el accionamiento de un generador eléctrico y también se puede dar uso de la energía generada directamente para el accionamiento de una máquina. La generación de energía eléctrica es el uso de la energía eólica más importante hoy en día.

Los aerogeneradores pueden ser construidos con una configuración del eje vertical u horizontal, siendo los diseños con el eje horizontal los que cuentan con un mayor dominio de aplicación en el mercado. Entre las ventajas principales que ofrece esta configuración destacan un buen aprovechamiento de las corrientes de aire por estar instalados a una altura promedio de entre 40 y 60 metros del suelo, la capacidad de adaptarse a diferentes potencias y una eficacia muy alta. Los aerogeneradores de eje horizontal han sido los que se han impuesto principalmente por la eficiencia que otorgan, contando con el mayor esfuerzo de investigación y desarrollo en los últimos años [18]. Entre la capacidad de generación eléctrica ofrecida por estos aerogeneradores se encuentra en un rango de menos de 1 kW hasta potencias de varios mega watts [19, 20].

Para el presente trabajo se emplea una configuración con el eje horizontal en el banco de pruebas, la figura 2.2 muestra los principales componentes de un aerogenerador de eje horizontal.

### 2.2.1 Descripción de los componentes de un aerogenerador

La función de los principales subsistemas que conforman al aerogenerador es la siguiente [21, 22]:




Figura 2.2: Componentes básicos de un aerogenerador de eje horizontal

## Rotor

El rotor es el componente primordial del aerogenerador, consiste en una serie de aspas que se encuentran unidas al eje del rotor, su función es convertir la energía cinética del viento en energía mecánica de rotación. Es por ello que a manera que aumenta el diámetro del rotor, incrementa la cantidad de energía que el rotor puede extraer del viento.

## Aspas

Las aspas son el elemento del aerogenerador que capturan la energía del viento y transmiten la potencia hacia el eje del rotor al que se encuentran unidas. Las aspas utilizan el principio aerodinámico conocido como “*lift*”, el principio se basa en que por debajo de las aspas las corrientes de aire producen una sobre presión y sobre ellas el flujo de corriente produce vacío, esta interacción de fuerzas son las que producen que el rotor gire. Actualmente la mayoría de los rotores tienen tres aspas, un eje horizontal, y un diámetro promedio de entre 40 y 90 metros.

## Eje

Es el elemento de unión entre las aspas y el sistema de rotación, ya que esta está acoplado al eje de baja velocidad del aerogenerador.

## Eje de baja velocidad

El eje de baja velocidad es el encargado de conectar al rotor con el tren de engranes y transmitir la energía capturada por las aspas.

## Multiplicadora

Por la velocidad de rotación baja a la que gira el rotor se necesita de una multiplicadora, para aumentar la velocidad a la que gira el rotor y así lograr el accionamiento del generador. La multiplicadora conecta el eje de baja velocidad del rotor con el eje de alta velocidad del generador.

### **Eje de alta velocidad**

Es el encargado de transmitir al generador eléctrico la velocidad que fue aumentada por el tren de engranes.

### **Generador**

Su función es convertir la energía mecánica de rotación en energía eléctrica. El generador eléctrico tiene que trabajar bajo niveles de cargas fluctuantes, debido a las variaciones en la velocidad del viento.

### **Góndola**

La góndola encierra en su interior al tren de engranes, el generador eléctrico y los sistemas auxiliares del aerogenerador, dispone de una cubierta de protección y de insonorización de los componentes de la máquina, también, incorpora las aberturas necesarias para lograr una ventilación efectiva de los componentes.

### **Controlador**

El sistema de control tiene como función, mantener la velocidad de rotación constante y regular la potencia eólica adquirida por el rotor. Cuando la velocidad del viento es menor a la necesaria para producir la energía o mayor a un límite permisible, el sistema de control frena el aerogenerador como medida para prevenir daños. Para lograr esto, se cuenta con dos tipos de frenos, el frenado aerodinámico y el freno mecánico. El primero, realiza el frenado por medio de la variación del ángulo de las aspas con el sistema de orientación, lo que produce una detención de forma suave y en unas pocas vueltas; cuando se aplica este freno las aspas quedan en un estado de libre giro pero no son detenidas completamente. El segundo sistema de frenado es por medio de un freno mecánico, consiste un freno de disco situado en el eje de alta velocidad de la multiplicadora; al obtener una detención completa del aerogenerador, el freno se usa en caso de emergencia o durante las tareas de mantenimiento para la inmovilización por seguridad.

### **Sistema de orientación**

Tiene como función posicionar el rotor de forma que quede colocado de forma perpendicular a la dirección del viento y así se obtenga la mayor captura de viento.

### **Anemómetro**

Mide la velocidad del viento.

### **Veleta**

Se utiliza para medir la dirección del viento.

### **Torre**

La torre es la encargada de soportar la góndola y el rotor. Entre más alta sea mayor cantidad de energía podrá obtenerse, ya que la velocidad del viento aumenta con la altura respecto al nivel del suelo.

## **2.2.2 Diseño de aerogeneradores**

Debido al incremento en las dimensiones de los aerogeneradores y a la necesidad de aumentar su eficiencia energética, el diseño de los aerogeneradores de eje horizontal se enfoca principalmente en el eje, las aspas y el generador [19]. No obstante, también se realiza trabajo en el diseño estructural de componentes, los algoritmos de control y los procesos de fabricación.

Es importante en el diseño de los aerogeneradores tomar en consideración las diferencias que tienen con una máquina rotativa convencional, entre las de mayor importancia se encuentra sus condiciones de funcionamiento bajo parámetros de velocidad y carga variable.

Aunque es posible realizar configuraciones de aerogeneradores que operen bajo velocidad fija o variable, el utilizar un generador que trabaje con velocidad variable provee de manera efectiva una mayor captura de energía contra uno que trabaje bajo velocidad fija. Para demostrar esta afirmación se han realizado estudios que demuestran un aumento en la captura total de energía entre 8 y 15 % mayor para los diseños que operan bajo velocidad variable [22]. Para poder trabajar en condiciones de velocidad variable es necesario un sistema de control que pueda capturar la mayor cantidad de energía. Con el incremento de la tecnología en este tipo de máquinas rotatorias, se han desarrollado controladores más eficientes para el ajuste del ángulo de las aspas y también configuraciones con el uso de un tren de engranes o sin ellos [22, 23].

Por otra parte, los aerogeneradores se encuentran sometidos a cargas y esfuerzos específicos que son altamente variables, producto de la naturaleza del viento. Las cargas variables son más difíciles de manejar que las cargas estáticas porque el material sufre una fatiga a lo largo de su ciclo de operación y además en muchas ocasiones es difícil conocer el estado de desgaste de un componente.

Estos esfuerzos a los que estarán sometidos todos los elementos mecánicos de un aerogenerador (rotor, tren de engranes y ejes) tanto en régimen estacionario como en régimen dinámico deben ser determinados, para ser considerados en el diseño y en el mantenimiento. Es importante que se tenga el conocimiento de las cargas, para de esta manera determinar las dimensiones y el material de los componentes del aerogenerador; de tal forma que las tensiones y deformaciones sobre ellos no superen los límites establecidos.

Al ser las aspas el componente del aerogenerador que tiene la función de transmitir la velocidad

del viento en energía mecánica, son el componente que transmite la variación de carga a los demás componentes y en gran medida determinan la carga que sufren, como en el caso del tren de engranes que se encuentra conectado al rotor. El análisis sobre las cargas que actúan en un aerogenerador se enfoca principalmente en el rotor, al ser el elemento que esta conectado a las aspas y las transmite a todo el sistema [13, 23].

## 2.3 Mantenimiento predictivo

Las pérdidas producidas en la industria por los fallos inesperados dentro de maquinaria involucrada en cadenas de producción, motivaron a la implementación del mantenimiento predictivo para evitar los tiempos de paro, alargar la vida útil de los equipos y aumentar la productividad. Al paso del tiempo, el mantenimiento ha ido adquiriendo un mayor interés y desarrollo por muchos sectores industriales, al tener con el uso adecuado la disminución de costos de reparaciones y además reducir las pérdidas por fallos inesperados.

La primera técnica de mantenimiento que se utilizó, fue la del mantenimiento correctivo la cual solo se limitaba a reparar o sustituir los componentes que presentaban averías, siendo una técnica muy limitada con respecto a querer aumentar la vida útil de equipos o disminuir la cantidad de fallos inesperados; por ello se comenzó a implementar el mantenimiento preventivo. El mantenimiento preventivo establece la realización de tareas preventivas programadas en un intervalo de tiempo periódico, dichas tareas preventivas se ejecutan sin importar el estado de degradación de los componentes para evitar fallos no programados, estas acciones producen una disminución en los fallos inesperados pero generan un mayor costo por inspecciones innecesarias y además cuenta con la desventaja de no poder predecir fallos inesperados. Posteriormente por las limitaciones de las técnicas de mantenimiento mencionadas, surgió el mantenimiento predictivo, este tipo de mantenimiento se enfoca en el desarrollo de sistemas de detección de fallos los cuales evalúan los datos que se adquieren de los procesos del sistema, con el fin de identificar fallos incipientes en estados de degradación prematuros y así evitar la propagación de fallos o que la severidad del daño produzca un fallo grave [4, 24].

El mantenimiento predictivo se encuentra organizado en tres etapas las cuales son:

- a. Detección: Basada en el seguimiento de la evolución de uno o varios parámetros seleccionados adecuadamente, de acuerdo a la sensibilidad que presentan ante los cambios en la condición de la máquina analizada.
- b. Identificación: Al haber detectado el problema, se hace un análisis para determinar cuál fue la causa que originó el problema, para ello se identifican el o los elementos de la máquina que produjeron el incremento en las vibraciones, con respecto a referencias que se obtienen de una condición mecánica normal.

- c. Corrección: Al conocer la causa y ubicación del problema, es posible organizar y ejecutar de modo eficiente y eficaz los trabajos de eliminación del problema y la causa que lo generó. La identificación de los problemas en una etapa prematura, permite planificar los trabajos de mantenimiento oportuno, logrando que las pérdidas por concepto de mantenimiento sean mínimas.

En general el programa contribuye a detectar el comienzo de una futura avería a la vez que permite disponer de las herramientas necesarias para analizar la causa del problema que se está desarrollando, lográndose determinar finalmente, el momento oportuno para corregir eficaz y eficientemente el problema detectado [24].

### 2.3.1 Mantenimiento en aerogeneradores

Los modernos aerogeneradores están diseñados para un tiempo de vida útil de 20 años, teniendo un costo de mantenimiento bajo al principio de su funcionamiento, pero que se va incrementando con el tiempo debido al desgaste de los elementos que lo conforman. Algunos componentes son más propensos al desgaste que otros, es el caso de las palas del rotor y la multiplicadora, esto debido a las cargas con que trabajan producto de la variación en la velocidad del viento. El problema del remplazo de uno de estos componentes es por el valor elevado que tienen, por ejemplo el precio de un nuevo conjunto de palas, de una multiplicadora o de un generador es usualmente del 15 al 20 % del precio total de un aerogenerador [16, 25].

Durante la etapa de diseño de un aerogenerador, se tienen en cuenta las operaciones de mantenimiento necesarias para alcanzar el tiempo de vida útil promedio, es por ello que el fabricante incluye en el correspondiente manual, el plan de mantenimiento preventivo que debe aplicarse a la máquina y las operaciones de mantenimiento preventivo que se realizan una o dos veces al año. En las tareas comunes a realizar se incluyen inspecciones periódicas, limpieza de las aspas, cambios de aceite, calibración del sistema de control, ajuste de los sensores y actuadores entre otras actividades.

Entre los fallos más frecuentes en los aerogeneradores se encuentran los producidos en los sensores, el sistema de control, el sistema de cableado, los componentes del sistema eléctrico y el sistema de control; con un promedio de fallo aproximado de cada dos años. En comparación con lo mencionado anteriormente un fallo en el tren de potencia solo ocurre en promedio cada 19 años, en la figura 2.3 se pueden observar los porcentajes de fallos imprevistos que ocurren en los componentes principales de un aerogenerador [26, 27].

Un aspecto adicional a considerar además de las frecuencias de fallo de los componentes, son los periodos de inactividad del aerogenerador al momento que se producen estos fallos, el costo asociado a su reparación y la pérdida económica generada por su inactividad (ver figura 2.4), desde este punto de análisis los fallos en la multiplicadora, el generador, el tren de potencia y en las aspas son una fuente de gastos considerables debido a que requieren un




Figura 2.3: Porcentaje de fallos de los componentes básicos de un aerogenerador

mantenimiento correctivo no planificado que puede dejar al aerogenerador sin funcionamiento durante bastante tiempo [16].

En años recientes se han realizado investigaciones con respecto a la detección incipiente de fallos en la multiplicadora, esto debido a que aunque no son el componente que falla con mayor porcentaje, si tiene un elevado costo de reparación y el tiempo de inactividad para realizar una reparación es uno de los más elevados.




Figura 2.4: Fallos de los componentes de un aerogenerador y su tiempo de reparación

Para reducir los costos y tiempos de mantenimiento, el mantenimiento predictivo en los aerogeneradores ha sido implementado como una medida para poder disminuir los fallos inesperados. Las técnicas empleadas para el monitoreo de los diversos componentes deben tener especial atención en que un fallo en los sistemas de medición nunca debe producir la

detención del aerogenerador [26]. En la tabla 2.1 se muestran las técnicas de monitoreo y de análisis que se utilizan en los aerogeneradores.

Tabla 2.1: Técnicas de monitoreo y análisis en aerogeneradores

	<b>Aspas</b>	<b>Rotor</b>	<b>Tren de engranes</b>	<b>Generador</b>
<b>Vibraciones</b>	Métodos estadístico, Wavelet	Métodos estadísticos, Cepstrum	Métodos estadísticos, FFT, Wavelet, Análisis en el dominio del tiempo	
<b>Emisiones acústicas</b>	Métodos estadísticos Wavelet	Wavelet	Métodos estadísticos Wavelet	
<b>Análisis de aceite</b>			Métodos estadísticos Análisis en el dominio del tiempo	Nuevas técnicas
<b>Radiografía</b>	Nuevas técnicas			
<b>Termografía</b>	Nuevas técnicas		Nuevas técnicas	Nuevas técnicas

Las técnicas de monitoreo más utilizadas en los aerogeneradores son el análisis de vibraciones mecánicas, el análisis de aceites, la termografía y la monitorización acústica, siendo las vibraciones las más utilizada por la información que ofrece del estado del generador eólico. Para la medición de las vibraciones los acelerómetros son los mayormente utilizados por su facilidad de uso y la buena sensibilidad que tienen para poder medir las señales de vibraciones.

Con el análisis de vibraciones se obtiene mayor información sobre el estado de la multiplicadora que con el uso de otras técnicas como la termografía o un análisis sonoro, para ello se registran dos tipos de datos de frecuencia, un campo de bajas frecuencias en el que se analiza el comportamiento de la estructura del aerogenerador y los elementos giratorios de baja velocidad y un campo de altas frecuencias que comprende el análisis de los elementos giratorios de alta velocidad [23].

Existen varios niveles de monitorización de la condición de aerogeneradores. El nivel 1 se basa en la monitorización de niveles de alarma de parámetros de vibración, el nivel 2 en la monitorización de valores de alarma de parámetros de diagnóstico y en el nivel 3 en el diagnóstico de la condición de cambios que se apoyan en la amplitud del espectro, la envolvente del espectro, el análisis en el dominio del tiempo y los procesos especiales.



Lo que la experiencia sugiere y las demandas de las compañías aseguradoras muestran, es que el nivel 3 es el apropiado para la monitorización de la condición de aerogeneradores de velocidad variable.

Para llevar a cabo una monitorización de la condición de nivel 3 existen las siguientes opciones:

- Fijar la velocidad temporalmente mientras las mediciones de diagnóstico se están realizando.
- Realizar mediciones únicamente cuando las variaciones de la velocidad son pequeñas.
- Los tiempos de medición y las ventanas de medición se reducen con el fin de reducir los efectos del “*smearing*” en los espectros de frecuencia.
- Mediciones de velocidad y análisis de órdenes de los espectros, permiten tiempos adecuados de medición.

Estas características del monitoreo de los aerogeneradores, son generadas por sus condiciones de funcionamiento bajo parámetros de velocidad y carga variable, razón por la que las técnicas convencionales de procesamiento de señales deben ser modificadas y adecuadas para ser utilizadas en la monitorización de la condición de los aerogeneradores.

## **2.4 Maquinaria funcionando bajo condiciones de velocidad y carga variables**

El análisis de vibraciones es el método mayormente implementado y estudiado en las máquinas rotatorias. La necesidad de sistemas más complejos ha derivado a la existencia en mayor cantidad de máquinas que son sometidas a condiciones de velocidad y carga variables, al estar presentes este tipo de condiciones en una gran variedad de sistemas muchos trabajos de investigación se han realizado en el análisis y detección de fallos. Entre los sistemas que trabajan bajo estas condiciones operativas destacan los sistemas de engranajes como los que se encuentran en helicópteros, excavadoras, en aerogeneradores, etc. Los tipos de análisis pueden ser divididos principalmente en el dominio del tiempo, en el dominio de la frecuencia y en el dominio tiempo-frecuencia.

### **2.4.1 Análisis en el dominio del tiempo**

Las técnicas en el dominio del tiempo utilizan la forma de señal para extraer directamente sus rasgos característicos, los análisis tradicionales en este dominio son las medidas estadísticas como son el promedio, la varianza, la desviación estándar, el factor de cresta, la media cuadrática, Kurtosis etc.

Una de las técnicas que se han convertido en un enfoque atractivo es el promedio de tiempo síncrono (TSA). Su uso permite remuestrear las vibraciones en engranajes para reducir el ruido y eliminar los efectos de otros elementos del sistema, en [28] se desarrolla un esquema para la predicción de fallos basado en la estimación bayesiana en el eje de un sistema de prueba, implementando los TSA para determinar las condiciones del sistema.

En el trabajo [29] se introduce una técnica para el diagnóstico de engranajes planetarios, de los cuales es importante identificar las variaciones de las condiciones de carga externa. Utilizando la distribución de Wigner-Ville para realizar un mapa en tiempo de las vibraciones. Bartelmus realiza una suposición de la existencia de una dependencia lineal entre la carga externa y el parámetro de vibración que está representado por la condición del engranaje.

En un desarrollo posterior partiendo de la hipótesis de la existencia de la dependencia lineal mencionada Bartelmus [30] hace uso de la pendiente de la regresión entre las condiciones de operación y la amplitud de la señal como una nueva característica de diagnóstico aplicado a engranajes planetarios en excavadoras utilizadas bajo condiciones de carga variable.

Tomando en cuenta los efectos de la carga variable en una máquina rotatoria como sistemas de engranajes, en Luisa et al. [2] realiza un algoritmo de identificación de fallos utilizando el mismo banco de pruebas de esta investigación. Para poder identificar los diferentes fallos se calculan una serie de parámetros estadísticos como kurtosis, varianza, el valor rms, entre otros y aplicando una regresión lineal los autores determinan que variables son más sensibles a las vibraciones dependiendo el tipo de fallo mecánico a analizar, por último para la detección, se mide un parámetro estadístico conocido como nivel de significación (p-valor) de los fallos con respecto al tiempo. Los resultados de la investigación son muy prometedores por la complejidad de las señales de vibración y la existencia de pocos trabajos que trabajen con perfiles de velocidad y carga variable como los que ellos emplean.

Otros enfoques de análisis en el dominio del tiempo aplican modelos de series de tiempo para la extracción de parámetros, la principal idea de la modelización de series de tiempo es ajustar los datos a un modelo de serie temporal paramétrico y extraer características sobre la base de este modelo. Los modelos más populares utilizados en la literatura son el modelo auto regresivo (AR) y modelo auto regresivo media móvil (ARMA) [31].

En [5] se presenta un sistema de diagnóstico de fallos que utiliza como técnica de clasificación una red neuronal artificial tipo perceptrón multicapa. Como técnica de procesamiento el autor calcula los coeficientes predictores lineales de señales de vibraciones y sonido para describir las condiciones de la maquinaria, para posteriormente con la red neuronal medir las variaciones de los valores de los coeficientes con respecto a las diferentes condiciones mecánicas analizadas, las señales de vibraciones fueron obtenidas cambiando las revoluciones por minuto de un motor entre valores de 500, 1000, 2000 y 3000 rpm, realizando las mediciones con una frecuencia de muestreo de 25,600 Hz. La clasificación presentada tiene un excelente desempeño y una buena eficiencia computacional.

Han [5] utiliza una estructura de análisis y clasificación similar a la desarrollada en esta tesis, no obstante el perfil de velocidad con el que trabaja es para determinados valores de velocidad y no un perfil completo de velocidad variable como en el presente trabajo. Además de la ausencia del perfil de velocidad aleatorio, Han no realiza cambios en las condiciones de carga de la maquinaria analizada, condiciones que al ser incluidas en un sistema de múltiples etapas como en el banco de pruebas empleado (ver sección 4) producen cambios en las señales de vibraciones, es por ello que la influencia de la variación de la carga debe ser considerada, teniendo en cuenta que el uso de métodos clásicos de análisis y monitoreo puede tener limitaciones y no ser siempre adecuados [29].

Utilizando modelos auto regresivos con enfoques como el propuesto por Yang [32] es posible localizar y detectar fallos en un engranaje que trabaja bajo condiciones de carga variable, Yang utiliza un modelo auto regresivo con variables exógenas (ARX) para la extracción de parámetros, sincronizando las señales de las vibraciones con el promedio de tiempo síncrono lo que le permite obtener resultados de gran rapidez en la detección y localización de daños en un engranaje.

Las diferentes técnicas en el dominio del tiempo ofrecen diversas ventajas y han obtenido buenos resultados. Trabajos que hacen uso de modelos auto regresivos han sido aplicados en vibraciones de maquinaria con engranajes bajo condiciones de velocidad y carga por separado o con valores fundamentales de las mismas, demostrando una buena capacidad para la obtención de rasgos de señales de vibraciones.

### **2.4.2 Análisis en el dominio de la frecuencia**

El análisis en este enfoque se basa en la transformada de la señal en el dominio de la frecuencia, la ventaja de utilizar el dominio de la frecuencia con respecto del dominio del tiempo, se encuentra en que otorga la posibilidad de identificar y describir los componentes de interés de la señal con respecto a la frecuencia. El análisis mayormente utilizado es el análisis del espectro de la transformada rápida de Fourier (FFT) de la señal, teniendo como idea principal el monitorizar las frecuencias de la señal de interés a lo largo del espectro de frecuencia de la señal, debido a las potabilidades que ofrece y la facilidad que es su aplicación en muchos problemas se ha desarrollado una teoría fuerte de su uso, así como la relación de los cambios en frecuencia con distintos fallos mecánicos en máquinas rotatorias [4, 31].

Para el análisis espectral de una señal, el espectro de potencia es la técnica mayormente utilizada, otras herramientas son el uso de filtros de frecuencia, análisis de la estructura de bandas y la envolvente del espectro. Trabajos recientes que utilizan como base las técnicas tradicionales mencionadas anteriormente pueden ser encontrados en la literatura. En [33] se menciona que el uso del análisis de vibraciones y de corrientes puede ayudar a determinar el estado de un rotor, midiendo las vibraciones en direcciones axial y radial permite distinguir

entre un tipo de fallo de corriente o de rompimiento de la barra del rotor, observando en frecuencias fundamentales de la señal la presencia de bandas de frecuencia junto estas frecuencias.

Una técnica que ha demostrado tener buenas capacidades comparada con el análisis del espectro de potencia es el cepstrum [34]. Existen muchas variantes del Cepstrum pero es definido como la transformada inversa de Fourier del espectro logarítmico de potencia, el Cepstrum permite identificar fácilmente los armónicos de una señal y sus bandas en el espectro de potencia. Mediante el uso del análisis de ordenes este método ha sido aplicado en señales de vibraciones con condiciones de velocidad variable como en [6] donde se demuestra la efectividad del uso de los coeficientes cepstrales en señales de vibraciones y acústicas, se hace uso de un remuestreo que permite sincronizar las señales para transferir la componente de periodo en una sola frecuencia teniendo la posibilidad de identificar el fallo presente.

En [7] se presenta la aplicación del Cepstrum además de otras variantes como el espectro de potencia y el bi-espectro para la identificación de fallos en motores de inducción, la clasificación de los fallos es mediante el uso de una red neuronal de propagación hacia adelante. Liang et al. describen las características del Cepstrum, siendo capaz de identificar los fallos en un motor si las vibraciones contienen una buena cantidad de armónicos y bandas. Los resultados de la clasificación obtenidos en el trabajo y las ventajas ofrecidas lo hacen una buena alternativa para la extracción de rasgos en señales de vibraciones.

Al no encontrar un trabajo reportado en la literatura que utilice los coeficientes cepstrales para generar la envolvente de una señal para el perfil de velocidad y carga variables se tiene la posibilidad de utilizar esta técnica para caracterizar las diferentes condiciones mecánicas, conociendo por el trabajo desarrollado en [2] los diferentes armónicos presentes en los datos y siendo demostrada la capacidad del Cepstrum para el procesamiento de señales de vibraciones [7].

### **2.4.3 Análisis en el dominio tiempo-frecuencia**

La deficiencia de las técnicas para poder analizar señales no estacionarias sin algunas modificaciones o apoyadas del uso de otros métodos, permitió el desarrollo de técnicas que pudieran permitir el análisis de una señal para sus componentes de frecuencia en el tiempo. Como una de las alternativas más populares para esta problemática se encuentra la transformada de Fourier en tiempo corto, el espectrograma y la distribución de Wiener-Vile [31].

Una técnica que ha demostrado ser poderosa y eficiente para una gran cantidad de aplicaciones es la transformada wavelet que a diferencia de las técnicas mencionadas anteriormente, permite el uso de grandes intervalos de tiempo en los segmentos que se quiere una mayor precisión en baja frecuencia e intervalos de tiempo menores cuando se desea obtener información de alta

frecuencia, es por ello que se dice que hace una representación escalada en tiempo de la señal (tiempo-escala).

De manera sencilla el funcionamiento de esta transformada es decir que la señal en base de tiempo se pasa por varios filtros pasa bajos y pasa altos, los cuales separan los componentes de la señal de alta frecuencia de las de baja frecuencia.

En la actualidad por las características y ventajas que ofrecen la representación escalada de una señal existen muchos trabajos que hacen uso de la transformada wavelet.

Algunas de las aplicaciones de la transformada wavelet son la supresión de señales y la eliminación del ruido, el procesamiento digital de imágenes, el reconocimiento de voz y procesamiento de señales en general.

Uno de los campos del procesamiento de señales donde las wavelets han sido utilizadas para la detección y clasificación de fallos, es en el análisis de engranajes de aerogeneradores. Wang y McFadden presentan en [35] uno de los primeros trabajos con el uso de wavelets para la identificación y clasificación de señales de vibraciones adquiridas de engranajes, para el caso de estudio de este trabajo se utilizó el tren de engranes de un helicóptero del cual se obtuvieron señales de diferentes condiciones del engranaje. Los autores demuestran que utilizando la distribución en tiempo-escala de la transformada wavelet se pueden localizar fallos específicos en el engranaje.

La importancia de los primeros trabajos sobre las wavelets es el que con la investigación realizada se pudo probar la capacidad que tienen de mostrar simultáneamente diferentes escalas de corta o larga duración, utilizando las diferentes longitudes de escala es posible localizar fallos distribuidos y fallos en una zona en particular.

Tomando como referencias los primeros trabajos y la gran cantidad de wavelets madre que han sido creadas y agrupadas en familias según su utilidad, fue posible el desarrollo diferentes tipos de transformadas como son, la wavelet continua, la wavelet discreta, el paquete wavelet (WPT), multiwavelets etc.

Trabajos recientes utilizan diferentes tipos de wavelets combinadas con diferentes métodos para la clasificación de patrones demostrando buenos resultados. En [36] se presenta un procedimiento que reconoce experimentalmente fallos en engranajes y rodamientos de una caja de engranes. Midiendo las vibraciones del engranaje y utilizando la interpolación Hermitiana para la sincronización de las señales para diferentes valores de velocidad, el vector característico de las diferentes condiciones estudiadas fue obtenido del valor de la desviación estándar de los coeficientes de un paquete wavelet. La clasificación de las condiciones mecánicas fue realizada con una red neuronal perceptrón multicapa.

En el trabajo [37] se presenta un enfoque para la extracción y diagnóstico de fallas mecánicas en la maquinaria rotatoria. Para la extracción de los rasgos característicos en frecuencia de

las vibraciones mecánicas, los autores hacen uso de la descomposición de un paquete wavelet (WPD) y la descomposición de modo empírico (EMD). Para realizar el diagnóstico de los fallos anticipadamente se utiliza una red neuronal artificial de base radial.

Utilizando la diversidad de tipos de wavelets y procedimientos de reconocimiento de patrones, el procesamiento digital de señales ha sido uno de los campos de aplicación de mayor estudio para esta transformada, aplicaciones de gran complejidad pueden ser desarrolladas mediante el uso de esta técnica con resultados muy eficientes.

El uso de redes neuronales artificiales es utilizado en una gran cantidad de trabajos de wavelets, además de ellas, otras técnicas han sido utilizadas para realizar diagnóstico en otros trabajos como son las máquinas de vector soporte, la lógica difusa y los sistemas neuro difusos [31].

## 2.5 Modelos computacionales neuronales híbridos

Dada la complejidad de algunos problemas de clasificación de modelos computacionales que deben considerar perturbaciones externas al sistema de medición como pueden ser: ruido, temperatura, ráfagas de viento, etc. Las arquitecturas para los modelos neuronales han tenido desarrollo de diferentes topologías y RNA's, resultando en modelos de clasificación híbridos (paralelo, serie o combinados) para poder aumentar el grado de robustez y el desempeño del modelo computacional.

En trabajos como el presentado por Sánchez-Fernández et al. [38], los autores realizan la identificación de aviones empleando dos redes neuronales artificiales feedforward en paralelo, de las que se obtiene el resultado de clasificación con un módulo de decisión que combina los resultados de cada uno de las técnicas de extracción empleadas (LPC y análisis de octavas).

En otro trabajo, Márquez-Molina et al. [39] utiliza dos redes neuronales artificiales en paralelo con LPC y MFCC para la extracción de rasgos y empleando un método de suma ponderada para el módulo de decisión, en el trabajo presenta mejoras con respecto a los resultados presentados en [38], comprobando la mejora de la clasificación por el modelo neuronal; debido a que aunque utilizan la misma arquitectura cambian los métodos de extracción de parámetros y el módulo de decisión.

En [40] los autores realizan un método de segmentación en cuatro segmentos en señales de ruido para la clasificación de aviones, para la extracción de parámetros Sánchez-Pérez et al. emplean a los LPC como único método. Considerando condiciones ambientales reales obtienen muy buenos resultados de clasificación en comparación con trabajos que utilizan modelos neuronales sencillos y modelos neuronales con dos técnicas diferentes para la extracción de rasgos [38, 39].

## 2.6 Conclusiones del capítulo

Debido a la necesidad de disminuir la contaminación del medio ambiente el uso de la energía eólica se ha convertido en una de las principales fuentes alternativas en la actualidad, un gran número de parques eólicos se han instalado en todo el mundo teniendo un buen desempeño y crecimiento en los últimos años.

La velocidad y carga variable generada por los cambios en las corrientes de viento genera a lo largo del tiempo un desgaste en los componentes de los aerogeneradores, el desgaste puede provocar fallos que por el elevado costo y tiempo de reparación como en el caso del tren de engranes producen pérdidas muy costosas; razón por la que se ha implementado el mantenimiento predictivo para poder evitar fallos inesperados y reducir los gastos por reparaciones en los componentes de mayor costo como son el tren de engranes, las aspas y el generador. Trabajos que realizan el análisis de vibraciones en el tren de engranes han sido desarrollados con buenos resultados en la detección de fallas incipientes.

En los trabajos reportados en la literatura los métodos de procesamiento de señales como son los LPC y el Cepstrum han sido aplicados en la extracción de rasgos de vibraciones mecánicas. No obstante, no se utilizan en perfiles de carga y velocidad variable; condiciones presentes en este tipo de maquinaria.

# Capítulo 3

## Marco teórico

Las vibraciones mecánicas tienen un importante estudio en el tren de engranes de un aerogenerador por la información vital que presentan con respecto al estado en que se encuentra. Es importante para el mantenimiento predictivo la detección de fallas incipientes para obtener la mayor productividad y además evitar que se produzca un daño grave el cual genere grandes costos en su reparación.

En esta sección se presenta una descripción de los métodos de medición, los métodos de procesamiento digital de señales y las técnicas de reconocimiento de patrones utilizadas para el desarrollo del modelo computacional.

### 3.1 Medición

Como se mencionó en el capítulo 2 el Acelerómetro es el sensor mayormente utilizado para la medición de vibraciones en maquinaria, básicamente un acelerómetro es un transductor que detecta el movimiento de una superficie produciendo una señal eléctrica análoga al movimiento (ver figura 3.1).

En el mercado actualmente los acelerómetros más utilizados son de tipo piezoeléctrico debido a la fidelidad de la señal capturada y a la versatilidad que otorgan. Sobre un material cerámico como el cuarzo se adiciona una carga  $M$  la cual ejerce fuerzas de inercia sobre un material piezoeléctrico, estas fuerzas producen cargas eléctricas proporcionales a la aceleración y a la masa  $M$ . El potencial variable obtenido producto de la aceleración es medido para obtener las vibraciones resultantes, además cuentan con un preamplificador interno que permite una mayor sensibilidad sin importar la longitud o la calidad del cable, lo que produce un buen comportamiento ante condiciones como polvo y humedad.

Es importante tomar en cuenta que para obtener una medición del estado de una máquina fiable, los acelerómetros deben colocarse de manera ortogonal y ser fijados de manera que se evite la adición de señales espurias [4].

#### 3.1.1 Unidades de frecuencia

Para expresar de una manera adecuada las vibraciones mecánicas medidas en máquinas rotatorias, se puede expresar la frecuencia de vibración en Hertz (Hz) y en revoluciones






Figura 3.1: Componentes básicos de un acelerómetro piezoeléctrico

por minuto (rpm), el uso de las rpm se debe a la posibilidad de hacer una expresión que exprese las rotaciones de un cuerpo en cada minuto, no obstante en la mayoría de los análisis de vibraciones se emplean los Hertz, al ser la magnitud utilizada en el SI como unidad de frecuencia.

Un hercio es la frecuencia de una oscilación que sufre una partícula en un período de un segundo.

$$f = \frac{1}{T} = \text{Hz} = \frac{1}{s} \quad (3.1)$$

Mediante las ecuaciones 3.2 y 3.3 es posible realizar la conversión de rpm a Hz y viceversa.

$$\text{rpm} = \text{Hz} \times 60 \quad (3.2)$$

$$\text{Hz} = \frac{\text{rpm}}{60} \quad (3.3)$$

### 3.1.2 Frecuencia de Nyquist

Para poder realizar el procesamiento digital de una señal, es necesario disponer de un número finito de muestras discretas de la señal en el tiempo. El intervalo de tiempo sobre el cual la señal es adquirida va desde 0 hasta un tiempo  $T$ .

La transformada de Fourier de este segmento de señal se puede apreciar en la ecuación 3.4:

$$Y(f) = \int_0^T y(t)e^{-j2\pi ft} dt \quad (3.4)$$

El segmento  $y(t)$  se encuentra limitado entre 0 y  $T$ , por lo que su transformada lo está entre  $-F$  y  $F$ . Así, para describir a  $y(t)$ , sólo es necesario un número finito de muestras de la

propia señal en el tiempo o de su espectro  $Y(f)$ , si dicho espectro se muestrea a intervalos de frecuencias de igual longitud al co-intervalo de Nyquist  $\frac{1}{T}$  dentro del intervalo  $-F$  hasta  $F$  entonces, el numero de muestras requeridas será dado por:

$$N = \frac{2F}{\frac{1}{T}} = 2FT \quad (3.5)$$

Si se muestrea el segmento  $y(t)$  al intervalo de Nyquist  $\frac{1}{2F}$ , entonces el número muestras requerido será:

$$N = \frac{T}{\frac{1}{2F}} = 2FT \quad (3.6)$$

Las ecuaciones 3.5 y 3.6 demuestran que muestreando el espectro según el co-intervalo de Nyquist, requiere el mismo tamaño de muestreo de la señal en el tiempo con el intervalo de Nyquist. Lo que representa el valor mínimo que se requiere para muestrear una señal y poder reconstruirla.

En el procesamiento digital de señales para el uso de las diferentes técnicas, en muchos casos se muestrea la señal en el tiempo a intervalos iguales, por lo que escoger la longitud de los intervalos de manera errónea puede provocar problemas en el procesamiento de una señal. Considerando las ecuaciones 3.5 y 3.6 es posible inferir que el máximo intervalo de tiempo de muestreo es  $\frac{1}{2F}$ , es por ello que si se emplea un intervalo mayor a este valor, por lo consiguiente, el número de muestras adquiridas sera mayor obteniendo un mayor tiempo de cálculo y memoria de la computadora. Por lo contrario, si el intervalo de muestreo es menor al requerido, entonces se almacenarían menos muestras de las que son necesarias provocando confusiones en las frecuencias del espectro; efecto que se conoce como *aliasing*.

La figura 3.2 muestra un ejemplo del aliasing, el poder reconstruir al coseno de una mejor forma, depende de las muestras por ciclo utilizadas para representar a la señal discretamente, si el valor de muestras es muy pequeño la señal obtenida no es representativa de la señal original, por lo tanto a una mayor cantidad de muestras la semejanza es más significativa.

La frecuencia de muestreo se define tomando al intervalo de muestreo  $\delta t$  como base.

$$f_s = \frac{1}{\delta t} \quad (3.7)$$

Al saber que se requieren al menos dos muestras por periodo de señal para poder definir una componente de frecuencia en la señal original, es por ello que la mayor frecuencia que puede ser adquirida es:

$$f_s = \frac{1}{2\delta t} = \frac{f_s}{2} \quad (3.8)$$




Figura 3.2: Ejemplo de aliasing

Donde  $f_n$  se conoce con el nombre de frecuencia de Nyquist.

## 3.2 Procesamiento digital de señales

El objetivo del procesamiento digital de señales es extraer información relevante de un conjunto de datos obtenidos mediante la medición de un fenómeno físico. Las técnicas en el procesamiento de señales pueden ser analizadas en el dominio del tiempo, en el dominio de la frecuencia y en la frecuencia con respecto al tiempo. Una vez adquiridas las señales es necesario seleccionar aquellas que ofrezcan ventajas para el caso de estudio, analizarlas en el dominio deseado para hacer uso de ellas en sistemas de reconocimiento y clasificación.

Al medir las vibraciones mecánicas mediante una señal eléctrica analógica, debe obtenerse una señal digital en el dominio del tiempo para realizar su procesamiento mediante una computadora. Con el uso de tarjetas de adquisición de datos y convertidores analógicos a digitales es posible realizar esta conversión.

Mediante la transformada rápida de Fourier (FFT) la señal puede convertirse del dominio del tiempo al dominio de la frecuencia en forma de espectro. El análisis espectral en frecuencia consiste en descomponer la señal en sus componentes de frecuencia, lo cual es de gran utilidad en las vibraciones mecánicas para la detección de rasgos característicos.

Los métodos utilizados para el desarrollo de este trabajo para caracterizar las vibraciones mecánicas son:

- FFT

- Modelo auto regresivo (LPC)
- Cepstrum

### 3.2.1 Transformada de Fourier

La Transformada de Fourier (FT) de una señal analógica  $x(t)$  se expresa como

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (3.9)$$

#### Transformada discreta de Fourier

La transformada discreta de Fourier (DFT) de una variable continua  $t$  es sustituida por una variable discreta  $nTs$  siendo  $Ts$  el periodo de muestreo. Las ecuaciones que describen a la DFT se definen:

$$Y(k) = \frac{1}{N} \sum_{n=0}^{N-1} y(n)e^{-j\frac{2\phi kn}{N}} \quad (3.10)$$

$$y(n) = \sum_{k=0}^{N-1} Y(k)e^{j\frac{2\phi kn}{N}} \quad (3.11)$$

para  $n = 0, 1, 2, \dots, N - 1$ ;  $k = 0, 1, 2, \dots, N - 1$

siendo  $N$  el número de muestras discretas de la señal.

#### FFT

La transformada rápida de Fourier es un algoritmo eficiente que permite calcular la transformada de Fourier discreta y la transformada inversa de Fourier discreta (IDFT) [41].

La FFT aprovecha la periodicidad y simetría de la transformada de Fourier, descomponiendo a la DFT de  $n$  puntos en transformadas más pequeñas. El objetivo central de este algoritmo es dividir recursivamente a la DFT en dos o más DFT pequeñas, cada una de las cuales pueden computarse en forma individual y combinarse en forma lineal a fin de obtener la DFT de la secuencia de  $N$  puntos originales. La rapidez de cálculo del algoritmo, con una complejidad logarítmica es uno de los motivos principales de su uso, esto debido a que la evaluación de la transformada directamente toma un valor cuadrático de operaciones lo cual no es eficiente para valores de  $N$  grandes.

### 3.2.2 Modelo auto regresivo (LPC)

Un método apropiado para la estimación espectral de alta resolución son los modelos auto regresivos (AR), los cuales permiten la estimación de espectros con picos finos, siendo está una de las limitaciones de las técnicas de estimación de la densidad de potencia espectral basadas en procedimientos de la FFT [42].

Entre los modelos AR se encuentra la codificación predictiva lineal (LPC), la cual se puede definir como un método para codificar una señal en la que un valor de la misma en determinado instante de tiempo se predice por una función lineal de valores pasados de la señal.

El supuesto básico de la predicción lineal es que un proceso aleatorio puede ser predecible basado en el pasado infinito. Esto puede ser representado por una serie de tiempo  $\{x_n : n \in \mathbb{Z}\}$  que es expresada como una combinación lineal infinita de todo los puntos precedentes.

$$x_n = - \sum_{k=1}^{\infty} \alpha_k x_{n-k} \quad (3.12)$$

Los coeficientes  $\{\alpha_k : 0 < k \in \mathbb{Z}\}$  se obtienen a través del análisis predictivo lineal. Con estos coeficientes es posible describir una señal como un filtro IIR utilizando un pequeño número de datos y predecir el valor actual basado en valores anteriores.

Una serie de tiempo puede ser representada utilizando una serie finita de  $p$  valores anteriores, este modelo se expresa mediante una regresión lineal sobre sí misma más un término de error,

$$x_n = - \sum_{k=1}^p \alpha_k x_{n-k} + e_n \quad (3.13)$$

donde  $p$  es el orden del modelo,  $\alpha_k$  son los coeficientes auto regresivos y  $e_n$  es un proceso aleatorio de ruido blanco Gaussiano con media cero y varianza  $\sigma^2$ . Se puede demostrar que la varianza del ruido  $\sigma^2$ , representa la potencia del error de aproximación.

Si la ecuación (3.13) es considerada como un sistema lineal donde  $e_n$  es la entrada y  $x_n$  la salida; la función de transferencia del sistema es:

$$H(z) = \frac{1}{A(z)} = \frac{1}{1 + \sum_{k=1}^p \alpha_k z^{-k}} \quad (3.14)$$

donde  $z$  es el operador de desplazamiento hacia adelante. Esto se llama un modelo auto regresivo (AR) o un modelo lineal de polos lineal de orden  $p$ .

### Ecuaciones de Yule-Walker

Sea  $\{x_n : n \in \mathbb{Z}\}$  que denota la serie de tiempo representada por el modelo AR dado por la ecuación (3.13). La función de auto covarianza de este proceso estacionario está definida como  $C_{xx}(k) = E[(x_n - m)(x_{n-k} - m)]$  donde  $m$  es la expectativa de  $x_n$  que es cero para un modelo AR con un ruido blanco de promedio cero. Multiplicando  $x_n$  por su conjugado desplazado a ambos lados de la ecuación (3.13) y calculando la esperanza matemática; las características del modelo AR pueden ser expresadas en términos de la función de auto covarianza de la siguiente manera:

$$C_{xx}(k) = - \sum_{i=1}^p \alpha_i C_{xx}(l-i) + \sigma^2 \delta_k \quad (3.15)$$

donde  $\delta_k$  es la delta de Kronecker definida como

$$\delta_k = \begin{cases} 1, & \text{para } k = 0, \\ 0, & \text{para } k \neq 0, \end{cases} \quad (3.16)$$

Escribiendo la ecuación (3.15) para  $l = 1, 2, \dots, p$ , se obtiene un conjunto de  $p$  ecuaciones lineales simultáneas, que pueden ser expresadas en forma matricial de la siguiente manera

$$\begin{bmatrix} r_0 & r_1 & \cdots & r_{p-1} \\ r_1 & r_0 & \cdots & r_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & \cdots & r_0 \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_p \end{bmatrix} = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix} \quad (3.17)$$

donde  $r_k = C_{xx}(k)$  para  $k = 1, \dots, p$  son valores conocidos y las incógnitas son los coeficientes AR  $w_k = -a_k$ , para  $k = 1, \dots, p$ .

Las ecuaciones matriciales de 3.17 son llamadas ecuaciones de Yule-Walker y son expresadas de una forma compacta matricial como;

$$\mathbf{R}\mathbf{w} = \mathbf{r} \quad (3.18)$$

donde la matriz  $\mathbf{R}$  es Hermitiana y Toeplitz. La esperanza matemática y la función de auto covarianza pueden ser estimadas de la serie de tiempo  $\{x_n\}$

$$\hat{m}^N = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.19)$$

$$\hat{C}_{xx}^N(k) = \frac{1}{N-k-1} \sum_{i=k+1}^N (x_i - \hat{m}^N)(x_{i-k} - \hat{m}^N), \quad (3.20)$$

para  $k = 1, \dots, p$  y  $N$  suficientemente largos, es decir  $N \gg p$ .

Donde para un valor finito  $k$  se garantiza que  $\hat{m}^N$  y  $\hat{C}_{xx}^N(k)$  convergen para  $m$  y  $C_{xx}(k)$ , respectivamente cuando  $N$  se aproxima a infinito.

### Algoritmo de Levinson-Durbin

El algoritmo de Levinson-Durbin es un procedimiento recursivo para resolver de manera eficiente una ecuación lineal que implica una matriz Toeplitz [43]. Dado que la matriz  $\mathbf{R}$  en las ecuaciones de Yule-Walker (ver ecuación 3.18) es Hermitiana y Toeplitz, el vector característico  $\mathbf{w}$  se puede resolver mediante la aplicación del algoritmo de Levinson-Durbin.

1. Inicializar el algoritmo estableciendo:

$$\begin{aligned} a_{0,0} &= 1 \\ P_0 &= r(0) \end{aligned}$$

2. Para  $m = 1, 2, 3, \dots, p$ , se realiza lo siguiente:

$$\begin{aligned} k_m &= -\frac{1}{p_{m-1}} \sum_{i=0}^{m-1} r(i-m) a_{m-1,i} \\ a_{m,i} &= \begin{cases} 1, & \text{para } i = 0 \\ a_{m-1,i} + k_m a_{m-1,m-i}^* & \text{para } i = 1, 2, \dots, m-1 \\ k_m & \text{para } i = m \end{cases} \\ P_m &= P_{m-1} (1 - |k_m|^2) \end{aligned}$$

donde

$a_{m,i}$  son los coeficientes AR estimados.

$P_m$  es el error de potencia de predicción  $P_p = \sigma^2$ .

$K_m$  es el coeficiente de reflexión.

### 3.2.3 Cepstrum

El Cepstrum es usualmente definido como la transformada inversa de Fourier (IFT) del logaritmo de la transformada de Fourier de una señal. El nombre de Cepstrum es derivado de invertir las primeras cuatro letras de *spectrum*. Al realizar la transformada inversa de la función en el dominio de la frecuencia, la frecuencia se convierte en el parámetro de dominio en el tiempo para este método [34].

Existen varias formas del Cepstrum, pero todas pueden ser consideradas como el espectro de

la transformada de Fourier logarítmica de una señal. Entre los diferentes tipos de Cepstrum, comúnmente se utiliza el complejo, el de potencia.

El Cepstrum de una señal  $x[n]$  es:

$$c_r[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log |X(e^{j\omega})| e^{j\omega n} d\omega \quad (3.21)$$

El cálculo del Cepstrum puede ser resumido como: señal  $\rightarrow$  FT  $\rightarrow$  abs( )  $\rightarrow$  log  $\rightarrow$  IFT  $\rightarrow$  Cepstrum.

El Cepstrum complejo de una señal  $x[n]$  esta definido como:

$$\begin{aligned} c_c[n] &= \frac{1}{2\pi} \int_{-\pi}^{\pi} \log [X(e^{j\omega})] e^{j\omega n} \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} \log [X(e^{j\omega}) + j \arg(X(e^{j\omega}))] e^{j\omega n} d\omega \end{aligned} \quad (3.22)$$

donde  $arg$  es la función continua de fase.

El Cepstrum complejo se refiere al uso del logaritmo complejo. Por lo tanto mediante el uso del logaritmo se conserva un valor real para secuencias reales.

El Cepstrum de potencia de una señal  $x[n]$  se encuentra dado por:

$$c_p[n] = \frac{1}{2\pi} \left| \int_{-\pi}^{\pi} \log |X(e^{j\omega})| e^{j\omega n} d\omega \right|^2 \quad (3.23)$$

El espectro de potencia se define como el cuadrado de la magnitud de la TF de una señal.

Si se selecciona un número de muestras entre los primeros valores del espectro de potencia esto permite encontrar la envolvente de una señal, siendo este tipo de análisis útil para el reconocimiento de voz [42]. La transformada de Fourier de los elementos produce la envolvente espectral logarítmica en términos de un factor llamado cuasi frecuencia, de la que la envolvente espectral lineal se puede obtener a través de la transformación exponencial. El orden máximo de elementos de baja cuasi frecuencia utilizado determina la suavidad de la envolvente espectral.

La ecuación 3.24 muestra la expresión cuando el número de valores  $p$  de la envolvente del espectro se calcula utilizando la IDFT . Un diagrama de bloques del algoritmo para calcular la envolvente de una señal con un valor  $p$  de cesptrales se muestra en la figura 3.3.

$$c_n = \frac{1}{p} \sum_{p=0}^{p-1} \log |e^{j\omega}| e^{i2kn/p} \quad (3.24)$$



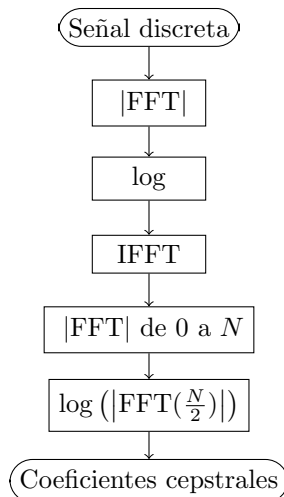


Figura 3.3: Algoritmo para calcular los coeficientes cepstrales

### 3.2.4 Redes neuronales artificiales

Las técnicas de reconocimiento de patrones basadas en redes neuronales artificiales (RNA) han sido muy estudiadas en los últimos años por demostrar un procesamiento distribuido en paralelo, que le permite hacer una decisión de un problema. Estas redes han sido inspiradas en la fisiología de la célula del sistema nervioso de los seres humanos, conocida como neurona. Análogamente con base en el cerebro humano con el cerebro humano, una RNA necesita una cantidad determinada de información para su entrenamiento y posteriormente las conexiones entre las neuronas se utilizan para almacenar información. El aprendizaje se realiza por medio del establecimiento de relaciones entre las variables de entrada con respecto a las variables de salida, siendo esta una de las características principales de las RNA, además permiten trabajar con problemas no lineales utilizando el tipo de red adecuado [44]. Posteriormente al proceso de entrenamiento la red adquiere la capacidad de generalizar ante cualquier conjunto de valores nuevos que se le presenten.

Las neuronas que conforman la red están conectadas entre sí a través de uniones caracterizadas por pesos, estos pesos junto con los valores de umbral asociados a cada neurona definen la configuración de la red. Cada nodo transforma la suma ponderada de las salidas de las neuronas de la capa anterior de acuerdo con una función de transferencia, la cual debe ser apropiada al problema que se está estudiando como la clasificación o aproximación de señales.

#### Perceptrón multicapa

El perceptrón multicapa (MLP) es una de las RNA más comunes, su funcionamiento se basa en otra red más simple llamada perceptrón simple. Con la posibilidad de tener más de una capa oculta, lo que le permite tener la capacidad de poder resolver problemas linealmente

no separables utilizando el algoritmo de aprendizaje *backpropagation* y siendo una red unidireccional *feedforward*.

En el aprendizaje del MLP utiliza un algoritmo de gradiente descendiente en el que los pesos de la red varían a través del gradiente negativo de la función de salida.

La capacidad de relacionar un conjunto de patrones de entrada y sus salidas correspondientes con la adaptación del valor de los pesos en las neuronas de las capas intermedias, hace a esta red neuronal muy útil para los problemas de clasificación.

Por las características descritas, este tipo de red es altamente aplicada en el reconocimiento de patrones, donde el entrenamiento mencionado anteriormente le permite identificar y clasificar patrones incluyendo aquellos que nunca le han sido presentados [45].

### Redes de base radial

Las redes neuronales artificiales de base radial realizan una transformación no lineal de la entrada con respecto al espacio de salida utilizando una sola capa oculta a diferencia del perceptrón multicapa que puede contener  $n$  capas ocultas. Las neuronas de la capa oculta pueden tener una función de activación de base radial con diferentes rangos de activación para los patrones de entrada, esta característica permite que las neuronas no estén activas para determinados valores de entrada [44].

Las funciones de base radial  $\phi_i(n)$  pueden ser expresadas como se muestra en la ecuación (3.25).

$$\phi_i(n) = \phi \left( \frac{\|x(n) - c_i\|}{d_i} \right) \text{ para } i = 1, 2, \dots, m \quad (3.25)$$

donde  $\|\cdot\|$  denota la distancia euclidiana,  $\phi$  es la función de base radial y  $c_i$  y  $d_i$  son los centro y la amplitud de la función de base radial respectivamente.

Existen diferentes tipos de funciones de activación de base radial, pero la mayormente utilizada es la función Gaussiana (ver ecuación 3.26).

$$\phi(r) = e^{-\frac{r^2}{2}} \quad (3.26)$$

Al ser la función Gaussiana la más utilizada, la activación de las neuronas ocultas de las redes de base radial, generalmente, es expresada como:

$$\phi_i(n) = e^{-\frac{\|x(n) - c_i\|^2}{2d_i^2}} \text{ para } i = 1, 2, \dots, m \quad (3.27)$$

### 3.3 WPT

Un paquete wavelet es una simple generalización de una transformada wavelet que utiliza un conjunto extendido de bases, el cual es obtenido tomando combinaciones lineales de las funciones wavelets usuales. Un paquete wavelet se define como una colección de funciones  $\{2^{-j/2}W_n(2^{-j}t - k), n \in \mathbb{N}, j, k \in \mathbb{Z}\}$ . El índice  $n$  es llamado parámetro de modulación,  $j$  es el índice de escala y  $k$  representa las operaciones de traslación [46, 47].

Las funciones del paquete wavelet son generadas de la secuencia

$$\begin{aligned} W_{2n}(t) &= \sqrt{2} \sum_i h_i W_n(2t - i) \\ W_{2n+1}(t) &= \sqrt{2} \sum_i g_i W_n(2t - i) \end{aligned} \quad (3.28)$$

donde  $h$  y  $g$  son los filtros de cuadratura,  $W_0(t)$  y  $W_1(t)$  son la función de escalamiento y la wavelet madre respectivamente.

Al ser la base del WPT ortonormal, los coeficientes del WPT de la función  $f$  se pueden obtener por el producto interno de la función y el correspondiente elemento base,

$$W_n = \langle f, W_n \rangle = \int f(t)W_n(t)dt \quad (3.29)$$

Para una señal discreta, la descomposición de los coeficientes del paquete wavelet pueden ser computados iterativamente como sigue:

$$\begin{aligned} x_{2n,j+1}^k &= \sum_i h_{i-2k} x_{n,j}^i \\ x_{2n+1,j+1}^k &= \sum_i g_{i-2k} x_{n,j}^i \end{aligned} \quad (3.30)$$

Un árbol binario está organizado en relación con los coeficientes provenientes de la descomposición de wavelet, donde  $h$  representa un filtro pasa bajos más una decimación y  $g$  un filtro pasa altas más una decimación (ver figura 3.4).

El WPT descompone la señal utilizando los componentes de baja frecuencia y alta frecuencia, lo que le permite conseguir para altas frecuencias una buena resolución en el tiempo a cambio de perder resolución en frecuencia y para las componentes de bajas frecuencias conocer su frecuencia aunque con ello se pierda resolución temporal.

La flexibilidad proporcionada por una abundante colección de información con arbitrariedad de resolución en tiempo-frecuencia, permite la extracción de rasgos característicos que combinan las características estacionarias y no estacionarias de la señal [46].




Figura 3.4: Arbol binario de un WPT

### 3.4 Interpolación de Hermite

En el análisis numérico, la interpolación de Hermite es un método con una función polinómica. De manera similar al polinomio de Newton, el polinomio de Hermite se deriva del cálculo de diferencias divididas [48]. La interpolación de Hermite se desarrolla, asumiendo  $h_k$  la longitud del  $k$ -ésimo subintervalo

$$h_k = x_{k+1} - x_k \quad (3.31)$$

Entonces la primera diferencia,  $\delta_k$  es

$$\delta_k = \frac{(y_{k+1} - y_k)}{h_k} \quad (3.32)$$

Siendo  $d_k$  el gradiente de la interpolación en  $x_k$

$$d_k = P'(x_k) \quad (3.33)$$

Para la interpolación lineal por pedazos  $d_k = \delta_{k-1} \delta_k$

Suponiendo la siguiente función dentro del intervalo  $x_k \ll x \ll x_{k+1}$ , expresada en términos de las variables locales  $s = x - x_k$  y  $h = h_k$ ,

$$P(x) = \frac{3hs^2 - 2s^3}{h^3} y_{k+1} + \frac{h^3 - 3hs^2 + 2s^3}{h^3} y_k + \frac{s^2(s-h)}{h^2} d_{k+1} + \frac{s(s-h)^2}{h^2} d_k \quad (3.34)$$

que es un polinomio cúbico en  $s$ , por lo tanto también en  $x$ , que cumple cuatro condiciones de interpolación, dos en la función valores y dos en los posibles valores desconocidos derivados

$$\begin{aligned} P(x_k) &= y_k & P(x_{k+1}) &= y_{k+1}, \\ P'(x_k) &= d_k & P'(x_{k+1}) &= d_{k+1}, \end{aligned} \tag{3.35}$$

### 3.5 Filtros IIR

Dentro del área de procesamiento de señales el uso de filtros digitales es utilizado en diversos tipos de señales analógicas como digitales, permitiendo el poder modificar la fase y la respuesta en frecuencia de un sistema, aplicando una serie de multiplicaciones y adiciones a la información en el dominio del tiempo. La respuesta y modificación en fase de la señal varía dependiendo del tipo de filtro utilizado [49]. Existiendo como principales filtros los que cuentan con filtros de Respuesta Finita al Impulso (FIR) y los filtros de Respuesta Infinita al Impulso (IIR).

La estabilidad que proporcionan los filtros FIR y su respuesta en fase lineal, hace que tengan un diseño menos complicado que los filtros IIR, no obstante la recursividad de los filtros IIR y una buena respuesta con una reducción de orden del filtro comparado con un FIR [50], conlleva a la existencia de muchos estudios y aplicaciones donde son de gran utilidad.

Para obtener la salida de un filtro IIR se deben utilizar los valores previos de la señal de entrada y salida. La ecuación 3.36 muestra cómo se describe un filtro IIR de una señal de entrada  $x$ .

$$y[n] = \frac{\sum_{k=0}^N b_k z^{-k}}{1 + \sum_{k=1}^M a_k z^{-k}} \tag{3.36}$$

donde

$a$  y  $b$  son los coeficientes del filtro.

$M$  y  $N$  son los polos y ceros.

### 3.6 Conclusiones del capítulo

La información del estado de una maquinaria proporcionada por las vibraciones mecánicas genera en la actualidad un gran interés en el ámbito científico, por esta razón se ha buscado establecer métodos de estudio eficientes en el desarrollo de sistemas de identificación de fallos.

En este capítulo se mencionan las herramientas de procesamiento digital de señales útiles para la extracción de rasgos característicos de señales de vibraciones. Se describió la metodología

de un modelo auto regresivo y del Cepstrum, además se incluye la descripción fundamental de los paquetes wavelet, los cuales son utilizados para comprobar resultados con las técnicas utilizadas.

Se incluye da una breve descripción de las redes neuronales artificiales utilizadas para clasificación de los rasgos característicos de las vibraciones mecánicas, el perceptrón multicapa para los LPC y la red de base radial para el Cepstrum.

# Capítulo 4

## Descripción del banco de pruebas

El objetivo del trabajo es poder analizar las condiciones de velocidad y carga a las que se encuentra sometido el tren de engranes de un aerogenerador. Sin embargo, el difícil acceso a uno que se encuentre en operación y el tener mediciones fiables de diferentes condiciones mecánicas para poder caracterizarlas, son algunas de las principales desventajas.

Por las razones mencionadas anteriormente el uso de un banco de pruebas que permita representar a los componentes principales del aerogenerador otorga una excelente opción para el desarrollo de sistemas de medición, de análisis y detección de fallos, que posteriormente puedan ser probados en un generador eólico en operación.

En este capítulo se describirá el banco de pruebas utilizado, el sistema de medición que fue implementado para la captura de las vibraciones y el sistema de control que permitió realizar la simulación física de las diferentes condiciones mecánicas estudiadas.

### 4.1 Banco de pruebas

Los aerogeneradores son máquinas rotatorias que tienen un funcionamiento con carga variable, producto de los cambios en la velocidad del viento a las cuales se encuentran sometidos. Para poder generar un ensayo controlado con diferentes condiciones de velocidad y carga, en el centro tecnológico CARTIF se realizó un banco de pruebas para la simulación de un aerogenerador en el orden de 1:61 [23], utilizando elementos comerciales que permiten representar a los componentes principales descritos en la sección 2.1.

La figura 4.1 muestra al banco de pruebas, en la parte derecha se observa un motor eléctrico (en lugar de un generador), a la izquierda del motor una reductora paralela y una reductora planetaria respectivamente; las cuales representan al tren de engranes.

El motor empleado es trifásico tipo asíncrono de jaula de ardilla y fue usado en una configuración triángulo a 50 Hz. En condiciones nominales de funcionamiento los valores de corriente, velocidad y potencia son 1.82 A, 1370 rpm y 0.37 kW respectivamente.

Las reductoras se utilizan para obtener la relación de multiplicación necesaria para el orden del aerogenerador comercial deseado. Esta relación de multiplicación se obtiene, considerando al freno colocado en el lado izquierdo del banco de pruebas como el eje acoplado a las aspas. Con base en la descripción de los componentes de la sección 2.1, es posible hacer fácilmente la analogía del banco de pruebas con esta máquina rotatoria. Al tener una reductora paralela




Figura 4.1: Banco de pruebas

como una planetaria, permite al banco de pruebas realizar el acoplamiento de los componentes y además con sus respectivas relaciones de reducción obtener en la etapa planetaria la velocidad del eje lento y en la etapa paralela la velocidad incrementada por el tren de engranes.

La carga variable a la que está sometido el tren de engranes debido a los cambios del viento presentes en cualquier instante de tiempo, fue generada con el freno mencionado anteriormente. El freno en condiciones nominales de funcionamiento tiene unos valores de corriente, voltaje y par de 9.1 A, 390 V y 10.8 Nm / 3.9 kW respectivamente.

En el anexo A se pueden ver detalladamente las características principales del resto de los componentes utilizados en el banco de pruebas.

La configuración de las reductoras se encuentra especificada en la tabla 4.1, calculando las respectivas relaciones de disminución es posible obtener la velocidad del eje lento entre 15 y 30 Hz, los cuales son valores promedio en regiones adecuadas para la instalación de aerogeneradores.

#### 4.1.1 Fallos simulados

Por estar entre los fallos más comunes en maquinaria rotatoria y ser junto con fallos en engranes los que tienen una mayor probabilidad de ocurrir en aerogeneradores, los tipos de fallos simulados en el banco de pruebas fueron los siguientes: desbalance, desalineamiento y un fallo conjunto con los máximos valores de desalineamiento más desbalance.

Para el desbalance y el desalineamiento se produjeron diferentes niveles de fallo. La tabla 4.2 muestra los valores de masa de desequilibrio en gramos y su porcentaje equivalente con respecto a la masa total del rotor del banco de pruebas, el espesor de la lámina utilizada para el desalineamiento y su respectivo ángulo de desalineamiento.



Tabla 4.1: Especificaciones de las reductoras

<b>Tipo</b>	<b>Ubicación</b>	<b>Relación de reducción</b>	<b>Número de dientes</b>
Paralela	Acoplada al motor	10.3	Piñon = 10 Engranaje = 103
Planetaria una etapa	Acoplada con la reductora paralela	5.77	Anillo = 62 Planetas = 24 Sol = 13
Planetaria dos etapas	Acoplada al freno	24.6	Primera etapa Anillo = 62 Planetas = 24 Sol = 13 Segunda etapa Anillo = 62 Planetas = 21 Sol = 19

Tabla 4.2: Tipos de fallos

<b>Desbalance</b>			<b>Desalineamiento</b>			<b>Desbalance+Desalineamiento</b>				
Tipo/etiqueta	gr	%	Tipo/etiqueta	mm	grados	Tipo/etiqueta	gr	%	mm	grados
A	5.79	0.077	A	0.75	0.78	A	28.8	0.38	2	1.53
B	9.13	0.12	B	2	1.53					
C	19.5	0.26								
D	28.8	0.38								

En el caso del desbalance más desalineamiento, como lo ilustra la tabla 4.2 fue el único fallo que se simulo bajo las máximas condiciones de desbalance y desalineamiento, con el objetivo de obtener un estudio de las vibraciones que ocurren en fallos compuestos. Para tener en la base de datos con muestras similares para las diferentes condiciones, el fallo compuesto se mantuvo constante durante un periodo de medición igual que las demás condiciones con diferentes niveles.

En la figura 4.2 se ilustra cómo se produjeron físicamente las condiciones de desbalance y desalineamiento. La flecha verde muestra una palanca fue utilizada para producir el desbalance, por medio de presión en una de las reductoras planetarias se obtuvo el porcentaje de desequilibrio con respecto a la masa del rotor. La flecha roja señala una de las láminas de diferente espesor que fueron empleadas para producir el grado de desalineamiento entre las reductoras planetarias y la reductora paralela.

Como parte de un estudio de fallos evolutivos, mediante ataques químicos corrosivos y cortes con láser, se generó desgaste en los engranajes de las reductoras planetarias y la reductora paralela. Tomando como estado inicial al engrane dañado se mantuvo al banco de pruebas funcionando durante varios días para posteriormente aumentar el valor de fallo manualmente y obtener las vibraciones correspondientes a este tipo de ensayos [23]. Para el presente trabajo




Figura 4.2: Desbalance y desalineamiento en el banco de pruebas

no se utilizaron las vibraciones de los fallos evolutivos en los engranes, únicamente las señales del engranaje paralelo con las diferentes condiciones mecánicas.

Para realizar los perfiles de carga y velocidad controlados en las fallas simuladas en el banco de pruebas es necesario un sistema de control que permita regular el par de freno y la velocidad del motor. La sección 4.2 presenta una descripción general del sistema de control empleado.

## 4.2 Sistema de control

Para garantizar las condiciones de velocidad y carga variable deseados, se realizaron perfiles en un rango aleatorio de velocidad entre 1000-1800 rpm, y entre 0-100 % de carga. Para generar los perfiles de forma automática, era necesario configurar un sistema de control que pudiera cubrir los perfiles con la mayor exactitud posible.

Al tener tanto el freno como el motor sistemas integrados de manejo, el sistema de control solo requiere modificar los valores del variador de par en el caso del freno y un convertidor de voltaje a frecuencia para modificar la velocidad del motor. Utilizando los valores de par y velocidad medidos directamente en el variador del freno, el sistema de control puede conocer las condiciones actuales de velocidad y carga para tener un esquema de control de lazo cerrado que garantice la fiabilidad de los perfiles aleatorios generados (ver figura 4.3).

Como puede ser visto en el diagrama de bloques de la figura 4.3 es necesario un dispositivo que genere y adquiera las señales analógicas como digitales del variador y del convertidor de frecuencia a voltaje. Para realizar esta tarea se utilizó una tarjeta de adquisición de datos de

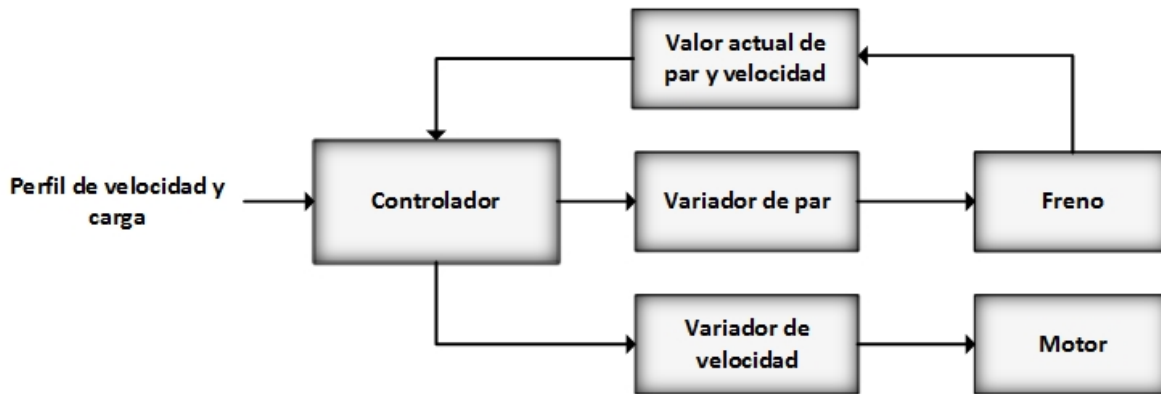


Figura 4.3: Diagrama del sistema de control

*National Instruments* modelo USB-6009 (ver figura 4.4). Este tipo de tarjetas permiten de manera adecuada el manejo de las variables digitales y analógicas necesarias para el sistema de control, con la etapa de potencia adecuada.



Figura 4.4: NI USB-6009

La tarjeta de USB-6009 ofrece funcionalidad para aplicaciones como registro de datos simple y mediciones portátiles. Las principales características de la tarjeta son:

- 8 entradas analógicas (14 bits, 48 mil muestras por segundo).
- 2 salidas analógicas (12 bits a 150 mil muestras por segundo).
- 12 Entrada y salidas digitales.
- Energizado por bus para una mayor movilidad, conectividad de señal integrada.
- 1 contador de 32 bits de alta velocidad.

Entre las ventajas de utilizar esta tarjeta de adquisición de datos, se encuentra el poder

manejar las entradas analógicas como digitales en el mismo dispositivo, la portabilidad que otorga y su bajo consumo de energía al ser alimentada por medio de una entrada usb.

Las variables utilizadas por el sistema de control son una salida analógica para el convertidor voltaje a frecuencia del motor, dos salidas digitales para aumentar o incrementar el valor del par en el variador del freno, una entrada analógica para medir la velocidad del freno y una última entrada analógica para medir el par. El uso de las variables mencionadas es para poder tener la referencia del estado actual del sistema y si cumple con los valores del perfil generado.

Un aspecto de gran relevancia en un sistema de control se encuentra en considerar la velocidad de la adquisición de datos y el tiempo requerido para la generación de las señales de control [51]. Para el caso del sistema descrito previamente los cambios en el valor de velocidad y par son después de periodos de tiempo largos, además las variaciones que tienen los controladores del freno y el motor son muy pequeñas durante un segmento de medición, es por ello que la USB-6009 es una buena opción por cumplir con los requerimientos del sistema tanto en tiempo de procesamiento como en la generación de voltaje analógico y digital.

El sistema de control con los componentes mencionados anteriormente, más algunos relevadores utilizados para el manejo de la potencia se puede observar en la figura 4.5.

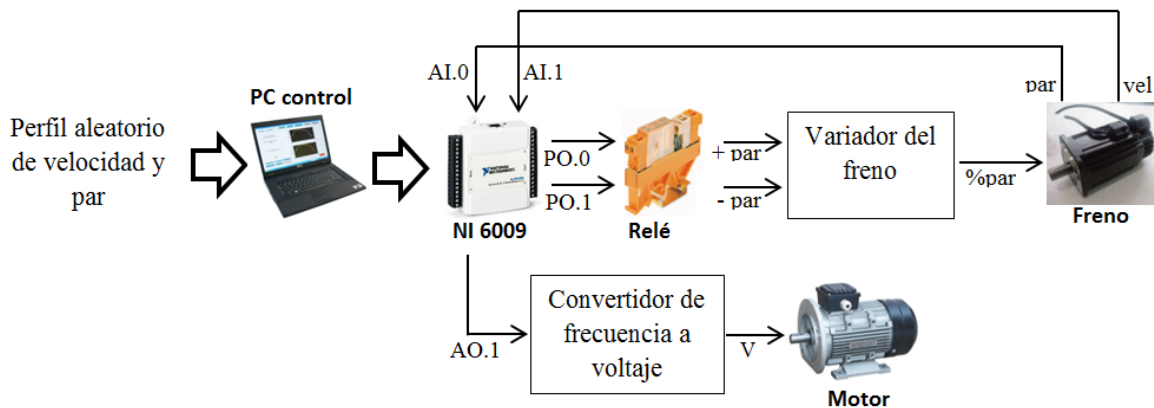


Figura 4.5: Sistema de control

### 4.3 Sistema de medición

Uno de los puntos importantes en la medición de señales físicas es contar con los elementos adecuados que conviertan las magnitudes físicas en señales digitales que puedan ser manejadas y analizadas por una computadora digital o un instrumento de procesamiento.

Basado en las necesidades del sistema de medición como son: las características de las señales, la cantidad de información que se desea almacenar, etc. Es necesaria la selección adecuada de los instrumentos y los equipos para llevar a cabo esta tarea de manera que se obtengan

registros precisos y confiables.

### 4.3.1 Arquitectura del sistema de medición

En CARTIF el sistema de medición implementado utiliza tarjetas de adquisición de National Instruments por la portabilidad y eficiencia que otorgan en estas tareas, siendo algunos de los módulos sistemas dedicados para medir señales provenientes de acelerómetros o micrófonos.

La figura 4.6 muestra la representación del sistema de medición utilizado para la adquisición de las vibraciones mecánicas de las reductoras y la velocidad del eje lento.

Para el sistema de medición la computadora encargada de la adquisición y almacenamiento es independiente de la computadora encargada de manejar al sistema de control descrito en la sección 4.2. La razón de tener dos módulos independientes fue para poder manejar a las dos tareas sin la necesidad de utilizar un equipo con una buena potencia de cómputo el cual las pudiera realizar simultáneamente. Debido a que la cantidad de información que se almacena requiere varios segundos para su procesamiento, dificulta la sincronización de las señales del sistema de control y el sistema de medición si no se cuenta con un sistema de cómputo de buen desempeño.

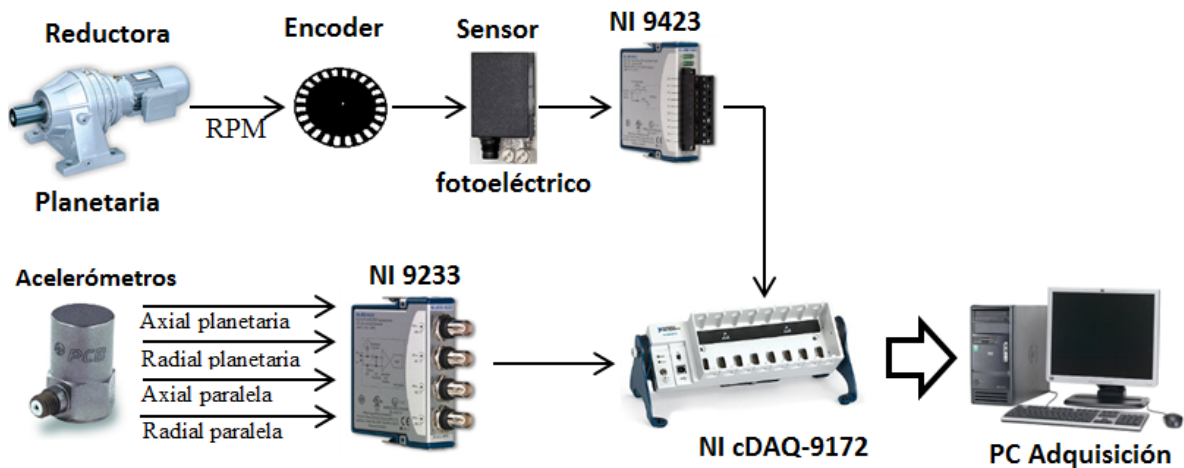


Figura 4.6: Sistema de medición

Como puede ser visto en la arquitectura del sistema de medición se utilizaron dos módulos de adquisición de datos, uno exclusivo para las vibraciones mientras que el segundo mide las rpm provenientes del eje lento, que como fue mencionado en la sección 4.1 es representado por la etapa planetaria.

### 4.3.2 Adquisición de las vibraciones

Para la adquisición de las señales de vibraciones se utilizaron 4 acelerómetros piezoeléctricos modelo ICP 352C65 de la marca PCB Piezotronics, los sensores fueron colocados en la posiciones axial y radial de las reductoras. Las principales características de los acelerómetros son las siguientes:

- Sensor miniatura (2 gm) de alta sensibilidad
- Sensibilidad: ( $\pm 10\%$ ) 100 mV/g
- Rango de medición:  $\pm 50$  g pk
- Rango de frecuencia: ( $\pm 5\%$ ) 0.5 - 10 KHz
- Peso: 2.0 g

La selección del sensor tipo industrial fue por sus características físicas y de operación, ya que cuentan con un rango en frecuencia amplio (0.5 - 10 KHz), el cual cubre las especificaciones necesarias para la medición de vibraciones en maquinaria rotatoria. Entre sus principales ventajas se encuentran una alta sensibilidad, un diseño resistente, un tamaño y peso reducidos para poder permitir su fijación sin que interfieran en las simulaciones realizadas.

El montaje de los acelerómetros fue realizado mediante fijación por perno en las reductoras, este método se emplea para medir vibraciones en una banda de altas frecuencias, las cuales se necesitaban para poder analizar los daños en engranajes, lo que requiere garantizar una frecuencia de resonancia alta. La colocación física de los acelerómetros se puede apreciar en la figura 4.1.

Los acelerómetros se emplean para el monitoreo permanente de las vibraciones en maquinarias y estructuras, debido a que garantiza un desempeño óptimo, al no limitar el rango de temperatura en que pueden ser operativos; lo que les permite medir altos niveles de vibraciones.

### Módulo de adquisición de datos NI 9233

En el sistema de medición se utiliza una tarjeta de adquisición de datos NI USB-9233. Esta tarjeta cuenta con un microprocesador y cuatro canales para hacer mediciones de alta precisión, mediante sensores IEPE. Tiene un rango dinámico de 102 dB, además incorpora un acondicionamiento de la señal para acelerómetros y micrófonos el cual evita la adición de un ruido mayor al que estos sensores tienen al realizar mediciones.

Una de las capacidades de mayor relevancia de esta tarjeta es la adquisición simultánea de sus cuatro canales con rangos de 2 a 50 kHz, los cuales poseen filtros digitales anti-aliasing que se

ajustan automáticamente a la frecuencia de muestreo. El ADC interno es de tipo delta-sigma con una resolución de 24 bits, el ADC.

En el anexo B, se muestran las especificaciones detalladas de la tarjeta de adquisición de datos. La figura 4.7 ilustra la tarjeta de adquisición de datos NI USB-9233.



Figura 4.7: NI 9233

Entre las características que hacen conveniente esta tarjeta para haber sido seleccionada en el sistema de medición son: el bajo consumo de energía eléctrica que requiere, puesto que se alimenta del puerto USB de la computadora a la cual sea conectada, la portabilidad que ofrecen para poder ser utilizadas en distintos tipos de ambiente de medición y la posibilidad de tener una adquisición simultánea con el acondicionamiento de señal necesario para los acelerómetros empleados.

### **Frecuencia de muestreo y tiempo de medición**

La velocidad del rotor usualmente se encuentra asociada con el valor mínimo de frecuencia a ser analizado. La velocidad mínima del eje lento del banco de pruebas estudiado es aproximadamente 15 rpm (0.25 Hz), es por ello que, con un mínimo de precisión deseada entre 10 y 20 líneas para esta frecuencia (0.025-0.0125 Hz), los tiempos de medición deben ser entre 40 s y 80 s.

Para tener una buena precisión de aproximadamente 18 líneas se utilizó una precisión de frecuencia de 0.014 Hz, que es equivalente a un tiempo de medición de 72 s para los cuatro acelerómetros.

Para seleccionar la frecuencia de muestreo, considerando el teorema de Nyquist, el cual establece que para reconstruir una señal a partir de sus muestras la frecuencia de muestreo debe ser al menos el doble de la frecuencia del mayor armónico de la señal. Por lo tanto al no conocer en las señales al armónico mayor, la frecuencia de muestreo utilizada es de 25,600 Hz

para poder utilizar todo el rango de medición de los acelerómetros que asciende hasta los 10 KHz y sincronizar a las vibraciones con la medición de la velocidad del eje lento, el cual es muestreado a 6,400 Hz; lo que resulta en un valor de 4 veces la frecuencia de muestreo para las vibraciones.

#### 4.4 Medición de la velocidad del eje lento

La velocidad del eje lento fue medida con un sensor fotoeléctrico láser modelo OJ5058 de la compañía IFM Electronic. El sensor utilizado funciona como un sistema de reflexión directa, que como su nombre lo indica sirve para una detección directa de objetos. Dentro de una carcasa de plástico se encuentran un emisor láser y un receptor, el emisor irradia luz que es reflejada por el objeto a reconocer y recibida por el receptor permitiendo medir la reflexión de la luz por un objeto. Entre las principales características del sensor se encuentran:

- Sistema de reflexión directa.
- Supresión de fondo.
- Alcance objeto blanco (90% de remisión): 7 – 150 mm
- Objeto más pequeño detectable:  $\varnothing$  0.8 mm
- Diámetro de punto luminoso: 0.8 mm

Para medir las revoluciones a las que el eje lento del banco de pruebas giraba, se posicionó al sensor láser en paralelo a un disco con 24 orificios. Los pasos de la luz del láser con respecto a los orificios fueron registrados obteniendo un tacómetro, de manera análoga se puede encontrar un sistema en un aerogenerador real con el uso de un sensor inductivo en lugar de un láser.

#### Módulo de adquisición de datos NI 9423

Para adquirir las señales del sensor fotoeléctrico se utilizó un módulo de entrada digital de alta velocidad 9423 de National Instruments. Esta tarjeta cuenta con 8 canales de alta velocidad a 1  $\mu$ s, donde cada canal puede recibir niveles discretos de voltaje de hasta 30 V, además ofrece una protección de sobrevoltaje transitorio de 2,300 Vrms entre los canales de entrada y la tierra.

Para poder sincronizar las señales provenientes de los dos módulos de medición es necesario adicionar un chasis que se encargue de esta tarea, conectando las dos tarjetas de adquisición de datos en un chasis NI cDAQ-9172 es posible realizar esta tarea con alta fidelidad.






Figura 4.8: Tacómetro con el uso del sensor fotoeléctrico OJ5058



Figura 4.9: NI 9423

La sincronización fue realizada automáticamente por el cDAQ, con lo cual solo fue necesario conectar a este módulo a la computadora encargada del almacenamiento de las señales para capturar las señales provenientes de las tarjetas de adquisición de datos.

En el anexo B se pueden ver detalladamente las características del chasis y el resto de los dispositivos empleados en el sistema de medición.

## 4.5 Conclusiones

La importancia de contar con un estudio controlado de fallos en maquinaria rotatoria que opera bajo condiciones de carga y velocidad variable, llevo al centro tecnológico CARTIF a desarrollar un banco de pruebas con componentes comerciales con la configuración de un

aerogenerador comercial a escala.

El sistema de medición y el sistema de control fueron realizados con el uso de dispositivos capaces de responder a las necesidades de las señales que se necesitaban analizar, con una buena capacidad de integración y exactitud en sus mediciones.

Los fallos generados en las reductoras fueron desalineamiento, desbalance y un fallo conjunto con los máximos valores de desalinamiento y desbalance.

# Capítulo 5

## Procesamiento y análisis de datos

La respuesta en frecuencia de los acelerómetros y la tarjeta de adquisición de datos cumplen con los rangos de frecuencia necesarios para medir las vibraciones mecánicas, es por ello que una vez obtenidas las señales de las vibraciones con las características en tiempo y frecuencia mencionadas en el capítulo 4, es necesario realizar el procesamiento y análisis de las vibraciones obtenidas de la base de datos mediante los métodos que serán comparados.

Para implementar y analizar los diferentes enfoques estudiados se hizo uso de MATLAB 2012a, el cual es un lenguaje de alto nivel que cuenta con un entorno interactivo para el cálculo numérico, la visualización y la programación. Las principales ventajas de usar este software matemático, son la posibilidad de desarrollar algoritmos, crear modelos o aplicaciones y que además cuenta con herramientas optimizadas de procesamiento de señales como el caso de los LPC donde tiene incorporada una función de cálculo en las herramientas de procesamiento de señales.

### 5.1 Análisis mediante la FFT

En el capítulo 3 se describió la transformada de Fourier, presentado en la ecuación 3.10 la expresión que define a la transformada para un número de muestras finito. La importancia de la FFT en el procesamiento de señales, es por ser considerada como núcleo central del análisis de señales y sistemas. La FFT es un método que consiste en llevar una señal real variante en el tiempo y dividirla en componentes, cada una con una amplitud, fase y frecuencia.

En la teoría de Fourier cualquier forma de onda sin importar su complejidad, puede ser expresada como la suma de ondas sinusoidales de varias amplitudes, fases y frecuencias.

La figura 5.1 muestra la FFT de una señal del banco de pruebas para un estado sin falla mecánica. Es importante recordar que como fue descrito en el capítulo 4 la transformada de la señal muestra que existe una gran cantidad de armónicos que a diferencia de maquinaria rotatoria sencilla como los motores, la cantidad de componentes es mayor por los efectos de la carga variable.

Para el propósito de análisis del trabajo se hace uso de los armónicos de baja frecuencia de las señales, esto debido a que aportan la mayor cantidad de información del estado de las reductoras sin tener que enfocarse en las componentes de alta frecuencia, a diferencia del análisis de fallos en engranajes donde es necesario utilizar armónicos de alta frecuencia.

Para reducir la cantidad de información y frecuencias que no se consideran de relevancia para

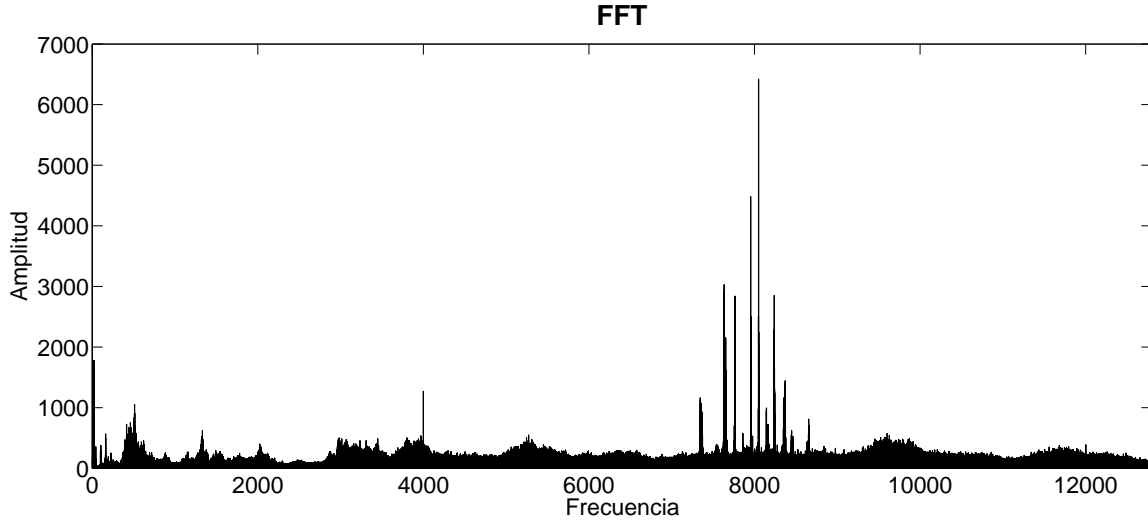


Figura 5.1: FFT de una señal sin fallo mecánico

el caso de estudio, con el uso de la función especializada `decimate` de MATLAB se realizó la decimación de la señal por un factor de 2.

La decimación reduce la frecuencia de muestreo por una de menor valor dependiendo el factor que se desee realizar, por ejemplo si se selecciona un decimado por 2 como en el caso del presente trabajo, la cantidad de datos se reduce a la mitad al igual que la frecuencia máxima en el espectro. Para el procesamiento los datos de entrada son filtrados con un filtro pasa bajas y después se muestrea la señal suavizada resultante a una frecuencia de muestreo menor. El filtro pasa bajas empleado por la función es un Chebyshev tipo 1 (ver ecuación 5.1) de octavo orden [52]. Para remover la distorsión de fase, se filtra la señal en ambos sentidos (hacia adelante y hacia atrás) lo que además duplica el orden del filtro.

$$|H(\Omega)|^2 = \frac{1}{1 + \xi^2 T_n^2\left(\frac{\Omega}{\Omega_c}\right)} \quad \text{para } 0 \leq \xi \leq 1 \quad (5.1)$$

donde  $N$  es el orden del filtro  $\Omega_c$  es la frecuencia de corte,  $T_N(x)$  es el polinomio de Chebyshev de orden  $N$  definido como:

$$f(n) = \begin{cases} \cos(N \cos^{-1}(x)), & 0 \leq x \leq 1 \\ \cosh(N \cosh^{-1}(x)), & 1 \leq x \leq \infty \end{cases} \quad \text{donde } x = \frac{\Omega}{\Omega_c} \quad (5.2)$$

La figura 5.2 muestra la FFT de la señal decimada, es posible apreciar en la transformada que después de los 5600 Hz las frecuencias ya no aportan datos de relevancia. No obstante, no se realizó un decimado por un número mayor para no perder los valores de frecuencia cercanos a 4000 Hz los cuales presentan amplitudes muy grandes, donde puede existir información

del estado de la máquina al realizar la extracción de parámetros con los diferentes métodos empleados.




Figura 5.2: FFT de la señal decimada por 2

## 5.2 Ventaneo

Las funciones de ventaneo se utilizan con el fin de evitar discontinuidades introducidas al analizar solo una fracción de la señal o al introducir muestras con valor de cero que introducen componentes de alta frecuencia en el espectro [4].

Por el hecho que la transformada de Fourier asume que la señal es periódica, es muy recomendable realizar el ventaneo a la señal que se va a utilizar.

Para este trabajo se utilizó la función de ventana de Hanning, por su buen funcionamiento con señales de vibraciones que pueden ser descritas como procesos aleatorios no estacionarios. La ventana es definida como un vector columna  $\mathbf{w}$  de tamaño  $L$ , la ecuación muestra la ecuación utilizada para el cálculo de los coeficientes de la ventana de Hanning.

$$w(n) = 0,5 \left( 1 - \cos \left( 2\pi \frac{n}{N} \right) \right), \text{ para } 0 \leq n \leq N \cos \quad (5.3)$$

donde la longitud de la ventana es  $L = N + 1$  y  $N$  es la longitud de la señal de entrada.

La figura 5.3 muestra una señal del banco de pruebas después de haber sido multiplicada por la ventana de Hanning, el mismo procedimiento se utiliza para todas las señales de la base de datos.

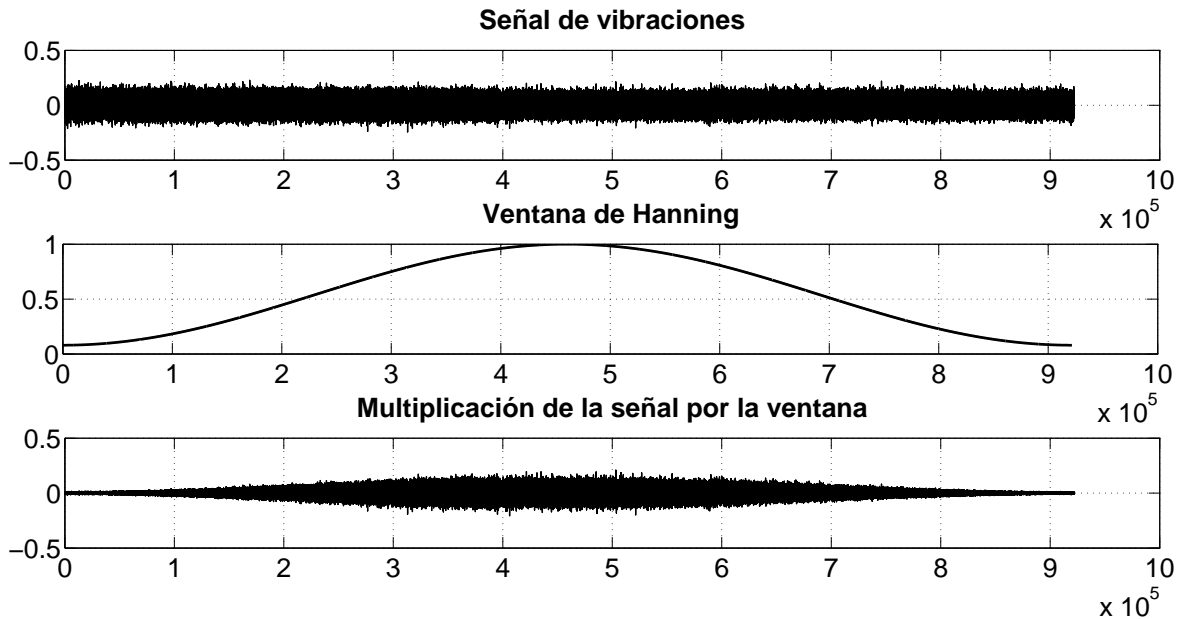


Figura 5.3: Señal multiplicada por una ventana de Hanning

### 5.3 Perfiles de velocidad y par

Con el uso del sistema de control descrito en la sección 4.2 fue posible desarrollar un perfil de velocidad y carga que tuviera la mayor aleatoriedad y exactitud posible, para poder comparar los resultados de las diferentes técnicas utilizadas en el trabajo, de la base de datos creada en CARTIF se emplearon 500 muestras de 72 segundos, lo que equivale a perfiles de diez horas para cada condición mecánica analizada.

Un ejemplo de los perfiles utilizados se presenta en la figura 5.4, por la aleatoriedad del experimento al capturar las mediciones de vibraciones y además con la selección de las muestras, existen valores de velocidad y carga que tienen un número mayor de mediciones. Sin embargo, se cumple un valor mínimo de 30 muestras para todos los posibles rangos de velocidad, lo que permite analizar todas las posibles velocidades del banco de pruebas contando con una distribución adecuada de las muestras.

Con respecto a los perfiles de carga las muestras tienen una distribución centralizada, pero de igual manera que en el caso de la velocidad existe un valor promedio de 30 señales para todas las condiciones de par. Un aspecto importante de la distribución es debido a que tanto valores pequeños y muy grandes de par son condiciones que se presentan en menor medida en un aerogenerador en operación. No obstante, es importante poder contar con mediciones de estas condiciones operativas para conocer los efectos que tienen sobre las vibraciones.

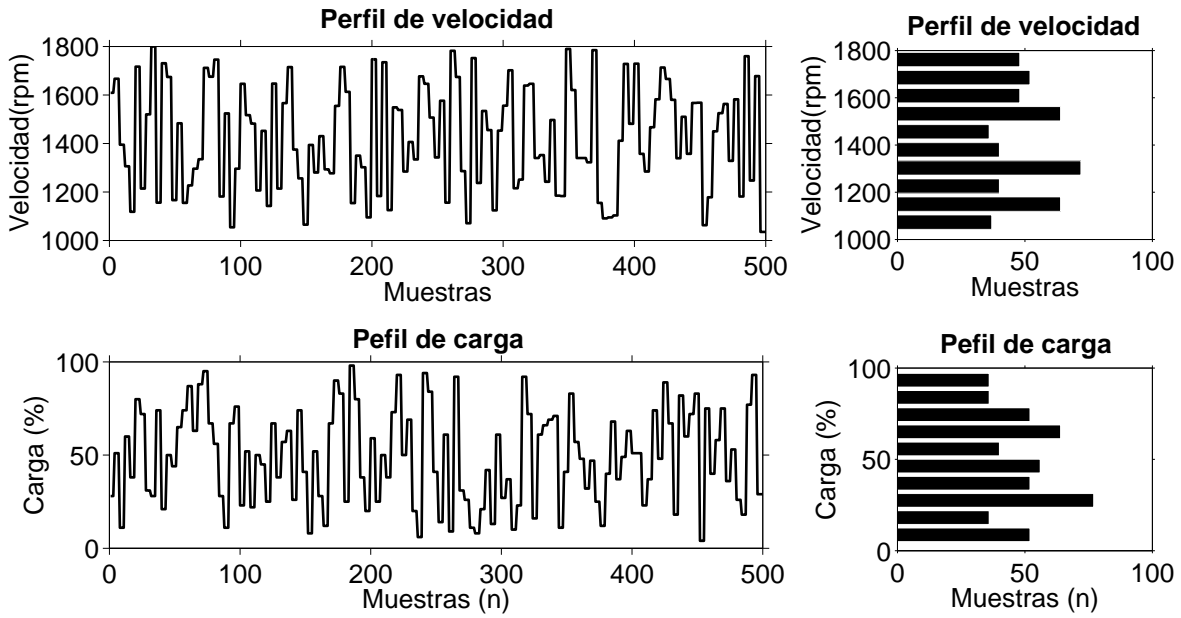


Figura 5.4: Perfil de velocidad y carga

## 5.4 LPC

Como se mencionó en la sección 4.1.1 las vibraciones utilizadas para las pruebas con las diferentes técnicas de procesamiento de señales empleadas en el trabajo son de la reductora paralela del banco de pruebas, la razón principal es porque la velocidad es mayor aumentando la magnitud de las señales de vibraciones capturadas en esta etapa.

Para analizar las vibraciones provenientes de un desbalance siguiendo lo que indica la teoría se utilizaron las mediciones de la reductora paralela provenientes de su eje radial, en el caso del desalineamiento el eje axial y para el fallo combinado se hizo uso de cualquiera de la componente axial solo por seleccionar un eje para analizar sin tener algún efecto diferente el poder utilizar al eje radial [4].

El uso de un modelo auto regresivo como son los LPC permite la posibilidad de obtener la envolvente del espectro en frecuencia de una señal, involucrando a los picos en frecuencia y valles de la señal. Con esta técnica se obtiene el porcentaje de energía que existe en una cada una de las bandas donde se encuentran las mayores concentraciones de energía que los LPC muestran dependiendo el orden del modelo empleado.

Para determinar el orden adecuado del modelo AR se realizó un estudio comparativo del desempeño de entrenamiento obtenido por la RNA para diferentes valores de coeficientes (ver sección 6.4.1), por lo tanto con base en los resultados por el estudio, fueron estimados 15 coeficientes aplicando el algoritmo de Levinson-Durbin para todas las señales que fueron estudiadas. Los coeficientes de las diferentes condiciones mecánicas y con valores de velocidad

y carga tomados aleatoriamente pueden ser apreciados en la figura 5.5. Los resultados son clasificados en cuatro grupos, uno por cada tipo de fallo y son representados en cuatro diferentes gráficas; los diferentes colores representan una condición diferente del banco de pruebas.

Los patrones tienen una forma similar para cada tipo de fallo, no obstante, hay diferencias en ciertos puntos específicos que son perceptibles por medio de una simple inspección visual. Este hecho apoya la idea de poder clasificar los fallos empleando un modelo auto regresivo.

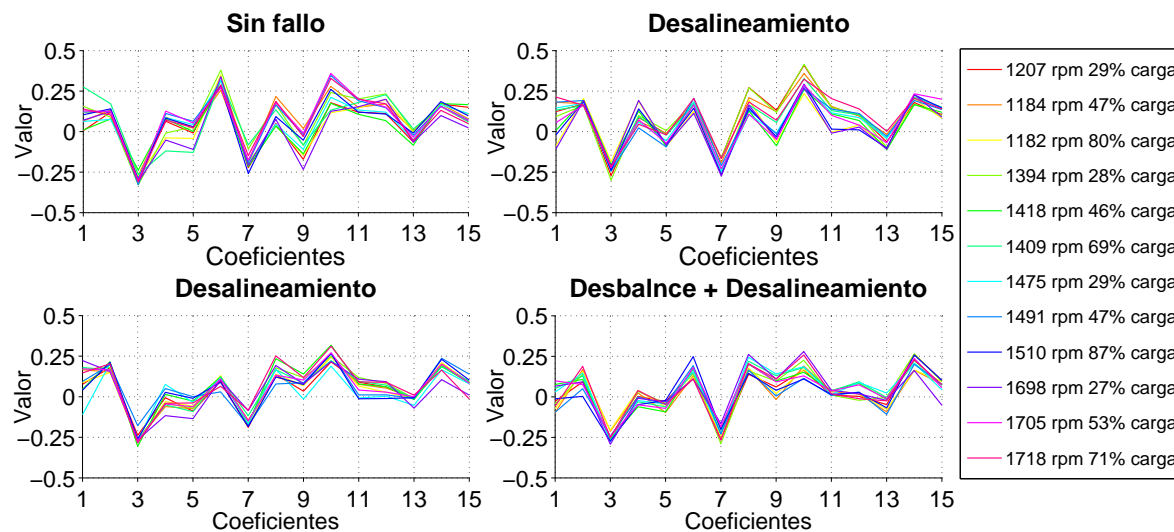


Figura 5.5: Coeficientes para diferentes valores de velocidad y carga

Los coeficientes estimados del modelo AR de orden 15 para desalineamiento con todos los posibles porcentajes de fallo, velocidad y carga se representan en la figura 5.6. El modelo estimado muestra que las variaciones en los valores de los coeficientes producto de los cambios en los armónicos de las señales. Sin embargo, los armónicos de baja frecuencia son difíciles de apreciar debido a que su valor de potencia es pequeño comparado con otras componentes en el espectro de frecuencia, principalmente en valores superiores a 500 Hz [2].

Con el uso de los coeficientes calculados, la respuesta en frecuencia del modelo auto regresivo puede ser calculada para poder comparar la similitud del espectro contra la transformada de Fourier de la señal y saber si el valor seleccionado del orden del modelo auto regresivo es adecuado [38].

La respuesta en frecuencia  $H(\omega)$  del filtro IIR descrito por los valores de los LPC se encuentra basada en la ecuación (5.4). Los coeficientes obtenidos después de aplicar la FFT son divididos termino por termino.

$$H(\omega) = \text{Re}(\omega) + \text{Im}(\omega) = \frac{\text{FFT}(1)}{\text{FFT}(A(z))} \quad (5.4)$$



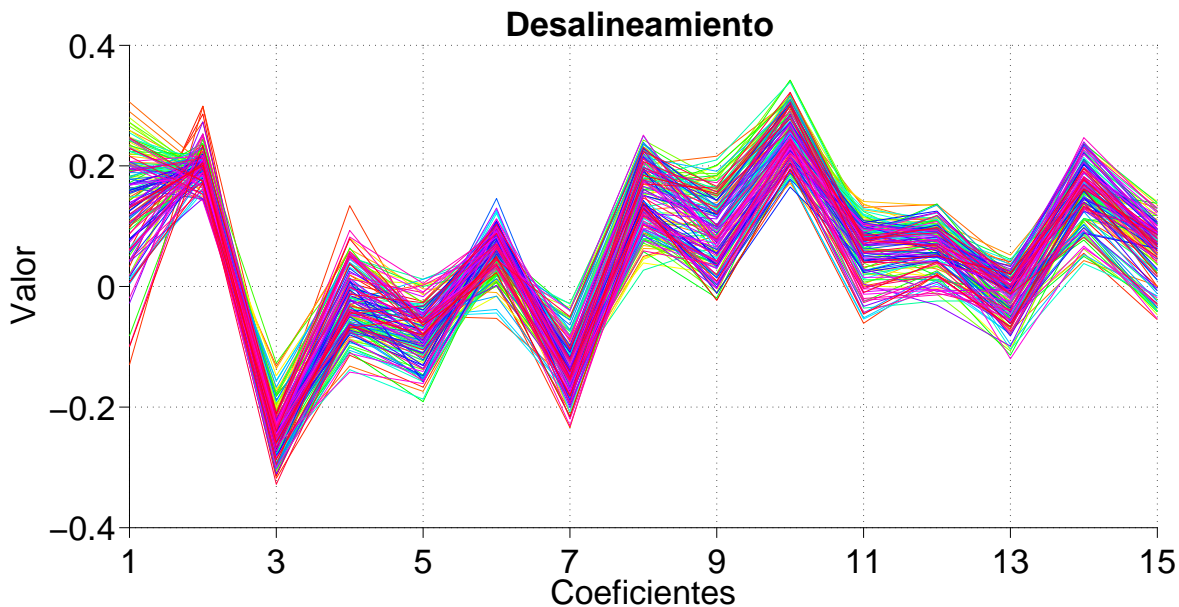


Figura 5.6: Coeficientes LPC para los 500 patrones con desalineamiento

Una FFT de 2048 puntos de frecuencia fue utilizada debido a que permite una buena precisión y disminuye el tiempo de cálculo con el uso de solo unos pocos valores, la magnitud de cada número complejo es computada utilizando la ecuación (5.5).

$$|H(\omega)| = \sqrt{\text{Re}^2(\omega) + \text{Im}^2(\omega)} \quad (5.5)$$

La figura 5.7 muestra la transformada de Fourier y la respuesta en frecuencia del filtro IIR calculadas para una medición de desalineamiento y para diferentes valores de orden del filtro  $p = (15, 30, 50, 100)$ .

Como es de esperar, utilizar un modelo de orden mayor es más preciso en los resultados de la estimación del espectro de la señal. No obstante, la información adicional capturada por con un valor de coeficientes mayor que  $p = 15$  es poco relevante para mejorar los resultados de la clasificación. Por otra parte, el aumento del orden del modelo penaliza el tiempo de cálculo, por lo tanto el orden  $p = 15$  proporciona un buen desempeño entre la caracterización del espectro y el costo computacional. Otro aspecto a considerar es que si el valor de  $p$  es mayor, la resolución del filtro tiende a parecerse a la respuesta en frecuencia obtenida mediante FFT y por lo tanto hay una mayor similitud entre señales de diferentes clases.

La estimación espectral de una señal para las tres posibles condiciones de fallo con 80% de carga y una velocidad de 1.700 rpm se puede apreciar en la figura 5.8. De esta figura, se puede llegar a apreciar que las existen diferencias sustanciales en el espectro de cada condición de fallo sin emplear a los valores más cercanos a la frecuencia de giro del eje lento (15-30 Hz), lo que

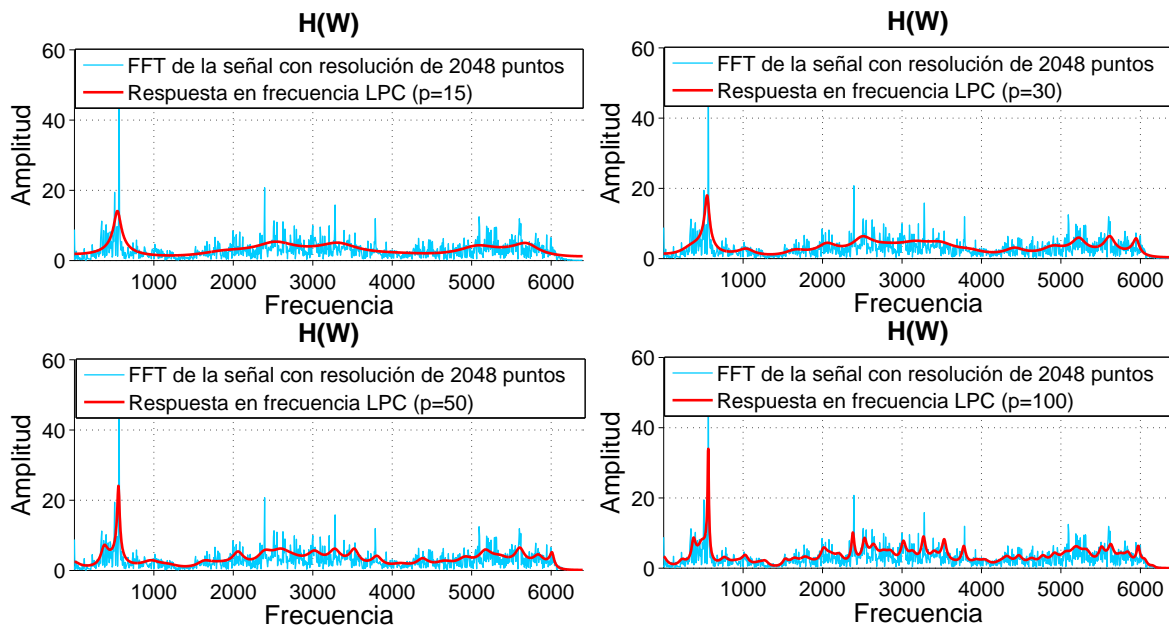


Figura 5.7: Respuesta en frecuencia para diferentes ordenes del modelo AR

permite al modelo AR ser capaz de capturar la información del patrón correspondiente a cada condición mecánica simulada.

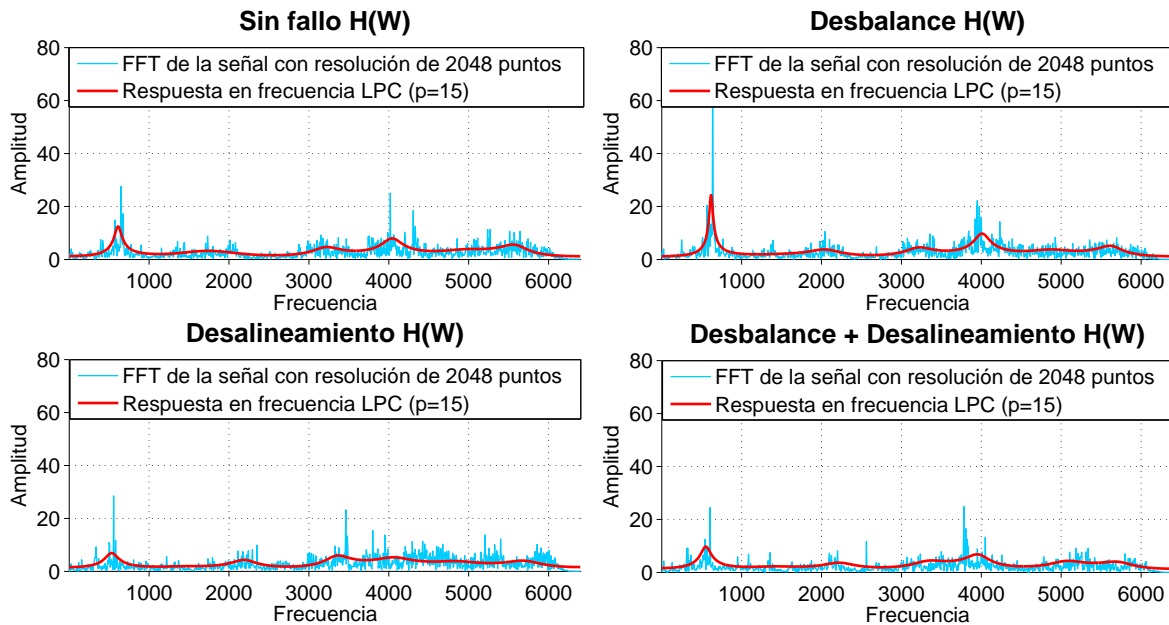


Figura 5.8: Respuesta en frecuencia de los LPC para 80% de carga y 1700 rpm

## 5.5 Cesptrum

Como fue mencionado en el capítulo 3, el Cepstrum es muy útil para el reconocimiento de voz, además de esto es empleado para caracterizar los ecos de las ondas tectónicas que provenían de terremotos y para analizar las señales provenientes de un radar, siendo un método con buenos resultados para una diversidad de aplicaciones.

El análisis cepstral en máquinas rotatorias se ha utilizado para su monitoreo bajo distintas condiciones de velocidad y carga, empleando solamente valores específicos de los mismos. En distintos trabajos ha demostrado tener buenos resultados en la clasificación de fallas mecánicas, producto de la información que aporta con respecto a los armónicos fundamentales de una señal [6, 7].

En la sección 3.2.3 se hizo mención el algoritmo empleado para calcular los coeficientes cepstrales, estos coeficientes son utilizados para obtener la envolvente de una señal y poder caracterizarla en su espectro de potencia. La figura 5.9 ilustra la aplicación del algoritmo con una señal del banco de pruebas, las fases son mostradas de izquierda a derecha empezando por la primera fila.

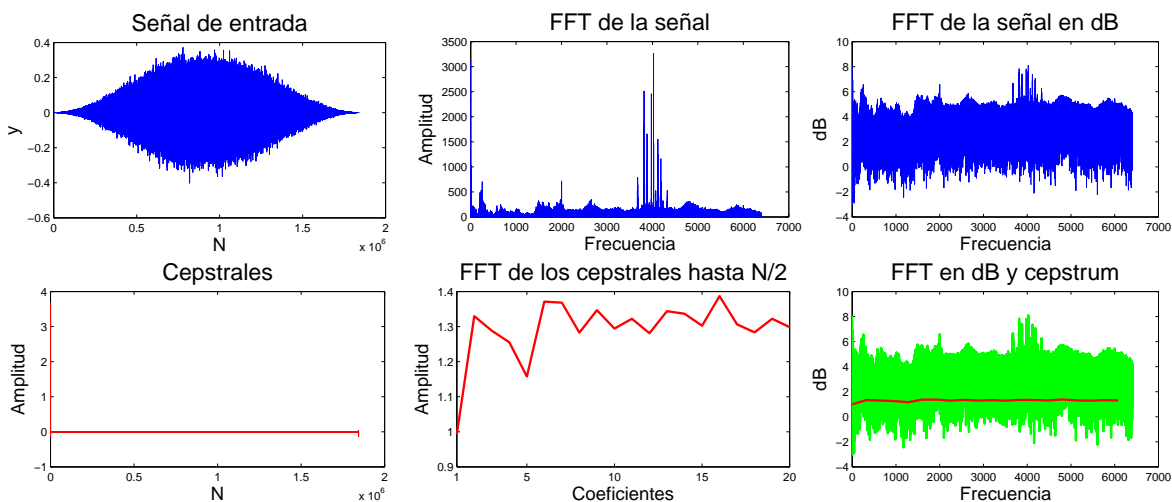


Figura 5.9: Etapas del algoritmo para calcular al Cepstrum

El procedimiento del cálculo de los coeficientes cepstrales presentado la figura 5.9 es el siguiente: primero se obtiene la FFT en decibelios (dB) de la señal ventaneada para posteriormente calcular el Cepstrum hasta una posición escogida, por último se obtiene la transformada de Fourier de ese segmento de señal en potencia, lo que genera al Cepstrum de potencia; método escogido para el desarrollo del trabajo.

Previo a obtener los coeficientes cepstrales de las señales de vibraciones del banco de pruebas, un valor  $N$  en la ecuación 3.24 necesita ser escogido. Al hacer algunos experimentos para

diferentes condiciones, fue posible apreciar que cuando el valor  $N$  es incrementado, aumenta la diferencias entre señales de la misma clase. Estas variaciones están relacionadas con el aumento de la precisión en regiones de frecuencia, haciendo que al incrementar el número de coeficientes los picos en el Cepstrum sean más susceptibles a los cambios en el espectro.

Un ejemplo de la variación entre los diferentes valores de  $N$  puede ser observado en la figura 5.10, donde se puede apreciar que cada color representa una condición diferente para un perfil de vibraciones de un estado sin fallo.

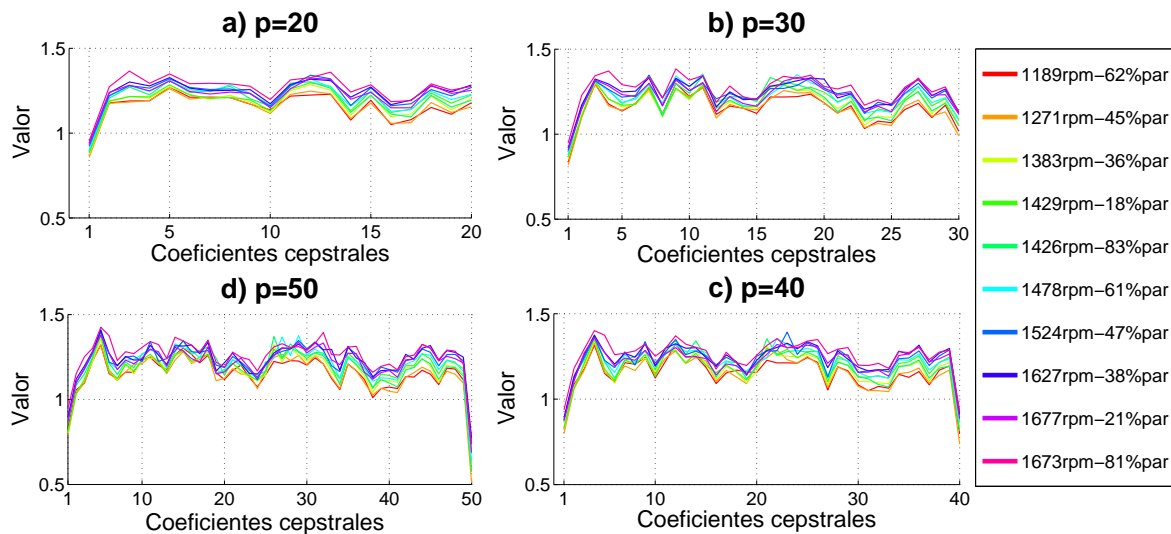


Figura 5.10: Cepstrales para diferentes valores de  $N$

Para poder tener una referencia que permita seleccionar un valor adecuado de coeficientes, la dispersión entre los coeficientes cepstrales se puede utilizar como medida de variación. Puesto que la longitud es diferente, es necesario utilizar la media de la desviación estándar calculada para los diferentes valores de  $N$ . La tabla 5.1 presenta los diferentes promedios calculados para la desviación estándar  $\sigma$ , y el coeficiente de variación  $\frac{\sigma}{\bar{x}}$ .

Tabla 5.1: Medidas estadísticas para diferentes valores de  $N$

Diferentes valores de $N$									
	20	30	40	50	60	70	80	90	100
$\sigma$	0.0949	0.0980	0.0990	0.1000	0.1005	0.1015	0.1025	0.1030	0.1025
$\frac{\sigma}{\bar{x}}$	0.1023	0.1044	0.1050	0.1038	0.1046	0.1037	0.1043	0.1047	0.1038

Los resultados muestran que los cambios de dispersión entre los coeficientes cepstrales son muy pequeños. Teniendo en cuenta los cambios mínimos de dispersión con la adición de un mayor número de coeficientes, se emplearon veinte para describir las características de las condiciones mecánicas. La razón de la elección de este valor es el uso de un valor cercano a los

LPC y a los coeficientes obtenidos mediante el paquete wavelet, para tener una comparación que también se pueda relacionar con el número de patrones extraídos por todos los métodos.

El valor de los coeficientes seleccionados se calculó para todas las señales utilizadas en este estudio. Las figuras 5.11 y 5.12 muestran la respuesta de los coeficientes cepstrales con diez señales de la base de datos para las distintas condiciones evaluadas. La figura 5.11 muestra señales con velocidad constante y carga variable mientras que la figura 5.12 presenta valores de carga constante y velocidad variable. Debido a la longitud de los datos, el espectro contiene bajas frecuencias con una pequeña amplitud y armónicos de mayor potencia encontrados a lo largo del espectro como en el trabajo hecho por Luisa et al. [2].

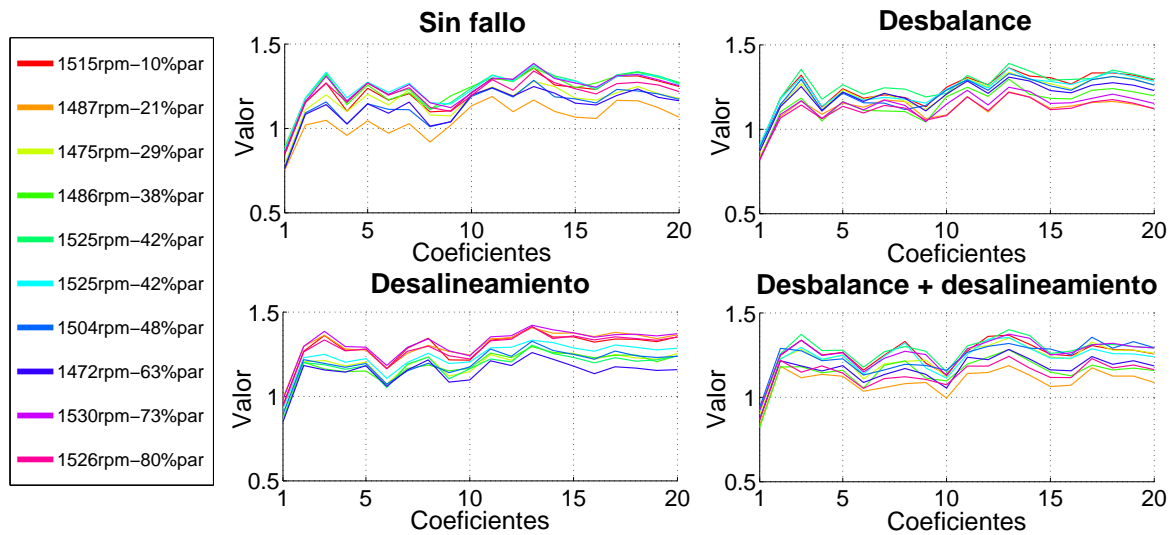


Figura 5.11: Cepstrales velocidad constante - carga variable

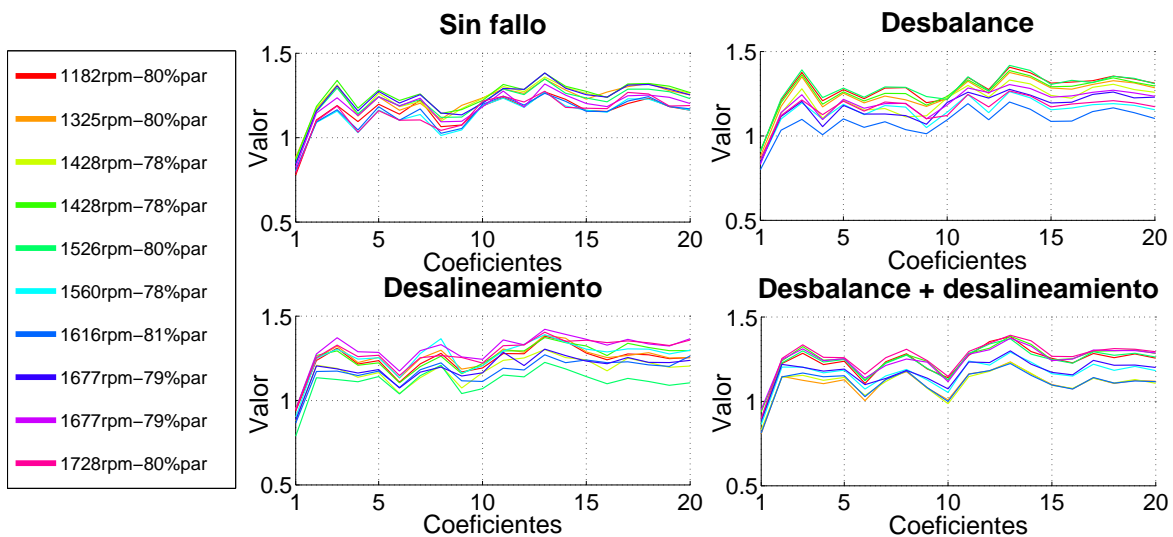


Figura 5.12: Cepstrales carga constante - velocidad variable

Como en el caso del análisis con los LPC las variaciones de los cepstrales para diferentes condiciones de velocidad y carga muestran que es posible realizar una clasificación con un algoritmo inteligente. La razón de esto es debido a que aunque las diferencias no son grandes existen valores en los coeficientes que pueden ser apreciadas visualmente lo que soporta la idea de que pueden ser un método adecuado para esta tarea.

La variación de la velocidad angular y el perfil con diferentes condiciones de carga sugiere el uso de un análisis de ordenes en lugar del Cepstrum de potencia [6, 7, 53]. No obstante, el uso de este método sin el remuestreo de ordenes produce buenos resultados con un pequeño número de coeficientes, ya que la longitud de las señales empleadas, el número elevado de armónicos y a la gran cantidad de energía distribuida en el espectro, oculta los primeros armónicos que son los órdenes comúnmente analizados a partir del orden 1x hasta el 10x.

Métodos estadísticos han sido utilizados para analizar diferentes parámetros de las señales de vibraciones, con regresión lineal u otros métodos para seleccionar los valores más significativos. No obstante, poco trabajo ha sido reportado en la literatura que haga uso de condiciones como las presentadas, haciendo de este enfoque una buena opción para poder analizar su rendimiento y limitaciones.

## 5.6 WPT

Para realizar una comparación de los resultados y el desempeño en los tiempos de cálculo del LPC y el Cepstrum es necesario utilizar un método que haya sido empleado en condiciones como las presentadas en el trabajo y con buenos resultados. La técnica seleccionada para la comparación fue el WPT, este método realiza una extracción de información en el dominio tiempo-frecuencia y además tiene la ventaja de poder caracterizar señales con componentes estacionarios y no estacionarios.

Existen una gran variedad de métodos de clasificación de señales que combinados con WPT pueden extraer rasgos de vibraciones mecánicas, es por ello que de la literatura se empleó un trabajo relevante en la caracterización y clasificación de fallos en maquinaria rotatoria. El método propuesto Rafiee et al., [36] emplea la desviación estándar de los coeficientes obtenidos del último nivel de un paquete wavelet.

### 5.6.1 Wavelet

La wavelet empleada por Rafiee et al., fue una función wavelet Daubechies de cuarto orden (db4), por el hecho de que ha sido utilizada exitosamente en otros estudios sin importar el orden de la wavelet, ya que esto no incrementa el costo computacional.

Los coeficientes de la wavelet db4 son obtenidos como:




Figura 5.13: Daubechies wavelet de orden 4

$$\alpha_0 = \frac{(1 + \sqrt{3})}{4 + \sqrt{2}}, \alpha_1 = \frac{(3 + \sqrt{3})}{4 + \sqrt{2}}, \alpha_2 = \frac{(3 - \sqrt{3})}{4 + \sqrt{2}}, \alpha_3 = \frac{(-1 - \sqrt{3})}{4 + \sqrt{2}}. \quad (5.6)$$

La función de escala es definida para un  $M$  número de coeficientes del filtro wavelet  $\alpha_k$  for  $k = 1, 2, \dots, M - 1$  por

$$\phi(t) = \sum_{k=1}^{M-1} \alpha_k \phi(2t - k) \quad (5.7)$$

y la correspondiente wavelet

$$w(t) = \sum_{k=1}^{M-1} (-1)^k \alpha_k \phi(2t + k - M - 1). \quad (5.8)$$

Una representación gráfica del cálculo de los coeficientes y de la función de escalamiento de la db4 se puede apreciar en la figura 5.13. Este tipo de wavelets son de la familia de tipo ortogonal, donde la función de escalamiento y la wavelet no tienen una simetría lo que puede notar en su gráfica; siendo la wavelet de Haar la única que es simétrica de esta familia.

De igual manera que el orden de la wavelet se encuentran los niveles del WPT, como se mencionó en el capítulo 3 el procesamiento para obtener los diferentes niveles del paquete wavelet. Rafiee utilizó un árbol de 4 niveles y de ellos empleo el último nivel, a las 16 señales obtenidas por el WPT se les calcula su desviación estándar (ver figura 5.14) y este es el vector de rasgos que se utiliza para la clasificación por medio de un MLP.

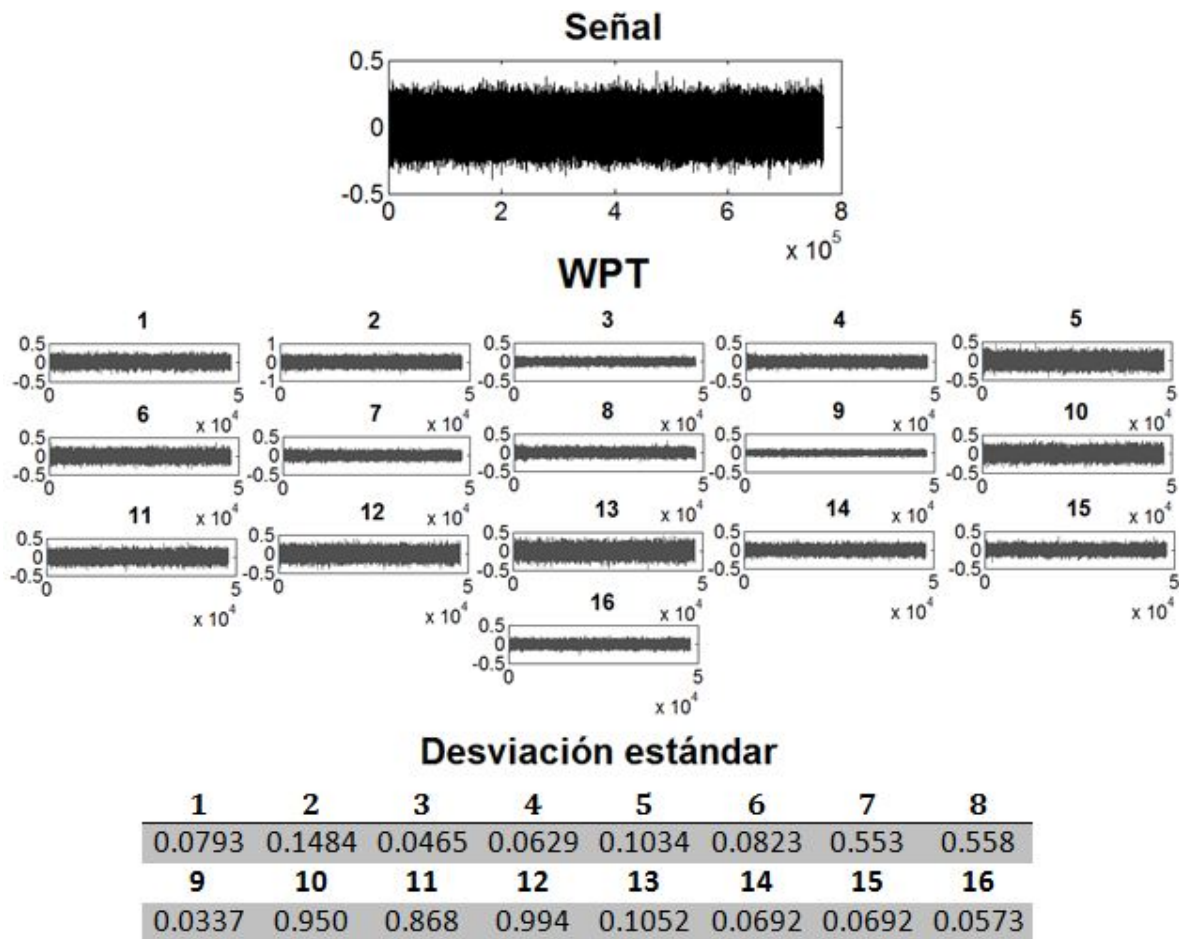


Figura 5.14: Cálculo de la desviación estándar de los coeficientes de un WPT

## 5.7 Conclusiones

En el capítulo se hizo una descripción de los métodos empleados para el procesamiento de las señales de vibraciones. En un primer análisis con el uso de la FFT se pudo apreciar que por la gran cantidad de información que contenían los archivos de medición y por el hecho que el trabajo desarrollado no identifica fallos en engranajes se realizó la decimación de las señales por un factor de dos. El uso del desimado disminuye las altas frecuencias del espectro (utilizadas para fallos en engranajes) las cuales no se emplean en el procesamiento y conserva las bajas frecuencias más un buen rango de frecuencia para poder estudiarlo.

Los métodos de procesamiento utilizadas permiten obtener la envolvente del espectro en frecuencia y en el espectro de la potencia para los LPC y el cepstrum respectivamente. Lo anterior les permite poder caracterizar las diferentes condiciones mecánicas con solo unos pocos valores, aminorando el costo computacional generado.

Por último se describe un método reportado en la literatura, el cual obtiene los rasgos de las



señales de vibraciones con la desviación estándar de los coeficientes de un WPT, lo que ha sido empleado exitosamente en la clasificación de fallas mecánicas en maquinaria rotatoria. Este trabajo sirve para poder realizar una comparación de los resultados obtenidos en el presente trabajo.

## Capítulo 6

# Reconocimiento de patrones y redes neuronales artificiales

Los sistemas de monitoreo y el reconocimiento de patrones en señales de vibraciones para la detección de fallas en maquinaria rotatoria han sido en varios sectores industriales, de los cuales se han obtenido importantes beneficios económicos al evitar mantenimientos innecesarios y paros inesperados en la producción.

Para la detección de fallos en la actualidad es posible adaptar un algoritmo automático e inteligente, capaz de reconocer medidas de vibración, por ejemplo, mediante características de la forma de onda de la señal en el dominio del tiempo, en el dominio de la frecuencia y el dominio frecuencia-tiempo.

Las redes neuronales artificiales son un uno de los algoritmos de análisis inteligentes de mayor popularidad en la actualidad y han sido usadas exitosamente en diversas áreas, como en la detección de fallas incipientes en maquinaria. Existe una gran diversidad de estructuras y topologías de redes neuronales de las cuales destacan la Feedforward, Kohonen, Hamming, etc. La arquitectura de la red Feedforward es la más popular por su versatilidad y la resolución de muchos problemas de clasificación que no son linealmente separables [45].

### 6.1 Metodología del reconocimiento de patrones

Para los propósitos del trabajo se requería un modelo neuronal que hiciera la clasificación de fallos en maquinaria rotatoria de una manera eficiente y sin un elevado costo computacional, para ello es necesario definir una metodología para la extracción y clasificación de las vibraciones de la reductora paralela del banco de pruebas. La metodología utilizada es la siguiente:

1. Obtener señales de vibraciones de las diferentes condiciones estudiadas, descrito en el capítulo 4.
2. Emplear los métodos de procesamiento de señales para caracterizar las señales como son los LPC, el Cepstrum y uno que emplea la desviación estándar de los coeficientes de un paquete wavelet.
3. Entrenar el sistema de reconocimiento de patrones con el uso de redes neuronales

artificiales de tipo perceptrón multicapa y de base radial, las cuales fueron seleccionadas por la eficiencia que han demostrado en trabajos de reconocimiento similares.

4. Realizar una comparativa entre los diferentes métodos de procesamiento y los modelos neuronales para la clasificación, con base en su porcentaje de reconocimiento y al tiempo de procesamiento en la extracción de rasgos.

## 6.2 Extracción de patrones

Una vez definido el número de coeficientes que se va a emplear por cada método (ver capítulo 5), es necesario verificar que existen patrones que sean significativos para que el modelo neuronal realice una adecuada clasificación.

### 6.2.1 Patrones LPC

Con el fin de apreciar claramente las diferencias entre los valores de los coeficientes para cada tipo de fallo, se realizaron gráficas comparativas donde se calcularon los coeficientes LPC para todas las señales de vibraciones, para posteriormente graficarlos con respecto a las demás condiciones. La figura 6.1 muestra a los coeficientes AR para una condición normal (en línea azul) con los estados de fallo con un diferente color (rojo para el desequilibrio, verde para el desalineamiento y magenta para desequilibrio más desalineamiento).

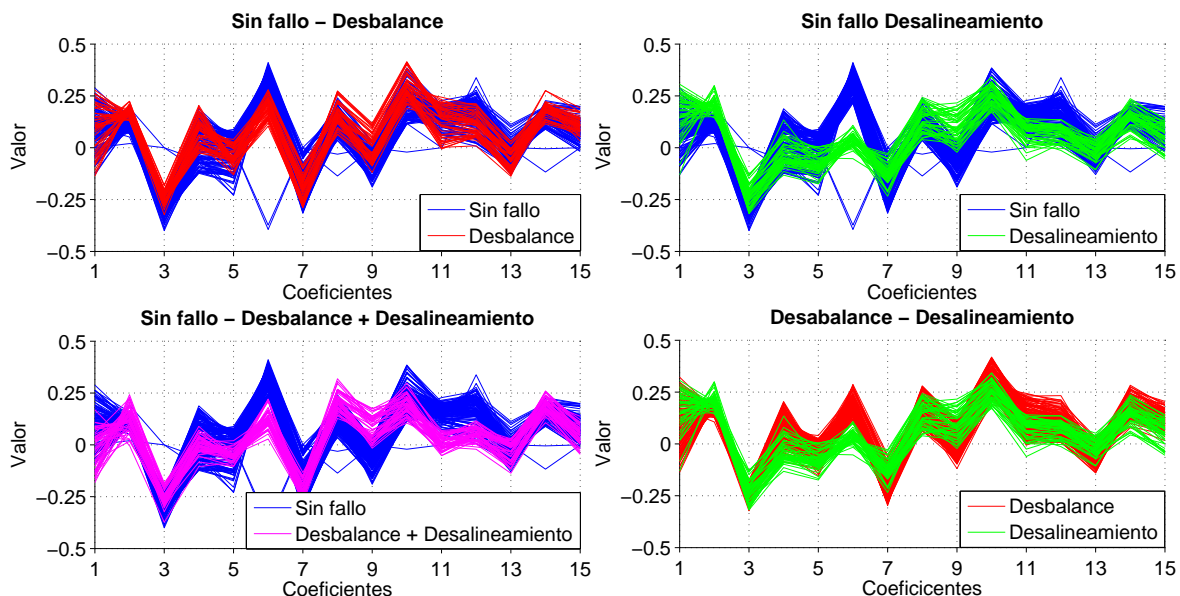


Figura 6.1: Estudio comparativo del modelo AR para las condiciones simuladas

Mediante la figura 6.1 es posible observar que existen diferencias en puntos en particular para todos los coeficientes y que además de ello en otras zonas existe una gran similitud para

los diferentes estados. Sin embargo, las diferencias que se presentan permiten realizar una clasificación con el uso de redes neuronales artificiales.

### 6.2.2 Patrones Cepstrum

Empleando un procedimiento similar al realizado para los LPC, se realizó un estudio para poder observar las diferencias de los patrones obtenidos del Cepstrum. Comparando las gráficas obtenidas para todas las condiciones simuladas es posible identificar las zonas donde el espectro de potencia representado por los cepstrales es diferente y si los patrones mantienen una forma constante sin importar las variaciones de par y velocidad.

La figura 6.2 muestra las diferentes gráficas obtenidas para este método, los coeficientes tienen una mayor similitud en forma que los LPC producto de que la potencia de las señales no tiene demasiados cambios. No obstante, existen diferencias en la magnitud y forma que son suficientes para poder realizar la clasificación.

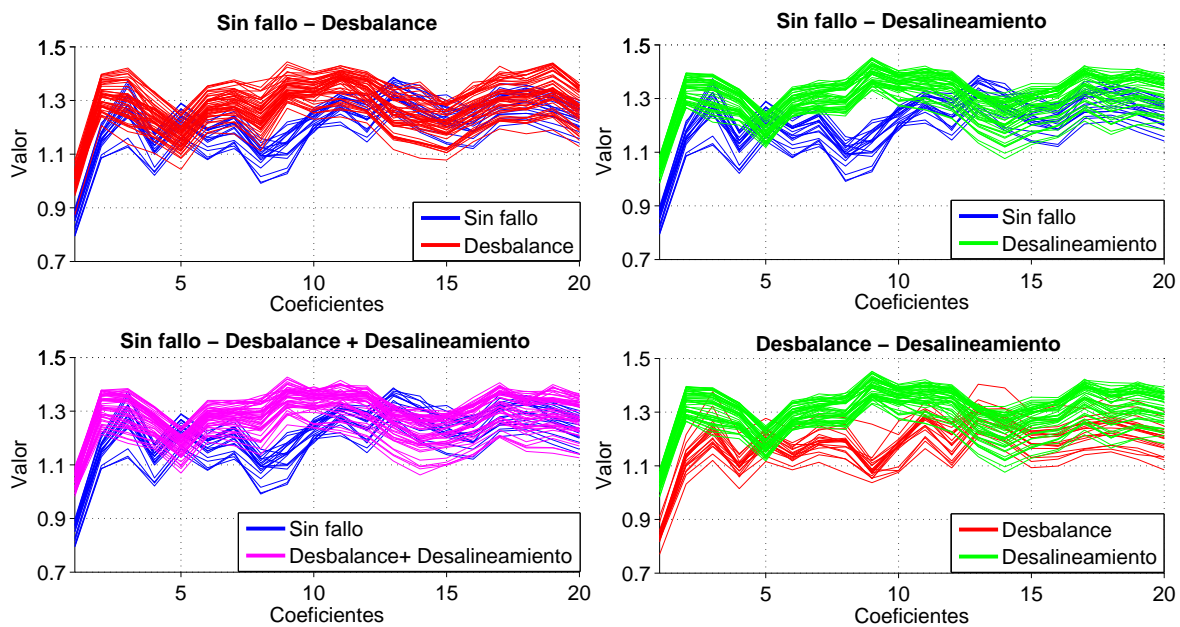


Figura 6.2: Estudio comparativo del Cepstrum para las condiciones simuladas

Figuras a mayor detalle de los patrones de los coeficientes cepstrales y los LPC pueden ser apreciadas en el anexo C.

### 6.2.3 Patrones WPT

Para poder comparar los resultados de la extracción de patrones con el uso del paquete wavelet, se calculó la desviación estándar promedio de las diferentes condiciones y con ello poder determinar si existían diferencias que fueran significativas. La tabla 6.1 muestra las

desviaciones promedio de los patrones de entrada, las celdas sombreadas de rojo corresponden a valores donde existen diferencias para todas las condiciones.

Tabla 6.1: Desviación estándar promedio de las diferentes condiciones simuladas

$\sigma$								
	1	2	3	4	5	6	7	8
<b>S-F</b>	0.1593	0.0314	0.0094	0.0159	0.0131	0.0103	0.0085	0.0075
	<b>9</b>	<b>10</b>	<b>11</b>	<b>12</b>	<b>13</b>	<b>14</b>	<b>15</b>	<b>16</b>
	0.0065	0.0272	0.0091	0.0256	0.0149	0.0180	0.0073	0.0148
	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>
<b>DB</b>	0.0637	0.0617	0.0185	0.0306	0.0239	0.0189	0.0187	0.0159
	<b>9</b>	<b>10</b>	<b>11</b>	<b>12</b>	<b>13</b>	<b>14</b>	<b>15</b>	<b>16</b>
	0.0164	0.0609	0.0168	0.0478	0.0299	0.0353	0.0148	0.0305
	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>
<b>DS</b>	0.0677	0.0664	0.0220	0.0364	0.0223	0.0222	0.0204	0.0172
	<b>9</b>	<b>10</b>	<b>11</b>	<b>12</b>	<b>13</b>	<b>14</b>	<b>15</b>	<b>16</b>
	0.0171	0.0517	0.0251	0.0554	0.0275	0.0377	0.0263	0.0321
	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>
<b>D+D</b>	0.0396	0.0298	0.0191	0.0232	0.0123	0.0096	0.0180	0.0110
	<b>9</b>	<b>10</b>	<b>11</b>	<b>12</b>	<b>13</b>	<b>14</b>	<b>15</b>	<b>16</b>
	0.0046	0.0150	0.0089	0.0178	0.0136	0.0126	0.0104	0.0152

S-F= Sin fallo, DB= Desbalance, DS= Desalineamiento, D+D= Desbalance + Desalineamiento

Los resultados de la tabla 6.2 permiten corroborar la efectividad del método propuesto por Rafiee et al., para la identificación de fallos en una maquina rotatoria con las condiciones estudiadas, lo que le permite ser un buen método de comparación.

Otra similitud que pudo ser apreciada en los resultados fue que, como sucedió con los otros métodos las diferencias para los patrones no son muy grandes. Tanto la cantidad de tiempo de medición y la gran cantidad de armónicos presentes en las señales producen diferencias mínimas en el reducido número de coeficientes, pero ya que las redes neuronales tienen la capacidad de generalización y de poder trabajar con problemas que no son linealmente separables les permite poder clasificar patrones con diferencias pequeñas como las presentadas para todas los métodos.

### 6.3 Redes neuronales artificiales utilizadas

Las redes neuronal artificiales empleadas para la clasificación de los patrones se basan en la arquitectura de FeedForward/BackPropagation. En los patrones de los LPC se utilizó un perceptrón multicapa, en el caso del Cepstrum y el paquete wavelet fue una red de base radial

Tabla 6.2: Número de patrones utilizados por las RNA's

Distribución de patrones			
Condición	Patrones entrenamiento	Patrones validación	Patrones prueba
Sin fallo	400	200	1400
Desbalance	400	200	1400
Desalineamiento	400	200	1400
Desbalance + Desalineamiento	400	200	1400

la empleada. La selección de las RNA's no tiene ninguna causa en particular, únicamente se deseaba utilizar dos tipos de redes neuronales artificiales que tuvieran una arquitectura del mismo tipo y poder comparar su desempeño.

Antes de procesar los datos con cualquiera de las redes neuronales, la matriz de datos de entrada  $\mathbf{x}$  (ver ecuación 6.1) y las salidas deseadas son normalizadas en el rango de  $[-1, 1]$ . La normalización se realiza utilizando la expresión de la ecuación (6.2) asumiendo que los valores de entrada son finitos y que los elementos de cada fila no sean todos iguales lo que en datos como los obtenidos del procesamiento no presenta esta posibilidad.

$$\mathbf{x} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{p1} & x_{p2} & \cdots & x_{pn} \end{bmatrix} \quad (6.1)$$

donde  $p$  es el número de coeficientes calculados y  $n$  es la longitud de los patrones de entrada.

$$y_{ij} = \frac{(\bar{y} - \underline{y})(x_{ij} - \underline{x}_i)}{\bar{x}_i - \underline{x}_i} + \underline{y} \quad \text{para } i = 1, \dots, p \quad \text{y } j = 1, \dots, n. \quad (6.2)$$

donde

- $\underline{y}$  es el valor mínimo normalizado
- $\bar{y}$  es el valor máximo normalizado
- $\underline{x}_i$  es el valor mínimo de cada fila
- $\bar{x}_i$  es el valor máximo de cada fila

El criterio seleccionado para medir el desempeño de las RNA fue el error cuadrático promedio (MSE), la razón de ello fue por ser uno de los criterios más utilizados y que además otorgan

una buena referencia para el aprendizaje de las redes. El error se encuentra dado por:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - y)^2 \quad (6.3)$$

donde  $y_i$  el  $i$ -ésima neurona de salida,  $y$  es el valor deseado y  $N$  es el número de datos a evaluar.

Las etiquetas de salida según el tipo de fallo son clasificadas por las redes neuronales de la siguiente manera:

- SF. Sin fallo
- DB. Desbalance
- DS. Desalineamiento
- DD. Desbalance + Desalineamiento

### 6.3.1 Arquitectura del MLP

La determinación de la arquitectura óptima se llevó a cabo entrenando distintas topologías, con una o más capas ocultas, con distintas cantidades de neuronas y usando varias inicializaciones aleatorias de la matriz de pesos. Al realizar estas acciones se intenta disminuir la probabilidad de que el algoritmo de entrenamiento quede atrapado en un mínimo local de la superficie del error.

Para tener una adecuada referencia del adecuado número de capas ocultas para los patrones obtenidos por los LPC, se realizó un estudio de los tiempos de entrenamiento y el MSE promedio de entrenamiento, la tabla 6.3 muestra algunos de las topologías que fueron probadas. Para el estudio se empleó la siguiente potencia de computo:

- Procesador Intel<sup>®</sup> Core<sup>™</sup> i3 CPU M 380 (2.53 GHz).
- 4.0GB DDR3-1333MHZ.
- Windows<sup>®</sup> 7 Ultimate.

Los resultados de la tabla 6.3 facilitaron la selección del número de capas ocultas, debido a que para una capa oculta es posible observar que el valor de error llega un punto donde no la disminución no es reducida considerablemente, es por ello que el adicionar más neuronas a esta capa solo provocaría un sobre entrenamiento de la RNA. En los casos de utilizar dos o tres capas ocultas los resultados no cambian demasiado en tiempo como en los errores; lo cual fue la razón de emplear dos capas ocultas en el perceptrón multicapa.

Tabla 6.3: Comparación de las diferentes arquitecturas del MLP

Topologías del MLP			
Capas ocultas	Neuronas por capa	MSE	Tiempo de entrenamiento (s)
1 capa	5	0.080000	1.25
	10	0.007500	2.53
	15	0.002500	4.76
	20	0.003000	8.80
	30	0.002700	17.09
2 capas	3-3	0.002300	1.92
	5-3	0.000100	2.8
	8-5	0.000013	3.73
	10-10	0.000011	6.73
	20-10	0.000008	10.47
3 capas	5-5-5	0.000100	3.2
	5-8-5	0.000011	6.47
	8-8-5	0.000008	7.02
	10-10-5	0.000009	8.42
	10-10-10	0.000007	15.01

El procedimiento aplicado en el MLP para el entrenamiento es el siguiente, primero como se mencionó anteriormente para evitar errores en el procesamiento de la RNA es recomendable normalizar los datos de entrada y salida en valores de  $[-1, 1]$ ; es por ello que los valores del conjunto de entrenamiento y validación son normalizados. Después de haber realizado el procesamiento de los datos con la red neuronal, con el mismo procedimiento que el empleado en los datos de entrada, de la ecuación 6.2 se calcula el valor de salida con los valores de la distribución original.

Cómo se puede apreciar en la figura 6.3, el perceptrón multicapa utilizado contiene:

- Una capa de entrada con 15 neuronas.
- Dos capas ocultas con 8 y 5 neuronas respectivamente.
- Una capa de salida con 4 neuronas.

Las funciones de activación de las neuronas de la capa oculta son funciones logarítmicas sigmoideas (ver ecuación 6.4), mientras que la capa de salida emplea una función lineal que no modifica el valor de entrada que procesa.

$$\text{logsig}(n) = \frac{1}{1 + e^{-n}} \quad (6.4)$$






Figura 6.3: Topología del perceptrón multicapa

### 6.3.2 Arquitectura de la red de base radial

La red neuronal de base radial (RBF) utilizada en el presente trabajo emplea la misma estructura y funciones de activación para los cepstrales como en los coeficientes obtenidos del paquete wavelet. Su configuración contiene tres capas que incluyen la capa de entrada y la capa de salida.

A diferencia de un perceptrón multicapa, las funciones de activación de las neuronas de la capa oculta son funciones de base radial, donde la función Gaussiana es la más utilizada. En el modelo neuronal propuesto se emplean funciones Gaussianas en la capa oculta y en la capa de salida funciones de tipo tangente hiperbólica sigmoidea (ver ecuación 6.5).

$$\text{tangsig}(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (6.5)$$

Entre las ventajas de una RBF se encuentran, la posibilidad de respuesta distinta de cero entre un rango establecido por las características de la función de base radial para los valores de entrada en las neuronas de la capa oculta, el contar con número de neuronas activas pequeño para los datos de entrada y que el tiempo requerido para su entrenamiento es menor en comparación con el perceptrón multicapa.

El algoritmo de regularización bayesiana se utiliza para el entrenamiento de la red neuronal, este algoritmo maximiza el error de predicción cuadrático medio utilizando la probabilidad posterior de los pesos una vez procesados los datos. Entre sus principales ventajas permite evitar problemas temas como el sobreajuste y la selección de un modelo sin la necesidad de un proceso independiente de validación cruzada [54].

La regularización bayesiana emplea la retropropagación para calcular el jacobiano  $jX$  del

rendimiento con respecto a los pesos y a los bias (véase la ecuación 6.6). Cada variable se ajusta en función del método de Levenberg-Marquardt [55].

$$\begin{aligned}
 jj &= jX \cdot jX \\
 je &= jX \cdot E \\
 dX &= -\frac{(jj + \mathbf{I} \cdot \mu)}{je}
 \end{aligned} \tag{6.6}$$

donde

$E$  es el error

$\mu$  es el valor adaptativo

$\mathbf{I}$  es la matriz identidad

Para la selección del número adecuado de neuronas en la capa oculta de la RBF, con un estudio con la mismas características y potencia de computo que el realizado para el perceptrón multicapa se seleccionó la cantidad de neuronas para el Cepstrum como el WPT con base a los valores de tiempo y MSE promedio de los dos métodos (ver tabla 6.4). Los resultados muestran que para un número mayor a 25 neuronas, el valor del error no tiene una disminución considerable comparado con el aumento en el tiempo de procesamiento; lo cual justifica el uso de este valor.

Tabla 6.4: Resultados de entrenamiento de la RBF

Neuronas por capa	MSE	Tiempo de entrenamiento (s)
10	0.008000	10.67
15	0.006000	16.34
25	0.000015	25.23
30	0.000013	33.76
40	0.000009	42.89

La figura 6.4 ilustra la arquitectura de la RNA, donde la red de base radial contiene:

- Una capa de entrada con 20 neuronas para los cepstrales y 16 entradas para el WPT.
- 25 neuronas en la capa oculta.
- Una capa de salida con 4 neuronas.

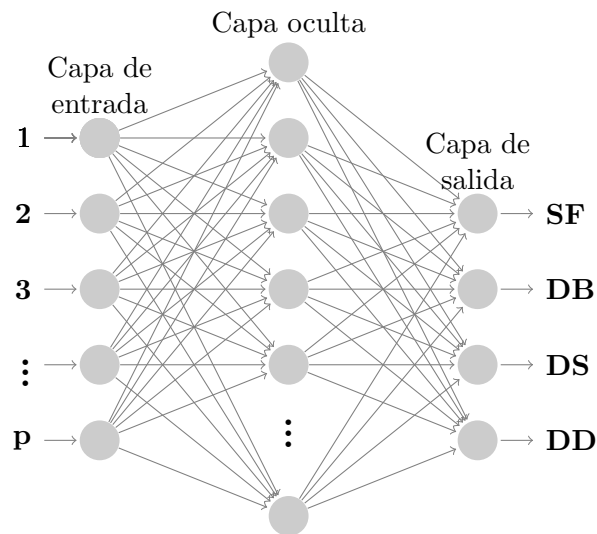


Figura 6.4: Topología de la red neuronal de base radial

## 6.4 Entrenamiento

El entrenamiento realizado para los tres métodos tuvo una convergencia al valor del gradiente mínimo establecido de una manera rápida. En la figura 6.5 se observa que el valor máximo de épocas fue de 22 para el Cepstrum, sin tener mucha diferencia con respecto a los demás métodos. Con respecto a los errores finales, todos se encuentran por debajo de  $1 \times 10^{-6}$  lo cual refleja los buenos resultados de entrenamiento de las dos redes neuronales artificiales empleadas.




Figura 6.5: Errores de entrenamiento de las RNA's para cada método de procesamiento

### 6.4.1 Búsqueda del orden apropiado del los LPC

Con el fin de analizar el número apropiado de entradas (coeficientes del modelo AR) para ser utilizados por el perceptrón multicapa, el siguiente experimento fue realizado. Para cada orden del modelo desde  $p = 5$  hasta  $p = 50$ , se realizaron entre 10 y 12 pruebas con inicializaciones aleatorias de los pesos y posteriormente realizar el entrenamiento de la RNA. Almacenando el valor promedio de los errores de entrenamiento para cada orden y por último seleccionar el error más pequeño para la comparación. El error promedio cuadrático fue utilizado para calcular los errores de entrenamiento (ecuación 6.3).

El MSE resultante para las diferentes longitudes de entradas se presenta en la figura 6.6, se puede observar que la capacidad de clasificación de la red mejora al aumentar el número de coeficientes AR empleados, pero de igual manera existe una respuesta oscilatoria para un orden del modelo mayor a 20. Este comportamiento es debido a que los resultados del experimento demostraron que el error de entrenamiento tiene un valor sobre el cual las disminuciones posteriores son muy mínimas y para algunos valores de orden tiene unos incrementos pequeños.

El buen desempeño del perceptrón multicapa para  $p = 15$  y las pocas mejoras obtenidas mediante la adición de nuevas entradas, fueron las razones para seleccionar el orden del modelo AR.

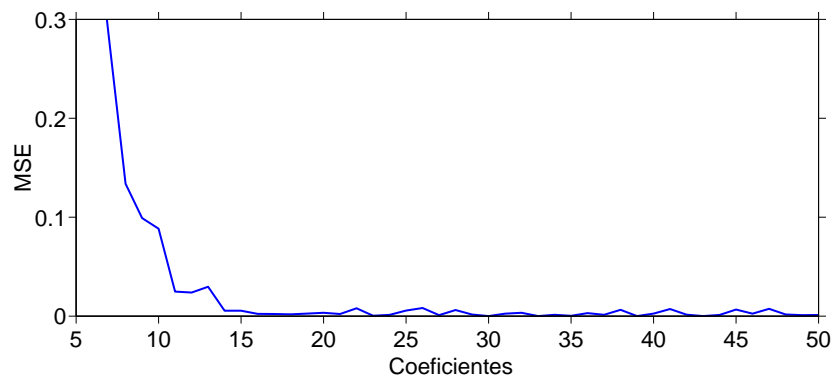


Figura 6.6: Desempeño de entrenamiento al incrementar los coeficientes de los LPC

## 6.5 Conclusiones

El reconocimiento de patrones de señales de vibraciones mecánicas en maquinaria rotatoria se ve muy beneficiado con el uso de métodos numéricos, como las redes neuronales artificiales. El proceso de entrenamiento y diseño de una red neuronal artificial requiere de un tiempo para poder encontrar una arquitectura adecuada, modificando el número de neuronas y capas ocultas como en el caso del MLP, pese a que existen algunos criterios que sirven para poder encontrar estos parámetros de forma adecuada, no existe un método específico para ello.

No obstante por su capacidad de generalización, el tiempo computacional requerido para su aplicación posterior a la fase de aprendizaje, les permiten obtener buenos resultados para el diagnóstico de fallas en la reductora paralela estudiada.

# Capítulo 7

## Resultados y discusiones

Utilizando los patrones de las diferentes técnicas estudiadas, se emplearon las 1400 señales de prueba para el sistema por cada método (ver tabla 6.2). Es posible observar en la tabla 7.1 y la figura 7.2 que los resultados de clasificación, los errores de validación y los errores prueba para los tres métodos fueron muy similares, contando los errores de prueba con las mayores diferencias.

Los resultados experimentales muestran que tanto el Cepstrum como los LPC proporcionan excelentes resultados para la extracción de los armónicos de mayor energía en el espectro, además de los altos porcentajes de clasificación para las condiciones que fueron simuladas en el banco de pruebas es importante recordar que la extracción de rasgos se realizó sin emplear el análisis de órdenes, el cual es el método mayormente utilizado para este tipo de maquinaria, pero que muchas veces en señales con un elevado número de muestras como las estudiadas tiene un tiempo de procesamiento elevado. Otro aspecto a mencionar es que los modelos neuronales utilizados consiguieron realizar la clasificación con pocas épocas de entrenamiento, lo cual confirma su rápida capacidad de generalización y el uso que tienen en trabajos de clasificación de vibraciones mecánicas [5, 7, 36].

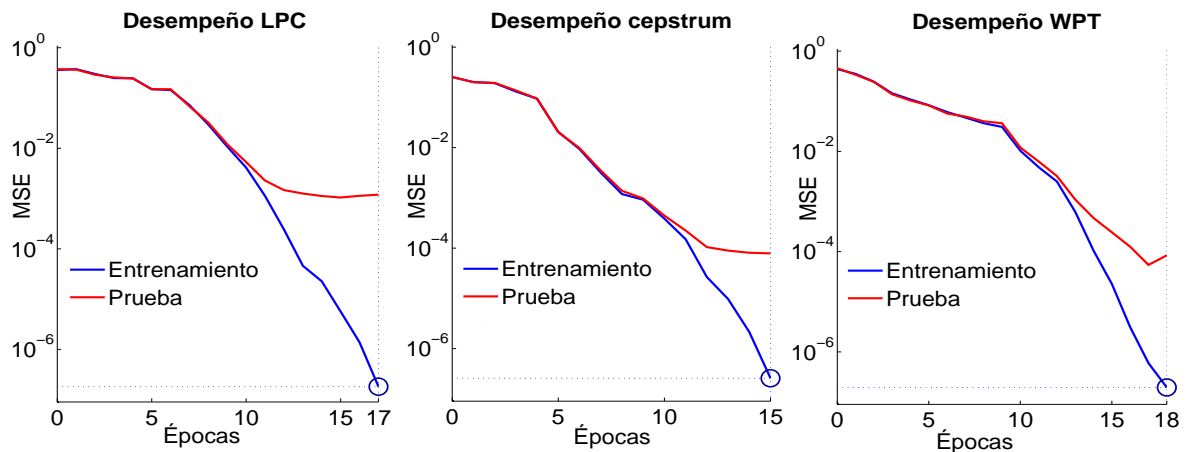


Figura 7.1: Desempeño de las RNA's

Un hecho significativo en este análisis es la adición del perfil de carga y velocidad variable, el cual no ha sido utilizado en trabajos en la literatura que emplean tanto al Cepstrum como a los LPC para la extracción de rasgos [5, 32, 6, 7] en señales de vibración mecánica. Al no poder determinar en sistemas compuestos, como es el tren de engranes de un aerogenerador los

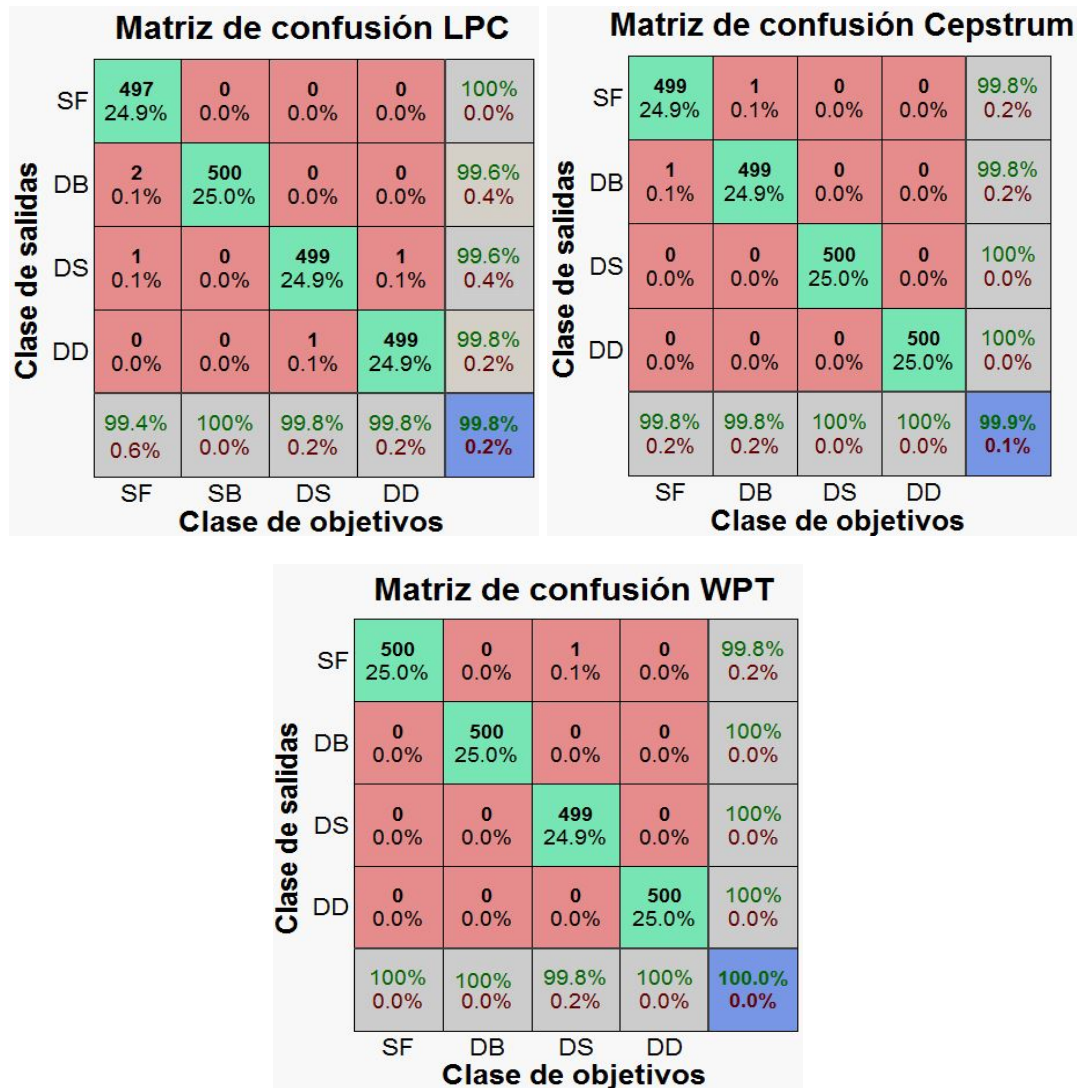


Figura 7.2: Matriz de confusión

efectos que produce la carga en las vibraciones mecánicas, la clasificación es más complicada para algunos métodos de procesamiento con la adición de estas condiciones variables.

En trabajos que fueron reportados en la literatura con el uso del Cepstrum, la mayoría de ellos emplean el análisis de órdenes para extraer un vector de características de las condiciones mecánicas; en este trabajo se propone generar un vector con el uso de coeficientes cepstrales sin el análisis de órdenes. Los errores de prueba obtenidos con el método propuesto en comparación con otros trabajos que trabajan con maquinaria rotatoria son de un valor muy similares [6, 7].

Para el caso de los LPC, en investigaciones anteriores, los sistemas de diagnóstico de fallas presentan valores de precisión aproximadamente del 96 al 98 % [5, 32]. Comparando con estos resultados, el modelo computacional presenta una precisión que se encuentra entre un promedio del 98 %.

## 7.1 Desempeño en tiempo de procesamiento de las técnicas estudiadas

Para tener un elemento adicional para la comparación de los resultados de los diferentes métodos estudiados, se realizó un estudio del tiempo de procesamiento de cada uno de los métodos para diferentes cantidades de patrones de entrada, para las pruebas se determinó el promedio del tiempo de procesamiento de 200 señales hasta 2000 (máxima cantidad de datos) con incrementos de 100 patrones cada prueba.

Con la misma potencia de computo que la empleada en la búsqueda del número de capas ocultas y neuronas de las RNA's (ver sección 6.3) se realizó este estudio. La figura 7.3 muestra el tiempo de procesamiento para cada método, tomando como base de tiempo de comparación  $x = 10s$ . Además de los tiempos de cada método se ha incluido el tiempo requerido para llevar la interpolación de Hermite, la cual es utilizada para el pre-procesamiento de las señales de vibración en el WPT [36]. Puesto que el tiempo de interpolación aumenta considerablemente dependiendo el número de puntos a interpolar y los valores de velocidad del eje de alta velocidad van desde 1000 hasta 1800 rpm, el tiempo presentado es el promedio de todas las velocidades de giro estudiadas.



Figura 7.3: Tiempo de procesamiento para el Cepstrum, LPC, WPT y PCHI

El tiempo de procesamiento en la figura 7.3 demuestra que los métodos empleados en el presente trabajo para la extracción de rasgos tienen un costo computacional aproximadamente 4 veces menor para el caso del Cepstrum y 1.33 para los LPC, en comparación con el método que emplea al paquete wavelet. Los resultados obtenidos se deben al tipo de operaciones realizadas por cada uno de los métodos, siendo el WPT el que requiere realizar los diferentes niveles de filtrado para posteriormente obtener la desviación estándar del último nivel, operaciones que necesitan más tiempo que la transformada de Fourier y calcular los coeficientes de un sistema de ecuaciones lineales como es en el caso del Cepstrum y los LPC respectivamente. Por otro lado, si además se toma en cuenta el tiempo de interpolación, que



es aproximadamente 100 veces mayor que todos los tiempos de procesamiento; los métodos utilizados ofrecen resultados similares de clasificación con un procesamiento en mucho menor tiempo.

Si se comparan los resultados entre los cepstrales y LPC, la diferencia entre ellos es de un tiempo de procesamiento 3 veces mayor para los LPC, relacionado en gran medida con las operaciones necesarias para la obtención de sus coeficientes, es por ello que el uso del Cepstrum ofrece el mejor rendimiento en tiempo y clasificación.

## 7.2 Programación e integración del modelo computacional

Es importante para la interacción del modelo con algún usuario, implementar una herramienta que permita manipular las variables de entrada, las posibilidades de procesamiento y mostrar los resultados de una manera adecuada. Las pantallas de comunicación con el usuario implementadas en el presente trabajo, fueron desarrolladas con la herramienta de programación gráfica LabVIEW 13.0. La figura 7.4 muestra la interfaz principal del instrumento virtual desarrollado para utilizar una señal de la base de datos e identificar su condición mecánica con el modelo neuronal programado. Entre las opciones que ofrece el programa es posible modificar el número de coeficientes, observar la FFT de la señal, los coeficientes del método de procesamiento seleccionado, así como la comparación de los coeficientes obtenidos contra el espectro en frecuencia y el espectro en dB para los LPC y el Cepstrum respectivamente. El diagrama de bloques correspondiente al instrumento virtual se puede apreciar en la figura 7.5.

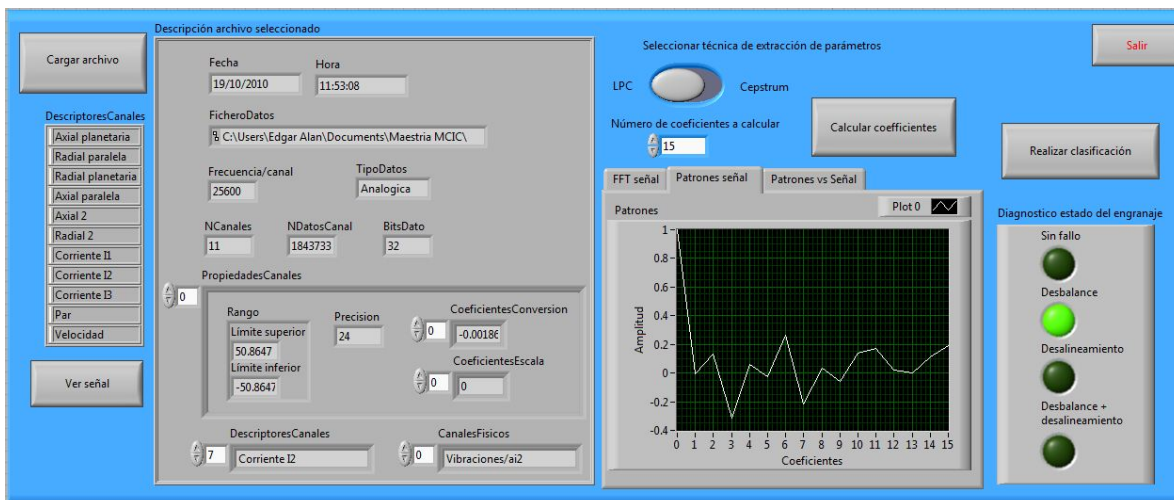


Figura 7.4: Interfaz del modelo computacional en LabVIEW

Las capturas completas del instrumento virtual pueden ser apreciadas en el anexo D.

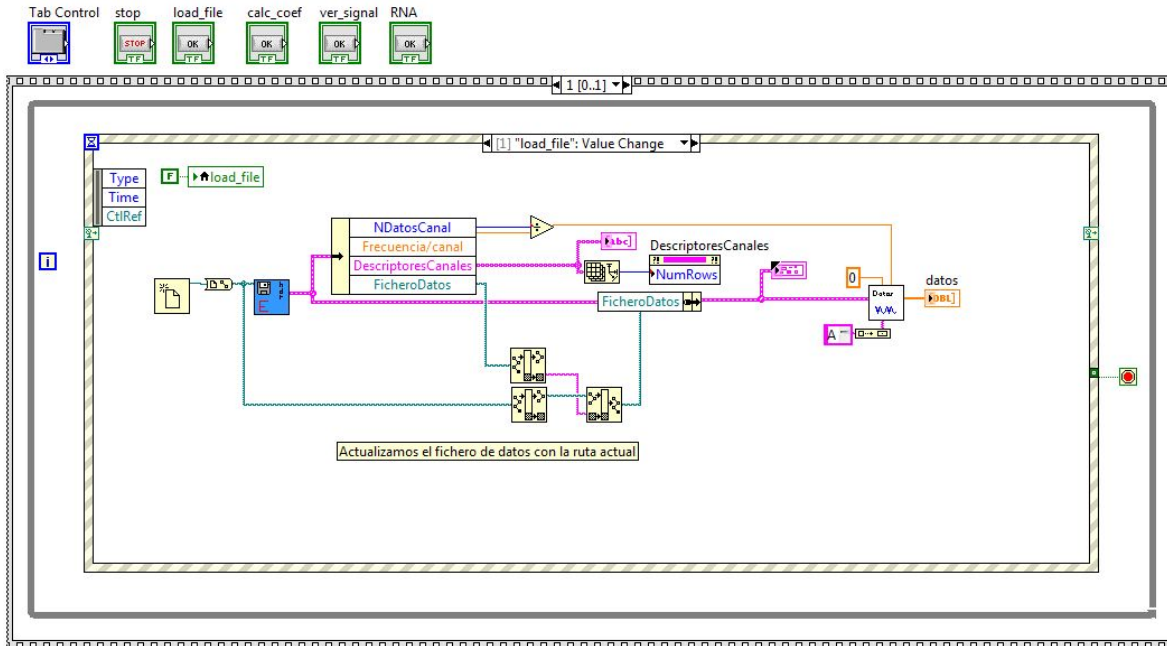


Figura 7.5: Diagrama a bloques de la Interfaz del modelo computacional

### 7.3 Experimentación con un modelo en paralelo

Trabajos que emplean modelos neuronales en paralelo con el objetivo de aumentar la robustez de un modelo computacional han sido desarrollados en la actualidad. En el área de reconocimiento de aviones se han obtenido muy buenos resultados bajo condiciones reales de medición (temperatura, presión, velocidad del viento, etc.) las cuales presentan una mayor dificultad para la clasificación [38, 40]. Es por ello que empleando una metodología similar, se decidió probar un modelo neuronal con una topología en paralelo para comprobar los resultados con el trabajo realizado.

Para poder utilizar el modelo paralelo es necesario procesar al problema en diferentes módulos utilizando diferentes métodos de procesamiento de señales, diferentes modelos neuronales, una segmentación de la señal, entre otras posibilidades. Para el caso de estudio se decidió por hacer una segmentación en frecuencia y no en tiempo como la que utiliza Sanchez et al. [40].

La segmentación se realiza dividiendo a los patrones de la base de datos dependiendo del rango para el cual se desea entrenar a la RNA, posteriormente al entrenamiento se prueba su desempeño con valores desconocidos en el intervalo más cercano; por lo que para una señal de la base de datos solo se encuentran activas dos RNA's que han sido entrenadas en el valor más cercano a esa velocidad. Al tener dos salidas es necesario un módulo de decisión que permita presentar los resultados de clasificación, la forma más sencilla es calcular la suma de las salidas de las RNA's y dividir las entre dos. No obstante, existen otros tipos de módulos

de decisión como por ejemplo el método de suma ponderada [39].

Para la cantidad de nodos del modelo paralelo se probaron dos topologías, una con divisiones de velocidad cada 100 rpm y la otra con divisiones por cada 200 rpm, lo que produce modelos paralelos de 8 y 4 nodos respectivamente. La figura 7.6 muestra los dos modelos implementados. Como se mencionó en la sección 5.3 por la distribución de las mediciones en los perfiles de velocidad, existen como máximo 30 muestras para cada 100 rpm de intervalo de velocidad, es por ello que para la topología con ocho RNA's existen 30 patrones para cada red y con cuatro RNA's 60 patrones.

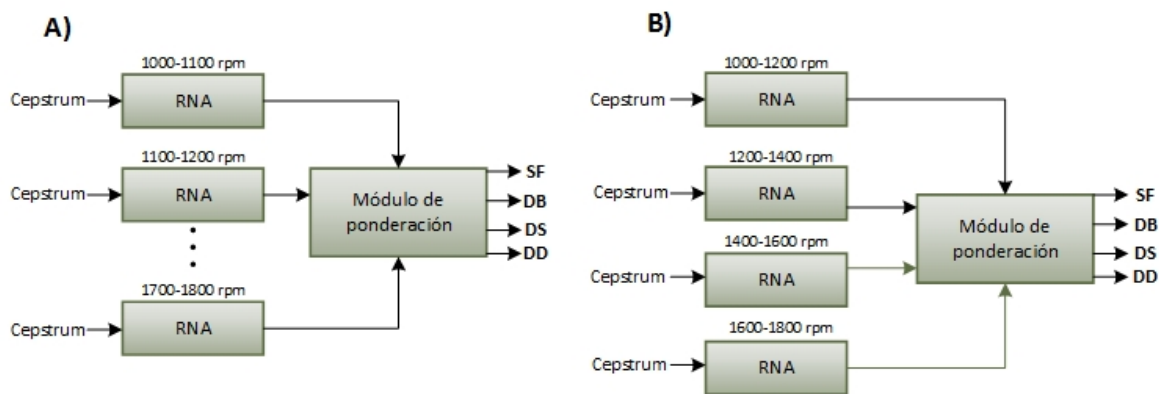


Figura 7.6: Módulo de decisión de 8 y 4 RNA's en paralelo

La distribución de los patrones empleada para el modelo neuronal con 8 redes fue de 15 patrones de entrenamiento 5 de validación y 10 de prueba, para el modelo con 4 redes fue el doble de estos valores. Para la extracción de rasgos se utilizó al Cepstrum y para la clasificación a la RBF, por ser las técnicas con el mejor desempeño. Los resultados de los errores para las diferentes topologías se muestran en la tabla 7.1, por la baja cantidad de patrones y los cambios en las señales producto de la carga variable, los errores son altos en comparación con el modelo con una sola red neuronal artificial; es por ello que los porcentajes de reconocimiento son bajos.

Aunque los resultados no fueron del todo favorables para este experimento, no se descarta el uso de modelos neuronales en paralelo, obteniendo más patrones de los diferentes rangos para mejorar la simulación, modificando al modelo neuronal utilizado o empleando un módulo de decisión distinto que permita utilizar simultáneamente una mayor cantidad de RNA's.

## 7.4 Conclusiones

En este capítulo se presentaron los resultados de los diferentes métodos empleados en el presente trabajo, así como una comparación entre ellas contra un método que utiliza la desviación estándar de los coeficientes de un paquete wavelet.

Tabla 7.1: Errores RBF

<b>Modelo neuronal</b>	<b>MSE entrenamiento</b>	<b>MSE validación</b>	<b>MSE prueba</b>	<b>Reconocimiento</b>
Una RNA	$1 \times 10^{-6}$	0.00620	0.00048	99 %
4 RNA's	0.0170	0.0450	0.0243	60 %
8 RNA's	0.0098	0.0170	0.0092	75 %

La eficacia de la WPT en el presente caso de estudio es casi el 100 % de clasificación correcta (ver la figura 7.2, demostrando una buena eficiencia en el procesamiento y diagnóstico de maquinaria. El modelo computacional desarrollado ofrece una alternativa para la extracción de rasgos en vibraciones mecánicas con una mejora en el tiempo de procesamiento y con buenos resultados de clasificación para diferentes estados operativos de un engranaje paralelo.

Por último se mostraron las pantallas del instrumento virtual del modelo computacional propuesto, con el cual se puede seleccionar el método para la extracción de parámetros, el número de coeficientes que se desea calcular, visualizar la FFT de la señal como una comparación entre el espectro con respecto a los coeficientes calculados y obtener los resultados de la clasificación con el MLP o la red de base radial.

# Capítulo 8

## Conclusiones y trabajo futuro

### 8.1 Conclusiones

Se desarrolló un modelo computacional para la identificación de fallos del engranaje paralelo de un banco de pruebas con la configuración de un aerogenerador comercial.

Las señales empleadas en el presente trabajo fueron obtenidas de una plataforma de pruebas adaptada en el centro tecnológico CARTIF, de la cual se simularon diferentes niveles de desbalance y desalineamiento, bajo condiciones de velocidad y carga variable similares a las condiciones que aparecen en un tren de engranes de un aerogenerador.

Para poder trabajar con las vibraciones mecánicas fue necesario conocer las características del banco de pruebas, así como los sistemas de medición y control utilizados, para posteriormente realizar un análisis de vibraciones y aplicar los métodos para la extracción de rasgos.

Para caracterizar a las diferentes señales se emplearon dos métodos que han tenido buenos resultados en reconocimiento de fallas mecánicas en otros trabajos, pero que no han utilizado un perfil de condiciones como el estudiado. Se demostró la eficacia de los métodos de procesamiento utilizados con un pequeño número de coeficientes (20 cepstrales y 15 LPC) en comparación con un método que emplea la desviación estándar de 16 coeficientes del último nivel de un paquete wavelet de cuatro niveles.

Los patrones obtenidos para los LPC y el Cepstrum se localizan en los armónicos de la señal con mayor energía, característica que les permite con un pequeño número de coeficientes obtener excelentes resultados de clasificación comparándolos con los del WPT.

Para comprobar el rendimiento computacional resultante, se realizó un estudio de los tiempos de procesamiento para las técnicas estudiadas. Este estudio demostró la capacidad de reducir el tiempo de procesamiento de un método reportado en la literatura que hace uso de la desviación estándar de los coeficientes de un WPT, incluso si no se considera el tiempo que se requiere para realizar la interpolación de Hermite; necesaria para el procesamiento del paquete wavelet.

Con el uso de redes neuronales artificiales MLP y RBF para los LPC y los coeficientes cepstrales respectivamente, fue posible identificar las diferentes condiciones mecánicas simuladas, con resultados que igualan a los reportados en la literatura

El modelo propuesto surge como una herramienta alternativa en la detección de fallas

incipientes en un tren de engranes.

Se verificó la hipótesis, se cumplió el objetivo general y los objetivos específicos planteados en la tesis. El modelo computacional propuesto será empleado como base para trabajos futuros en el estudio de diferentes fallas mecánicas, así como alternativas del mismo para la mejora del rendimiento en el procesamiento y la clasificación con el uso de diferentes modelos neuronales.

## 8.2 Trabajo futuro

1. Diagnosticar una mayor cantidad de fallas mecánicas.
2. Emplear una base de datos diferente para probar al modelo computacional propuesto.
3. Probar las técnicas de diagnóstico para detectar fallos en engranes.
4. Utilizar el análisis de componentes principales (PCA) para seleccionar los coeficientes más relevantes y poder emplear un orden mayor del modelo AR.
5. Experimentar con diferentes arquitecturas del modelo neuronal para el reconocimiento de patrones.

## 8.3 Trabajo enviado para arbitraje

- “Computational model with wrapper feature selection for gearbox fault diagnosis”.Engineering Applications of Artificial Intelligence. En revisión.

# Referencias

- [1] E. HAU. “Wind Turbines: Fundamentals, Technologies, Application, Economics”. Springer (2006).
- [2] L.F. VILLA, A. REÑONES, J. R. PERÁN, Y L.J. DE MIGUEL. Statistical fault diagnosis based on vibration analysis for gear test-bench under non-stationary conditions of speed and load. *Mechanical Systems and Signal Processing* **29**, 436–446 (2012).
- [3] Z. ZIJUN, A. VERMA, Y A. KUSIAK. Fault analysis and condition monitoring of the wind turbine gearbox. *Energy Conversion, IEEE Transactions on* **27**(2), 526–535 (2012).
- [4] P. GIRDHAR Y C. SCHEFFER. “Practical Machinery Vibration Analysis and Predictive Maintenance”. Newnes, Oxford (2004).
- [5] H. HYUNGSEOB, C. SANGJIN, Y C. UIPIL. Fault diagnosis system using lpc coefficients and neural network. In “Strategic Technology (IFOST), 2010 International Forum on”, págs 87–90 (2010).
- [6] H. LI, Y. ZHANG, Y H. ZHENG. Gear fault detection and diagnosis under speed-up condition based on order cepstrum and radial basis function neural network. *Journal of Mechanical Science and Technology* **23**(10), 2780–2789 (2009).
- [7] B. LIANG, S.D. IWNICKI, Y Y. ZHAO. Application of power spectrum, cepstrum, higher order spectrum and neural network analyses for induction motor fault diagnosis. *Mechanical Systems and Signal Processing* **39**(1-2), 342–360 (2013).
- [8] V. PALADE, J. LAKHMI, Y B. COSMIN. “Computational Intelligence in Fault Diagnosis”. Springer (2006).
- [9] S.R. BULL. Renewable energy today and tomorrow. *Proceedings of the IEEE* **89**(8), 1216–1226 (2001).
- [10] G.L. JOHNSON. “Wind energy systems”. Prentice Hall PTR (1985).
- [11] C. ZHE, J.M. GUERRERO, Y F. BLAABJERG. A review of the state of the art of power electronics for wind turbines. *Power Electronics, IEEE Transactions on* **24**(8), 1859–1875 (2009).
- [12] G. STEFAN Y P. JEAN-DANIEL. World wind energy report 2012 (2013). Obtenido de [http://www.wwindea.org/webimages/WorldWindEnergyReport2012\\_final.pdf](http://www.wwindea.org/webimages/WorldWindEnergyReport2012_final.pdf).
- [13] R. WISER Y M. BOLINGER. 2012 wind technologies market report (2012). Obtenido de [http://www1.eere.energy.gov/wind/pdfs/2012\\_wind\\_technologies\\_market\\_report.pdf](http://www1.eere.energy.gov/wind/pdfs/2012_wind_technologies_market_report.pdf).

- [14] PROSPECTIVA DEL SECTOR ELÉCTRICO 2013-2027 (2013). Obtenido de [http://www.sener.gob.mx/res/PE\\_y\\_DT/pub/2013/Prospectiva\\_del\\_Sector\\_Electrico\\_2013-2027.pdf](http://www.sener.gob.mx/res/PE_y_DT/pub/2013/Prospectiva_del_Sector_Electrico_2013-2027.pdf).
- [15] PLAN INTEGRAL PARA EL DESARROLLO DE LAS ENERGÍAS RENOVABLES 2013-2018 (2013). Obtenido de <http://http://www.uimtec.com/media/docs/130222-Plan-integral-para-desarrollo-de-energias-renovables.pdf>.
- [16] A. CREUS. “Aerogeeradores”. Cano Pina (2008). 273 págs.
- [17] D. SÖREN, K.AND STEFFEN. On public attitudes towards wind power. *Renewable Energy* **16**(1–4), 954–960 (1999).
- [18] L.Y. PAO Y K.E. JOHNSON. Control of wind turbines. *Control Systems, IEEE* **31**(2), 44–62 (2011).
- [19] A. ABDULLAH Y A. FEKIH. An overview of the current state of wind energy technology development in the us. In “Green Technologies Conference, 2013 IEEE”, págs 120–126 (2013).
- [20] J.H. LAKS, L.Y. PAO, Y A.D. WRIGHT. Control of wind turbines: Past, present, and future. In “American Control Conference, 2009. ACC '09.”, págs 2096–2103 (2009).
- [21] J.M ESCUDERO. “Manual de energía eólica”. Mundi-Prensa, segunda ed edición (2008). 277 págs.
- [22] G.O. SUVIRE. “Wind Farm – Technical Regulations, Potential Estimation and Siting Assessment. Croatia”. InTech (2011).
- [23] L. F. VILLA MONTOYA. “Mantenimiento predictivo aplicado a máquinas sometidas a velocidad y carga variables mediante análisis de órdenes”. Tesis doctoral , UVA, Valladolid,España (2011).
- [24] R. MOBLEY KEITH. “An introduction to predictive maintenance”. Butterworth-Heinemann, segunda ed edición (2002).
- [25] DANISH WIND TURBINES MANUFACTURERS ASSOCIATION. Guided tour on wind energy. Obtenido de <http://www.windpower.org>.
- [26] F.P. GARCÍA MÁRQUEZ, A.M. TOBIAS, J.M. PINAR PÉREZ, Y M. PAPAELIAS. Condition monitoring of wind turbines: Techniques and methods. *Renewable Energy* **46**(0), 169–178 (2012).
- [27] J.M. PINAR PÉREZ. Wind turbine reliability analysis. *Renewable and Sustainable Energy Reviews* **23**(0), 463–472 (2013).



- [28] J. RUI, Y. JING, Y M. VILIAM. Optimal bayesian estimation and control scheme for gear shaft fault detection. *Computers & Industrial Engineering* **63**(4), 754 – 762 (2012).
- [29] W. BARTELMUS Y R. ZIMROZ. Vibration condition monitoring of planetary gearbox under varying external load. *Mechanical Systems and Signal Processing* **23**(1), 246–257 (2009).
- [30] W. BARTELMUS Y R. ZIMROZ. A new feature for monitoring the condition of gearboxes in non-stationary operating conditions. *Mechanical Systems and Signal Processing* **23**(5), 1528–1534 (2009).
- [31] A.K.S. JARDINE, D. LIN, Y D. BANJEVIC. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing* **20**(7), 1483–1510 (2006).
- [32] M. YANG Y V. MAKIS. Arx model-based gearbox fault detection and localization under varying load conditions. *Journal of Sound and Vibration* **329**(24), 5209–5221 (2010).
- [33] C. CONCARI, G. FRANCESCHINI, Y C. TASSONI. Differential diagnosis based on multivariable monitoring to assess induction machine rotor conditions. *Industrial Electronics, IEEE Transactions on* **55**(12), 4156–4166 (2008).
- [34] A.V. OPPENHEIM Y R.W. SCHAFER. From frequency to quefrency: A history of the cepstrum. *IEEE Signal Processing Magazine* **21**(5), 95–106 (2004).
- [35] W.J. WANG Y P.D. MCFADDEN. Application of wavelets to gearbox vibration signals for fault detection. *Journal of Sound and Vibration* **192**(5), 927–939 (1996).
- [36] J. RAFIEE, F. ARVANI, A. HARIFI, Y M.H. SADEGHI. Intelligent condition monitoring of a gearbox using artificial neural network. *Mechanical Systems and Signal Processing* **21**(4), 1746 – 1754 (2007).
- [37] G.F. BIN, J.J. GAO, X.J. LI, Y B.S. DHILLON. Early fault diagnosis of rotating machinery based on wavelet packets—empirical mode decomposition feature extraction and neural network. *Mechanical Systems and Signal Processing* **27**(0), 696–711 (2012).
- [38] L.P. SÁNCHEZ FERNÁNDEZ, L.A. SÁNCHEZ PÉREZ, J.J. CARBAJAL HERNÁNDEZ, Y A. ROJO RUIZ. Aircraft classification and acoustic impact estimation based on real-time take-off noise measurements. *Neural Processing Letters* **38**(2), 239–259 (2012).
- [39] MIGUEL MÁRQUEZ-MOLINA, LUIS PASTOR SÁNCHEZ-FERNÁNDEZ, SERGIO SUÁREZ-GUERRA, Y LUIS ALEJANDRO SÁNCHEZ-PÉREZ. Aircraft take-off noises classification based on human auditory’s matched features extraction. *Applied Acoustics* págs– (2014).

- [40] L.A. SÁNCHEZ-PÉREZ, L.P. SÁNCHEZ-FERNÁNDEZ, S. SUÁREZ-GUERRA, Y J.J. CARBAJAL-HERNÁNDEZ. Aircraft class identification based on take-off noise signal segmentation in time. *Expert Systems with Applications* **40**(13), 5148–5159 (2013).
- [41] K.R. RAO, D.N. KIM, Y J.J. HWANG. “Fast Fourier Transform - Algorithms and Applications”. Signals and Communication Technology. Springer (2010). págs.
- [42] S. FURUI. “Digital Speech Processing, Synthesis, and Recognition”. Marcel Dekker, 2nd edición (2000).
- [43] G. CYBENKO. The numerical stability of the levinson-durbin algorithm for toeplitz systems of equations. *SIAM Journal on Scientific and Statistical Computing* **1**(3), 303–319 (1980).
- [44] S. HAYKIN. “Neural Networks and Learning Machines”. Prentice Hall, 3rd edición (2008).
- [45] A.K. JAIN, R.P.W. DUIN, Y JIANCHANG MAO. Statistical pattern recognition: a review. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* **22**(1), 4–37 (2000).
- [46] G.G. YEN Y KUO-CHUNG LIN. Wavelet packet feature extraction for vibration monitoring. *Industrial Electronics, IEEE Transactions on* **47**(3), 650–667 (2000).
- [47] B. LIU. Selection of wavelet packet basis for rotating machinery fault diagnosis. *Journal of Sound and Vibration* **284**(3-5), 567–582 (2005).
- [48] CARL DE BOOR. “A practical guide to splines”. Appl. Math. Sci. Springer, New York, NY (1978).
- [49] J.G. PROAKIS Y D.K. MANOLAKIS. “Digital Signal Processing (4th Edition)”. Prentice Hall, 4th edición (2006).
- [50] C.M. RADER Y B. GOLD. Digital filter design techniques in the frequency domain. *Proceedings of the IEEE* **55**(2), 149–171 (1967).
- [51] B.C. KUO. “Sistemas de control automático”. Prentice Hall Hispanoamericana, séptima edición (1996).
- [52] VINAY K. INGLE Y JOHN G. PROAKIS. “Digital Signal Processing Using MATLAB”. Cengage Learning, tercera edición (2010).
- [53] SHUFENG AI Y HUI LI. Application of order cepstrum and neural network to gear fault detection. In “Computational Engineering in Systems Applications, IMACS Multiconference on”, págs 1822–1827 (2006).
- [54] D.J.C. MACKAY. Bayesian interpolation. *Neural computation* **4**(3), 415–447 (1992).

- [55] K. HIRSCHEN Y M. SCHÄFER. Bayesian regularization neural networks for optimizing fluid flow processes. *Computer Methods in Applied Mechanics and Engineering* **195**(7-8), 481–500 (2006).

# Anexos

## Anexo A

Los elementos utilizados en el banco de pruebas son los siguientes:

- Freno Lucas Nüelle, referencia SE2663-6E. En condiciones nominales de funcionamiento los valores de corriente, voltaje y torque son 9.1 A, 390 V y 10.8 Nm / 3.9 kW respectivamente.
- Motor Siemens de 3 fases jaula de ardilla, usado en configuración triángulo a 50 Hz. En condiciones nominales de funcionamiento los valores de corriente, velocidad y potencia son 1.82 A, 1370 rpm y 0.37 kW respectivamente.
- Caja de engranajes paralela de referencia comercial S 30 1 F 10.3 P71 Bonfiglioli, perteneciente a la serie S de este tipo de cajas de engranajes de tamaño 30, con 1 etapa de reducción con una relación de reducción de 10.3, de forma constructiva F y configuración de entrada P71.
- Primera etapa del engranaje planetario, una caja de engranajes planetaria de referencia comercial 300 L 1 5.77 MC P90 ALH Bonfiglioli, perteneciente a la serie 3 de este tipo de cajas de engranajes, con diseño en línea y con una etapa de reducción de 5.77.
- En la segunda etapa planetaria, una caja de engranajes planetaria de referencia comercial 300 L 2 MC P90 LH Bonfiglioli, perteneciente a la serie 3 de este tipo de cajas de engranajes, con diseño en línea y con dos etapas de reducción de 24.6.



## Anexo B

El presente apartado muestra las especificaciones de las tarjetas de adquisición de datos (ver Tabla A.1) y los sensores (ver Tabla A.2) utilizados en el banco de pruebas.

Tabla A.1: Tarjetas de adquisición de datos

NI USB-6009		La NI/USB-6008/6009 provee conexión a 8 canales de entradas analógicas (AI), 2 canales desalidas analógicas (AO), 12 canales de entrada/salida digital y 1 contador de 32 bits con interfaz full-speed USB.
NI 9423		El módulo NI 9423 provee conexiones 8 canales, hasta para 8 canales de entradas digitales. Cada canal tiene una terminal DI o pin de en el cual se pueden conectar voltajes o señales.
NI 9233		El módulo NI 9233 tiene 4 conectores BNC que proveen conexión para 4 módulo canales de muestreo simultaneo de entrada analógica entradas análogas. Cada canal tiene un conector BNC en el cual se puede conectar un sensor Integrado electrónico piezoeléctrico (IEPE).
NI cDAQ 9172		El NI cDAQ – 9172 es un chasis USB de 8 ranuras diseñado para ser usado con los módulos I/O de la serie C. El chasis NI cDAQ – 9172 es capaz de medir un ancho rango de medidas análogas y digitales I/O y de sensores usando una interfaz USB 2.0 de alta velocidad.

Tabla A.2: Sensores

Acelerómetro PCB Piezotronics Ref: ICP 352C65		Sensor 352C65 sensibilidad ICP miniatura (2 gm) de alta Sensibilidad: ( $\pm 10\%$ ) 100 mV/g (PCB Piezotronics) Rango de medición: $\pm 50$ g pk [PCB]. Rango de frecuencia: ( $\pm 5\%$ ) 0.5-10000 Hz Peso: 2.0 g
Sensor fotoeléctrico IFM Electronic OJ5058		Sistema de reflexión directa. Carcasa con forma cúbica, de plástico. Conexión por conector. Bloqueo electrónico. Función externa de aprendizaje, bloqueo electrónico y supresión de fondo. Alcance objeto blanco (90 % de remisión): 7 – 150 mm. Objeto más pequeño detectable: $\phi$ 0.8 mm. Diámetro de punto luminoso: 0.8 mm. Tensión de alimentación: 10–30 V DC.

## Anexo C

### Patrones obtenidos con LPC y Cepstrum




Figura A.1: Patrones LPC desbalance




Figura A.2: Patrones LPC desalineamiento




Figura A.3: Patrones LPC desbalance contra desalineamiento




Figura A.4: Patrones LPC desbalance + desalineamiento




Figura A.5: Patrones Cepstrum desbalance




Figura A.6: Patrones Cepstrum desalineamiento






Figura A.7: Patrones Cepstrum desbalance contral desalineamiento

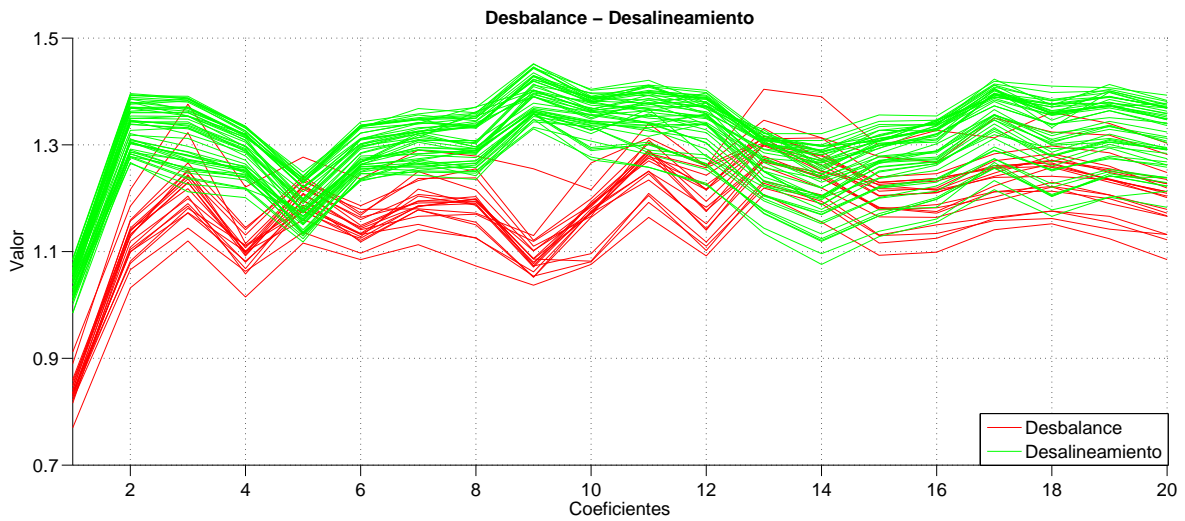


Figura A.8: Patrones Cepstrum desbalance + desalineamiento

## Anexo D

Capturas de pantalla instrumento virtual

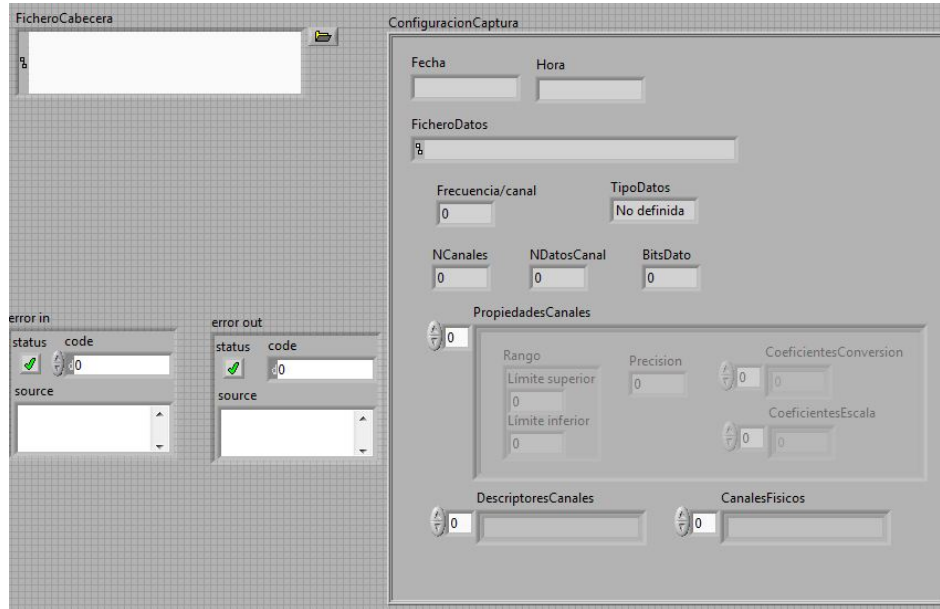


Figura A.9: Módulo de lectura de archivos




Figura A.10: Diagrama a bloques módulo de lectura de archivos

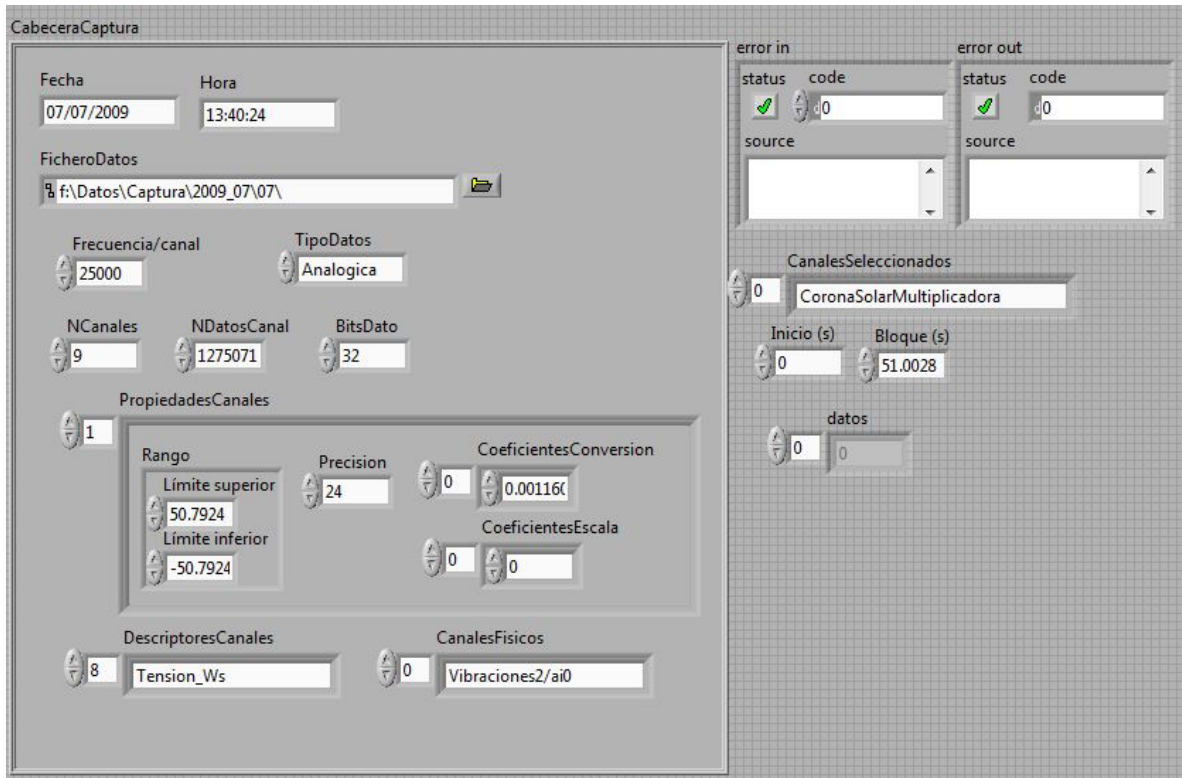


Figura A.11: Módulo de lectura procesamiento de señal

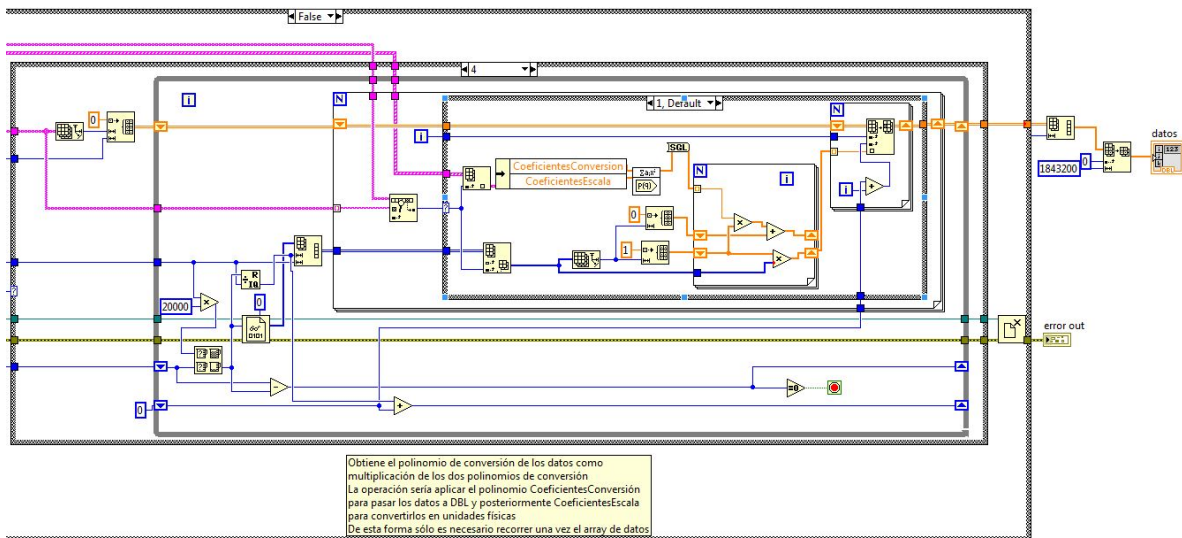


Figura A.12: Diagrama a bloques módulo procesamiento de señal

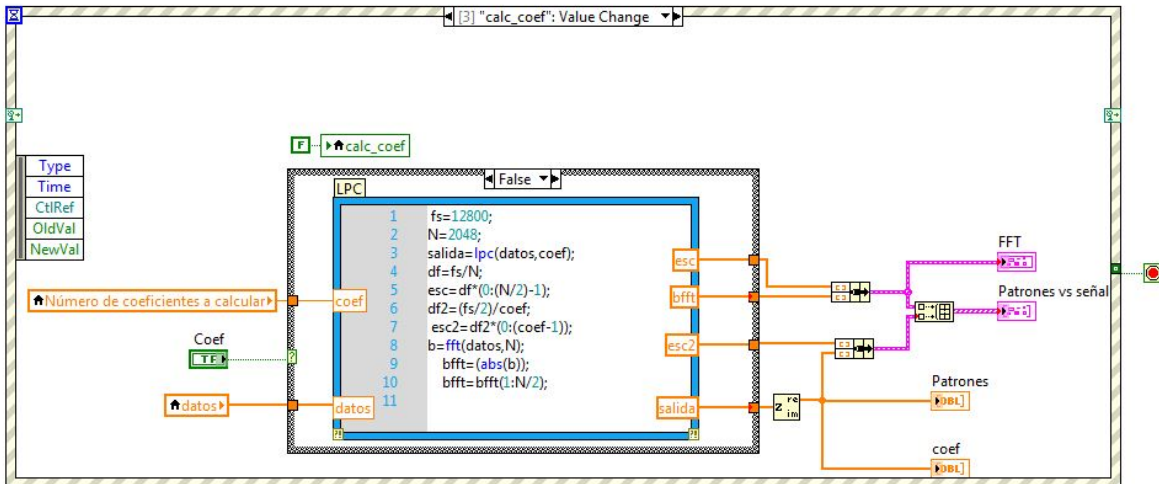


Figura A.13: Diagrama a bloques cálculo de coeficientes

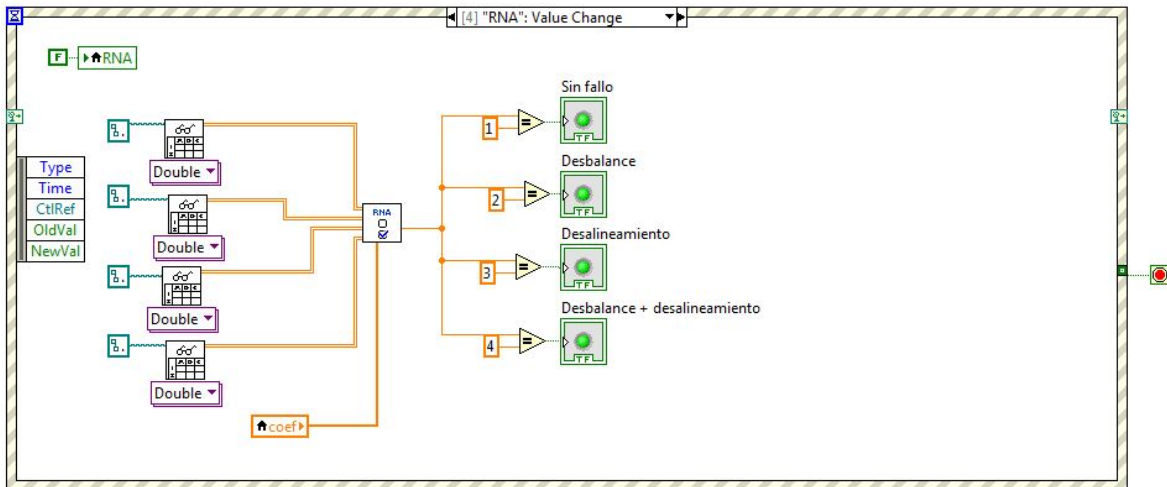


Figura A.14: Diagrama a bloques red neuronal en el programa principal

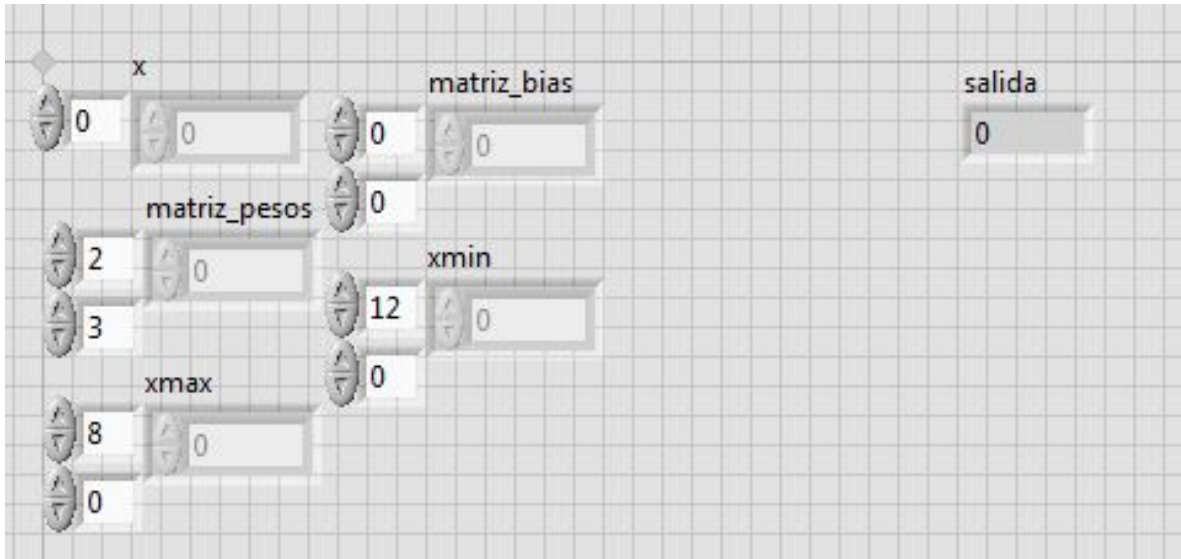


Figura A.15: Propagación RNA

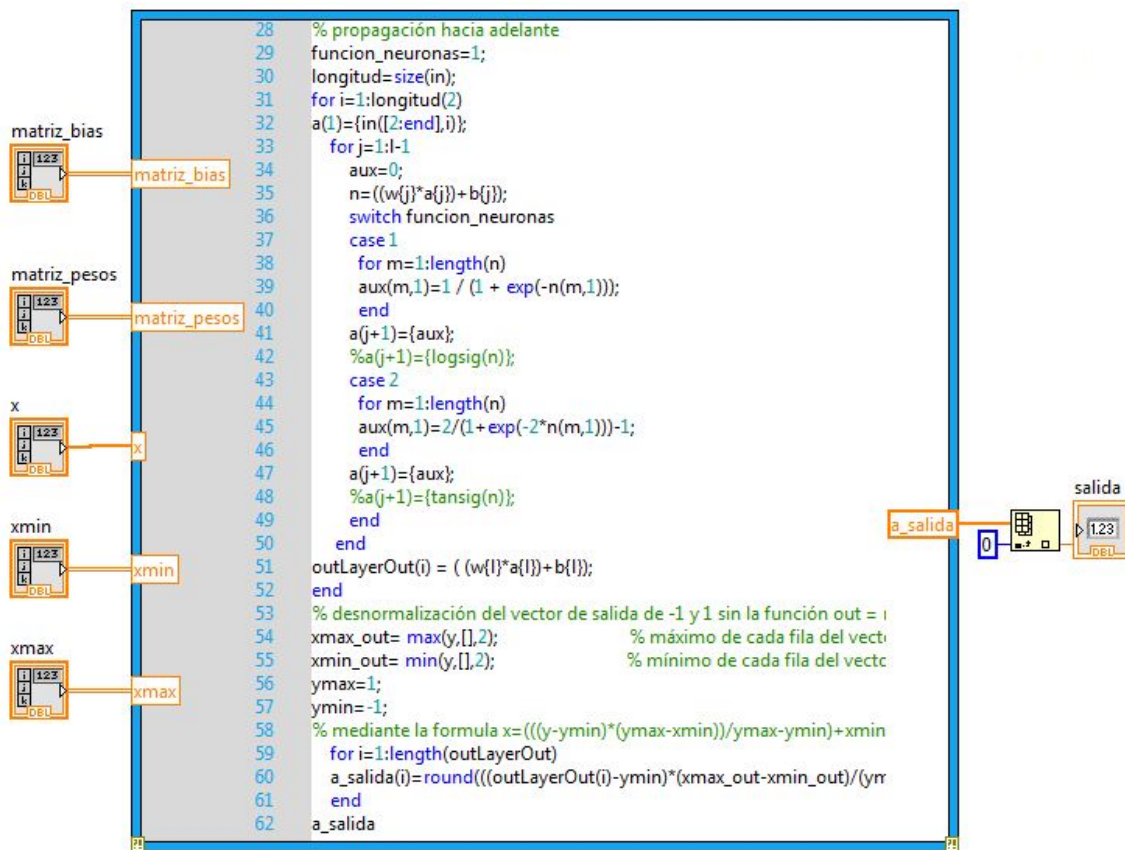


Figura A.16: Diagrama a bloques propagación RNA