


UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA ELECTROMECÁNICA  
MAESTRÍA EN MECATRÓNICA



*TESIS*

Clasificación de fallos en baleros en cadenas cinemáticas utilizando la técnica de análisis de componentes principales

PRESENTA

Ana Karen Martínez Luna


DIRECTOR

Dr. Juan José Saucedo Dorantes

San Juan del Río, Querétaro. Junio 2021



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA ELECTROMECÁNICA  
MAESTRÍA EN MECATRÓNICA



*TESIS*

Clasificación de fallos en baleros en cadenas cinemáticas utilizando la técnica de análisis de componentes principales

Presenta

Ana Karen Martínez Luna

Dirigido por

Dr. Juan José Saucedo Dorantes

Dr. Juan José Saucedo Dorantes  
Presidente

Dr. Roque Alfredo Osornio Ríos  
Secretario

Dr. Miguel Trejo Hernández  
Vocal

Dr. Luis Morales Velázquez  
Sinodal

Dr. Ángel Pérez Cruz  
Sinodal

San Juan del Río, Qro.

Junio, 2021

# RESUMEN

La identificación de fallas en la maquinaria es una tarea que cada vez ha cobrado más importancia dentro de la industria, razón por la cual constantemente se realizan diferentes metodologías utilizando diferentes técnicas para mejorar e innovar en este campo de necesidad. En este proyecto, se diseñó un método híbrido entre software y hardware que permite la identificación de fallas en cadenas cinemáticas, basándose primordialmente en la técnica de Análisis de Componentes Principales (PCA), el uso de indicadores estadísticos para caracterizar el comportamiento de las señales de vibración de la cadena y el uso de redes neuronales para la clasificación final de las fallas. Este método, propone una parte de entrenamiento en software, donde se lleva a cabo el cálculo de una matriz de coeficientes que permita proyectar los indicadores en un plano de máxima varianza, agrupando así los datos con características similares, luego entonces se obtienen los pesos y bias correspondientes para cada capa de la red neuronal. En la etapa de explotación en hardware, estos datos son trasladados desde software y son directamente utilizados, así, se evita un proceso de reentrenamiento, obteniendo directamente un diagnóstico.

(**Palabras clave:** PCA, indicadores estadísticos, redes neuronales, identificación de fallas en cadenas cinemáticas, software/hardware, BPFO)

## SUMMARY

The identification of failures in machinery is a task that has become increasingly important within the industry, this is why different methodologies are constantly being carried out using different techniques to improve and innovate in this field of need. In this project, a hybrid method between software and hardware was designed that allows the identification of faults in kinematic chains, based primarily on the Principal Component Analysis (PCA) technique, the use of statistical indicators to characterize the behavior of the vibration signals of the chain and the use of neural networks for the final classification of faults. This method proposes a part of software training, where the calculation of a coefficient matrix is carried out that allows the indicators to be projected on a plane of maximum variance, thus grouping the data with similar characteristics, then the weights and corresponding bias for each layer of the neural network. In the hardware exploitation stage, these data are transferred from software and are directly used, thus, a retraining process is avoided, obtaining a diagnosis directly.

**(Keywords:** PCA, statistical indicators, neural networks, kinematic chain failure identification, software / hardware, BPFO)

# AGRADECIMIENTOS

Primero, quiero agradecer a mi familia por brindarme su amor incondicional y porque han apoyado todas mis decisiones sin importar cuales sean; si bien, los últimos meses han sido difíciles para nosotros, hemos sabido afrontar la situación y hemos salido adelante. Les agradezco por brindarme la fuerza para continuar sin importar las circunstancias en las que nos encontremos. Mejores tiempos están por venir.

También quiero agradecer principalmente a mi director de tesis, el Dr. Juan José, quien siempre mostró su apoyo, comprensión y paciencia a pesar de los obstáculos que se presentaron en el transcurso de la elaboración de este proyecto, sin el nada de esto hubiera sido posible. Al Dr. Roque por permitirme integrarme a este programa y ayudarme con sus consejos. Al Dr. Luis por mostrar una gran disposición aún en cuarentena para dar respuesta a las dudas que surgieron y ayudarme a dar forma al proyecto. Al Dr. Miguel y al Dr. Ángel, que con sus observaciones me ayudaron a concluir este trabajo de manera satisfactoria.

No puedo dejar de agradecer a mis compañeros de clase David, Christian, Rogelio y Juan, quienes me ayudaron a reintegrarme al ambiente escolar, me brindaron su apoyo cuando lo necesitaba y también me brindaron su amistad, sin ellos definitivamente no hubiera logrado llegar a este punto.

A todas aquellas personas que aún sin saberlo se convirtieron en una fuente de inspiración y ejemplo para mí, que cambiaron mi vida y me motivan a esforzarme al máximo para conseguir mis metas.

Finalmente, quiero agradecer a la universidad por recibirme nuevamente y permitirme continuar con mi preparación profesional, así como al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo económico otorgado durante el posgrado.

# ÍNDICE GENERAL

Resumen .....	III
Summary.....	IV
Agradecimientos .....	V
Índice General.....	VI
Índice De Figuras .....	IX
Índice De Tablas .....	XIII
1 Introducción.....	1
1.1 Antecedentes.....	2
1.2 Objetivos e Hipótesis.....	5
1.2.1 Objetivos.....	5
1.2.2 Hipótesis .....	6
1.3 Justificación .....	7
1.4 Planteamiento General.....	8
2 Fundamentación teórica.....	11
2.1 Rodamientos .....	11
2.1.1 Clasificación de rodamientos por material .....	11
2.1.1.1 Rodamientos metálicos.....	12
2.1.1.2 Rodamientos cerámicos.....	12
2.1.1.3 Rodamientos híbridos .....	13
2.1.2 Defectos en rodamientos .....	14
2.2 Métodos de detección de fallas.....	15
2.2.1 Análisis de señales en el dominio del tiempo.....	15
2.2.2 Análisis de señales en el dominio de la frecuencia .....	18
2.2.3 Análisis de señales en el dominio tiempo – frecuencia .....	20
2.3 Selección de indicadores .....	20
2.4 Análisis de Componentes Principales (PCA).....	22
2.5 Redes Neuronales Artificiales .....	26
2.6 VHDL .....	26
3 Metodología.....	27
3.1 Instrumentación de la cadena cinemática .....	28
3.2 Experimentación.....	30

3.2.1	Fallas Inducidas .....	30
3.2.2	Descripción de las pruebas .....	30
3.3	Entrenamiento en software .....	31
3.4	Explotación en Hardware .....	34
3.4.1	Bloque de Indicadores estadísticos.....	36
3.4.2	Bloque PCA.....	52
3.4.3	Bloque Redes Neuronales.....	55
3.5	Análisis en el dominio de la frecuencia.....	62
4	Análisis de resultados .....	63
4.1	Rodamientos Metálicos .....	64
4.1.1	Pruebas de 5 Hz .....	64
4.1.2	Pruebas de 15 Hz .....	68
4.1.3	Pruebas de 50 Hz .....	69
4.1.4	Pruebas de 60 Hz .....	71
4.2	Rodamientos Cerámicos .....	73
4.2.1	Pruebas de 5 Hz .....	73
4.2.2	Pruebas de 15 Hz .....	75
4.2.3	Pruebas de 50 Hz .....	76
4.2.4	Pruebas de 60 Hz .....	78
4.3	Rodamientos Híbridos .....	80
4.3.1	Pruebas de 5 Hz .....	80
4.3.2	Pruebas de 15 Hz .....	81
4.3.3	Pruebas de 50 Hz .....	83
4.3.4	Pruebas de 60 Hz .....	85
4.4	Aplicación de la metodología de diagnóstico en la detección de diferentes fallas en rodamientos .....	86
4.5	Análisis Frecuencial .....	89
4.5.1	Pruebas de 5 Hz .....	90
4.5.2	Pruebas de 15 Hz .....	92
4.5.3	Pruebas de 50 Hz .....	95
4.5.4	Pruebas de 60 Hz .....	98
5	Conclusiones.....	102
6	Prospectivas .....	103

7	Referencias .....	104
8	Apéndice.....	106

Dirección General de Bibliotecas UAQ



## ÍNDICE DE FIGURAS

Figura 1.- Planteamiento General.....	8
Figura 2.- Cadena cinemática bajo análisis .....	9
Figura 3.- Partes de un rodamiento de bolas (NTN, 2019).....	11
Figura 4.- Rodamientos metálicos (NTN, 2019) .....	12
Figura 5.- Rodamiento cerámico (Ortech, 2019).....	13
Figura 6.- Rodamiento híbrido (Ortech, 2019).....	13
Figura 7.- Grietas en la pista exterior de un rodamiento de doble hilera de rodillos cilíndricos (Koyo, 2019).....	15
Figura 8.- Astilladura en la pista exterior en un rodamiento de rodillos cilindricos (Koyo, 2019).....	15
Figura 9.- Geometría de un rodamiento.....	19
Figura 10.- Métodos de Filtro. (Autoría propia).....	21
Figura 11.- Métodos de envoltura (Autoría propia) .....	22
Figura 12.- Proceso de extracción de indicadores mediante PCA a) Conjunto original de datos supuesto en 5 dimensiones b) Proyección de vectores con mayor distribución c) Proyección nuevo plano d) Representación del conjunto de indicadores extraídos en 2 dimensiones .....	25
Figura 13.- Metodología General .....	28
Figura 14.- Banco de pruebas .....	29
Figura 15.- Fallas inducidas a) Daño pista externa de rodamiento metálico, b) Daño pista externa de rodamiento cerámico y c) Daño pista externa de rodamiento híbrido .....	30
Figura 16.- Metodología del entrenamiento en software.....	32
Figura 17.- Funcionamiento de las redes neuronales en Matlab .....	33
Figura 18.- Diagrama general de la explotación en VHDL.....	34
Figura 19.- Diagrama de bloques de la explotación en hardware .....	35
Figura 20.- Máquina de estados del bloque de explotación en hardware.....	36
Figura 21.- Diagrama de bloques de la media .....	37
Figura 22.- Máquina de estados de la media .....	38
Figura 23.- Diagrama de bloques del valor máximo .....	38
Figura 24.- Máquina de estados de valor máximo .....	39
Figura 25.- Diagrama de bloques de RMS .....	40
Figura 26.- Máquina de estados de RMS .....	40
Figura 27.- Diagrama de bloques de SRM .....	41
Figura 28.- Máquina de estados de SRM .....	42
Figura 29.- Diagrama de bloques de varianza y desviación estándar.....	42
Figura 30.- Máquina de estados de varianza y desviación estándar.....	43
Figura 31.- Diagrama de bloques de SFrms, SFsrm y factor impulso.....	44
Figura 32.- Máquina de estados de SFrms, SFsrm y factor impulso.....	45
Figura 33.- Diagrama de bloques de Skewness .....	46
Figura 34.- Máquina de estados de Skewness .....	46
Figura 35.- Diagrama de bloques de kurtosis .....	47
Figura 36.- Máquina de estados de kurtosis .....	48

Figura 37.- Diagrama de bloques del quinto momento .....	49
Figura 38.- Diagrama de bloques del sexto momento .....	49
Figura 39.- Diagrama de bloques de los quince indicadores estadísticos .....	51
Figura 40.- Máquina de estados de Features .....	52
Figura 41.- Diagrama de bloques de PCA .....	54
Figura 42.- Máquina de estados de bloque PCA .....	54
Figura 43.- Código para calcular salidas de la red neuronal .....	55
Figura 44.- Diagrama de bloques de Redes Neuronales.....	56
Figura 45.- Máquina de estados de bloque Redes Neuronales .....	57
Figura 46.- Diagrama de bloques de Normalización.....	59
Figura 47.- Diagrama de bloques de Desnormalización.....	61
Figura 48.- Metodología del análisis en el dominio de la frecuencia.....	62
Figura 49.- Rodamiento metálico a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	64
Figura 50.- Simulación en Xilinx ISE de las pruebas de rodamientos metálicos a 5 Hz sin presencia de falla .....	66
Figura 51.- Simulación en Xilinx ISE de las pruebas de rodamientos metálicos a 5 Hz con presencia de falla .....	67
Figura 52.- Rodamiento metálico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	68
Figura 53.- Rodamiento metálico a 50 Hz del eje x. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	70
Figura 54.- Rodamiento metálico a 60 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	72
Figura 55.- Rodamiento cerámico a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	73
Figura 56.- Rodamiento cerámico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	75
Figura 57.- Rodamiento cerámico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	77
Figura 58.- Rodamiento cerámico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	78
Figura 59.- Rodamiento híbrido a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	80

Figura 60.- Rodamiento híbrido a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	82
Figura 61.- Rodamiento híbrido a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	83
Figura 62.- Rodamiento híbrido a 60 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN .....	85
Figura 63.- Bancada experimental usada para generar la Base de Datos de Rodamientos de la Universidad Case Western.....	87
Figura 64.- Proyección del conjunto extraído de características resultante de PCA para el conjunto de datos Universidad Case Western Reserve evaluando condiciones de fallo.....	88
Figura 65.- Proyección del conjunto extraído de características resultante de PCA para el conjunto de datos Universidad Case Western Reserve evaluando severidades de fallo en rodamientos .....	89
Figura 66.- Espectro de frecuencias del eje Y a 5 Hz de rodamientos metálicos a) HLT-M b) BD-M .....	90
Figura 67.- Espectro de frecuencias del eje Y a 5 Hz de rodamientos cerámicos a) HLT-C b) BD-C .....	91
Figura 68.- Espectro de frecuencias del eje Y a 5 Hz de rodamientos híbridos a) HLT-H b) BD-H .....	91
Figura 69.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos metálicos a) HLT-M b) BD-M .....	92
Figura 70.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a BPFO).....	93
Figura 71.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos cerámicos a) HLT-C b) BD-C .....	93
Figura 72.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 2xBPFO).....	93
Figura 73.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 3xBPFO).....	94
Figura 74.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos híbrido a) HLT-H b) BD-H .....	94
Figura 75.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a 2xBPFO).....	94
Figura 76.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a 3xBPFO).....	95
Figura 77.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos metálicos a) HLT-M b) BD-M .....	95
Figura 78.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a BPFO).....	96

Figura 79.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a 2xBPFO).....	96
Figura 80.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos cerámicos a) HLT-C b) BD-C .....	96
Figura 81.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos cerámicos a) HLT-C b) BD-MC (acercamiento a 2xBPFO).....	97
Figura 82.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos híbridos a) HLT-H b) BD-H .....	97
Figura 83.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a 3xBPFO).....	97
Figura 84.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos metálicos a) HLT-M b) BD-M .....	98
Figura 85.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a BPFO).....	99
Figura 86.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a 3xBPFO).....	99
Figura 87.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C .....	99
Figura 88.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a BPFO).....	100
Figura 89.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 2xBPFO).....	100
Figura 90.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 3xBPFO).....	100
Figura 91.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos híbridos a) HLT-H b) BD-H .....	101
Figura 92.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a BPFO).....	101
Figura 93.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a 3xBPFO).....	101

## ÍNDICE DE TABLAS

Tabla 1.- Aproximación PLAN en el intervalo [-5,5].	61
Tabla 2.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 5Hz	65
Tabla 3.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 5Hz	65
Tabla 4.- Comparativa resultados software-hardware para rodamientos metálicos a 5Hz	67
Tabla 5.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 15Hz	68
Tabla 6.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 15Hz	69
Tabla 7.- Comparativa resultados software-hardware para rodamientos metálicos a 15Hz	69
Tabla 8.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 50 Hz	70
Tabla 9.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 50Hz	71
Tabla 10.- Comparativa resultados software-hardware para rodamientos metálicos a 50Hz	71
Tabla 11.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 60 Hz	72
Tabla 12.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 60Hz	72
Tabla 13.- Comparativa resultados software-hardware para rodamientos metálicos a 60Hz	72
Tabla 14.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz	74
Tabla 15.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz	74
Tabla 16.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz	74
Tabla 17.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz	75
Tabla 18.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz	76
Tabla 19.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz	76
Tabla 20.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz	77
Tabla 21.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz	77
Tabla 22.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz	78
Tabla 23.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz	79
Tabla 24.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz	79

Tabla 25.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz	79
Tabla 26.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 5Hz .....	80
Tabla 27.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz.....	81
Tabla 28.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz...	81
Tabla 29.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 5Hz .....	82
Tabla 30.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz.....	82
Tabla 31.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz...	83
Tabla 32.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 5Hz .....	84
Tabla 33.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz.....	84
Tabla 34.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz...	84
Tabla 35.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 60Hz .....	85
Tabla 36.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz.....	86
Tabla 37.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz...	86
Tabla 38.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 5 Hz .....	91
Tabla 39.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 15 Hz .....	92
Tabla 40.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 50 Hz .....	95
Tabla 41.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 60 Hz .....	98

# Capítulo I

## 1 Introducción

Una de las mayores preocupaciones de cualquier industria es mantener e incluso mejorar la calidad de sus productos para entregarlos en el menor tiempo posible, con el fin de ser una opción viable en el mercado debido a la gran competencia de productos que existen hoy en día, para ello deben mantener toda su maquinaria operando de manera óptima, asegurándose de cumplir con las exigencias de los clientes. Si bien, con el paso de los años los procesos son cada vez más precisos y sofisticados, las máquinas rotatorias siguen y seguirán siendo parte crítica en ellos, pero debido al constante movimiento y condiciones a las que están sometidas, están inevitablemente expuestas a la aparición de fallos durante su operación. Es por ello por lo que, con el fin de cumplir con los estándares de calidad y tiempos de entrega, así como reducir potencialmente las pérdidas que se pudieran generar en procesos de producción de plantas industriales es que existe la necesidad de crear técnicas aplicadas al monitoreo de condición y diagnóstico que ayuden a identificar y clasificar la aparición de fallas. Así, para mantener el buen estado de operación de un proceso es necesario monitorear continuamente la maquinaria y sus elementos involucrados, es decir, se deben de establecer las condiciones normales de operación con el fin de detectar cualquier cambio o desviación que pueda ser representado por la aparición de algún defecto de malfuncionamiento del proceso y posteriormente clasificarlo.

Siendo los motores de inducción (IM) uno de los principales componentes de las cadenas cinemáticas empleadas en la industria y los causantes de más del 50% del consumo eléctrico a nivel mundial (Hulst, 2017), diversos estudios se han realizado demostrando que la principal causa de fallos en IM tiene origen en sus rodamientos, representando un 40% del total, daños en el estator ocupan el segundo lugar con un 32%, mientras que los fallos en el rotor simbolizan solamente el 10% (Natu M. , 2013). A causa de esto y a la gran cantidad de aplicaciones en las que son utilizados, la fabricación de los rodamientos se ha perfeccionado con el paso de los años, haciéndolos cada vez más precisos para las crecientes necesidades y nuevas tecnologías, lo que implica el uso de diferentes técnicas y materiales, los cuales suelen ser críticos al momento de elegir la aplicación para la cual se emplean; respecto a esto, los rodamientos se pueden clasificar en tres principales grupos: metálicos, cerámicos e híbridos.

Si bien, la detección de defectos en rodamientos es un área que ha sido ampliamente estudiada, no se ha profundizado en analizar las diferencias que existen cuando una falla se origina en los tres tipos de rodamientos anteriormente mencionados y es justamente en lo que se enfoca el presente proyecto, en analizar el comportamiento de los diferentes rodamientos cuando una falla localizada se hace presente en su pista externa, pero sobre todo se enfoca en un método para la detección y clasificación de fallos aplicada a estas diferentes tecnologías empleando el método de reducción de indicadores PCA (*Principal Component Analysis* o análisis de componentes principales) complementado con el método heurístico de redes neuronales (*NN, neural networks*). Es importante mencionar que la implementación se realizó en un formato híbrido, combinando software y hardware para una mejor ejecución.

## 1.1 Antecedentes

La confiabilidad en la detección y clasificación de fallas en la maquinaria es parte importante en la industria ya que permite la mejorar la productividad, así como planificar y ejecutar más eficientemente las acciones de mantenimiento correspondientes tratando de reducir costos, además de que permite conservar e incluso incrementar la disponibilidad de las máquinas (Saucedo, 2017). Es por ello que el desarrollo de nuevas técnicas de condición de monitoreo y diagnóstico aplicadas a la detección de fallos ha cobrado mayor relevancia en los últimos años, de tal forma que una gran cantidad de metodologías de investigación se han desarrollado. En este sentido, algunos de los trabajos realizados han sido, por ejemplo, el de Cariño et al (2016), donde presenta una metodología adaptativa para detectar fallas en una cadena cinemática, en primera instancia solo se tiene información de la cadena en condiciones normales de operación para después ser reentrenada bajo un método de aprendizaje automático, empleando primero el método de reducción de indicadores *Laplacian Score* para después en la siguiente etapa utilizar el *Fisher Score*. Para la comprobación de la metodología propuesta se inducen dos tipos de falla en la cadena, con media barra rota del rotor y una barra completa rota, sin embargo, se realiza el procesamiento en software, limitando los tiempos de respuesta por tratarse de instrucciones secuenciales.

Otro método de detección de fallas en cadenas cinemáticas fue propuesto por Saucedo et al (2016), quienes realizaron la detección de anomalías en la caja de engranes y defectos en los rodamientos del motor de inducción, por medio de mediciones de corrientes, vibraciones



y velocidad; utilizando el filtro Hanning, la FFT (*Fast Fourier Transform*, Transformada Rápida de Fourier) y PSD (*Power Spectral Density*, Densidad Espectral de Potencia) logrando determinar las condiciones de operación de la cadena cinemática, sin embargo se desarrolló completamente en software, limitando su aplicación en línea.

Si bien, una cadena cinemática está compuesta por diversos elementos, tales como motores de inducción, cajas de engranes, generadores, entre otros elementos; gran parte de las investigaciones se han enfocado específicamente en detectar fallas en los baleros, esto es debido a que son uno de los elementos más importantes que permiten a la mayoría de las máquinas realizar el movimiento rotatorio. En este sentido, Kang et al (2014) desarrollaron una metodología para la detección de fallos en rodamientos, aunque la detección de fallos se realizó en línea bajo condiciones continuas de operación su trabajo está más enfocado en demostrar las ventajas que tiene realizar esta clasificación en una FPGA (*Field Programmable Gate Array*) Xilinx Virtex-7 de 50MHz sobre una tarjeta Texas Instrument (TI) TMS320C6748. Dicha comprobación incluía la obtención de datos adquiridos de señales de emisión acústicas (AE), mediante la utilización de RWPE (*Reliable Wavelet Packet Energy*) y WPNK (*Wavelet Packet Node Kurtosis*) como técnicas de procesamiento, y en la clasificación de fallas el uso de MCSVM (*Multiclass Support Vector Machine*, máquina de soporte vectorial multiclase) y OAA (*One-against-all*, uno contra todos). De la misma forma, Kang et al (2014) desarrollaron un sistema que permitía clasificar las fallas en rodamiento utilizando el método BAI (*Bearing Anormality Index*, Índice de anormalidad del rodamiento), pudiendo distinguir entre fallas en la pista interior (BCI), exterior (BCO), rodillo (BCR), interior y exterior (BCIO), interior y rodillo (BCIR), exterior y rodillo (BCIOR); utilizando sensores de emisión acústica para realizar las mediciones, además fue implementado en una FPGA Xilinx Virtex-7 200MHz, no obstante, su estudio se enfocó solamente a los rodamientos metálicos.

Por otra parte, una de las técnicas que se ha incluido ampliamente en estrategias de condición de monitoreo y diagnóstico de fallos es el Análisis de Componentes Principales (PCA), ya que permite reducir la dimensionalidad de espacio original manteniendo al máximo la varianza del espacio original; es decir, se obtiene la representación de la información original en un espacio reducido. De este modo, Stief et al (2019) proponen una

metodología para diagnosticar fallas eléctricas y mecánicas en motores de inducción utilizando un método bayesiano de dos etapas combinado con la técnica de PCA, para ello utilizan señales acústicas, eléctricas y de vibración, sin embargo su implementación es completamente en software.

En el ámbito eléctrico, Alsafasfeh et al (2010) desarrollaron una metodología para la detección y clasificación de fallas en sistemas de potencia eléctrica, utilizando lecturas de corriente de fase durante 1/4 de ciclo, para ello combinaron la técnica de componentes simétricos (extracción de datos) con el PCA; logrando distinguir entre una falla real y una transitoria, siendo viable para utilizarse en sistemas de transmisión, así como de distribución en tiempo real.

Otra aplicación industrial de PCA fue la propuesta por Chaouch et al (2017), en la que desarrollaron un sistema para localizar y clasificar fallas de acuerdo a su severidad en un proceso de producción de harina, para lo primero utilizan la técnica de PCA y determinaron la cantidad de componentes con el método Xu y Kailath; mientras que para la clasificación se apoyan en el método heurístico de lógica difusa tomando como base la calidad del producto.

Como se pudo observar, el uso del método de PCA es bastante amplio debido a los buenos resultados que ha demostrado con el paso de los años, y así como se ha aplicado en diversas ramas de la industria, su utilización en la detección de fallas de baleros no es la excepción; Shuang & Meng (2007), propusieron un método de diagnóstico de fallas de rodamientos basado en PCA y soporte de vector (*Support Vector Machine*, SVM). La variable correlacionada multidimensional se convierte en un vector propio de baja dimensión mediante PCA y por medio de SVM se realiza el reconocimiento de patrones y la regresión no lineal, distinguen tres estados: falla en la carrera interior, falla en la carrera exterior y un estado que indica un comportamiento normal de los baleros, sin embargo es exclusivo de rodamientos metálicos, dejando al lado tanto los cerámicos como los híbridos.

La metodología propuesta por Sharma (2018) para la detección de fallas en baleros obtiene señales de vibración en el dominio del tiempo y por medio de PCA reduce la dimensionalidad de los datos, y realiza la clasificación empleando el WKNN (*Weighted K-Nearest Neighbor*); dicha propuesta fue aplicada a detección y clasificación de baleros sanos

y con falla. Por otro lado, Picot et al (2018) desarrollaron un esquema de clasificación automática para detección de fallas en rodamientos en máquinas síncronas magnéticas permanentes empleando el método de PCA recursiva, para ello solo necesitan los datos de la máquina en buen estado para así entrenar el algoritmo, además utilizan la distancia euclidiana para la detección de clases. Saucedo desarrolló en el 2016 un método para la detección y clasificación de fallas en una cadena cinemática, permitiéndole distinguir entre falla de baleros y desgaste de engranes. Para la señal de vibración se aplica la FFT mientras que para la señal de corriente se hace un análisis espectral de potencias (PSD), para la extracción de indicadores utiliza tanto la técnica LDA (Análisis Discriminante Lineal) como PCA, además se emplea la fusión de datos y algoritmos inteligentes GA (Algoritmos Genéticos), sin embargo, los trabajos antes mencionados no realizan una distinción de fallas donde se tomen en consideración los materiales con los que están fabricados los rodamientos, haciéndolos exclusivos para rodamientos metálicos.

En base a los antecedentes presentados, si bien diversas metodologías han sido desarrolladas para la clasificación de fallas en rodamientos, se enfocan solamente en analizar los elementos rodantes sin importar el material del que están fabricados, es por ello que en este proyecto se propone realizar la clasificación de fallas de la pista externa de rodamientos metálicos, cerámicos e híbridos en una cadena cinemática utilizando indicadores estadísticos junto con la técnica de PCA, además, en la clasificación se incluirán dos fallos más de la cadena, los cuales son la presencia de barras rotas y desbalance de cargas. También, para no limitar sus aplicaciones, se implementará tanto en software como en hardware.

## 1.2 Objetivos e Hipótesis

### 1.2.1 Objetivos

El objetivo general de esta tesis se centra en analizar la aparición de fallos en rodamientos mediante el uso indicadores estadísticos y el análisis de componentes principales para generar una metodología de diagnóstico basada en hardware que conduzca a la detección de fallos en tiempo real.

Para cumplir el objetivo general deben de cumplirse los siguientes objetivos particulares:

- Instrumentar una cadena cinemática con diferentes sensores para realizar la adquisición de diferentes magnitudes físicas, como vibraciones y corrientes, que caractericen la condición de operación de rodamientos fabricados por diferente material (cerámicos, metálicos e híbridos) bajo condiciones sanas y de fallo.
- Procesar en software las diferentes magnitudes físicas mediante el cálculo de indicadores estadísticos para obtener los patrones característicos que describan el comportamiento de los diferentes rodamientos bajo la influencia de diferentes severidades de fallo en la pista exterior.
- Calcular y analizar el conjunto de indicadores estadísticos que caracterizan el comportamiento de fallo de los diferentes rodamientos mediante la técnica de análisis de componentes principales para reducir la dimensionalidad del espacio original y obtener una representación visual de las condiciones evaluadas.
- Realizar la detección automática de diferentes condiciones de falla mediante el uso de un clasificador basado en una red neuronal para validar la aplicabilidad de la metodología ante la detección de fallas en rodamientos fabricados por diferente material.
- Diseñar y desarrollar las estructuras digitales mediante la descripción de lenguaje en VHDL para realizar el cálculo de indicadores estadísticos y reducir la dimensionalidad del conjunto original de indicadores.
- Simular las estructuras digitales diseñadas para evaluar y clasificar los fallos en los diferentes rodamientos y determinar su condición, así como para evaluar el desempeño y eficacia del método respecto su aplicación en software.
- Analizar el rendimiento de la metodología de diagnóstico desarrollada en software y hardware para validar su aplicación en el diagnóstico y detección de fallas en rodamientos.

### 1.2.2 Hipótesis

A partir de la caracterización de magnitudes físicas con indicadores estadísticos y mediante la aplicación de la técnica de análisis de componentes principales sobre un conjunto de indicadores que caractericen la aparición de fallos rodamientos, será posible desarrollar una metodología de diagnóstico que pueda ser implementada en hardware y que permita

realizar la detección de fallas de forma automática y simple respecto a métodos clásicos que se basan en el análisis del dominio de la frecuencia.

### 1.3 Justificación

Una de las áreas que ha cobrado gran importancia en la industria es el monitoreo de condición y detección de fallos en la maquinaria, siendo los motores de inducción uno de los elementos principales que han sido objeto de estudio. En este sentido, se han desarrollado diversas metodologías para la supervisión de su funcionamiento, muchas de las cuales están enfocadas específicamente a los baleros que los componen. Pese a que existen diferentes métodos, la mayoría se enfocan en estudiar el comportamiento de los rodamientos metálicos, que, si bien son los más utilizados en la industria, no son los únicos, dejando de lado los rodamientos cerámicos e híbridos, los cuales presentan algunas ventajas frente a los metálicos para algunas aplicaciones, tales como su dureza, resistencia térmica, aislamiento eléctrico, entre otras. Pese a todo esto, no se han estudiado a fondo las firmas que los tres tipos de baleros poseen al estar en operación normal y de falla, así como su comparativa, por lo que la metodología planteada en este proyecto pretende estudiar esta nueva área de investigación, donde además se identifiquen y clasifiquen los fallos de la pista externa de los tres tipos de rodamientos. Para ello se emplearon indicadores estadísticos en conjunto con el método de PCA y redes neuronales.

Asimismo, generalmente la mayoría de los proyectos que identifican y clasifican fallas en rodamientos están desarrollados en software, condicionando la aplicación en línea de los métodos e identificación en tiempo real por lo que es deseable aplicarlo en hardware, sin embargo, el método de PCA no es un proceso iterativo, por lo que su completa aplicación en hardware resultaría en un posible desperdicio de recursos, por lo que se planteó un método donde se combine la parte de software con hardware, donde el primero servirá como método de entrenamiento mientras el segundo para la parte de ejecución, mejorando así los tiempos de actuación y tratando de optimizar recursos. En este sentido, desarrollar una metodología que utilice indicadores estadísticos para clasificar fallas en baleros en la pista externa considerando su composición es una buena oportunidad para estudiar las firmas de los tres grupos (metal, cerámico e híbrido) y así observar las repercusiones que tiene en la cadena cinemática.

## 1.4 Planteamiento General

El planteamiento general para este trabajo se muestra en la Figura 1 donde se observan las etapas propuestas para llevar a cabo la detección y clasificación de fallos en rodamientos.

En su primera etapa y con el fin de evaluar el estado de la cadena cinemática se debe realizar la instrumentación de ésta colocando diferentes sensores para la medición de diversas magnitudes físicas, tales como vibración, corriente y velocidad. Luego entonces en la parte de experimentación se seleccionan las condiciones de prueba, así como las de operación.

Como se puede observar, el proceso se divide en dos partes: Entrenamiento en software e Implementación en Hardware. La primera se encarga de recibir un grupo de señales, procesarlas y analizarlas en conjunto para obtener una serie de valores, los cuales permiten la identificación y clasificación de fallas. Éstos son exportados a la sección de implementación en hardware en formato binario, donde se tiene una sola señal de entrada, la cual es procesada y analizada siguiendo la misma metodología que en software, para finalmente obtener un diagnóstico de la señal sin necesidad de realizar todo el proceso de entrenamiento nuevamente.

- Instrumentación de la cadena cinemática

La cadena cinemática sobre la cual se realizaron las pruebas está conformada principalmente por un motor de inducción trifásico de 1HP cuya velocidad de rotación es controlada a través de un variador de frecuencia y un alternador convencional de uso automotriz que sirve como carga mecánica, el motor de inducción y el alternador se acoplan mediante un sistema de poleas y banda como como se observa en la Figura 2. Con el fin de obtener las magnitudes físicas necesarias para la detección y clasificación de fallas, se colocaron los sensores correspondientes en puntos estratégicos en la cadena cinemática; estos son un acelerómetro triaxial para medir las vibraciones que se presenten en el sistema, además de un encoder el cual se encarga de detectar la posición del rotor, con lo que se puede




Figura 1.- Planteamiento General

obtener la velocidad de giro del motor, asimismo se miden tanto la corriente del estator y su voltaje. Sin olvidar que las señales obtenidas por los sensores deben ser propiamente acondicionadas para poder manipular la información recopilada.

- Experimentación

Se establecen las condiciones de prueba a analizar: rodamiento metálico sano (HLT-M), rodamiento metálico con falla localizada en la pista externa (BD-M), rodamiento cerámico sano (HLT-C), rodamiento cerámico con falla localizada en la pista externa (BD-C), rodamiento híbrido sano (HLT-H) y rodamiento híbrido con falla localizada en la pista externa (BD-H). Además, se establecen las condiciones de operación, tales como frecuencia de operación, número de pruebas, tiempo de muestreo, etc.

- **ENTRENAMIENTO EN SOFTWARE**

- Procesamiento de señales

Primero se preparan los datos obtenidos de la cadena cinemática para poder utilizarlos, es decir, convertirlos del formato binario con el cual se adquirieron a valores reales, entre otras cosas que se describen a detalle en la metodología.

- Fusión de datos

Se calcula una serie de indicadores estadísticos que reflejan el comportamiento de las señales de entrada y después aplicando la técnica de PCA, se reduce su dimensionalidad para obtener un subconjunto de indicadores que mejor caractericen a las diferentes condiciones evaluadas. Del método elaborado en software se obtiene la matriz de transformación la cual se utiliza directamente en hardware, evitando así la descripción de todo el procedimiento de PCA en VHDL.



*Figura 2.- Cadena cinemática bajo análisis*

- Clasificador NN

Como método de clasificación se plantea la utilización de redes neuronales, donde al igual que en el paso anterior, en software se calculan los pesos pertinentes para ser aplicados directamente en VHDL. Finalmente se realiza una evaluación de desempeño de cada uno de los productos generados en función de las relaciones de clasificación resultantes, con el fin de realizar una comparativa entre ellos para determinar su rendimiento.

- **IMPLEMENTACIÓN EN HARDWARE**

- Procesamiento de señales

Al igual que en el entrenamiento en software se deben preparar los datos recibidos para ser analizados, sin embargo, en este caso solo se realiza el pre procesamiento de una sola señal de entrada ya que no es necesario re entrenar redes neuronales ni obtener los componentes principales, dado que estos valores ya fueron calculados en la etapa de entrenamiento y en la parte de implementación solo serán importados.

- PCA

Dado que la matriz de transformación ya fue calculada en software, se realiza la proyección de los indicadores al nuevo plano que representa los dos componentes principales.

- Redes Neuronales

Este último paso clasifica directamente la salida del paso anterior con los pesos y bias obtenidos del entrenamiento en software, dando así un diagnóstico del estado de la cadena cinemática.



# Capítulo II

## 2 Fundamentación teórica

### 2.1 Rodamientos

Los rodamientos son elementos mecánicos que ayudan a reducir la fricción entre la parte fija y los elementos giratorios de una máquina, permitiendo así el movimiento rotacional libre. La mayoría de los rodamientos están compuestos por cuatro partes principales: la pista o anillo interior, la pista exterior, la jaula y los elementos rodantes, las cuales se señalan en la Figura 3. Las pistas son las responsables de soportar las cargas que se ejercen sobre el balero, ya que en ellas se deslizan los elementos rodantes. Éstos últimos se pueden clasificar en dos tipos: rodillos y bolas, a su vez los de rodillos se dividen en cilíndricos, cónicos, esféricos, de aguja, etc. Cuando los elementos rodantes son tipo bola tienen un solo punto de contacto con las pistas interior y exterior, mientras que cuando son tipo rodillo se presenta toda una línea de contacto. Finalmente, la jaula se encarga de equidistar a los elementos giratorios entre sí, además dada la posición en que está ubicada, la carga no actúa directamente sobre ella (NTN corporation, 2004).




Figura 3.- Partes de un rodamiento de bolas (NTN, 2019)

#### 2.1.1 Clasificación de rodamientos por material

Los rodamientos se pueden clasificar tomando en cuenta los materiales que fueron utilizados para su fabricación, ya que éstos suelen determinar las aplicaciones para las cuales pueden ser utilizados dependiendo del entorno en que se coloquen y el uso que se les dé, o bien un rodamiento puede presentar ventajas o desventajas frente a otro del mismo modelo,

pero de diferente material para una aplicación específica. Luego entonces, los rodamientos se pueden separar en tres grupos: metálicos, cerámicos e híbridos.

### 2.1.1.1 Rodamientos metálicos

Son aquellos que están constituidos completamente de metales o de algún tipo de aleación; si bien diferentes materiales suelen ser utilizados, el acero y el aluminio son algunos de los principales componentes, además, es importante mencionar que el tratamiento térmico que reciben juega un importante papel en su elaboración, ya que de éste dependen algunas de sus características físicas. Los rodamientos metálicos han sido ampliamente estudiados ya que son los más utilizados dada su gran capacidad de carga y su precio, aunado el hecho de que existe una gran variedad de ellos, tal como se observa en la Figura 4, además de que algunas aleaciones son resistentes a la corrosión.



Figura 4.- Rodamientos metálicos (NTN, 2019)

### 2.1.1.2 Rodamientos cerámicos

Los rodamientos cerámicos (*full ceramic*) son aquellos que, como su nombre lo indica, están compuestos completamente de materiales cerámicos (Figura 5), siendo el Nitruro de Silicio ( $Si_3N_4$ ) el más utilizado así como el Óxido de Zirconio ( $ZrO_2$ ) y el Carburo de Silicio ( $SiC$ ). Algunas de sus principales ventajas son que imposibilita la corrosión, sin importar a la velocidad a la que sea operado, es silencioso por la dureza del material, además de que en la mayoría de los casos no es necesario el uso de lubricantes. También su vida útil es más larga que la de los rodamientos metálicos debido al bajo desgaste térmico y mecánico que presentan (deceramica, 2020).



*Figura 5.- Rodamiento cerámico (Ortech, 2019)*

### **2.1.1.3 Rodamientos híbridos**

Los rodamientos híbridos por su parte son aquellos cuyos elementos rodantes son de materiales cerámicos, pero sus pistas interior y exterior son metálicas o aleaciones (ver Figura 6). Una de las características principales que presentan es que gracias a que su dureza es mayor comparada con los rodamientos metálicos, la deformación microscópica con las cargas es menor, lo que reduce la resistencia de la rodadura logrando así que sean más durables. Sin embargo, también dada su gran dureza es necesario que la superficie de los elementos rodantes esté en perfectas condiciones. Otra de las ventajas que tienen además de necesitar poco mantenimiento es que reducen su peso un 60% comparándolos con los rodamientos metálicos tradicionales, al ser más ligeros se reduce la fuerza centrífuga y se genera menos fricción, alcanzando velocidades máximas (incluso con lubricación con grasa), además de que requieren de menos energía para mantenerla (Eurobearings, 2019). Asimismo, al generarse poca fricción, se presenta un menor incremento de temperatura logrando así menos desgaste del rodamiento, alargando su vida de servicio. Sus principales aplicaciones se dan en casos en donde se requiera aislamiento eléctrico y donde se manejan altas velocidades.



*Figura 6.- Rodamiento híbrido (Ortech, 2019)*

### 2.1.2 Defectos en rodamientos

Los rodamientos son elementos fundamentales en una cadena cinemática, si bien su tiempo de vida útil es calculable, también es común que se presenten fallas inesperadas debido a razones externas, lo cual reduce en gran medida su duración. Algunas de las razones por las cuales se originan los desperfectos son fatiga, carga excesiva, desalineamiento, sobrecalentamiento, almacenamiento y manipulación incorrectas, mal ajuste, así como la corrosión, generada por humedad. Asimismo, la contaminación es otro factor recurrente cuando se presentan defectos en baleros, ya que partículas extrañas generan desgaste abrasivo, abolladuras o rayado circunferencial en los elementos rodantes y las pistas. También una lubricación inadecuada puede ocasionar desperfectos, siendo el caso de que sea deficiente o el lubricante utilizado no sea el adecuado. El falso Brinell por su parte, se origina por movimientos axiales de los elementos rodantes cuando el equipo está inactivo (vibraciones externas), desplazando hacia afuera el lubricante y evitando que éste vuelva a ingresar por falta de rotación, generando estrías en las pistas. Igualmente, el paso continuo de una corriente eléctrica a través de un rodamiento afecta su funcionamiento, ya que puede generar cráteres en el mismo o bien soldar el material a causa de las altas temperaturas cuando se trata de amperajes muy elevados (Ritbearing, 2014).

Las fallas en los rodamientos se clasifican en defectos distribuidos y defectos localizados. Los primeros incluyen rugosidad en la superficie, ondulaciones, pistas desalineadas y elementos rodantes con dimensiones erróneas. Estos defectos están relacionados principalmente con errores de manufactura, desgaste abrasivo, así como con una inadecuada técnica de instalación del rodamiento. Por su parte, los defectos localizados incluyen huecos, grietas y descamación o astilladuras del material del rodamiento, siendo este último el más común. Además, se ha demostrado que el 90% de las fallas tanto en las pistas como en los elementos rodantes involucran defectos localizados. (Guptaa & Pradhan, 2017).

Las fallas localizadas en las pistas externas son muy comunes, se pueden generar debido un exceso en la carga, la tensión excesiva interna causada por una instalación defectuosa, debido a un aumento de temperatura parcial instantáneo del balero ocasionado por un deslizamiento repentino de las superficies de los anillos en contacto con el eje o el alojamiento o bien el deslizamiento de las superficies rodantes (Koyo, 2010). En la Figura 7

y Figura 8 se pueden observar dos ejemplos de defectos localizados en la pista externa de rodamientos.



Figura 7.- Grietas en la pista exterior de un rodamiento de doble hilera de rodillos cilíndricos (Koyo, 2019)



Figura 8.- Astilladura en la pista exterior en un rodamiento de rodillos cilíndricos (Koyo, 2019)

## 2.2 Métodos de detección de fallas

### 2.2.1 Análisis de señales en el dominio del tiempo

Las señales adquiridas en el dominio del tiempo frecuentemente son el resultado de realizar el monitoreo de un proceso industrial, y a pesar de que lo único que se obtiene de ellas en primera instancia es la variación de la amplitud medida en un tiempo determinado, se puede obtener información valiosa que puede ayudar a detectar fallas en sistemas electromecánicos con el uso de diferentes técnicas del dominio del tiempo.

El uso de estos métodos implica utilizar la estadística descriptiva (*descriptive statics feature*), la cual se separa en medidas de tendencia central, que describen la posición central de la distribución de un conjunto de datos; y medidas de variabilidad, las cuales analizan cómo es la dispersión de los datos. A menudo este método se utiliza calculando uno o varios indicadores estadísticos de una señal periódica y con base en el valor obtenido se determina la condición de estado del proceso monitoreado, sin embargo la efectividad de éste método por si solo para detectar defectos a menudo se ve afectada por las características físicas de la falla, por las condiciones de operación de la maquinaria o bien suelen ser poco precisos, por lo que es común trabajar éste mezclado con otros métodos.

Sin embargo, estos indicadores estadísticos en conjunto permiten la caracterización general de un sistema durante condiciones estacionarias, aunque también es posible aplicarlo bajo condiciones no estacionarias y de igual manera obtener información característica del sistema (Delgado, 2012). Si bien, no se obtiene directamente un diagnóstico a primera instancia, permite modelar el comportamiento de una señal que en junto con métodos de reducción o inteligencia artificial suelen ser muy efectivos. Algunos de los indicadores estadísticos basados en el dominio del tiempo más utilizados para analizar sistemas electromecánicos con resultados satisfactorios son los descritos por las ecuaciones de (1) a (14):

Media ( $\bar{X}$ ):

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

Valor máximo ( $\hat{x}$ ):

$$\hat{x} = \max(x_i) \quad (2)$$

Valor eficaz (*Root Mean Square, RMS*):

$$RMS = \sqrt{\frac{\sum_{i=1}^n (x_i)^2}{n}} \quad (3)$$

Media cuadrática (*Square Mean Root, SRM*):

$$SMR = \left( \frac{\sum_{i=1}^n \sqrt{|x_i|}}{n} \right)^2 \quad (4)$$

Desviación estándar ( $\sigma$ ):

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2} \quad (5)$$

Varianza ( $\sigma^2$ ):

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2 \quad (6)$$

Factor forma RMS ( $RMS_{sf}$ ):

$$RMS_{sf} = \frac{RMS}{\frac{1}{n} \sum_{i=1}^n |x_i|} \quad (7)$$

Factor forma SRM ( $SRM_{sf}$ ):

$$SRM_{sf} = \frac{SRM}{\frac{1}{n} \sum_{i=1}^n |x_i|} \quad (8)$$

Factor Cresta ( $CF$ ):

$$CF = \frac{\hat{x}}{RMS} \quad (9)$$

Factor Latitud ( $LF$ ):

$$LF = \frac{\hat{x}}{SMR} \quad (10)$$

Factor Impulso ( $IF$ ):

$$IF = \frac{\hat{x}}{\bar{X}} \quad (11)$$

Skewness ( $S_k$ ):

$$S_k = \frac{\sum_{i=1}^n (x_i - \bar{X})^3}{RMS^3} \quad (12)$$

Kurtosis ( $K_{ur}$ ):

$$K_{ur} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^4}{RMS^4} \quad (13)$$

Momentos de nivel superior ( $M_g$ ):

$$M_g = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^g}{RMS^g} \quad (14)$$

Donde  $n$  : número total de datos que conforman la señal bajo análisis, depende del tiempo y la frecuencia de muestreo.

$x_i$  : valor observado  $i$ -ésimo de la señal original

$g$  : momento que se desea calcular, siendo el quinto y sexto los más comunes.

### 2.2.2 Análisis de señales en el dominio de la frecuencia

Uno de los métodos más utilizados para la detección de fallas en rodamientos es el análisis en el dominio de la frecuencia o análisis espectral. En éste, como su nombre lo indica se calcula la presencia relativa de cada componente frecuencial de una señal periódica en el tiempo por medio de la transformada de Fourier, dicha conversión está dada por

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (15)$$

Donde  $X(f)$  es el espectro como una función de frecuencia  $f$ ,  $x(t)$  es la señal de prueba en el dominio del tiempo,  $e^{-j2\pi ft}$  es el factor de fase,  $t$  es el tiempo y  $f$  es la frecuencia en Hz. La transformada discreta de Fourier (*DFT, discrete transform Fourier*) se puede utilizar para calcular el espectro de frecuencias de una señal de tiempo discreta ( $x_n$ ) para  $N$  número de muestras, utilizando

$$X(k) = \sum_{n=0}^{N-1} x_n e^{-\frac{j2\pi}{N}kn} \quad (16)$$

Sin embargo, la DFT suele ser ineficiente al no aprovechar la simetría del factor de fase y sus propiedades de periodicidad, por lo que para hacerla más eficiente se utiliza la transformada rápida de Fourier (*Fast Fourier Transform, FFT*), cuyos algoritmos normalmente se ejecutan para señales cuya longitud es potencia de 2, reduciendo así la cantidad de operaciones requeridas (Proakis & Manolakis, 2007).

Este enfoque ha permitido desarrollar diversas herramientas para la detección de fallos en rodamientos, ya que gracias a que muchas de sus características han sido normalizadas, se ha logrado identificar la presencia de fallas localizadas en sus componentes tomando en cuenta sus características físicas por medio de señales de vibración. Así, cuando uno de los elementos rodantes del balero pasa sobre una falla localizada se produce un cambio en la tensión de contacto, resultando en un pulso de muy corta duración, el cual se repite



constantemente, la frecuencia con la que este pulso se genera se puede aproximar por medio de las ecuaciones (17) – (20), las cuales sirven para localizar la falla (pistas, jaula o elementos rodantes).

$$BPFI = \frac{N_b}{2} f_r \left( 1 + \frac{BD}{PD} \cos \theta \right) \quad (17)$$

$$BPFO = \frac{N_b}{2} f_r \left( 1 - \frac{BD}{PD} \cos \theta \right) \quad (18)$$

$$FTF = \frac{f_r}{2} \left( 1 - \frac{BD}{PD} \cos \theta \right) \quad (19)$$

$$BSF = \frac{PD}{2 BD} f_r \left( 1 - \left( \frac{BD}{PD} \right)^2 (\cos \theta)^2 \right) \quad (20)$$

Donde BPFI (*Ball Pass Frequency of the Inner race*) es la frecuencia característica de fallo de la pista interior, BPFO (*Ball Pass Frequency of the Outer race*) es la frecuencia característica de fallo de la pista exterior, FTF (*Fundamental Train Frequency*) es la frecuencia característica de fallo de la jaula y BSF (*Ball Spin Frequency*) es la frecuencia característica de los elementos rodantes, por su parte  $N_b$  es el número bolas del rodamiento,  $BD$  es el diámetro de la bola (*ball diameter*),  $PD$  es el diámetro de la jaula medido desde un centro de bola al centro de bola opuesta (*pitch diameter*),  $\theta$  es el ángulo de contacto y  $f_r$  la frecuencia de rotación del rotor en Hertz, en la Fig.10 se señalan las dimensiones de los rodamientos necesarias para el cálculo de éstas frecuencias de falla.




Figura 9.- Geometría de un rodamiento

Además, también es posible identificar la presencia de daños en rodamientos utilizando señales de corriente, ya que ésta se altera cuando se presentan fallas, así las frecuencias características de falla se calculan utilizando la ecuación (21).

$$f_{BE} = f_r \pm k f_{car} \quad (21)$$

Donde  $f_{car}$  es la frecuencia característica de falla del defecto estudiado, la cual se calcula con las ecuaciones (17)-(20) utilizando las características físicas de balero,  $f_r$  es la frecuencia de rotación del rotor y  $k$  es una constante que toma valores enteros positivos dependiendo del armónico que se desee obtener (Bellini, Immovilli, & Rubini, 2008).

### 2.2.3 Análisis de señales en el dominio tiempo – frecuencia

El análisis de señales en el dominio del tiempo-frecuencia pretende reducir las limitaciones que tienen las técnicas del dominio del tiempo y frecuencia por separado, de esta manera se describen los componentes frecuenciales variando a través del tiempo de una señal. Algunas de las técnicas más utilizadas son la transformada corta de Fourier (short-time Fourier transform, STFT), distribución Wigner-Ville y la transformada continua Wavelet, entre otras. Sin embargo, calcular estos métodos toma mucho tiempo y suelen ser muy complicados (Fu, Liu, Xu, & Liu, 2016)

## 2.3 Selección de indicadores

Reducir indicadores de un conjunto de datos recopilados es indispensable, ya que permite mejorar el rendimiento del algoritmo en el cual son utilizados, pues muchas veces los atributos adicionales actúan como ruido, además de no hacerlo, el procesamiento de los mismos sería más lento y se desperdiciarían recursos innecesarios. El objetivo entonces es encontrar  $M$  atributos importantes entre los  $N$  atributos originales, donde  $M \leq N$ , para así seleccionar las características que aporten la información más relevante y que describan al sistema tan bien como los datos originales (Liu & Setiono, 1996).

La selección de características es empleada en muchos campos de investigación, por lo que para éste propósito diversos métodos se han desarrollado, éstos se pueden clasificar en dos categorías: Métodos de filtrado y métodos de envoltura. Los primeros son muy eficientes y más rápidos de calcular, se utilizan generalmente como un paso de pre procesamiento de

datos por lo que son independientes de cualquier algoritmo de aprendizaje (ver Figura 10), para la reducción evalúan a cada uno de ellos según los puntajes estadísticos que determinan la correlación de los atributos con la variable de resultado, sirviendo así como filtro para las características irrelevantes o redundantes; sin embargo éste método no considera que si bien un indicador puede no incluir información discriminante por sí solo, si la puede contener en conjunto con algún otro indicador. Algunas de éstas técnicas son la correlación de Pearson, Anova, Chi-cuadrado, LDA y PCA.




Figura 10.- Métodos de Filtro. (Autoría propia)

Los métodos de envoltura, a diferencia del anterior, si requieren de un algoritmo de aprendizaje. Así, evaluando su propio rendimiento se genera un subconjunto que mejore su productividad agregando o quitando indicadores, por lo que la selección de características en este caso depende en gran medida del algoritmo de aprendizaje seleccionado, como se puede observar en la Figura 11; la selección hacia delante (*Forward Selection*), la eliminación hacia atrás (*Backward Selection*) y la eliminación de características recursivas (*Recursive Feature Elimination*) son algunos de los procedimientos más comunes. Sin embargo, el uso de este método se dificulta ya que conforme más características se agregan al conjunto original, la cantidad de subconjuntos obtenidos se incrementa exponencialmente, por lo que métodos heurísticos son necesarios para orientar la búsqueda del subconjunto, tales como algoritmos genéticos o redes neuronales, quedando expuesto a un posible sobre entrenamiento. Si bien, los métodos de envoltura generalmente tienen mejor desempeño, computacionalmente son muy caros ya que cada subconjunto de características debe ser evaluado por el algoritmo de aprendizaje. Además, la reducción de indicadores ejecutado por los métodos de filtro puede ser empleado para generar un subconjunto con un método de envoltura debido a la independencia del algoritmo de aprendizaje de los primeros, sin embargo esto no se puede hacer de manera inversa (García, 2016).

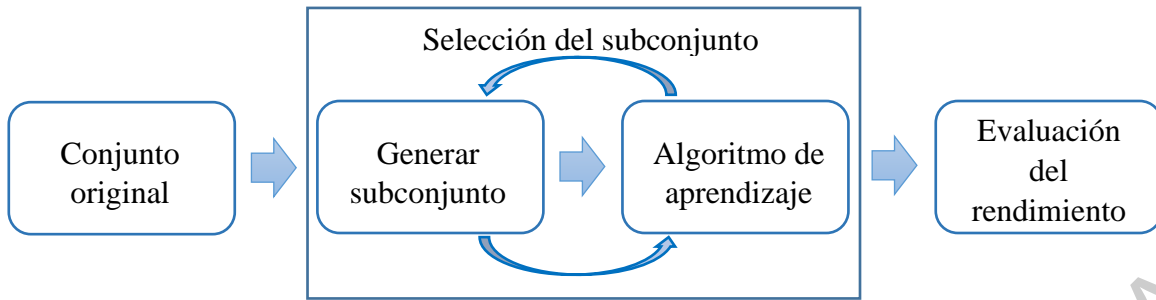


Figura 11.- Métodos de envoltura (Autoría propia)

## 2.4 Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales o la transformada KL (*Karhunen-Loève transform*) es un método lineal no supervisado de extracción de características, reducción de dimensiones, compresión y visualización de datos que usa una transformación ortogonal para convertir un conjunto de indicadores posiblemente correlacionados a un espacio lineal de indicadores no relacionados, ordenados de tal manera que los primeros contengan la variación más importante de la información original, a éstos se les conoce como componentes principales (Stief et al, 2019), donde cada uno de ellos es una combinación lineal de los indicadores originales. El número de componentes principales es igual o menor al conjunto original de variables.

Los datos originales se recolectan en una matriz  $\mathbf{X}$  de dimensiones  $mxl$ , donde  $m$  es el número de filas y  $l$  el número de columnas;  $m$  por su parte normalmente indica el número de muestras y  $l$  las variables o indicadores de cada una de ellas; así  $x_l$  son los vectores de las variables individuales y pertenecen a un espacio de  $l$  dimensiones (Rasmus & Age, 2014), tal como se muestra en la ecuación (15)

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{l1} & x_{l2} & \cdots & x_{lm} \end{bmatrix} \quad (15)$$

Antes de obtener los componentes principales, es necesario normalizar las señales de entrada, así que utilizando el método de estandarización de media-varianza se obtiene una media de cero y una varianza unitaria para cada variable, garantizando así que todos los datos estén en la misma escala y evitando que las variables con mayor varianza predominen sobre las demás (Li & Wang, 2014), (Li, Kong, & Dang, 2010), esto se consigue mediante la siguiente ecuación

$$X' = \frac{x_i - \bar{x}}{\sigma} \quad (16)$$

Luego entonces, es necesario calcular la matriz simétrica de varianza-covarianza  $\Sigma$  de  $X'$ , la cual está dada por la ecuación (18), donde  $l$  es el conjunto de datos y  $\bar{x}$  es la media del vector característico.

$$\Sigma = \sum_{i=1}^l (x_i - \bar{x})^2 \quad (17)$$

Tomando en cuenta que la covarianza de una variable y de sí misma es igual a la varianza de la variable  $Cov(x, x) = Var(x)$ , dentro de la diagonal principal de la matriz de varianza-covarianza se localizan entonces las varianzas de cada dimensión, mientras que fuera de ella la covarianza de cada par de variables, resultando en una matriz, tal como se muestra a continuación

$$\Sigma = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12} & \cdots & \sigma_{1m} \\ \sigma_{21} & \sigma_{22}^2 & \cdots & \sigma_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{l1} & \sigma_{l2} & \cdots & \sigma_{lm}^2 \end{bmatrix} \quad (18)$$

Donde

$l=m$  dado que es una matriz simétrica

$\sigma_{11}^2$  es la varianza de la primera variable respecto a su media, esto es  $Var(1,1)$

$\sigma_{12}$  es la covarianza de la primera variable respecto de la segunda variable, esto es  $Cov(1,2)$

Y así respectivamente con el resto de los elementos de la matriz (Rodó, 2020)

Recordando que la varianza es una medida de dispersión que indica la variabilidad de una serie de datos respecto a su media, mientras que la covarianza señala cuánto varían dos variables respecto a sus medias (López, 2017).

El objetivo entonces es encontrar los indicadores que estén óptimamente no correlacionados; para ello es necesario encontrar una transformación lineal ( $A$ ) (ver ecuación (19)) y obtener un nuevo conjunto de muestras de las cuales se seleccionan las más significativas,

$$Y = AX \quad (19)$$

Donde

$Y$  es una matriz de nuevas variables

$A$  es una matriz ortogonal de eigenvectores de la matriz de varianza-covarianza  $\Sigma$

$X$  es la matriz de observación pre procesada

Para esto es necesario realizar la descomposición propia de  $\Sigma$  y obtener los  $l$  eigen valores y eigen vectores mediante la ecuación (20) los cuales se organizan en orden descendiente, de tal manera que  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l$ , los cuales son conocidos como los componentes principales, finalmente se seleccionan los  $n$  primeros que representan la mayor variación.

$$\Sigma \vec{v} = \lambda \vec{v} \quad (20)$$

Para formar la matriz de transformación mencionada en la ecuación (19), se toman los eigenvectores obtenidos  $a_i, i = 1, 2, \dots, n$  (ver ecuación (21))

$$A = [a_1 \ a_2 \ \dots \ a_n] \quad (21)$$

De esta manera se transforma cada vector de dimensión  $l$  en el espacio original a un vector de  $n$  dimensiones, esto es, el elemento  $i$ -ésimo  $a(i)$  de  $A$  es la proyección de  $x$  sobre  $a_i$  (Theodoridis & Koutroumbas, 2010).

Para explicarlo de manera gráfica, considérese un conjunto de datos de cinco variables (Figura 12a) los cuales han sido previamente pre-procesados, como se explicó anteriormente; de dicho conjunto se obtiene la matriz de varianza-covarianza, recordando que ésta es

simétrica para asegurar la ortogonalidad, donde la diagonal principal está conformada por la varianza de cada dimensión y los valores restantes de la matriz por la covarianza de cada par de dimensiones correspondientes. Resolviendo el problema de eigen vectores y eigen valores, se obtienen cinco vectores perpendiculares los unos a los otros y ordenando los valores propios de manera descendente, se consigue identificar los que tienen mayor dispersión de datos, de esta manera si se seleccionan los primeros dos vectores ( $v_1$  y  $v_2$  con  $\lambda_1$  y  $\lambda_2$  respectivamente) y se dibujan en el espacio original (Figura 12b), se obtiene el plano (Figura 12c) en el cual se concentra la mayor cantidad de datos, esto es donde se consigue mayor dispersión. Luego entonces, se proyectan todos los datos en este nuevo plano (Figura 12d), consiguiendo así, reducir de 5 dimensiones a 2, maximizando la varianza y conservando la mayor cantidad de información. De manera general, PCA intenta identificar el subespacio en el cual se encuentran los datos.

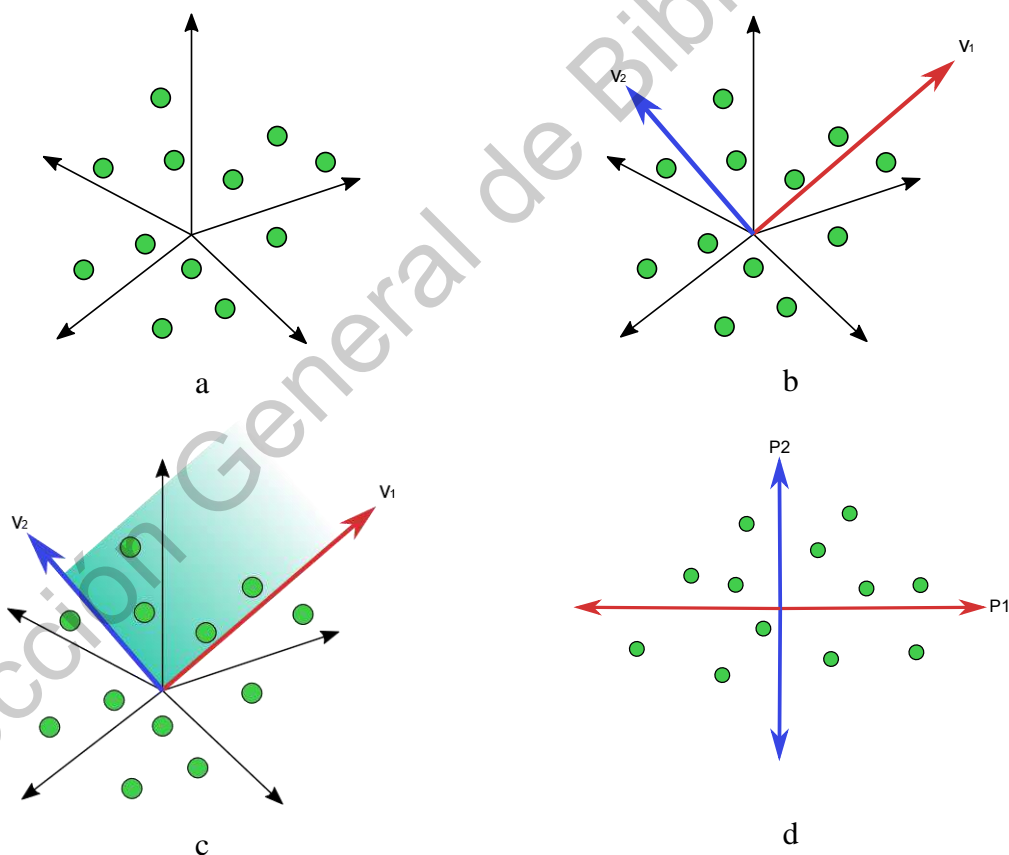


Figura 12.- Proceso de extracción de indicadores mediante PCA a) Conjunto original de datos supuesto en 5 dimensiones b) Proyección de vectores con mayor distribución c) Proyección nuevo plano d) Representación del conjunto de indicadores extraídos en 2 dimensiones

## 2.5 Redes Neuronales Artificiales

Una red neuronal es un conjunto interconectado de elementos simples de proceso, unidades o nodos, cuya funcionalidad se basa libremente en la neurona animal. La capacidad de procesamiento de la red se almacena en los puntos fuertes o pesos de conexión entre unidades, obtenidos mediante un proceso de adaptación o aprendizaje de un conjunto de patrones de entrenamiento. El elemento funcional básico son las neuronas, que se suelen agrupar en unidades estructurales denominadas capas. Dentro de una capa las neuronas pueden agruparse formando grupos neuronales. Dentro de una misma capa o agrupación, las neuronas suelen ser del mismo tipo. El conjunto de una o más capas constituye una red neuronal. Se pueden distinguir tres tipos de capas: Capa de entrada, las cuales reciben los datos o señales del exterior; la capa de salida que es la que proporciona las respuestas de la red neuronal y las capas ocultas que no tienen una conexión con su entorno.

## 2.6 VHDL

Es un lenguaje diseñado para describir sistemas electrónicos digitales. VHDL significa VHSIC (*Very High Speed Integrated Circuits*) Hardware Description Language. Su desarrollo comenzó como un proyecto en el departamento de defensa de Estados Unidos de América en 1983, pero no fue hasta 1987 cuando se estandarizó en el IEEE (*Institute of Electrical and Electronics Engineers*, Instituto de Ingenieros Eléctricos y Electrónicos). Una de sus características es que puede utilizarse durante todo el ciclo de diseño, esto es, que si bien es un lenguaje de diseño de hardware, también puede usarse como lenguaje de simulación, de especificación y de verificación funcional. También, al tratarse de un lenguaje de diseño de hardware soporta perfectamente el paralelismo, pero además admite programación secuencial. Asimismo, una de sus características fundamentales es que está altamente estructurado, lo que permite al compilador realizar verificaciones tempranas y reducir riesgo de errores de codificación (Jasinski, 2016). Principalmente se utiliza para programar FPGA, PLD (*Programmable Logic Device*), CPLD (*Complex PLD*), ASIC (*Application-Specific Integrated Circuit*), entre otros.



# Capítulo III

## 3 Metodología

En este capítulo se describe detalladamente la metodología que se siguió para la clasificación de fallos de rodamientos en una cadena cinemática utilizando la técnica de PCA. En la Figura 13 se muestra el diagrama de dicha metodología, donde en primer lugar se realizó la instrumentación de la cadena cinemática con un acelerómetro triaxial, sensores de efecto hall y un encoder digital. En la etapa de experimentación, se llevó a cabo la adquisición de señales de vibración, corriente y posición, para ello se definieron las condiciones de prueba a analizar, las cuales consistieron en un óptimo funcionamiento del sistema y otra en donde se sustituía el rodamiento sano del motor de inducción por uno con falla en la pista exterior, esto para los tres tipos de rodamientos, teniendo así seis condiciones de prueba.

Después, en la etapa de entrenamiento que se desarrolló en software, específicamente en MATLAB®, se procesaron las señales, esto es que cada señal fue descompuesta en ventanas y para cada una de ellas se calcularon quince indicadores estadísticos que caracterizaban su comportamiento. Una vez que el conjunto de indicadores está listo, se procede con la etapa de fusión de datos, que consiste en la obtención de la matriz de coeficientes o de transformación de dos dimensiones que permite reducir la dimensionalidad de la caracterización de las señales maximizando la varianza, esto es aplicando el método de PCA. Luego entonces, empleando redes neuronales se logra obtener el modelo para la clasificación final de las fallas.

En la etapa de explotación desarrollada en VHDL, también se calcularon todos los indicadores estadísticos, pero a diferencia de la etapa de entrenamiento aquí solo se recibe la señal que se desea analizar y no un conjunto de señales. Después, ya que se posee la matriz de coeficientes por que se obtuvo en la etapa de entrenamiento, se multiplica directamente por los indicadores estadísticos para obtener su reducción y del mismo modo, debido a que los pesos y bias de las redes neuronales son conocidos, se relacionaron con los valores obtenidos de la técnica de PCA, obteniendo la clasificación pertinente y así un diagnóstico de la cadena cinemática.

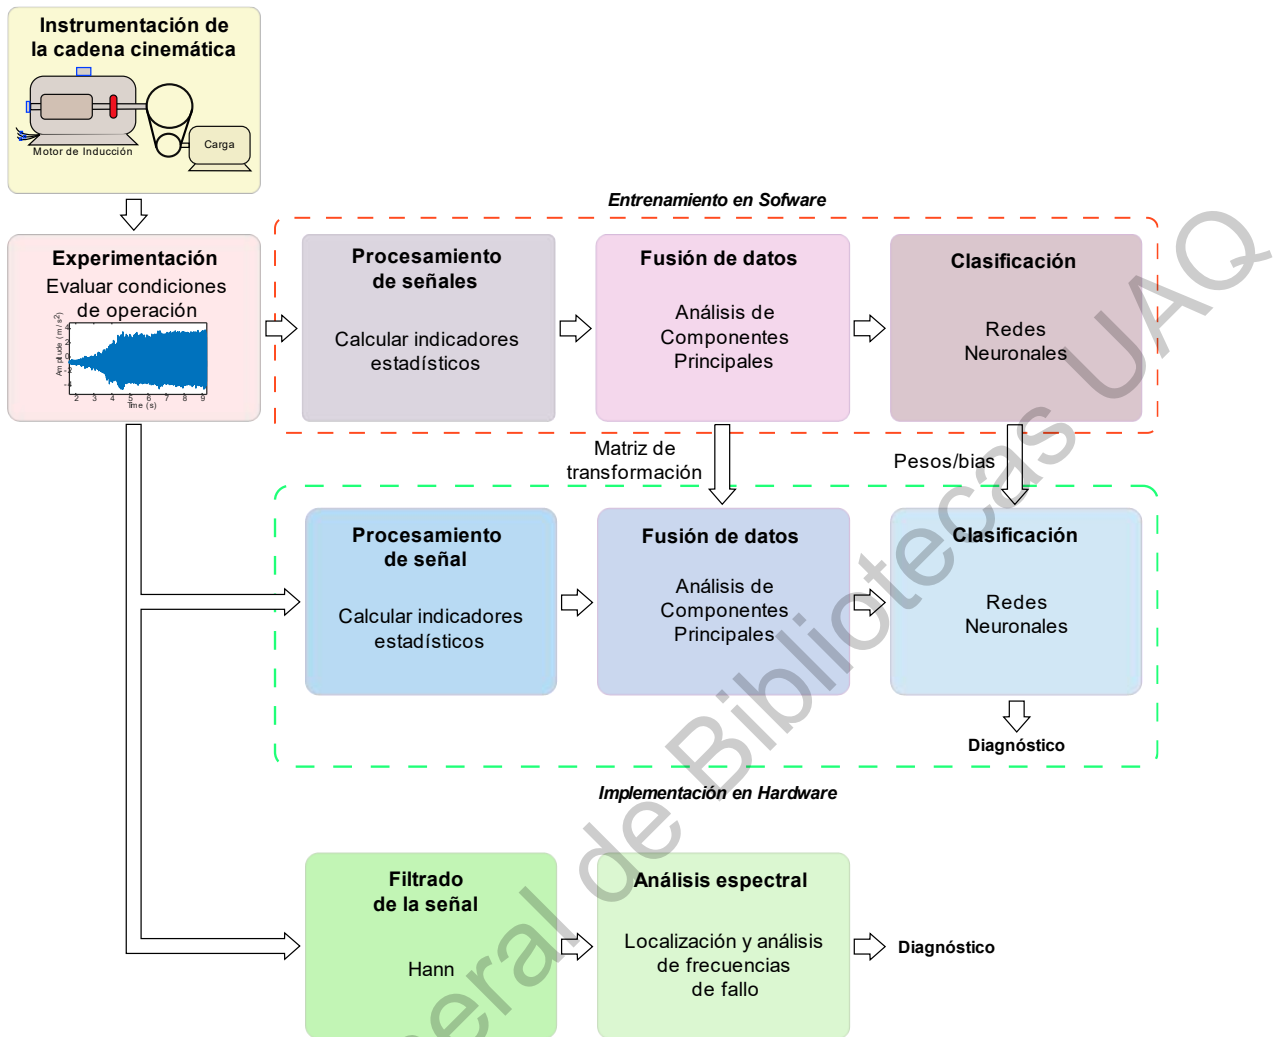


Figura 13.- Metodología General

Como método complementario, se realizó un *análisis espectral* de las señales de vibración de la cadena cinemática, calculando las respectivas frecuencias de fallo características del defecto inducido y localizándolas en el espectro correspondiente, no sin antes pasar por una etapa de *filtrado de la señal*. De igual manera, se analizaron los casos en pares donde la frecuencia de operación y material del rodamiento del motor de inducción fueran el mismo.

### 3.1 Instrumentación de la cadena cinemática

El banco de pruebas utilizado para evaluar las diferentes condiciones se muestra en la Figura 14, el cual está conformado por un motor de inducción trifásico de un polo de 0.745 KW 1 HP, cuya velocidad de rotación está controlada por un variador de frecuencia

(VFD) modelo WEG CFW- 08. El eje del motor de inducción está acoplado por un sistema de poleas a un alternador automotriz Delco Remy que sirve como carga mecánica. Dado que se estableció la adquisición de tres tipos de señales, fueron necesarios tres sensores diferentes, para las señales de vibración se utilizó un acelerómetro triaxial (LIS3L02AS4) el cual se colocó en la parte superior de la carcasa del motor de inducción (cuya orientación de los ejes se muestran en la imagen), las señales de corriente por su parte se adquirieron con sensores de efecto Hall (Tamura Corporation L08P050D15) colocados en los cables de alimentación entre el motor de inducción y el variador de frecuencias, la posición por su parte se obtuvo gracias a un encoder digital incremental colocado en la parte posterior del eje del motor de inducción.

La obtención de las señales se da a través de un sistema de adquisición de datos (DAS) desarrollado en la universidad basado en FPGA y que consta de un convertidor analógico-digital (Texas Instrument ADS7841) de 12 bits de 4 canales de salida en serie. La frecuencia de muestreo para las señales de vibración es de 3 KHz, mientras que para las de corriente y posición es de 6 KHz. Todos los datos obtenidos se almacenan en archivos de texto en una computadora personal para su posterior manipulación.




Figura 14.- Banco de pruebas

## 3.2 Experimentación

### 3.2.1 Fallas Inducidas

Como se mencionó anteriormente, se seleccionaron seis condiciones de prueba. Tres de ellas involucran el uso de rodamientos con falla en la pista externa, esto es, una para el rodamiento metálico (BD-M), otra para el cerámico (BD-C) y una más para el híbrido (BD-H). Las pruebas restantes corresponden a la condición sana de todos los rodamientos, así para el metálico su distintivo en el presente trabajo será HLT-M, para el cerámico será HLT-C y para el híbrido HLT-H. Para generar estas condiciones, se extrae el rodamiento sano del motor de inducción y se coloca uno dañado en su lugar para los tres tipos de baleros.

Para que todas las pruebas de estado de falla del balero fueran iguales, se indujo la misma falla en los tres tipos de rodamientos, la cual consistió en una sola perforación de 1.191 mm de diámetro en cada uno que atraviesa por completo la pista externa. Cabe mencionar que todos los rodamientos utilizados son modelo 6203. En la Figura 15 se muestran las imágenes de las fallas inducidas en los diferentes elementos de la cadena cinemática.



Figura 15.- Fallas inducidas a) Daño pista externa de rodamiento metálico, b) Daño pista externa de rodamiento cerámico y c) Daño pista externa de rodamiento híbrido

### 3.2.2 Descripción de las pruebas

Las pruebas se realizaron de la siguiente manera, primero se ajustaba el banco de pruebas dependiendo de la condición a probar, es decir, reemplazar la pieza requerida dependiendo de la prueba a ejecutar. Luego entonces se fijaba el valor del variador de frecuencias (5 Hz, 15 Hz, 50 Hz o 60 Hz) y se realizaba la adquisición de señales. El tiempo de muestreo fue de 40 segundos, de los cuales 10 se establecieron como la etapa de arranque del motor, quedando así 30 segundos de adquisición de señales en estado estacionario. Como se mencionó

anteriormente, la frecuencia de muestreo para las señales de vibración de la cadena cinemática es de 3 kHz, mientras que para las señales de corriente del rotor y velocidad es de 6 kHz. En total para cada condición con cada una de las frecuencias de operación del motor de inducción se realizaron 10 pruebas.

### 3.3 Entrenamiento en software

En esta etapa se analizaron en pares las pruebas realizadas para tener concordancia con el comportamiento de las señales de la cadena cinemática, esto es, se examinaron las señales HLT-M con BD-M, HLT-C con BD-C y HLT-H con BD-H, que fueron adquiridas a la misma frecuencia de operación. Cabe destacar, que la parte de entrenamiento se realizó por completo en MATLAB®, ya que al ser un software que posee una gran cantidad de herramientas permite un eficaz procesamiento de señales.

En la **¡Error! No se encuentra el origen de la referencia.** se observa el diagrama general de la metodología que se siguió para esta parte del proceso, donde en *Acceso y carga de datos*, como su nombre lo sugiere, se localizan los archivos *txt* que contienen la información de los sensores, se realiza su lectura y se almacenan para su utilización en software. Luego entonces, en el *pre procesamiento de datos*, se realizó la conversión para transformar los datos de su representación decimal del formato binario a su representación decimal correspondiente con las unidades de medida de cada señal, obteniendo así las corrientes del estator del motor de inducción, vibraciones de los ejes *x,y* y *z*, así como la velocidad de rotación del rotor.

Después se seleccionó la señal que se analizaría, escogiendo en primera instancia las relacionadas con las vibraciones en el eje *y*, ya que teóricamente junto con el eje *z* son las que brindan información más representativa de la cadena cinemática debido a que están ubicados perpendicularmente al eje del motor de inducción. Dentro de la etapa de *Cálculo de indicadores*, la parte estacionaria de la señal seleccionada es segmentada en 21 ventanas de 4096 datos, equivalente a 1.36s aproximadamente cada una, tiempo suficiente para que el rotor del motor de inducción de por lo menos una vuelta completa, permitiendo detectar la presencia de una falla en la pista externa del rodamiento por el cambio de vibración de la máquina cuando un elemento rodante pasa sobre la misma. Además, esta longitud se seleccionó con la finalidad de que la cantidad de datos de cada ventana fuera una potencia de

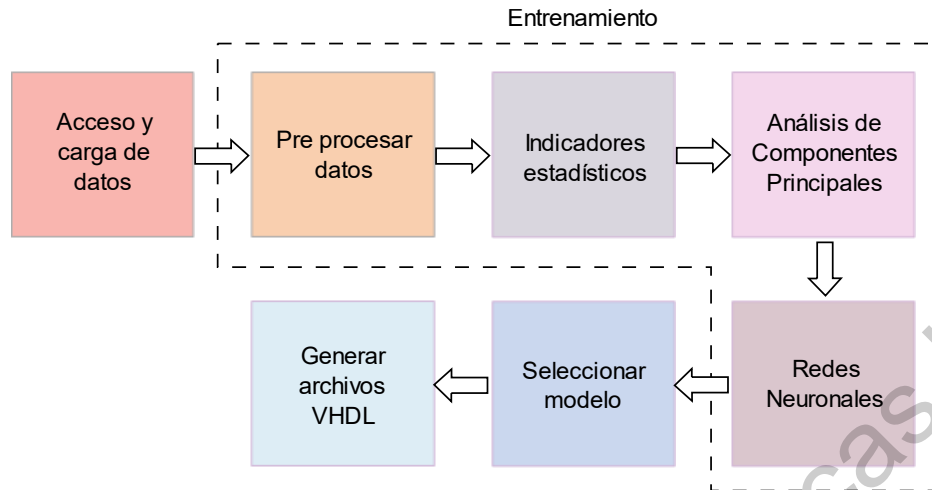


Figura 16.- Metodología del entrenamiento en software

dos, para igualarla a las ventanas desarrolladas en hardware, ya que de esta manera se agilizan los tiempos de cómputo en hardware, como se verá en la etapa de implementación. Conforme se va realizando la separación de ventanas, se van calculando los quince indicadores estadísticos de cada una de ellas, los cuales son: media ( $\bar{X}$ ), valor máximo ( $\hat{x}$ ), valor eficaz ( $RMS$ ), media cuadrática ( $SRM$ ), desviación estándar ( $\sigma$ ), varianza ( $\sigma^2$ ), factor forma  $RMS$  ( $RMS_{sf}$ ), factor forma  $SRM$  ( $SRM_{sf}$ ), factor Cresta ( $CF$ ), factor latitud ( $LF$ ), factor impulso ( $IF$ ), skewness ( $S_k$ ), kurtosis ( $K_{ur}$ ), quinto momento ( $M_5$ ) y sexto momento ( $M_6$ ); con la finalidad de caracterizar el comportamiento de cada sección de las señales originales; de este modo, se obtienen los quince indicadores para cada una, agrupándose en una matriz donde las filas representan las observaciones y las columnas a las variables (indicadores). Finalmente, como se indicó en la metodología, en este caso es necesario normalizar los datos obtenidos mediante el método de estandarización de media-varianza (ver ecuación (16)) para asegurar el funcionamiento del método de PCA con base a la condición HLT evaluada.

Una vez normalizados y agrupados los indicadores de las 10 pruebas de cada condición, así como las dos condiciones mismas, se dio comienzo a la etapa de *Fusión de datos*, donde se emplea la técnica de PCA con la finalidad de obtener los coeficientes de componentes principales o pesos no correlacionados que maximizan la varianza y así obtener la información más representativa de los indicadores. Para ello, se comienza con el cálculo de la matriz simétrica de varianza-covarianza de los datos, se resuelve el problema de eigen valores y eigen vectores, obteniendo una matriz simétrica de coeficientes de 15x15, donde

cada columna contiene los coeficientes para cada componente principal, además dichas columnas están ordenadas de forma descendente conforme a los componentes de varianza. Finalmente, se multiplica la matriz de indicadores normalizados por la matriz de transformación o de coeficientes obtenida, para proyectar los datos originales en el nuevo plano. En este caso, para fines de visualización se seleccionaron solamente los dos primeros componentes principales, ya que de esta manera es posible identificar la separación entre las condiciones fácilmente al momento de graficar; además de que en todos los casos solo éstos dos componentes principales se obtuvo más del 90% de la varianza total, cuando más del 85% ya se considera aceptable, lo cual se describirá a detalle en el capítulo de resultados.

Finalmente, la clasificación está a cargo de redes neuronales, en donde se utilizaron 10 neuronas para la capa oculta y como método de paro se estableció un máximo de 100 épocas. Los valores de entrada de la red se normalizaron entre 0 y 1, para que los mapas de las regiones de decisión quedaran acotados entre esos valores. Para las capas de entrada se utilizó la *sigmoide* como función de activación, mientras que para la capa de salida se utilizó *purelin*. Además, se estableció que el 80% de los datos sería utilizado para el entrenamiento de la red, mientras que el 20% restante sería utilizado en la parte de validación. Se generaron cinco redes neuronales de prueba y de cada una de ellas se obtuvo la tabla de confusión que resume la efectividad del entrenamiento, así como de la validación de los datos y se grafican las regiones de clasificación. Cada red neuronal entrenada dará como resultado una matriz *IW*, que corresponde con los pesos que van a las capas desde las entradas de la red, una matriz




Figura 17.- Funcionamiento de las redes neuronales en Matlab

$LW$  que define los pesos que van de capa a capa y un vector  $b$  que establece los valores de bias para cada capa. En la Figura 17 se muestra la arquitectura general para redes neuronales en Matlab, donde se muestran estas propiedades, además en la parte inferior de la imagen se muestra la función que define una red neuronal con tres capas, la misma que se siguió, pero para las diez capas del diseño.

En la *Selección de modelo*, se escoge con base en las tablas de confusión la red neuronal que mejor logre clasificar las fallas en la cadena cinemática, cuyos pesos y bias se exportarán en formato binario para la implementación. Finalmente, en la etapa llamada *Generar archivo VHD*, se manda llamar una función que convierte los valores decimales que reciba a formato binario con el formato de punto fijo que se le defina y los coloca en un archivo con formato *.vhd* con la descripción de una memoria ROM. En este caso, los archivos generados corresponden con la matriz de coeficientes obtenidas de la técnica de PCA, creando un archivo para cada componente principal, mientras que, para las redes neuronales, se generan seis archivos, separando los pesos y bias de entrada de los de salida.

### 3.4 Explotación en Hardware

La etapa de implementación en hardware está diseñada para recibir una señal de vibración de la cadena cinemática y dar un diagnóstico, el cual en este caso consiste en definir si está en buenas condiciones o si presenta fallas en la pista externa de su rodamiento. En la Figura 18 se muestra un esquema general del funcionamiento de esta fase, donde se comienza con la señal de vibración que se desea evaluar, después, pasa por un bloque que calcula quince indicadores estadísticos de dicha señal, mismos indicadores que se utilizaron en la etapa de entrenamiento en software. Luego entonces, el bloque PCA se encarga de realizar la

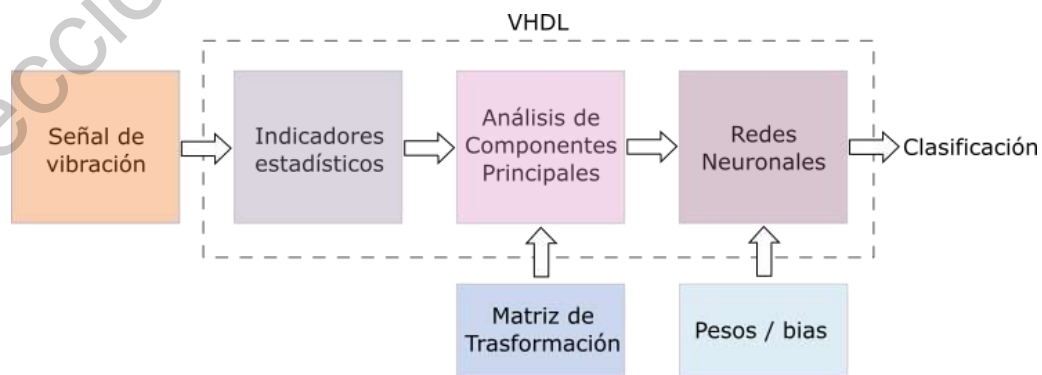


Figura 18.- Diagrama general de la explotación en VHDL



proyección de los datos recibidos a un nuevo plano de máxima varianza utilizando la matriz de coeficientes o de transformación generada en el entrenamiento, finalmente, se reciben estas coordenadas y se clasifican con la ayuda de redes neuronales.

A continuación, se explicarán los principales bloques que se realizaron para esta etapa, yendo desde los más generales hasta los particulares, donde además se describirán sus máquinas de estado para mostrar su funcionamiento.

En la Figura 19; **Error! No se encuentra el origen de la referencia.** se muestra el diagrama de bloques general de la explotación en hardware, donde se tienen dos entradas: la *señal* que corresponde con los datos de vibración de la cadena cinemática de la cual se desea obtener un diagnóstico y *str* la cual inicia todo el proceso. Este esquema está formado por tres bloques principales: *Features*, en donde se calculan los quince indicadores estadísticos y cuyas señales de salida entran directamente al bloque *PCA*, que como se ha explicado antes, realiza la proyección de los nuevos datos con ayuda de la matriz de coeficientes calculada en la etapa de entrenamiento la cual previamente se convirtió a formato binario y se almacenó en una memoria rom. Por último, las dos salidas del bloque *PCA* se convierten en la entrada del bloque de *Redes Neuronales*, que dará la clasificación final y así mismo un diagnóstico de la señal de entrada con ayuda de los pesos y bias calculados también previamente en la etapa de entrenamiento en software. Dicho diagnóstico se marca como *S1* y *S2*, donde la primera tendrá un valor lógico alto cuando la cadena cinemática esté en buenas condiciones, mientras que *S2* mostrará un valor lógico en alto si se detecta la presencia de un desperfecto en la pista externa del rodamiento.

En la Figura 20 se muestra la máquina de estados del diagrama anterior, donde *S0* se

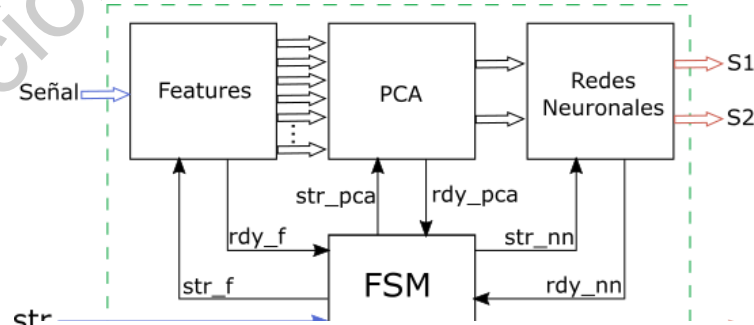


Figura 19.- Diagrama de bloques de la explotación en hardware

mantiene mientras la señal de inicio *str* no sea 1. Cuando esto suceda, inmediatamente se pasa a la condición *S1*, que inicializa el bloque *Features* con la señal *str\_f*, y mientras este

bloque no finalice sus operaciones, permanecerá en *S1*; en cambio, cuando *Features* termine el cálculo de los indicadores estadísticos, se lanza la señal *rdy\_f* que origina el cambio a *S2* y a su vez se envía una señal de inicio *str\_pca* para el bloque *PCA*. De igual manera, cuando éste bloque termine de realizar sus respectivas operaciones, lanzará la señal *rdy\_pca* que dará paso a *S3*, iniciando las operaciones descritas en el bloque de *Redes neuronales* gracias a *srt\_nn*. Finalmente, cuando la clasificación esté terminada, la señal *rdy\_nn* se podrá en alto y dará paso al último estado *S4*, que solamente mandará la señal *rdy* indicando que todo el proceso de identificación de fallas ha concluido exitosamente.




Figura 20.- Máquina de estados del bloque de explotación en hardware

### 3.4.1 Bloque de Indicadores estadísticos

El bloque de *Features* de la Figura 19 engloba a los quince indicadores estadísticos seleccionados y mencionados anteriormente, cada una de sus descripciones se detallan a continuación, es importante mencionar nuevamente que se trabajó con punto fijo en todos los bloques, ya que el formato puede variar dependiendo de las operaciones realizadas.

- **Media:** Tomando como base la ecuación (1), la media se calcula realizando la sumatoria de todos los valores ( $X_i$ ) dividido entre el número total de valores ( $n$ ), en la Figura 21 se muestra el diagrama de bloques. En este sentido, por  $X_i$  entra cada uno de los valores de las señales de vibración adquiridas, los cuales llegan a un sumador junto con la sumatoria acumulada, pero para poder efectuar esta adición es necesario que los sumandos tengan la misma longitud ya que se trabaja con números binarios, y dado que la sumatoria acumulada va aumentando de tamaño se debe igualar en dimensiones a los datos de entrada, luego entonces para conocer la cantidad de bits de guarda que se deben agregar se calcula el logaritmo de base dos

de la cantidad de sumatorias que se van a realizar, en este caso, ya que las ventanas para las cuales se calcula cada conjunto de indicadores estadísticos es de  $n=4096$  datos, se necesitan 12 bits de guarda, los cuales se adicionan a la parte entera modificando así el formato de punto fijo, y rellenándolos con una extensión de signo del valor de entrada  $X_i$ . Por su parte un registro es el encargado de almacenar la sumatoria acumulada y un contador es el encargado de determinar el momento en que la sumatoria total se llevó a cabo.

Para la división entre la sumatoria y el número total de datos  $n$  que requiere la fórmula de la media, se utilizó un bloque de corrimiento a la izquierda, esto es posible ya que el número de datos de entrada es  $2^{12} = 4096$ , y siendo potencia de dos la cantidad de posiciones a recorrer es 12, de esta manera se agilizan los tiempos de ejecución ya que se evita un bloque de división.

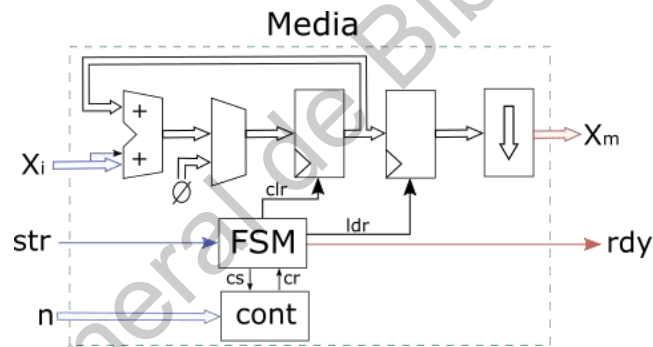


Figura 21.- Diagrama de bloques de la media

En la Figura 22 se muestra la máquina de estados que se encarga de sincronizar el intercambio de información de la media, la señal  $str$  es la encargada de iniciar el proceso y mientras ésta sea 0 el registro se mantendrá limpio. Cuando  $str$  tenga un valor lógico alto, el proceso iniciará y el contador se incrementará en cada ciclo de reloj mientras  $cs$  sea igual a la unidad y se detendrá hasta que todos los datos de entrada hayan sido recibidos, es decir que la cuenta sea igual al  $n$ , cuando esto suceda  $cr$  toma un valor lógico alto y da paso al siguiente estado. En  $S_2$  simplemente se habilita el registro con  $ldr$  y en  $S_3$  se lanza la señal  $rdy$  indicando el final del proceso y que la media ha sido calculada exitosamente.




Figura 22.- Máquina de estados de la media

- Valor Máximo:** Este indicador arroja el valor máximo de un conjunto de datos, en este caso, el valor máximo de cada ventana, su diagrama de bloques se muestra en la Figura 23. Primero por  $X_i$  ingresan uno a uno los valores de la señal de vibración original cada ciclo de reloj, así que cuando un nuevo valor ingresa, éste llega a un bloque que realiza la comparación entre el número actual y el máximo localizado hasta el momento de toda la ventana de datos, cuando la primera comparación es efectuada ésta se hace contra un valor de ceros. Luego entonces, cuando el contador indique que todos los valores han sido leídos, automáticamente ya se tiene el valor máximo y se detiene la comparación. Sin embargo, es necesario almacenar su valor en otro registro el cual es habilitado por  $ldr$ . Además, se debe tomar en cuenta que todos los indicadores estadísticos calculados deben tener el mismo formato de salida, y dado que la mayoría de ellos implica sumatorias, su formato se altera por los bits de guarda agregados, así que, en este caso, al valor máximo obtenido del bloque de comparación se le adicionan los bits de guarda con una extensión de signo.




Figura 23.- Diagrama de bloques del valor máximo

En la Figura 24 se muestra la máquina de estados para este bloque, el cual solo está conformado por cuatro de ellos, en el primero ( $S0$ ) se espera a que se le dé la instrucción de comenzar el proceso con la señal de  $str$ , mientras eso no suceda el registro habilitado se mantiene en ceros con  $clr = 1$ . Cuando se llega al segundo estado  $S1$ , se habilita el bloque de comparación y se comienza con la cuenta del contador  $cs$ , el cual determina el momento en que todos los datos de la ventana han sido procesados. Finalmente, se habilita el registro con  $ldr$  en  $S2$ , mientras que en  $S3$  la señal de  $rdy$  se coloca en nivel lógico alto indicando que se ha terminado el cálculo del indicador estadístico.

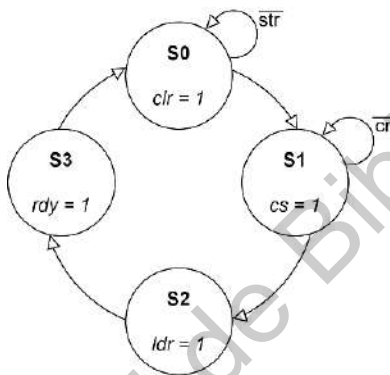


Figura 24.- Máquina de estados de valor máximo

- RMS:** La ecuación 3 nos indica los pasos necesarios a seguir para la descripción de este bloque, cuyo diagrama se muestra en la Figura 25. Lo primero que se hizo fue multiplicar el valor de entrada  $X_i$  por sí mismo para elevarlo al cuadrado, lo cual modifica su formato de punto fijo al doble. Este valor entra a un sumador en conjunto con la sumatoria acumulada, sin embargo, también se deben agregar los bits de guarda necesarios para la sumatoria con una extensión de signo, tal como se describió anteriormente en la media. Un bloque de corrimiento a la izquierda es el encargado de dividir el valor final de la sumatoria entre el número total de datos, el valor obtenido entra a un registro habilitado, el cual está conectado a un bloque encargado de calcular la raíz cuadrada. Sin embargo, si se toma en cuenta que al efectuar la multiplicación el número de bits resultante es el doble de tamaño que la señal de entrada y que es necesario agregar bits de guarda para la sumatoria, da como resultado una cadena binaria muy extensa, por lo que al final del bloque se coloca un limitador,

el cual recorta la cadena, dejando solamente los valores más significativos, sin perder de vista la configuración de punto fijo.

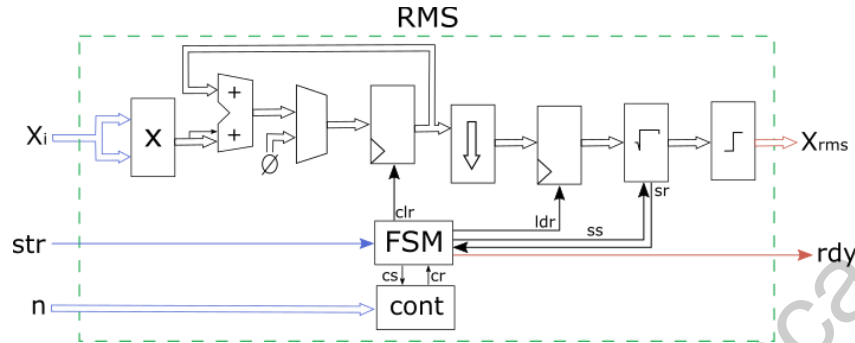


Figura 25.- Diagrama de bloques de RMS

La máquina de estados del bloque RMS se muestra en la Figura 26, la cual consta de cinco estados, el primero se encarga de limpiar los registros mientras no se dé la instrucción de iniciar el proceso mediante la señal *str*. En un segundo estado el contador controla la cantidad de datos que se han recibido y cuando se llegue el final de la cuenta, *cr* envía una señal *ldr* al registro habilitado para tomar el valor de la sumatoria final del cuadrado de *Xi*. Luego entonces se pasa de forma incondicional a otro estado indicando el arranque del bloque de la raíz cuadrada con *ri*, así cuando éste termina manda un pulso *sr* dando por finalizada dicha operación en *S3*. Luego entonces en *S4* se lanza la señal *rdy* indicando el término del valor RMS.




Figura 26.- Máquina de estados de RMS

- SRM:** La ecuación 4 nos permite conocer los pasos necesarios para calcular su valor, en esta debe realizar la sumatoria de la raíz cuadrada de los valores absolutos de los datos de entrada, para después dividirla entre el número total de datos  $n$  y finalmente elevarlo al cuadrado. En la Figura 27 se muestra el diagrama de bloques de este indicador, donde en cuanto un valor de  $X_i$  entra al bloque de SRM, se obtiene su valor absoluto, el cual entra directamente al bloque de raíz cuadrada, sin embargo, este bloque no es inmediato, es decir, requiere varios ciclos de reloj para completarse, por lo que es necesario esperar a que éste termine para poder hacer la sumatoria, para la cual se debe hacer la extensión de signo conforme a los bits de guarda. Luego entonces, la división se sustituye por un corrimiento a la izquierda, tal como en los casos anteriores, para después ser multiplicado por sí mismo y obtener así el cuadrado de la división. Finalmente, con el objetivo de que los formatos de todos los indicadores estadísticos sean iguales, se coloca un limitador en la salida junto a un registro habilitado.

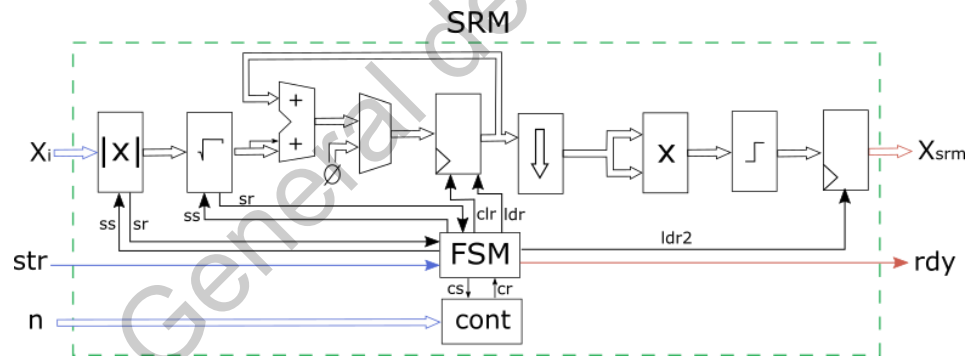


Figura 27.- Diagrama de bloques de SRM

La máquina de estados para este indicador se muestra en la Figura 28, donde en  $S0$  se espera la instrucción de inicio dada por  $str$ , luego cuando se pasa al siguiente estado  $S1$  la señal  $ss$  se ponen en alto indicando el inicio del bloque de raíz cuadrada y pasando incondicionalmente al siguiente estado. Cuando el cálculo de la raíz cuadrada se termina, se señala con  $sr$ , dando paso al estado  $S3$  donde se habilita el registro que almacena la sumatoria con  $ldr$ . En  $S4$  el contador aumenta una cuenta y se verifica si éste ya determinó si todos los datos de entrada fueron analizados, de ser

así se pasa al estado  $S5$ , si no lo es, se regresa al estado  $S1$  para seguir con la sumatoria de las raíces cuadradas. Cuando la cuenta se termina en  $S4$ , se pasa al estado  $S5$ , el cual habilita el segundo registro, para después dar paso al último estado, que solamente indica el final del cálculo de srm con  $rdy$ .




Figura 28.- Máquina de estados de SRM

- Varianza y desviación estándar:** El cálculo de la varianza requiere una sustracción de cada dato de entrada con la media de la ventana, cuyos valores al cuadrado se van acumulando en una sumatoria para finalmente dividirse entre el número de datos de entrada, tal como en la ecuación (6). La desviación estándar se calculó en este mismo bloque, ya que ésta es la raíz cuadrada del valor de la varianza, tal como se muestra en la ecuación (5). Así que ahora se tienen como señales de entrada tanto los valores de las señales de vibración  $X_i$  así como el valor calculado de la media de la ventana que se está analizando, como se puede observar en la Figura 29. Luego entonces, en un restador se efectúa la primera operación para proceder a elevar al cuadrado

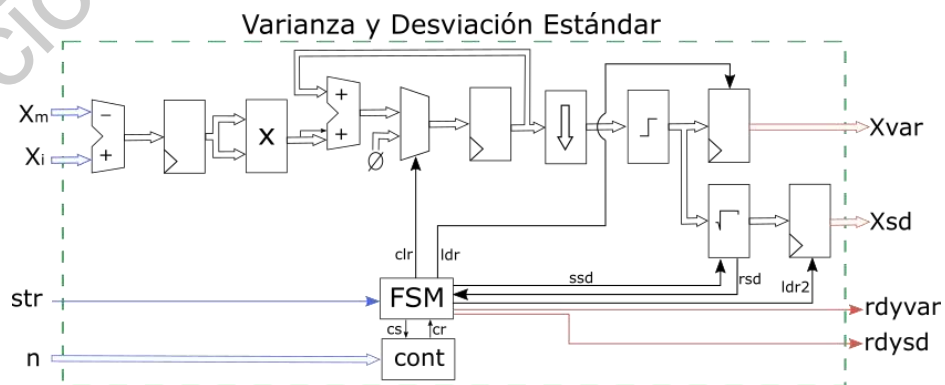


Figura 29.- Diagrama de bloques de varianza y desviación estándar



multiplicándolo por sí mismo, y agregándole los bits de guarda con extensión de signo se hace la sumatoria. Después un corrimiento es el encargado de dividir dicha sumatoria entre el número de datos de entrada, y dado que se modificó el formato de salida por la potencia efectuada se coloca un limitador que lo iguale a los demás indicadores estadísticos. Esto da como resultado el valor de la varianza, sin embargo, este valor además de ser una salida del bloque también entra a la raíz cuadrada para calcular la desviación estándar.

La máquina de estados empleada para este bloque se muestra en la Figura 30, donde S0 espera la señal *str* para iniciar. En el estado S1 se inicia al contador y permanece contando mientras se efectúan tanto la resta, la multiplicación y la sumatoria. Cuando ésta última está lista, el contador nos lo indicará con la señal *cr*, pasando así al estado S2, donde la señal que indica que el cálculo de la varianza ha terminado *rsy\_v* se coloca en alto, también se habilita el registro para mantener su valor con *ldr* y además se inicializa la raíz cuadrada para obtener la desviación estándar usando *ssd*. Luego entonces, el estado S3 se mantiene mientras la raíz no haya sido calculada. En el último estado se coloca en alto la señal que indica el final del proceso y se habilita un segundo registro para mantener valor de la desviación estándar.

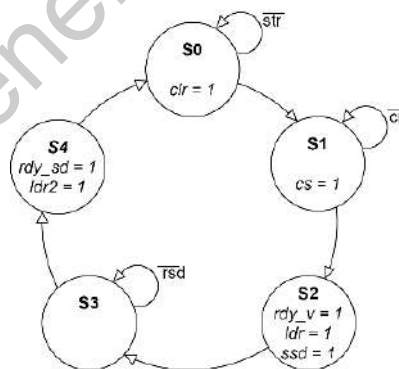


Figura 30.- Máquina de estados de varianza y desviación estándar

- **Factor forma RMS, Factor forma SRM y Factor impulso:** Como se puede observar en las ecuaciones (7), (8) y (11), tienen algo en común, que es la sumatoria de los valores absolutos de la señal de entrada, la cual es el del dividendo, siendo el divisor el que cambia, por lo que se decidió colocar estos tres indicadores estadísticos en un solo bloque, tal como se muestra en la Figura 31. Así que primero se calcula el

valor absoluto del valor de entrada  $X_i$  y se le agregan los bits de guarda para la sumatoria extendiendo su signo. Después, en el bloque sumador entran este valor, así como la suma acumulada. Luego, a esta sumatoria final se le recorre el punto como sustitución de la división entre  $n$ . Ya que la sumatoria que tienen en común los tres indicadores estadísticos está lista, se realiza el cálculo de cada uno de ellos de manera independiente, esto se hace a través de tres bloques divisores, la diferencia es el divisor que se ingresa, para el caso del factor forma RMS se coloca el valor obtenido del bloque RMS, para el factor forma SRM se le introduce el valor calculado por el bloque SRM, mientras que el divisor para el factor impulso es el valor máximo calculado anteriormente.

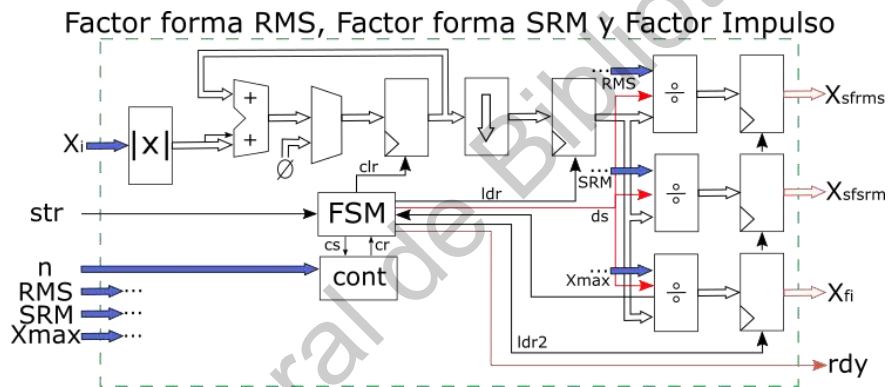


Figura 31.- Diagrama de bloques de SFrms, SFsrm y factor impulso

La máquina de estados de este bloque se muestra en la Figura 32 donde después de recibir la señal de inicio  $str$ , en  $S1$  se inicializa el contador encargado de llevar la cuenta de los datos de  $X_i$  recibidos. Cuando  $cr$  toma un valor lógico igual a uno, indica que todos los datos se han admitido y se pasa al siguiente estado. En  $S2$  se habilita el registro que almacena el valor de la sumatoria con  $ldr$  y se da inicio a las tres divisiones con  $ds$ , pasando incondicionalmente a  $S3$  y ya que el formato es el mismo para los tres casos, cuando una de las divisiones termina, significa que terminaron todas, dando como resultado un pulso en alto de la señal  $dr$ . Finalmente en  $S3$  se habilitan tres registros para conservar los valores calculados de los tres indicadores estadísticos y la señal de  $rdy$  se coloca en alto para indicar el final de todas las operaciones.




Figura 32.- Máquina de estados de SFrms, SFsrm y factor impulso

- Factor cresta y Factor latitud:** Las ecuaciones (9) y (10) pertenecen al factor cresta y factor latitud respectivamente y tal como se puede observar, para calcular el primero simplemente se divide el valor máximo entre RMS, mientras que en el segundo se divide el valor máximo entre SRM, así que no es necesario desarrollar un bloque como tal para estos factores, ya que simplemente se colocan estos valores como entradas en un bloque de división y su señal de finalización indicaría el término del cálculo de ambos indicadores.
- Skewness:** La ecuación (12) nos indica que para calcular el valor de skewness de un conjunto de datos se debe elevar al cubo la resta entre el dato de entrada menos la media del mismo conjunto y realizar la sumatoria acumulativa hasta llegar al final de los datos. Luego entonces se divide entre el cubo del valor de RMS elevado al cubo. Para esto, primero se restan las señales  $X_m$  (media) y  $X_i$  (valor de entrada), luego entonces el resultado se multiplica tres veces por sí mismo para cumplir con la potencia, tal como se muestra en la Figura 33. A este valor se le agregan los bits de guarda mencionados anteriormente realizando una extensión de signo para poder entrar al sumador al igual que la sumatoria acumulada. Al mismo tiempo, el valor de entrada de RMS se eleva al cubo, entrando entonces ambos valores en el divisor. El cociente se modifica con un corrimiento a la izquierda de 12 posiciones que representa la división entre  $n$ . Finalmente, dada la cantidad de multiplicaciones realizadas y lo que significa en el incremento del tamaño del número binario, se coloca un limitador al final para reducir y así igualar la cantidad de bits de los demás indicadores estadísticos. Sin embargo, al trabajar con potencias no pares, lo que indica

que es posible que se manejen valores negativos en la entrada, por lo que se deben tomar algunas consideraciones para evitar un cálculo incorrecto.

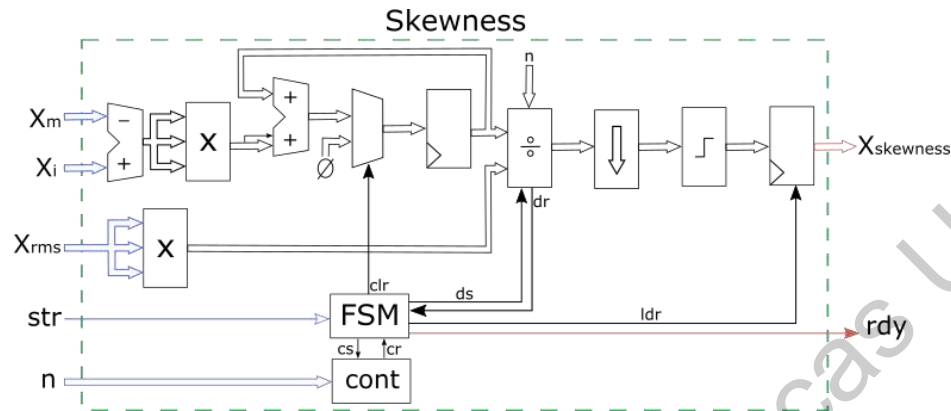


Figura 33.- Diagrama de bloques de Skewness

En la Figura 34 se muestra la máquina de estados de este bloque, en donde *S0* limpia los registros del bloque colocando la señal *clr* en alto mientras espera la señal *str*, así en el estado *S1* se inicia la cuenta que determina la cantidad de datos de entrada recibidos, así hasta que esta cuenta sea igual a *n* (4096); un pulso en alto se mandará a través de *cr*, originando un cambio de estado a *S2*, donde se inicia la división con  $di=1$ . El estado *S3* se mantiene hasta que la división haya sido calculada, indicado por la señal *dr*, originando el cambio a *S4* y habilitando el registro con *ldr* para mantener el valor calculado. Finalmente, en el último estado se manda un pulso en *rdy* indicando el final de la operación.




Figura 34.- Máquina de estados de Skewness

- Kurtosis:** La ecuación (13) indica las operaciones que se deben llevar a cabo para la descripción de este indicador, el diagrama de bloques se muestra en la Figura 35. Primero en un restador llegan las señales de entrada  $X_i$  y el valor de la media  $X_m$ . Luego entonces se colocan dos multiplicadores, el primero eleva al cuadrado la resta resultante, mientras que el segundo eleva al cuadrado el valor resultante de la primera multiplicación, dando así la potencia cuatro que requiere la fórmula. Este valor entra a un sumador junto con la sumatoria acumulada, cuyo resultado final entra como dividendo al bloque de división.  $X_{rms}$  es otro valor de entrada y corresponde a la salida del bloque *RMS* descrito anteriormente, éste también debe ser elevado a la cuarta potencia para lo cual se utilizan también dos multiplicadores cuyo resultado entra como divisor. Después de que la división se efectúa, se realiza un corrimiento a la izquierda de 12 bits simulando la división entre 4096 ( $n$ ). Finalmente se coloca un limitador que mantiene los bits más significativos conservando el formato de punto fijo y un registro habilitado que retiene el valor obtenido de la kurtosis

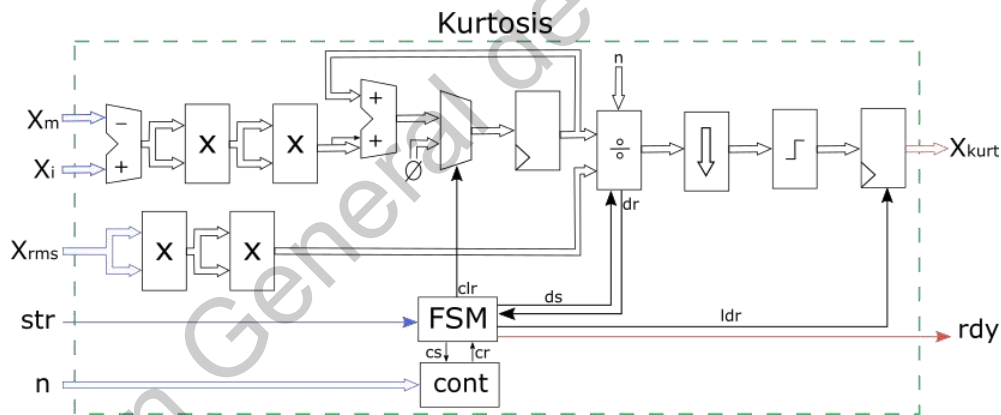


Figura 35.- Diagrama de bloques de kurtosis

La máquina de estados para la kurtosis se muestra en la Figura 36, donde al igual que en los demás bloques el primer estado se encarga de la limpieza del registro, el segundo de inicializar el contador y el tercero de dar la instrucción de comenzar la primera división con  $di$ , después de manera incondicional se pasa a  $S3$  el cual se mantiene hasta que el resultado de la división haya sido obtenido, la señal  $dr$  en alto indica el paso al estado  $S4$  que simplemente habilita el registro con  $ldr$ , mientras que en  $S5$  la señal  $rdy$  señala que el valor de la kurtosis ha sido calculado.




Figura 36.- Máquina de estados de kurtosis

- Quinto momento:** La ecuación (14) indica el procedimiento que se debe seguir para la descripción del bloque del quinto momento, que como se puede observar es similar a las ecuaciones (12) y (13) de skewness y kurtosis respectivamente, cambiando solamente las potencias a las que debe ser elevada la resta inicial y la potencia a la cual se eleva el valor del RMS, por lo que el diagrama de bloques de la Figura 37 es muy similar a los dos diagramas anteriores y por lo tanto la máquina de estados es igual a las dos anteriores, por lo que no se describirán nuevamente. En este sentido, después de realizar la sustracción entre  $X_m$  y  $X_i$  se eleva al cuadrado multiplicándolo por sí mismo, luego, este nuevo resultado se eleva al cuadrado de la misma manera y finalmente este producto se multiplica por el valor inicial de la sustracción para así obtener la potencia cinco que se necesita. El mismo procedimiento se realizó para elevar el valor de entrada RMS a la quinta potencia. El resto de los pasos es el mismo que para la skewness, ya que se debe tener en consideración la presencia de números negativos al tratarse de potencias impares, donde se hace lleva a cabo una sumatoria acumulativa y dos divisiones, una de ellas con un bloque y que toma varios ciclos de reloj para realizar el cálculo, y otra que se sustituye por un corrimiento.

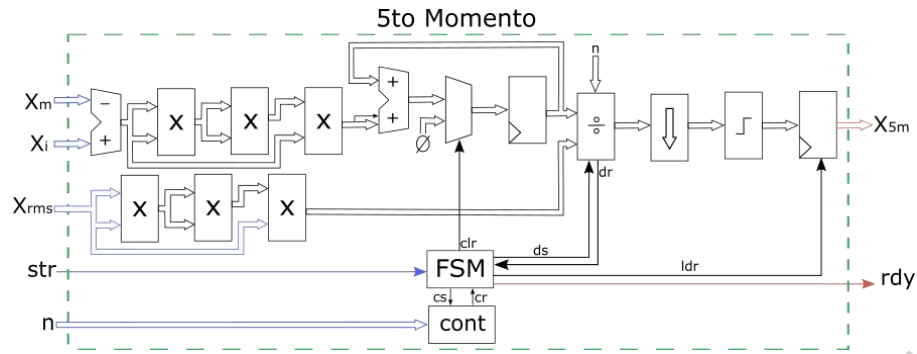


Figura 37.- Diagrama de bloques del quinto momento

- Sexto momento:** El diagrama de bloques del sexto momento es similar a los tres bloques anteriores, la diferencia es que en este la potencia que se maneja para la resta y para RMS es seis. Para esto, valiéndonos de las leyes de los exponentes, simplemente se eleva al cubo la resta entre  $X_m$  y  $X_i$ , para después elevar este resultado al cuadrado multiplicándolo por sí mismo. Lo mismo ocurre con el valor de RMS, el cual primero se eleva al cubo y el resultado se eleva al cuadrado. Dado que es una potencia par, no es necesario prevenir la presencia de signos negativos en la entrada de la división. La máquina de estados para este bloque es igual a la mostrada en la Figura 35.

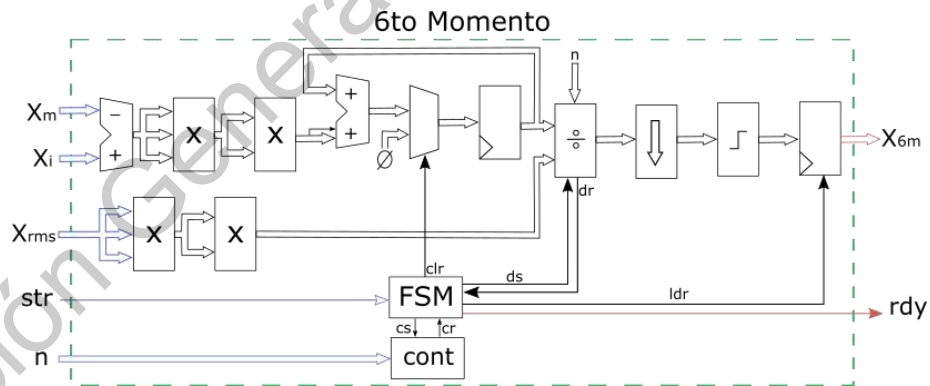


Figura 38.- Diagrama de bloques del sexto momento

- Indicadores Estadísticos:** Como se observa en el diagrama de la Figura 19, todos los indicadores estadísticos se agrupan en un solo bloque, y dado que muchos de ellos dependen del cálculo de otros, se muestra el diagrama de la Figura 39, donde los quince indicadores anteriormente descritos se conectan entre sí. En la parte inferior, se puede observar el diagrama general de la máquina de estados, donde todas las

señales de inicio de los indicadores son salidas y están nombradas al inicio con *str*, mientras que las señales que principian con las letras *rdy* son entradas de la máquina *FSM*. Además, se cuenta con un primer contador que controla la lectura de datos de la base de datos, la cual es una memoria de lectura ROM. Sin embargo, el bloque de SRM se rige por dos máquinas de estado, ya que la principal *FSM* le indica cuando comenzar, pero una segunda máquina de estados controla el flujo de datos desde la ROM hasta el bloque de SRM, ya que es el único bloque que no recibe un dato cada ciclo de reloj, sino que debe esperar a que el cálculo de la raíz cuadrada inicial termine, como se mostró anteriormente.

En la Figura 40 se muestran todos los estados de la máquina de la figura anterior, así que mientras no se reciba la señal *str* se mantendrá en el estado *S0*. Cuando se inicializa el cálculo de los indicadores en el estado *S1* las señales de arranque de la media, del valor máximo de RMS y SRM son lanzadas, de manera inmediata se pasa al estado siguiente, en el cual se espera la señal *eoc*, la cual es la señal del contador, indicando que todos los datos de la ROM han sido leídos. Este contador es diferente a los anteriores, ya que los utilizados en los indicadores estadísticos simplemente sumaban cuando *cs* estaba en alto, sin embargo, los contadores de la Figura 35 son diferentes, ya que su señal de entrada es *opc* y es de dos bits, por lo que cuando tiene valor de “00” el valor del contador se mantiene, cuando es “01” la cuenta aumenta en 1, y si es “10” o “11” el contador se reinicia a ceros. De ahora en adelante, cuando la entrada de un contador sea *opc* se referirá a este tipo de contador en específico, con esta misma tabla de verdad. Luego entonces, en *S3* se espera hasta que la media haya sido calculada. Después en el estado *S4* se espera el resultado del bloque *RMS*, y cuando está listo, todos los operadores que requieren de este valor se inicializan en el siguiente estado, los cuales son los bloques de skewness, curtosis, quinto momento y sexto momento. Así que el contador vuelve a iniciar y se espera hasta que los datos de la ROOM se reciban nuevamente, pero ahora por los bloques recién inicializados. El primero en terminar es el bloque de varianza, cuya señal de finalización se espera en el estado *S7*. Luego entonces el estado *S8* se mantiene hasta que la desviación estándar haya sido calculada. Lo mismo pasa para los siguientes estados, esperando las señales de los bloques de skewness,



curtosis, quinto momento y sexto momento, justo en ese orden. No es hasta el estado *S13* que el bloque de SRM termina su cálculo, así que en el siguiente se pueden inicializar los indicadores restantes, los cuales son los bloques de los factores FFrms/srm y FI, así como el cálculo del factor longitud y factor cresta. Así que cuando todos ellos han sido calculados y sus señales de fin han sido recibidas por la máquina de estados se envía una señal de finalización general en *S18*, indicando que los quince indicadores estadísticos han sido calculados.

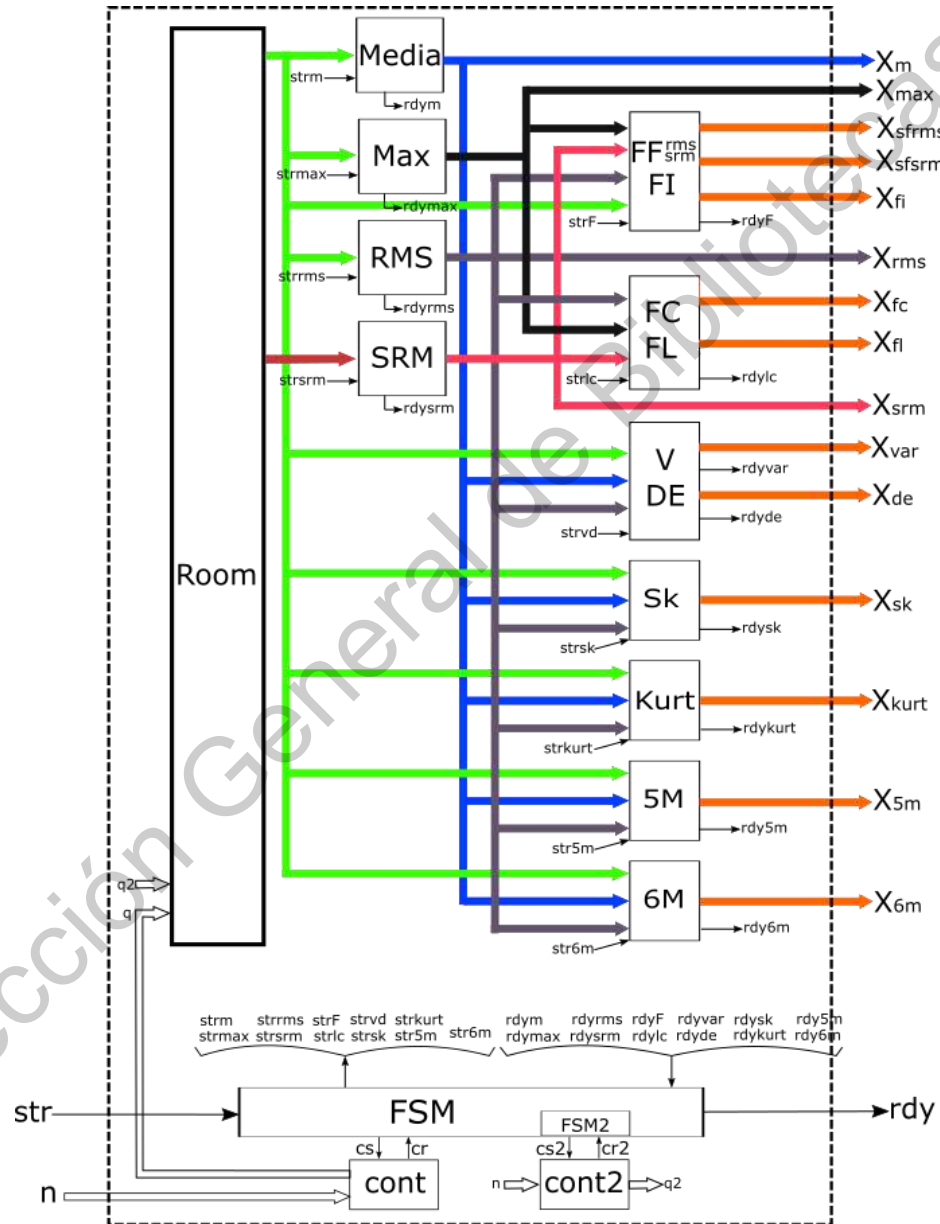


Figura 39.- Diagrama de bloques de los quince indicadores estadísticos

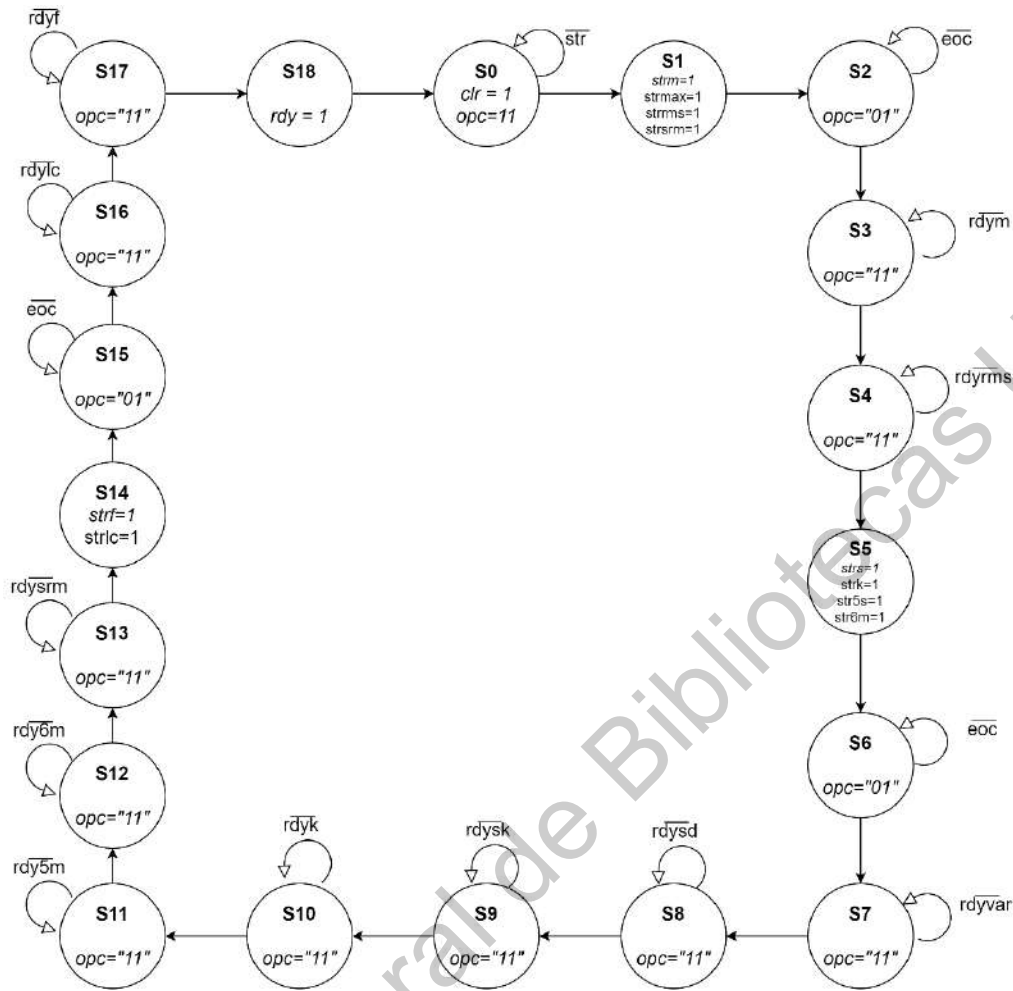


Figura 40.- Máquina de estados de Features

### 3.4.2 Bloque PCA

Para que se pueda efectuar la reducción de indicadores utilizando PCA, se utiliza la matriz de transformación calculada en la etapa de entrenamiento en software, que como se mencionó anteriormente, dichos valores fueron almacenados en dos archivos tipo *vhdl* en formato binario con punto fijo, específicamente en memorias rom. Así en la Figura 41, *xPCA* corresponde con los coeficientes del primer componente principal y *yPCA* con los del segundo componente principal. En términos algebraicos, este bloque se resume a una multiplicación matricial de una matriz de *A* de  $1 \times 15$  por una matriz *B* de  $15 \times 2$  (ver ecuación (22)). Donde *A* son los indicadores estadísticos, mientras que *B* es la matriz de transformación y está conformada por *xPCA* y *yPCA*, siendo el primero la columna principal de *B* y el segundo la columna posterior. De la multiplicación matricial se obtiene como resultado una

matriz de 1x2, que en este caso se representan como  $X$  y  $Y$ . La operación anterior se resume en un multiplicador acumulador (MAC).

$$A \cdot B = [X \ Y]$$

$$A \cdot B = [a_0 \ a_1 \ a_2 \ a_3 \ a_4 \ \dots \ a_{14}] \begin{bmatrix} b_{00} & b_{01} \\ b_{10} & b_{11} \\ b_{20} & b_{21} \\ b_{30} & b_{31} \\ b_{40} & b_{41} \\ \dots & \dots \\ b_{140} & b_{141} \end{bmatrix} = \dots \quad (22)$$

$$= [a_0 b_{00} + a_1 b_{10} + a_2 b_{20} + \dots + a_{14} b_{140} \quad a_0 b_{01} + a_1 b_{11} + a_2 b_{21} + \dots + a_{14} b_{141}]$$

El bloque  $PCA$ , mencionado en la Figura 19, tiene como entrada los quince indicadores estadísticos calculados en el bloque  $Features$ , además de una señal de inicio llamada  $str$ . Mientras que solo tiene tres señales de salida, una de ellas es  $rdy$ , de un solo bit y otras dos señales con formato de punto fijo, que se nombraron como  $X$  (el valor del primer componente principal) y  $Y$  (el valor del segundo componente principal), tal como se puede apreciar en la Figura 41.

Un contador  $Cont$  controla el flujo de información de un multiplexor que tiene como entrada los 15 indicadores estadísticos y de las memorias rom  $xPCA$  y  $yPCA$ , de esta forma los tres valores entran a su respectivo multiplicador. El producto resultante entra a un sumador acumulativo, y justamente por ser acumulativo, se requiere contemplar los bits de guarda necesarios, para ello se calcula el logaritmo base dos de 15 (ya que son quince sumas las que se realizarán por los quince indicadores). Dado que  $\log_2 15 = 3.9068 \cong 4$ , son cuatro los bits que se agregan a la parte entera del producto con una extensión de signo. Luego entonces, un registro habilitado conserva el valor de la sumatoria y este valor a su vez entra a un limitador, que reduce el tamaño de la cadena binaria, ya que, al involucrar multiplicaciones, se extiende su dimensión al doble.

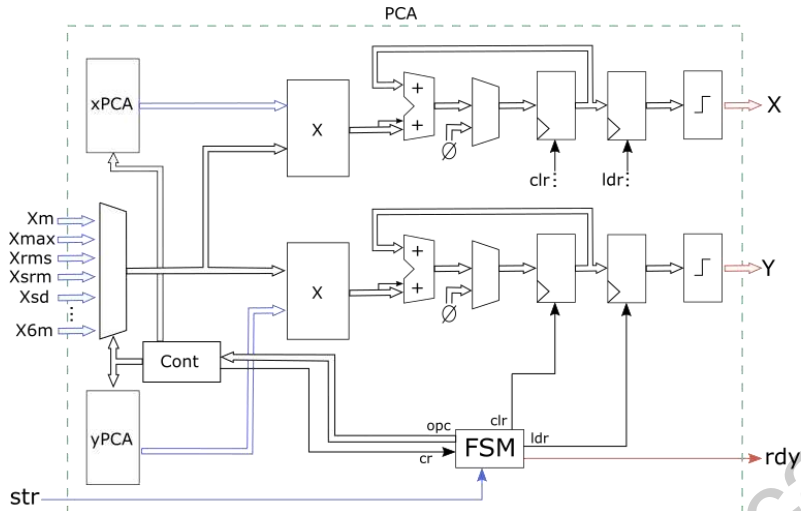


Figura 41.- Diagrama de bloques de PCA

En la Figura 42 se muestra la máquina de estados que sincroniza el bloque PCA, donde, en  $S_0$ , se limpia el registro habilitado con  $clr=1$  y mantiene el contador  $Cont$  en ceros con  $opc=10$  (la tabla de verdad de este contador se explicó anteriormente en el bloque de *Features*, en el punto *Indicadores Estadísticos*). Después en  $S_1$ , el contador se mantiene en ceros para leer el índice 0 del multiplexor, así como el índice 0 de las memorias rom, luego entonces, de manera incondicional se cambia al siguiente estado, donde el contador aumenta su cuenta en uno en cada ciclo de reloj hasta que la señal  $cr$  se ponga en alto, indicando que las quince multiplicaciones se han realizado. Así se da paso al estado  $S_3$ , que simplemente habilita el registro con  $ldr=1$  y  $S_4$  lanza la señal  $rdy$  indicando el fin de las operaciones del bloque PCA.

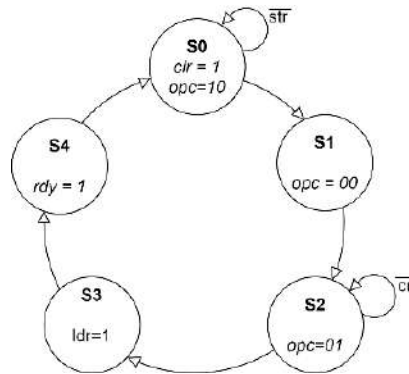


Figura 42.- Máquina de estados de bloque PCA

### 3.4.3 Bloque Redes Neuronales

El bloque de redes neuronales es el encargado de clasificar la condición de la cadena cinemática y dar un diagnóstico sobre ésta, determinando si se encuentra en buen estado o se localizó algún desperfecto en los rodamientos de esta. Para ello, utiliza los pesos y bias calculados en la etapa de entrenamiento en software, ya que como se ha mencionado, la implementación en vhdl no realiza adiestramiento de ningún tipo, sino que utiliza los valores obtenidos del entrenamiento directamente.

Para realizar el cálculo de las salidas de la red neuronal en VHDL se siguen los pasos mostrados en la Figura 43, donde  $x_n$  y  $y_n$  son las salidas normalizadas de PCA,  $IW\_1$  es la matriz que contiene los pesos que van a las capas desde las entradas de la red,  $LW\_1$  es la matriz donde se localizan los pesos que van de capa a capa,  $bias\_1$  son los valores de los bias de las capas de entrada, mientras que  $bias\_2$  son los valores de los bias de la capa de salida.  $Layers$  por su parte corresponde con el número de capas ocultas, que en este caso son 10 y  $S$  es la cantidad de salidas de la red, que para este análisis son 2. Luego entonces, habiendo seleccionado como función de activación la sigmoide para las capas de entrada, se evalúan en esta función la suma de la multiplicación de cada valor de entrada por su respectivo peso junto con el valor de bias correspondiente. Después, para la capa de salida se utilizan los valores anteriores y se multiplican por el peso  $LW$  pertinente para finalmente adicionar el valor de bias respectivo.

```
Layers = 10; %Capas ocultas
S=2; % Salidas

for i=1: Layers
    N(i)=sigmoidal((xn*IW_1(i,1))+(yn*IW_1(i,2))+bias_1(i));
end

%Capa de Salida
fcs=zeros(1,S);
for i=1: S
    for j=1:Layers
        fcs(i)=fcs(i)+(N(j)*LW_1(i,j));
    end
    fcs(i)=fcs(i)+bias_2(i);
end
```

Figura 43.- Código para calcular salidas de la red neuronal

Siguiendo esta metodología, se diseñó el bloque *Redes Neuronales* (ver Figura 44), que tiene como entradas las señales  $X$  y  $Y$ , las cuales son las salidas del bloque *PCA* y una

señal de inicio llamada *str*; además de las lecturas de las memorias rom de los pesos y bias. Mientras que las salidas son tres, *rdy* apuntando que todas las operaciones del bloque se han realizado y dos señales, *S1* y *S2*, ambas de un solo bit; cuando la primera está en alto apunta a un buen funcionamiento de la cadena, mientras que, si *S2* tiene un valor lógico alto, advierte una falla en la pista externa del rodamiento.

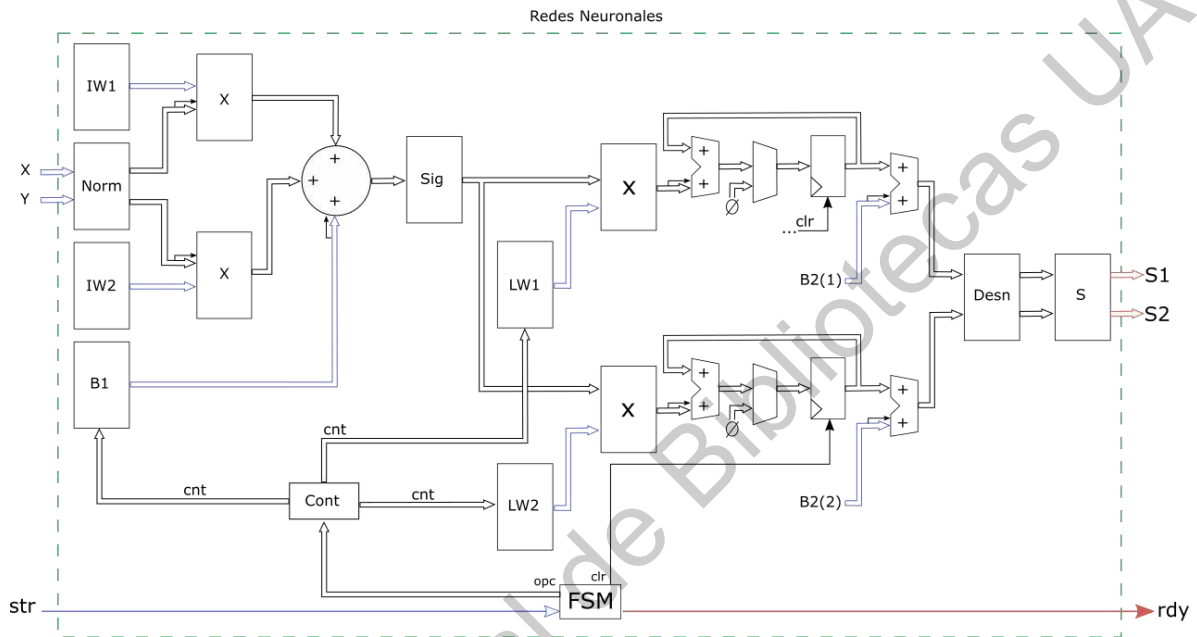


Figura 44.- Diagrama de bloques de Redes Neuronales

En la Figura 44 se observa el diagrama de bloques completo de las redes neuronales, tal como se muestra, las señales de entrada *X* y *Y* llegan a un bloque *Norm*, donde se normalizan sus valores. Después, los números binarios de *X* normalizados se multiplican por los pesos de entrada *IW1*, mientras que los valores de *Y* normalizados se multiplican por los pesos de entrada *IW2* y entran a un sumador junto con los valores de bias de entrada *B1*, para ser evaluados en la función de activación sigmoide. Después, la salida del bloque *Sig* se multiplica por su respectivo peso de salida y entra a un sumador acumulativo hasta completar las diez capas ocultas, finalmente se adiciona el valor del bias respectivo y se consiguen las salidas de la red neuronal, no sin antes pasar por un bloque de desnormalización *Desn*. Sin embargo, ya que son números binarios y existe la posibilidad de que las salidas sean negativos, positivos, enteros o fraccionarios, para una mejor interpretación se agregó un bloque más al final llamado *S*, el cual traduce los valores de salida de la red y los convierte a

simples valores de 0 o 1, dependiendo de la condición de la cadena cinemática que se haya detectado.

En la Figura 45 se muestra la máquina de estados para el bloque de redes neuronales, donde en el estado *S0* se espera la llegada de la señal de inicio *str* y mientras no suceda esto, los registros se mantienen en ceros y el contador pausado en ceros. Luego, en *S1* se mantiene al contador aumentando su cuenta en 1 hasta llegar a 10, que es la cantidad de capas ocultas de la red neuronal. Finalmente, el último estado *S2* manda la señal de *rdy* indicando la conclusión del proceso.




Figura 45.- Máquina de estados de bloque Redes Neuronales

Como se mencionó, las entradas *X* y *Y* pasan por un bloque de normalización *Norm*, en donde primero se delimitan los valores de la entrada entre 0 y 1 utilizando la ecuación (23) (mismo paso que se realizó en la etapa de entrenamiento), de esta forma la gráfica de las regiones de decisión quedarán acotadas en este intervalo.

$$x_n = \frac{(x - x_{min})(b - a)}{x_{max} - x_{min}} + a \quad (23)$$

Donde *x* es el valor que se desea normalizar

$x_{min}$  es el valor mínimo del conjunto de datos originales

$x_{max}$  es el valor máximo del conjunto de datos originales

*a* es el valor mínimo al cual se desea normalizar

*b* es el valor máximo al cual se desea normalizar

En este caso  $x_{min}$  y  $x_{max}$  corresponden con los respectivos valores mínimo y máximo para cada componente principal del conjunto de proyecciones nuevas generadas de todos los datos originales al nuevo plano 2D de máxima varianza originado en MATLAB®, esto es, los valores máximos y mínimos resultado de multiplicar el conjunto de indicadores estadísticos de todas las señales de prueba por la matriz de coeficientes de los 2 componentes principales. Además, como  $a=0$  y  $b=1$ , la ecuación anterior se simplifica

$$x_n = \frac{(x - x_{min})}{x_{max} - x_{min}} \quad (24)$$

De esta manera, para realizar la normalización pero evitar el uso de bloques de división, que consumen mayor cantidad de recursos y tiempo de ejecución en VHDL que una multiplicación, se plantea efectuar el uso de una constante  $x_d$

$$x_d = \frac{1}{x_{max} - x_{min}} \quad (25)$$

Así, la ecuación (24) se simplifica

$$x_n = (x - x_{min})x_d \quad (26)$$

Sin embargo, siguiendo la misma metodología que plantea MATLAB® por defecto, es necesaria una normalización más, entre  $-1$  y  $1$  de los valores obtenidos del entrenamiento de la red neuronal. Para obtener los valores máximos y mínimos de la matriz se utilizaron los siguientes comandos en software:

```
max2x= net.inputs{1}.processSettings{1}.xmax(1);
min2x= net.inputs{1}.processSettings{1}.xmin(1);

max2y= net.inputs{1}.processSettings{1}.xmax(2);
min2y= net.inputs{1}.processSettings{1}.xmin(2);
```

Donde *net* corresponde con la red neuronal seleccionada de las 5 generadas en el entrenamiento en software, además *max2x* y *min2x* (nombrados a continuación como  $x_{min2}$  y  $x_{max2}$  respectivamente) son los nombres de variables que corresponden con los valores máximo y mínimo del eje  $x$  respectivamente, mientras que *max2y* y *min2y* son los valores máximo y mínimo del eje  $y$  respectivamente.



Reescribiendo la ecuación (23) para esta segunda normalización, donde  $a=-1$  y  $b=1$ , se simplifica como

$$x_{2n} = \frac{2 * (x - x_{min2})}{x_{max2} - x_{min2}} - 1 \quad (27)$$

Aplicando el uso de constantes para evitar las divisiones, se plantea

$$x_{d2} = \frac{1}{x_{max2} - x_{min2}} \quad (28)$$

De esta manera la ecuación (27) queda simplificada como

$$x_{2n} = 2 * (x - x_{min})x_2 - 1 \quad (29)$$

El diagrama de bloques *Norm* se muestra en la **¡Error! No se encuentra el origen de la referencia.**, donde la primera normalización está marcada en color naranja, mientras que la segunda en color magenta. Al inicio, se realiza una resta entre el valor de entrada  $X$  y el valor mínimo  $x_{min}$  para después multiplicarlo por la constante  $x_d$ . Para evitar el uso de recursos innecesarios, se colocó un limitador que mantiene el formato en punto fijo, pero reduce la dimensión del número binario conservando los bits más significativos. Luego

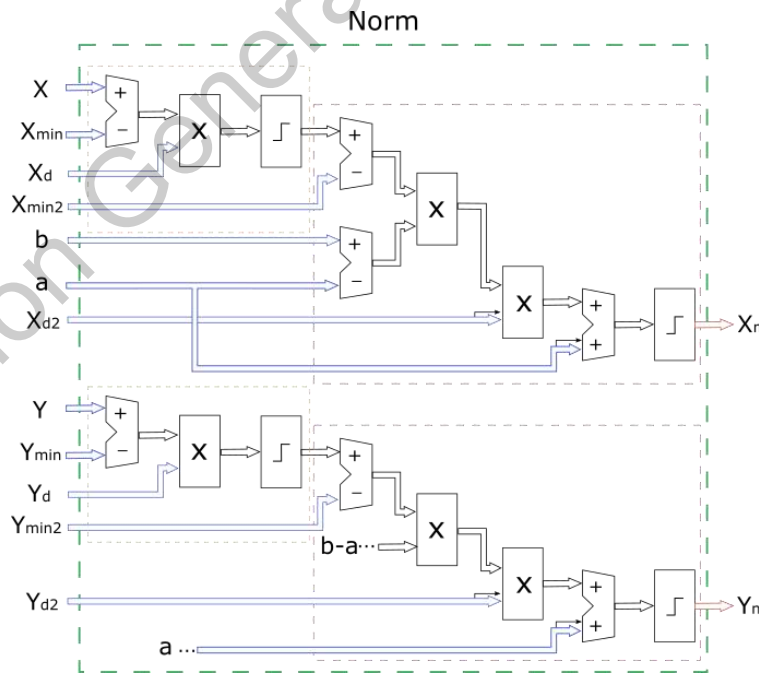


Figura 46.- Diagrama de bloques de Normalización

entonces, la segunda normalización comienza, restando ahora el número calculado y  $x_{min2}$  para después, multiplicar el número resultante por  $b-a=2$ . Finalmente se multiplica el producto obtenido por la segunda constante  $x_{a2}$  y pasa por un limitador a la salida. Debido a las operaciones que se realizan, el formato de punto fijo cambia constantemente, por lo que se debe considerar este cambio al momento de efectuar las operaciones binarias. Se puede observar que las mismas operaciones que se ejecutaron para la señal de entrada  $X$  también fueron aplicadas a la señal  $Y$ . Este bloque no contiene parte secuencial por lo que no es necesaria una máquina de estados como en los bloques anteriores.

Por su parte, el bloque *Desn* mostrado en la Figura 44, hace referencia a una desnormalización de sus valores de entrada, para ello, tomando la ecuación (23) se tiene que

$$x = \frac{(x_n - a)(x_{max} - x_{min})}{b - a} + x_{min} \quad (30)$$

Donde los valores de  $x_{max}$  y  $x_{min}$  se obtienen de manera similar a los valores de la segunda normalización en software, así

```
maxdx= net.outputs{2}.processSettings{1}.xmax(1);
mindx= net.outputs{2}.processSettings{1}.xmin(1);

maxdy= net.outputs{2}.processSettings{1}.xmax(2);
mindy= net.outputs{2}.processSettings{1}.xmin(2);
```

Donde  $maxdx$  y  $mindx$  corresponden con los valores máximo y mínimo de la red neuronal de la señal  $x$  para desnormalizar, caso similar ocurre para la señal  $y$ . Ahora, la constante utilizada para este paso fue

$$x_{dd} = \frac{(x_{maxdx} - x_{mindx})}{b - a} \quad (31)$$

De esta manera, la ecuación (30) se simplifica como

$$x = (x_n - a)x_{dd} + x_{min} \quad (32)$$

En la Figura 47 se muestra el diagrama de bloques de *Desn*, donde en comparación con la ecuación (32),  $x_{nn} = x_n$  y  $x_{dmin} = x_{min}$ . Se observa entonces, que la señal de entrada  $x_{nn}$  y el valor de  $a$  se restan para después multiplicar el resultado por la constante  $x_{dd}$ . Luego

entonces, al producto resultante se le adiciona el valor mínimo y al final se coloca un limitador. Las mismas operaciones para  $x_{nn}$  también se le aplican a  $y_{nn}$ .

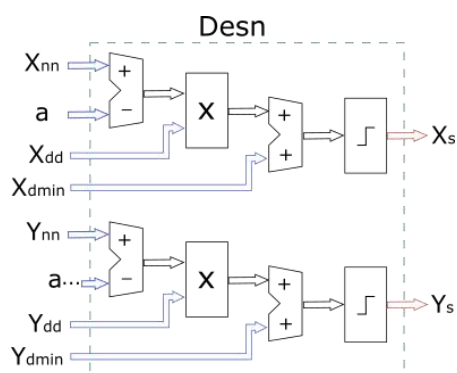


Figura 47.- Diagrama de bloques de Desnormalización

Finalmente, en lo que respecta el bloque Sigmoide *Sig* (mostrado en la Figura 44) que es la función de activación de las capas de entrada, se utilizó la aproximación *PLAN* (Caballero Hernández, Díaz Salaza, Moradillos Paz-Lago, & Pavoni Oliver, 2014), en donde basándose en la condición en la que se encuentre el valor de entrada de la función, tomará otro valor a través de una serie de operaciones. Dichas condiciones y aproximaciones se muestran en la siguiente table

Tabla 1.- Aproximación PLAN en el intervalo [-5,5].

PLAN (x)	Condición
1	$ x  \geq 5$
$\frac{ x }{2^5} + 0.84375$	$2.375 \leq  x  < 5$
$\frac{ x }{2^3} + 0.625$	$1 \leq  x  < 2.375$
$\frac{ x }{2^2} + 0.5$	$-1 \leq  x  < 1$
$\frac{ x }{2^3} + 0.375$	$-2.375 \leq  x  < -1$
$\frac{ x }{2^5} + 0.15625$	$-5 \leq  x  < -2.375$
0	$ x  < -5$

### 3.5 Análisis en el dominio de la frecuencia

Como se mencionó en el planteamiento general, se trabajó un método alternativo de análisis enfocado en el dominio de la frecuencia, en éste se estudiaron las mismas señales de vibración que las utilizadas en el clasificador software/hardware y se siguió el mismo patrón de separación, esto es, solo las pruebas de las condiciones donde el material del rodamiento del motor de inducción era el mismo y cuya frecuencia de operación era igual se utilizaron para cada análisis, en la Figura 48 se observa la metodología general de este análisis. Primero, se realizó la adquisición de señales para después aplicar una ventana de tiempo Hann a las señales de vibración y corriente, la cual atenúa los extremos de las señales hasta llegar a cero con la finalidad de reducir la filtración espectral. Luego entonces, promediando todas las señales de un mismo tipo de una misma condición se calculó su espectro frecuencial utilizando la transformada rápida de Fourier. Para realizar el análisis espectral con este método, es necesario conocer el comportamiento esperado del sistema ante una falla, en este caso la falla se encuentra en la pista externa del rodamiento del motor de inducción, por lo que es necesario calcular la frecuencia característica de fallo BPFO utilizando la ecuación (18), y ya que ésta fórmula emplea las dimensiones del rodamiento y la velocidad a la cual gira el rodamiento, es posible que exista cierto error entre la frecuencia de fallo teórica y la frecuencia de fallo real; es por esto que con la finalidad de que ambos valores sean lo más cercanos posibles, es que se calculó la velocidad de rotación del rotor promedio con ayuda de la señal adquirida con el encoder incremental, ya que es común que existan ligeras variaciones entre la velocidad real y la velocidad fijada en el variador de frecuencias. Para las señales de corriente se obtuvo la densidad espectral de potencia y a su vez con la ecuación (21) se obtuvieron las frecuencias características de fallo cuando se analizan señales de corriente. Finalmente, con las frecuencias estimadas es posible identificar la presencia de fallos observando el espectro frecuencial y la densidad espectral de potencia para así determinar el estado de la cadena cinemática, a su vez que es posible comparar el comportamiento entre los tres tipos de rodamientos ante la presencia de la misma falla.




Figura 48.- Metodología del análisis en el dominio de la frecuencia

# Capítulo IV

## 4 Análisis de resultados

En este capítulo se describen los resultados obtenidos, los cuales se separaron en rodamientos metálicos, rodamientos cerámicos y rodamientos híbridos, estos a su vez en la frecuencia de operación a la cual fueron adquiridas las señales: 5, 15, 50 y 60 Hz. Para la etapa de entrenamiento en software, se realizaron de 7 a 10 pruebas por cada una de estas condiciones, después estas se dividieron en ventanas de 4096 datos, de las cuales se realizó el cálculo de quince indicadores estadísticos que describen su comportamiento, sin embargo, probablemente no todos contienen información representativa respecto a la condición de la cadena cinemática, por lo que se sometieron a un proceso de reducción por medio de PCA, obteniendo así la matriz de coeficientes. Finalmente, para obtener un diagnóstico, se entrenó una red neuronal, consiguiendo las regiones de decisión, así como los pesos y bias de cada capa.

Para la etapa de implementación en hardware se tomó una señal de vibración de muestra, de la cual se conocía su condición, es decir, se sabía previamente si había una falla o no en la cadena cinemática al adquirirla, de esta manera se comprobó el funcionamiento de la metodología desarrollada, además esta señal se acotó entre -1 y 1 para un mejor manejo en formato binario. De esta señal de 4096 datos, se calcularon los quince indicadores estadísticos antes mencionados, el resultante fue un vector de 15 datos que se multiplicó por la matriz de transformación obtenida en software del PCA, para finalmente pasar por la evaluación de redes neuronales, obteniendo un diagnóstico.

De manera alterna se desarrolló la misma metodología en software que en hardware para determinar solamente la condición de la cadena y así verificar la pérdida de información generada por la representación binaria y el formato de punto fijo que se manejó, el cual fue de 2.14 de entrada, siendo dos bits para la parte entera y 14 para la parte fraccionaria.

Finalmente, se muestran los resultados del análisis espectral, el cual se desarrolló completamente en software, observando la diferencia en el comportamiento entre los tres tipos de rodamientos analizados ante la presencia de una misma falla.

## 4.1 Rodamientos Metálicos

### 4.1.1 Pruebas de 5 Hz

El primer entrenamiento en software se realizó con las señales de vibración del eje y para las pruebas relacionadas con los rodamientos metálicos cuando la operación del motor de inducción era de 5 Hz.

Dado que solamente se tomaron en consideración los dos primeros componentes principales, se realizó la sumatoria de la varianza acumulada entre ambos, dando un total de 90.6768%, siendo un porcentaje alto, considerando que la suma de todos es igual al 100%, logrando una buena agrupación de datos. En la Figura 49a se muestra la proyección de los indicadores calculados maximizando la varianza entre ellos, notando que se logran agrupar los datos con características similares, esto es, los datos correspondientes a la condición *HLT-M*, marcados con círculos azules se agruparon en una zona, mientras que los datos correspondientes a la falla del rodamiento *BD-M* señalada con triángulos rojos se unieron en otra zona diferente. En la Figura 49b se muestran las regiones de decisión de la red neuronal, notando que están bien definidas, así, cuando una señal sea sometida a diagnóstico, dependerá de la región en que se ubique en esta figura y se determinará su estado.




Figura 49.- Rodamiento metálico a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

La red neuronal se programó para que se ejecutaran como máximo 100 épocas contando con 10 capas ocultas; con esto se obtuvo un porcentaje de clasificación del 100% durante el entrenamiento, así como en la validación; en la Tabla 2 y 3 se muestran las matrices

de confusión generadas para ambas partes respectivamente. Donde, de los 168 datos que se utilizaron para la parte de entrenamiento de cada condición, se logró clasificar el 100% de ellos correctamente, mientras que, de los 42 datos utilizados para la validación de la red neuronal, también se alcanzó el 100%.

Tabla 2.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 5Hz

	<i>HLT-M</i>	<i>BD-M</i>	
<i>HLT-M</i>	168 50.0%	0 0.0%	100% 0.0%
<i>BD-M</i>	0 0.0%	168 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 3.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 5Hz

	<i>HLT-M</i>	<i>BD-M</i>	
<i>HLT-M</i>	42 50.0%	0 0.0%	100% 0.0%
<i>BD-M</i>	0 0.0%	42 50%	100% 2.3%
	100% 0.0%	100% 0.0%	100% 0.0%

Luego entonces, para la etapa de explotación en hardware, se introdujo una señal de prueba en la simulación en *Xilinx ISE*, la cual se obtuvo cuando la cadena cinemática estaba en buenas condiciones, después se calcularon los quince indicadores estadísticos de esta. Si bien el formato que se manejó para la señal de prueba fue de 2.14, dejando así 2 bits para la parte entera de la representación binaria con signo, mientras que 14 bits se dedicaron a la parte fraccionaria, (mismo formato aplicado para todo el proyecto), debido a los bits de guarda que se agregan al realizar sumatorias en *vhd*, el formato de salida para los indicadores estadísticos cambió a 14.14. Luego entonces, en este formato se introdujeron los coeficientes de la matriz de transformación y se obtuvieron las señales *X* y *Y*, que son las salidas del bloque *PCA*. Comparando los valores calculados entre *MATLAB* y *Xilinx ISE*, para *X* del primero se obtuvo  $-1.1737$  mientras que para *Y* fue  $0.2980$ , por su parte, en la simulación en hardware se obtuvieron valores de  $-1.2402$  y  $0.1957$  respectivamente en formato 14.14. Luego entonces, éstos valores entran al bloque *Redes Neuronales*, obteniendo valores de  $1.1008$  y





está en óptimas condiciones, mientras que si  $ss2$  es un número mayor que  $ss1$ , advierte la presencia de una falla de rodamientos en la pista externa.

Tabla 4.- Comparativa resultados software-hardware para rodamientos metálicos a 5Hz

Señal prueba	PCA				Redes Neuronales			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<b>HLT-M</b>	-1.1737	-1.2402	0.2980	0.1957	1.1008	1.1000	-0.1037	-0.1035
<b>BD-M</b>	2.2832	2.2610	0.1458	0.1803	-0.0054	-0.0018	0.9702	0.9736

En la Figura 51 se muestra la simulación cuando la prueba de una señal con falla en la pista externa se llevó a cabo, dando como resultado para  $ss2$  un valor mayor al de  $ss1$ , indicando la presencia de fallas en el rodamiento (formato de 6.14 con signo). Cabe destacar que solo para fines de visualización en este documento se muestran todos los indicadores estadísticos, los valores de salida del bloque de PCA y las señales  $ss1$  y  $ss2$  en formato de punto flotante en la simulación, sin embargo, en la versión final de los archivos en *vhd* solo se tiene como salidas los valores de un bit  $S1$  y  $S2$ .

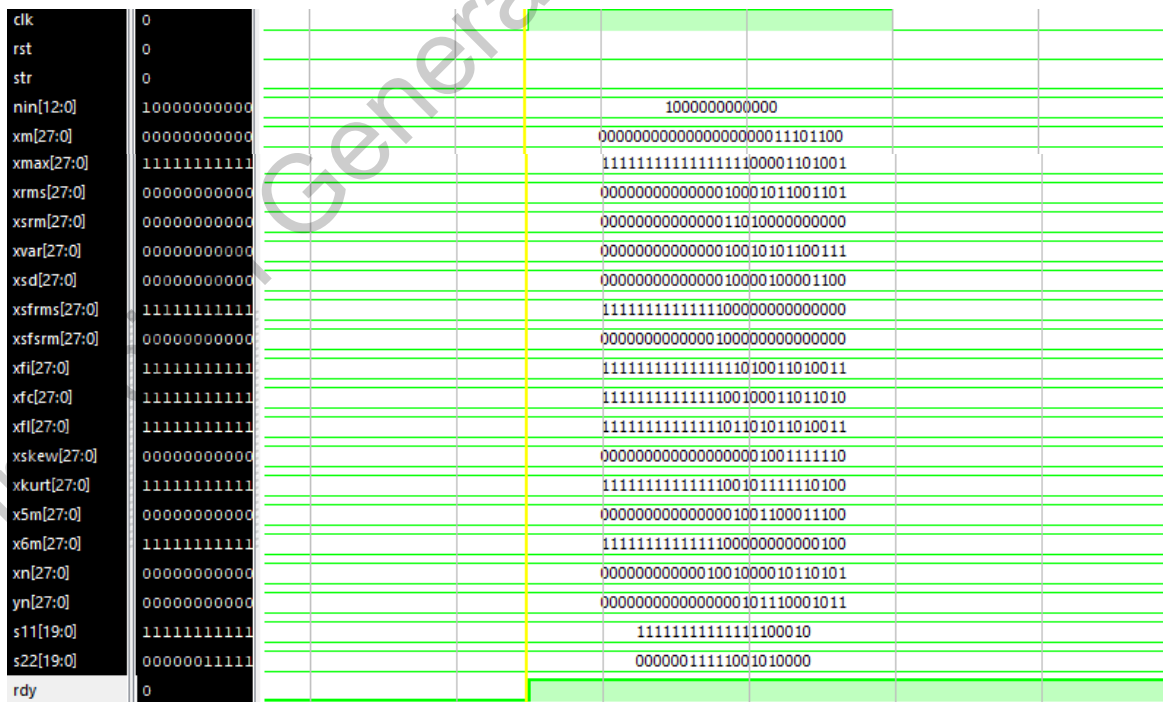


Figura 51.- Simulación en Xilinx ISE de las pruebas de rodamientos metálicos a 5 Hz con presencia de falla

### 4.1.2 Pruebas de 15 Hz

En el caso de las pruebas relacionadas con rodamientos metálicos donde la velocidad del motor de inducción de la cadena cinemática era de 15 Hz, se obtuvo la proyección del conjunto de indicadores calculados en el plano de máxima varianza mostrado en la Figura 59a, logrando una clara distinción entre ambas condiciones evaluadas. En este sentido, la sumatoria de las varianzas de los dos componentes principales fue de 89.4967%.




Figura 52.- Rodamiento metálico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Por su parte, el entrenamiento de las redes neuronales generó las regiones de decisión de la Figura 59b completamente definidas, como era de esperarse, dado que PCA logró una buena caracterización de las condiciones evaluadas, facilitando la tarea de diagnóstico. De esta manera, la matriz de confusión tanto para la parte de entrenamiento como para la parte de evaluación alcanzaron el 100%.

Tabla 5.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 15Hz

	<i>HLT-M</i>	<i>BD-M</i>	
<i>HLT-M</i>	168 50.0%	0 0.0%	100% 0.0%
<i>BD-M</i>	0 0.0%	168 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 6.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 15Hz

	<i>HLT-M</i>	<i>BD-M</i>	
<i>HLT-M</i>	42 50.0%	0 0.0%	100% 0.0%
<i>BD-M</i>	0 0.0%	42 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 7.- Comparativa resultados software-hardware para rodamientos metálicos a 15Hz

Para verificar que tanto la reducción de indicadores como el entrenamiento de la red neuronal y el cálculo de indicadores funcionan adecuadamente en *vhd* se introdujeron dos señales de prueba al igual que el caso anterior, una que corresponde con un estado saludable de la cadena cinemática (*HLT-M*) y otra indicando la presencia de falla en rodamientos (*BD-M*). Como se puede observar en la siguiente tabla, haciendo la comparativa entre los valores obtenidos entre Matlab y la simulación en Xilinx ISE, el diagnóstico fue correcto en ambos casos, dando un valor cercano a 1 para *SS1* cuando la señal de prueba fue *HLT-M*, mientras que *SS2* se mantuvo en valores cercanos a 0. En caso contrario, cuando la señal de prueba era *BD-M*, los valores obtenidos tanto en software como en hardware para *SS2* se acercaron a la unidad, indicando un mayor grado de pertenencia de la señal de entrada a esta condición de falla.

<i>Señal prueba</i>	<i>PCA</i>				<i>Redes Neuronales</i>			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<i>HLT-M</i>	-2.4053	-2.2806	-0.0507	-0.0270	1.0866	1.0669	0.0399	0.0408
<i>BD-M</i>	1.5176	1.6550	-1.0374	-0.9175	-0.0015	-0.0246	0.9805	0.9473

### 4.1.3 Pruebas de 50 Hz

Para las pruebas de 50 Hz del rodamiento metálico, a pesar de que entre los dos componentes principales se alcanzó un porcentaje de varianza del 96.4073%, se traslaparon un poco ambas condiciones, tal como se observa en la Figura 53a. Así, que también era de

esperar, que las regiones de decisión generadas por las redes neuronales lo hicieran también (ver Figura 53b).




Figura 53.- Rodamiento metálico a 50 Hz del eje x. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Debido a este traslape de condiciones en las regiones de decisión mostradas, los porcentajes del entrenamiento no alcanzaron el 100%. Sin embargo, tal como se mencionó anteriormente, para las redes neuronales se trabajó con un formato de validación cruzada de 5 veces, los cuales mostraron un comportamiento estable, centrándose en porcentajes de entrenamiento en el intervalo entre 95.5% y 96.7%. En la Tabla 8, se muestra la matriz de confusión para el entrenamiento de la red neuronal utilizada para generar las regiones de clasificación de la Figura 53b, notando que de los 168 datos de prueba para la condición *HLT-M* solo el 98.2% se clasificó correctamente, mientras que el 1.8% restantes se marcó como *BD-M*. Caso similar ocurrió con los datos correspondientes a *BD-M*, donde de los 168 solo el 97.6% de ellos se catalogó correctamente, dejando un error del 2.4%.

Tabla 8.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 50 Hz

	<i>HLT-M</i>	<i>BD-M</i>	
<i>HLT-M</i>	161 47.9%	4 1.2%	97.6% 2.4%
<i>BD-M</i>	7 2.1%	164 48.8%	95.9% 4.1%
	98.2% 1.8%	97.6% 2.4%	96.7% 3.3%

Tal como era de esperarse, si no se logró el 100% en todos los casos del entrenamiento, tampoco lo haría en la etapa de evaluación, sin embargo se mantuvo en un rango de efectividad entre 89.3% y 100%. Se seleccionó la red neuronal que mejores resultados arrojó respecto a la validación de datos, donde se alcanzó el 100%, tal como se muestra en la siguiente tabla.

Tabla 9.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 50Hz

	<i>HLT-M</i>	<i>BD-M</i>	
<i>HLT-M</i>	42 50.0%	0 0.0%	100% 0.0%
<i>BD-M</i>	0 0.0%	42 50%	100% 0.0%
	100% 0%	100% 0%	100% 0.0%

Tabla 10.- Comparativa resultados software-hardware para rodamientos metálicos a 50Hz

Comparando los resultados entre software y hardware (ver Tabla 10), se observa que los diagnósticos en ambos casos fueron correctos, sin embargo, debido al traslape generado en las regiones de decisión, el grado de permanencia para *BD-M* para SS2 no es tan elevado como en los casos anteriores, a pesar de eso, el resultado resulta satisfactorio.

<i>Señal prueba</i>	<i>PCA</i>				<i>Redes Neuronales</i>			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<i>HLT-M</i>	-2.7666	-2.7510	0.2186	0.4216	1.0148	1.0168	-0.0015	-0.0012
<i>BD-M</i>	-1.6927	-1.7285	-0.9431	-1.0460	0.4167	0.4117	0.6413	0.7130

#### 4.1.4 Pruebas de 60 Hz

Para las pruebas de 60Hz se logró una clara agrupación entre condiciones mediante la fusión de datos utilizando PCA, tal como se muestra en la Figura 54a, alcanzando un porcentaje de varianza acumulada entre los dos componentes principales del 96.4242%. Observando entonces las regiones de decisión generadas por el entrenamiento de las redes neuronales (ver Figura 54b) se percibe una notoria separación entre clases.




Figura 54.- Rodamiento metálico a 60 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Sin embargo, el rango de entrenamiento se mantuvo entre 99.1% y 100% entre las cinco redes neuronales generadas, mientras que para la validación el porcentaje se sostuvo entre el 81% y el 100%

Tabla 11.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento metálico a 60 Hz

	HLT-M	BD-M	
HLT-M	168 50.0%	0 0.0%	100% 0.0%
BD-M	0 0.0%	168 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 12.- Matriz de confusión de la validación de redes neuronales del rodamiento metálico a 60Hz

	HLT-M	BD-M	
HLT-M	42 50.0%	0 0.0%	100% 0.0%
BD-M	0 0.0%	42 50%	100% 0.0%
	100% 0%	100% 0%	100% 0.0%

Tabla 13.- Comparativa resultados software-hardware para rodamientos metálicos a 60Hz

Para este caso, en ambas pruebas *HLT-M* y *BD-M* fueron muy satisfactorias, debido a que los valores de pertenencia tanto en software como en hardware rondaron la unidad, indicando un gran grado de afinidad con cada una de sus respectivas condiciones.

Señal prueba	PCA				Redes Neuronales			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<b>HLT-M</b>	3.1769	3.1752	0.0863	0.1648	0.9629	0.9645	-0.0624	-0.0600
<b>BD-M</b>	-3.0123	-3.0142	-0.3092	-0.2339	-0.1321	-0.1260	1.0630	1.0603

## 4.2 Rodamientos Cerámicos

### 4.2.1 Pruebas de 5 Hz

Para este caso se efectuaron 7 pruebas por condición, es decir, 7 pruebas de 40 segundos para rodamientos cerámicos a 5Hz para la condición HLT-C y 7 pruebas de 40 segundos para rodamientos cerámicos a 5Hz para la condición BD-M (misma cantidad de pruebas para el resto de condiciones a evaluar) en contraste con las 10 pruebas para rodamientos metálicos por condición. Esto fue ocasionado por la pandemia, sin embargo, la cantidad de pruebas no afectó los resultados, ya que las señales obtenidas fueron suficientes para determinar el estado de la cadena cinemática.

Ahora bien, para las señales captadas cuando rodamientos cerámicos estaban montados en el eje del motor de inducción y giraba a una velocidad de 5Hz, se aplicó la misma metodología, obteniendo la agrupación de clases por parte del método de PCA mostrado en la Figura 55a, donde se alcanzó un porcentaje de varianza acumulada de 98.2476% entre los dos componentes principales.




Figura 55.- Rodamiento cerámico a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Si bien se seleccionó la red neuronal que mejor logró clasificar las dos clases, en la validación cruzada se mantuvo un porcentaje para el entrenamiento del 100%, mientras que para la validación de la red el porcentaje varió entre 94.8% y 100%. En las Tablas 14 y 15 se muestran la matriz de confusión seleccionada para cada caso.

Tabla 14.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	116 50.0%	0 0.0%	100% 0.0%
BD-C	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 15.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	29 50.0%	0 0.0%	100% 0.0%
BD-C	0 0.0%	29 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

ENTRENAMIENTO 100

Tabla 16.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz

Al evaluar una condición de prueba *HLT-C*, se obtuvo un valor de pertenencia para *SS1* cercano a 1 tanto en hardware como en software, mientras que los valores para *SS2* se mantuvieron cercanos al 0. Por otro lado, al estimar los grados de pertenencia cuando la señal de prueba fue *BD-C*, *SS1* se mantuvo en números bajos, mientras que para *SS2* en software y en hardware se alcanzaron valores superiores a la unidad.

Señal prueba	PCA				Redes Neuronales			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<b>HLT-C</b>	2.8490	2.9771	0.0968	0.3867	1.0102	0.9572	0.0155	0.0502
<b>BD-C</b>	-3.0854	-3.3288	0.0763	-0.4737	0.0938	0.1293	1.0529	1.0372



## 4.2.2 Pruebas de 15 Hz

Las pruebas evaluadas de rodamientos cerámicos cuando el motor de inducción giraba a 15Hz determinaron la proyección del conjunto de características resultante del PCA mostrada en la Figura 56a, donde se obtuvo la separación entre clases por medio de la maximización de la varianza. En este caso, la sumatoria de la varianza de las dos componentes principales fue de 96.5218%.




Figura 56.- Rodamiento cerámico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Como consecuencia de una buena agrupación por PCA, una buena clasificación se obtuvo por parte de las redes neuronales (ver Figura 56b), logrando un 100% en las matrices de confusión para entrenamiento y validación de los datos en las 5 redes entrenadas, en las tablas 17 y 18 se muestran dichas matrices de confusión.

Tabla 17.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	116 50.0%	0 0.0%	100% 0.0%
BD-C	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 18.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz

	<i>HLT-C</i>	<i>BD-C</i>	
<i>HLT-C</i>	29 50.0%	0 0.0%	100% 0.0%
<i>BD-C</i>	0 0.0%	29 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

En este caso, los valores obtenidos entre hardware y software fueron muy similares, desde la parte de fusión de datos, ya que mientras en MATLAB para la señal de prueba *HLT-C* la salida de *X* fue de 2.5748 y para *Y* de -0.6946, en hardware se obtuvieron 2.7400 y -0.6754 respectivamente, por consiguiente, los valores para *SS1* fueron muy aproximados, sin embargo, para *SS2* la variación fue mayor, a pesar de ello, el diagnóstico fue realizado correctamente. Mismo caso para *BD-C*, a pesar de las ligeras variaciones que presentan los valores de software y hardware, el diagnóstico se ejecutó correctamente.

Tabla 19.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz

<i>Señal prueba</i>	<i>PCA</i>				<i>Redes Neuronales</i>			
	<i>X</i>		<i>Y</i>		<i>SS1</i>		<i>SS2</i>	
	<i>S</i>	<i>H</i> 14.14	<i>S</i>	<i>H</i> 14.14	<i>S</i>	<i>H</i> 6.14	<i>S</i>	<i>H</i> 6.14
<i>HLT-C</i>	2.5748	2.7400	-0.6946	-0.6754	0.9561	0.9697	-0.0709	-0.1276
<i>BD-C</i>	-2.7277	-2.8727	0.3962	0.4000	-0.0698	-0.0706	0.8036	0.7564

### 4.2.3 Pruebas de 50 Hz

Para las señales de vibración obtenidas cuando el motor de inducción operaba a 50Hz, se obtuvo un porcentaje de varianza acumulada entre los dos componentes principales de 85.0633%, siendo la Figura 57a la proyección de éstos en 2D. Así, se obtienen las regiones de clasificación mostradas en la Figura 57b, logrando una separación entre clases adecuada.

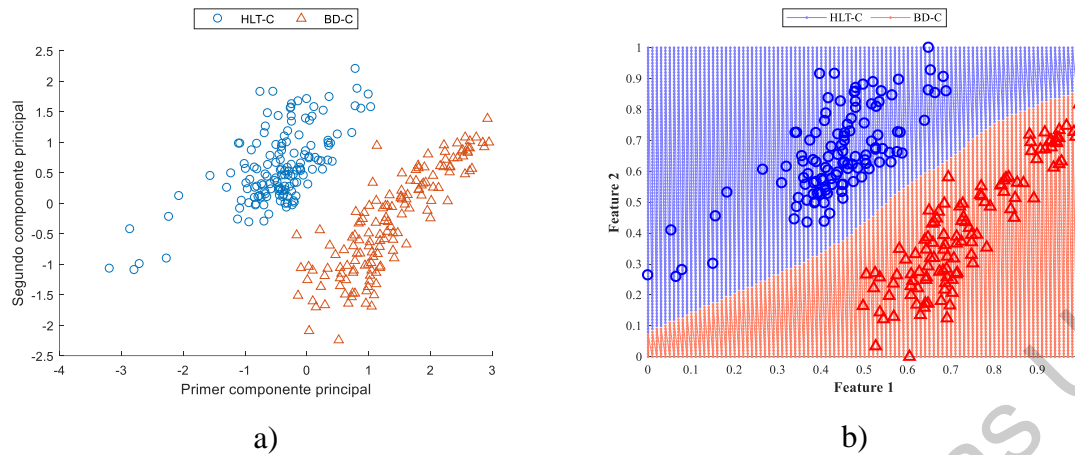


Figura 57.- Rodamiento cerámico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Sin embargo, el porcentaje de eficacia del entrenamiento varió entre 99.1% y 100%. En el caso de la red neuronal que se seleccionó para exportar sus valores a *vhdl*, el porcentaje de clasificación fue del 100% (ver Tabla 20).

Tabla 20.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	116 50.0%	0 0.0%	100% 0.0%
BD-C	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

En lo que respecta a la validación de los datos, el rango se mantuvo estable entre 98.3% y 100%. En la Tabla 21 se muestra la matriz de confusión de la red neuronal seleccionada relacionada con la validación de datos, donde de los 29 que fueron evaluados pertenecientes a la condición *BD-C*, solo el 3.4% se evaluó de forma incorrecta.

Tabla 21.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	29 50.0%	1 1.7%	96.7% 3.3%
BD-C	0 0.0%	28 48.3%	100% 0.0%
	100% 0.0%	96.6% 3.4%	98.3% 1.7%

Como era de esperarse, el diagnóstico final se llevó a cabo correctamente, siendo *SS1* mayor que *SS2* tanto en software como en hardware para *HLT-C* y *SS2* mayor que *SS1* cuando la prueba evaluada fue *BD-C*, tal como se muestra en la tabla siguiente.

Tabla 22.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz

Señal prueba	PCA				Redes Neuronales			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<b>HLT-C</b>	-1.0778	-1.4387	0.7993	1.1254	1.0548	0.8835	-0.1102	-0.2154
<b>BD-C</b>	2.4444	2.5812	0.6738	0.5516	-0.0818	-0.1016	1.0529	1.0916

#### 4.2.1 Pruebas de 60 Hz

Exactamente el mismo método se llevó a cabo para todas las frecuencias de operación, así que para el caso de 60 Hz utilizando el método de PCA se obtuvo la proyección en 2D mostrada en la Figura 58a, donde se logra una buena separación de clases, la varianza acumulada por su parte entre los dos componentes principales de este caso es 99.0517%. Debido a que el porcentaje es bastante elevado, se esperaba clasificación igual de buena, tal como se observa en la Figura 58b.




Figura 58.- Rodamiento cerámico a 15 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Por su parte, las matrices de confusión para el entrenamiento de la red se mantuvo siempre en un 100%, mientras que para su validación varió entre el 87.9% y 100%. Se

seleccionó la red neuronal que mejor clasificó, así que en las Tablas 23 y 24 se muestran las matrices de confusión correspondientes.

Tabla 23.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	116 50.0%	0 0.0%	100% 0.0%
BD-C	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 24.- Matriz de confusión de la validación de redes neuronales del rodamiento cerámico a 5Hz

	HLT-C	BD-C	
HLT-C	29 50.0%	0 0.0%	100% 0.0%
BD-C	0 0.0%	29 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

En la Tabla 25 se muestra la comparativa entre los valores obtenidos entre software y hardware para esta prueba, notando que, para ambos casos, el diagnóstico fue realizado correctamente, ya que los valores de SS1 y SS2 corresponden con la señal de prueba evaluada.

Tabla 25.- Comparativa resultados software-hardware para rodamientos cerámicos a 5Hz

Señal prueba	PCA				Redes Neuronales			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
HLT-C	-3.1643	-3.4018	-0.4920	-0.3043	1.1006	1.1743	0.1046	0.0001
BD-C	2.9481	3.1222	-0.0642	-0.2006	-0.0329	-0.0635	1.0217	1.1591

## 4.3 Rodamientos Híbridos

### 4.3.1 Pruebas de 5 Hz

Para los rodamientos híbridos cuando el motor de la cadena cinemática operaba a 5Hz son los siguientes: La proyección de los datos en el plano de máxima varianza en 2D se muestra en la Figura 59a, logrando una clara separación entre clases, y alcanzando un porcentaje de varianza acumulada entre los dos componentes principales de 98.3769%. Como se esperaba, las regiones de clasificación están bien definidas (ver Figura 59b), sin ningún traslape de datos, así, la matriz de confusión para el entrenamiento de la red neuronal así como la matriz de confusión para la validación se mantuvieron estables en 100% (Tablas 26 y 27).




Figura 59.- Rodamiento híbrido a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Tabla 26.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 5Hz

	HLT-H	BD-H	
HLT-H	116 50.0%	0 0.0%	100% 0.0%
BD-H	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 27.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz

	<i>HLT-H</i>	<i>BD-H</i>	
<i>HLT-H</i>	29 50.0%	0 0.0%	100% 0.0%
<i>BD-H</i>	0 0.0%	29 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

En lo que respecta a los valores de pertenencia para las pruebas de *HLT-H* y *BD-H* tanto en software como en hardware, se obtuvieron excelentes resultados, ya que para ambos casos estos valores sobrepasaron la unidad cuando era el caso y estando la otra señal en valores cercanos a 0.

Tabla 28.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz

<i>Señal prueba</i>	<i>PCA</i>				<i>Redes Neuronales</i>			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<i>HLT-H</i>	2.6194	2.8425	-0.2224	-0.3212	1.0610	1.0824	0.0215	0.0012
<i>BD-H</i>	-2.7080	-2.9764	-0.1846	-0.0687	0.0191	0.0208	1.2721	1.4280

### 4.3.2 Pruebas de 15 Hz

El gráfico en dos dimensiones obtenidos al proyectar los datos en el plano de máxima varianza se muestra en la Figura 60a, donde se logra agrupar a la mayoría de los datos en una misma zona, siendo el porcentaje de varianza acumulada entre los dos componentes principales de 93.4564%. Sin embargo, las regiones de decisión generadas por las redes neuronales mostradas en la Figura 60b están bien definidas, esperando así porcentajes altos relacionados con su entrenamiento y validación.




Figura 60.- Rodamiento híbrido a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

En este caso, la red neuronal seleccionada cuyos datos fueron importados a *vhdl*, tuvo valores de eficiencia del 100% tanto para el entrenamiento como para la validación de la red neuronal, tal como se muestra en las Tablas 29 y 30. Sin embargo, hubo ligeras variaciones entre las demás redes neuronales entrenadas, pero estos valores fueron constantes, manteniéndose entre 99.6% y 100% para la etapa de entrenamiento, mientras que para la de validación fue en todos los casos del 100%.

Tabla 29.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 5Hz

	HLT-H	BD-H	
HLT-H	116 50.0%	0 0.0%	100% 0.0%
BD-H	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 30.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz

	HLT-H	BD-H	
HLT-H	29 50.0%	0 0.0%	100% 0.0%
BD-H	0 0.0%	29 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%



Los valores calculados tanto en MATLAB como en la simulación en Xilinx ISE tanto para las salidas del bloque *PCA*, así como para los valores de pertenencia obtenidos de las *Redes Neuronales* se muestran en la Tabla 31. Observando que para ambas pruebas *HLT-H* y *BD-H* los diagnósticos son correctos.

Tabla 31.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz

Señal prueba	PCA				Redes Neuronales			
	X		Y		SS1		SS2	
	S	H	S	H	S	H	S	H
<i>HLT-H</i>	-2.4258	-2.5219	0.0629	-0.3209	0.9553	0.9917	-0.1329	-0.1042
<i>BD-H</i>	1.9906	2.1417	0.0862	0.0713	-0.2579	-0.4680	0.9599	1.0032

### 4.3.1 Pruebas de 50 Hz

Para las pruebas realizadas a 50Hz, se obtuvo la proyección de datos resultante de la PCA mostrada en la Figura 61a, donde se presenta un traslape de la condición *BD-H* en la agrupación de los indicadores de *HLT-H*. Sin embargo, el porcentaje de varianza acumulada entre los dos componentes principales fue de 91.4349%. Sin embargo, al realizar la clasificación con redes neuronales este traslape parece desaparecer, tal como se muestra en la Figura 61b.




Figura 61.- Rodamiento híbrido a 5 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Las matrices de confusión de entrenamiento de estas pruebas permanecieron en el rango de 99.6% y 100%, mientras que para las matrices de confusión relacionadas con la validación de las redes neuronales presentó variaciones entre el 94.8% y el 100%. En la tabla 32 se muestran los datos relacionados con el entrenamiento, mientras que en la tabla 33 se observa que para la validación, los 29 datos evaluados de la condición *HLT-H* se clasificaron correctamente, mientras que de la misma cantidad de datos pero de la condición *BD-H* el 86.2% se catalogó correctamente, siendo 4 los valores que se agruparon en la clase equivocada.

Tabla 32.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 5Hz

	<i>HLT-H</i>	<i>BD-H</i>	
<i>HLT-H</i>	116 50.0%	0 0.0%	100% 0.0%
<i>BD-H</i>	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 33.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz

	<i>HLT-H</i>	<i>BD-H</i>	
<i>HLT-H</i>	29 50.0%	4 6.9%	87.9% 12.1%
<i>BD-H</i>	0 0.0%	25 43.1%	100% 0.0%
	100% 0.0%	86.2% 13.8%	93.1% 6.9%

A pesar de los traslapes generados, las señales de pruebas tanto para *HLT-H* como para *BD-H* se clasificaron correctamente, tal como se puede observar en la Tabla 34, donde además se muestra la diferencia entre los valores obtenidos entre hardware y software.

Tabla 34.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz

<i>Señal prueba</i>	<i>PCA</i>				<i>Redes Neuronales</i>			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<i>HLT-H</i>	1.3964	1.09991	2.2193	2.8329	1.2692	1.3015	-0.1997	-0.2473
<i>BD-H</i>	-0.0887	-0.2082	-2.0205	-2.6340	0.0001	0.1479	1.0785	1.0351

### 4.3.2 Pruebas de 60 Hz

Finalmente, el análisis de las señales relacionada con rodamientos híbridos y donde la frecuencia de operación del motor de inducción de la cadena cinemática era de 60Hz se muestra a continuación. La proyección de máxima varianza en 2D obtenida gracias al método de PCA se muestra en la Figura 62a, sin mostrar signos de traslape de clases, de esta manera el porcentaje de varianza acumulada entre los dos componentes principales es de 99.5862%. El entrenamiento de las redes neuronales arrojó las regiones de decisión mostradas en la Figura 62b.

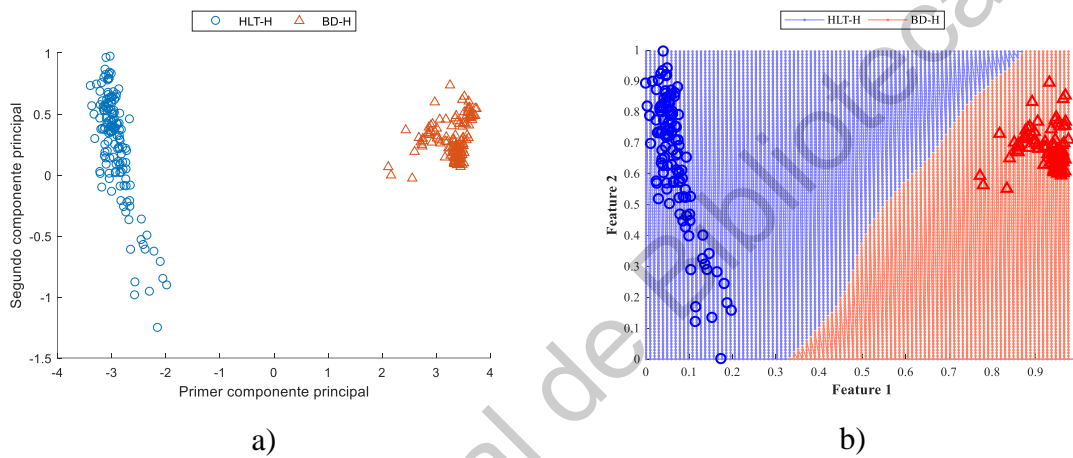


Figura 62.- Rodamiento híbrido a 60 Hz del eje y. a) Proyección del conjunto extraído de características resultante de PCA b) Proyección de las regiones de decisión resultantes de la NN

Si bien, el porcentaje de varianza acumulada y las regiones de clasificación están bien definidas, el porcentaje de las matrices de confusión del entrenamiento de las redes neuronales varió entre 86.2% y el 100%. Por su parte, todas las matrices de confusión correspondientes a la validación de las redes neuronales se mantuvieron en 100%. En las tablas 35 y 36 se presentan las matrices de confusión de la red neuronal seleccionada que se utilizó en la parte de la implementación en hardware.

Tabla 35.- Matriz de confusión del entrenamiento de redes neuronales del rodamiento híbrido a 60Hz

	HLT-H	BD-H	
HLT-H	116 50.0%	0 0.0%	100% 0.0%
BD-H	0 0.0%	116 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

Tabla 36.- Matriz de confusión de la validación de redes neuronales del rodamiento híbrido a 5Hz

	<i>HLT-H</i>	<i>BD-H</i>	
<i>HLT-H</i>	29 50.0%	0 0.0%	100% 0.0%
<i>BD-H</i>	0 0.0%	29 50%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%

En la tabla 37 se hace un resumen de las variaciones entre los valores obtenidos en MATLAB y en la simulación en Xilinx ISE de las pruebas que se realizaron para validar la metodología propuesta, notando que el diagnóstico final corresponde con las señales de prueba en cada caso.

Tabla 37.- Comparativa resultados software-hardware para rodamientos híbridos a 5Hz

<i>Señal prueba</i>	<i>PCA</i>				<i>Redes Neuronales</i>			
	X		Y		SS1		SS2	
	S	H 14.14	S	H 14.14	S	H 6.14	S	H 6.14
<i>HLT-H</i>	-3.1449	-3.3968	0.7383	0.5571	0.9480	1.0158	0.0147	0.0030
<i>BD-H</i>	3.4232	3.5809	0.1974	0.3104	-0.0646	-0.0472	1.0987	1.1243

#### 4.4 Aplicación de la metodología de diagnóstico en la detección de diferentes fallas en rodamientos

Además, con el objetivo de extender la validación del método propuesto a otras aplicaciones, la metodología propuesta se aplicó sobre la Base de Datos de Rodamientos de la Universidad Case Western Reserve, que es una base de datos pública que ha sido ampliamente utilizada en el marco científico para la validación de metodologías de diagnóstico centradas en el marco de la detección e identificación de fallas. La base de datos consta de señales de vibración adquiridas de un banco de pruebas de laboratorio compuesto por un motor de 2 caballos de fuerza que se conecta a un dinamómetro mediante un transductor de par como se muestra en la Figura 63.




Figura 63.- Bancada experimental usada para generar la Base de Datos de Rodamientos de la Universidad Case Western

Para generar dicha base de datos se llevaron a cabo diferentes pruebas experimentales con el fin de simular diferentes condiciones de falla en el rodamiento que se encuentra en la flecha de accionamiento del motor eléctrico, es decir, se evaluaron condiciones normales o sanas (SANO), falla de la pista interior (F.P.I.), falla de la pista exterior (F.P.E.) y defecto de falla del rodamiento en las bolas (F.R.B.). Además de evaluar diferentes condiciones de falla en diferentes partes del rodamiento, cada uno de los defectos de los rodamientos fueron producidos artificialmente por una máquina de electro-descarga bajo diámetros de falla de 7, 14 y 21 milésimas de pulgada para evaluar las diferentes severidades de cada fallo.

Las señales de vibración se adquirieron colocando un acelerómetro en la parte superior de la carcasa del motor, en el extremo del impulsor, a una frecuencia de muestreo de 48 kS/s, y la velocidad promedio del motor controlada por el dinamómetro fue de aproximadamente 1730 rpm. Para aplicar la metodología de diagnóstico propuesta, para cada condición evaluada, la señal de vibración se dividió en varios segmentos obteniendo 120 muestras consecutivas, y posteriormente, el método de detección de fallas en rodamientos se aplica de la siguiente manera:

*Paso 1:* se calculó el conjunto de 15 indicadores estadísticos para los diferentes segmentos de las señales de vibración adquiridas de cada una de las diferentes condiciones evaluadas bajo diferentes severidades de falla.

*Paso 2:* se aplicó el proceso de transformación de base y reducción de indicadores mediante la PCA buscando obtener una proyección de las condiciones evaluadas en un espacio bidimensional.

*Paso 3:* se evaluaron las proyecciones resultantes mediante el clasificador basado en la red neuronal con el objetivo de obtener la clasificación resultante y de evaluar el rendimiento alcanzado por la metodología propuesta en su aplicación a otras bases de datos.

Estos pasos previamente descritos, se aplicaron a la base de datos de la Universidad Case Western Reserve con dos objetivos principales, el primero es el de demostrar que el cálculo de indicadores estadísticos y el uso de la PCA pueden ser aplicados de forma efectiva en la detección de fallas diferentes en rodamientos; y el segundo objetivo es el de probar que dicha metodología propuesta también puede ser aplicada en la detección de diferentes severidades que estén asociadas a un mismo fallo. En el primer caso se analizó únicamente la información asociada con la condición sana del rodamiento (SANO), falla en la pista interna (F.P.I), falla en la pista externa (F.P.E.) y falla en las bolas de rodamiento (F.R.B.), todas las condiciones de falla bajo una severidad de 7 milésimas de pulgada. En la Figura 64 se muestra la proyección resultante tras calcular los indicadores estadísticos sobre las señales de vibración y aplicar la PCA, sobre esta Figura 64 se puede apreciar de forma clara que aparecen diferentes agrupaciones de datos bien separadas y que en el caso de la detección de diferentes fallas en rodamientos no existe un traslape entre muestras de diferentes condiciones, esto es dado por que cada una de las condiciones de falla es representada por un patrón característico específico, es decir, que no hay relación de información que puedan compartir las condiciones evaluadas.

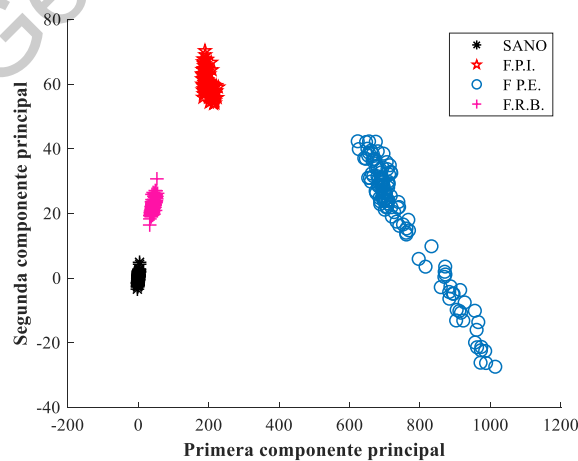


Figura 64.- Proyección del conjunto extraído de características resultante de PCA para el conjunto de datos Universidad Case Western Reserve evaluando condiciones de fallo

Por otra parte, en el segundo caso, para determinar que la metodología propuesta también puede ser aplicada en la detección de diferentes severidades de falla de un mismo modo de fallo, se evaluaron de forma específica la información asociada con la condición sana del rodamiento (SANO) y diferentes severidades del fallo en la pista interna del rodamiento (F.P.I), es decir, se evaluó el fallo en la pista interna del rodamiento bajo severidades de 7, 14 y 21 milésimas de pulgada. En este sentido, la proyección resultante obtenida es la que se muestra en la Figura 65, en la cual se puede apreciar, que incluso para diferentes severidades de fallo, la PCA tiene la capacidad de poder agrupar diferentes grupos de muestras en regiones completamente diferentes. Aunque el fallo analizado es el mismo, fallo en la pista interna, los patrones de vibración representados por los indicadores estadísticos son diferentes debido a que cada una de las severidades evaluadas tiende a producir sus propios efectos particulares.




Figura 65.- Proyección del conjunto extraído de características resultante de PCA para el conjunto de datos Universidad Case Western Reserve evaluando severidades de fallo en rodamientos

## 4.5 Análisis Frecuencial

Como método alternativo para la detección de fallas en rodamientos, se realizó una metodología independiente de la relacionada con métodos de reducción por PCA y clasificación por redes neuronales, en la cual es posible identificar daños en baleros con un análisis espectral, para lo cual es necesario calcular la frecuencia característica de la falla específica, en este caso la investigación se centró en la pista externa de un rodamiento modelo 6203 en donde se empleaban las señales de vibración, para que por medio de las frecuencias

características de fallo se lograra identificar la presencia de fallas. Este método ha sido ampliamente estudiado, pero se decidió anexarlo para observar el patrón de comportamiento de los diferentes materiales. En este caso, se analizarán las señales donde la frecuencia de operación era la misma, pero de todas las señales, realizando la respectiva separación por rodamientos, para analizar las diferencias entre las firmas de los rodamientos. Utilizando este método es posible identificar los daños en rodamientos con un análisis espectral, para lo cual es necesario calcular la frecuencia característica de la falla específica, en este caso la investigación se centró en la pista externa de un rodamiento modelo 6203, cuyo diámetro de paso ( $PD$ ) es de 28.5 mm, tiene 8 elementos rodantes ( $Nb$ ) y éstos a su vez tienen un diámetro ( $BD$ ) de 6.35 mm y al tratarse de un rodamiento de bolas su ángulo de contacto ( $\theta$ ) es de  $0^\circ$ .

#### 4.5.1 Pruebas de 5 Hz

Si bien, en todas las pruebas realizadas se trabajó con frecuencias de rotación del motor de inducción establecidas, siempre existen ligeras variaciones, por lo que se monitoreó la velocidad durante las mismas y se obtuvo el promedio de cada prueba, dando así una frecuencia de rotación ( $fr$ ) más aproximada a la realidad que si se utiliza la frecuencia de rotación teórica. Con todos estos datos, fue posible calcular la frecuencia característica de falla deseada utilizando la ecuación (18) para daños en la pista externa.

En la Figura 66 se muestran los espectros frecuenciales completos de las señales relacionadas con rodamientos metálicos, observando que las amplitudes de las componentes frecuenciales de BD-M son mayores que las de HLT-M. Mientras que en las Figuras 67 y 68 se muestran los espectros frecuenciales completos para las señales HLT y BD de los rodamientos cerámicos e híbridos respectivamente, donde el mayor incremento de amplitud se observa en las condiciones *HLT*.




Figura 66.- Espectro de frecuencias del eje Y a 5 Hz de rodamientos metálicos a) HLT-M b) BD-M






Figura 67.- Espectro de frecuencias del eje Y a 5 Hz de rodamientos cerámicos a) HLT-C b) BD-C




Figura 68.- Espectro de frecuencias del eje Y a 5 Hz de rodamientos híbridos a) HLT-H b) BD-H

En la Tabla 38, se muestran las frecuencias características de fallo específicamente para las pruebas de 5 Hz, junto con la frecuencia de rotación real  $f_r$  promedio utilizada para el cálculo de estos valores. Además, se muestran los valores para los armónicos segundo y terceros de las frecuencias de falla, que en teoría deberían de indicar también la presencia de fallas al aumentar su amplitud.

Tabla 38.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 5 Hz

5 Hz	Fr (Hz)	BPFO (Hz)	2 x BPFO (Hz)	3 x BPFO (Hz)
HLT-M	4.1670	12.9542	25.9084	38.8626
BD-M	4.3268	13.4510	26.902	40.353
HLT-C	4.3037	13.3792	26.7584	40.1376
BD-C	4.3494	13.5213	27.0426	40.5639
HLT-H	4.3182	13.4243	26.8486	40.2729
BD-H	4.2476	13.2049	26.4098	39.6147

Normalmente existen ligeras variaciones entre la BPFO calculada y la que aparece en el espectro de frecuencias de una señal de vibración, sin embargo, no fue posible localizar la

componente frecuencial característica BPFO para ninguno de los casos, ya que se pierde entre las demás componentes generadas por la propia naturaleza del sistema que suele generar vibraciones por sí solo.

#### 4.5.2 Pruebas de 15 Hz

En la siguiente tabla se muestran los valores de las fallas características de falla *BPFO*, así como sus dos armónicos siguientes para todas las condiciones de prueba.

Tabla 39.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 15 Hz

15 Hz	Fr (Hz)	BPFO (Hz)	2 x BPFO (Hz)	3 x BPFO (Hz)
HLT-M	14.0441	43.6600	87.3201	130.9801
BD-M	14.1203	43.8968	87.7936	131.6904
HLT-C	14.1246	43.9101	87.8202	131.7303
BD-C	14.1375	43.9504	87.9008	131.8512
HLT-H	14.1248	43.9109	87.8218	131.7327
BD-H	14.1685	44.0467	88.0934	132.1401

En la Figura 69 se muestra el espectro frecuencial de las dos condiciones del rodamiento metálico, donde también se observa a simple vista un incremento en las amplitudes cuando una falla está presente en la cadena cinemática.




Figura 69.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos metálicos a) HLT-M b) BD-M

Por otro lado, realizando un acercamiento a la zona donde se ubica la BPFO (ver Figura 70), se logra apreciar un ligero incremento en la amplitud de *BD-M* en comparación

con  $HLT-M_1$ , advirtiendo así la presencia de una falla en la pista externa del rodamiento metálico.




Figura 70.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos metálicos a)  $HLT-M$  b)  $BD-M$  (acercamiento a  $BPFO$ )

En la Figura 71 se muestra el espectro frecuencial para rodamientos cerámicos, observando un incremento en ruido y en amplitud en la condición  $HLT-C$ .

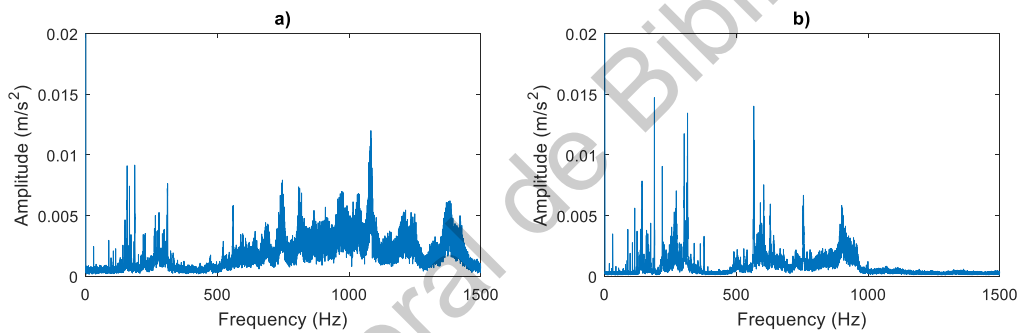


Figura 71.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos cerámicos a)  $HLT-C$  b)  $BD-C$

Tomando los valores de la tabla 39, se intentó localizar la frecuencia característica  $BPFO$  para los rodamientos cerámicos, sin embargo, no se consiguió. Sin embargo, para los dos armónicos siguientes si se logró apreciar un ligero incremento en amplitud, tal como se muestra en las Figuras 72 y 73.




Figura 72.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos cerámicos a)  $HLT-C$  b)  $BD-C$  (acercamiento a  $2xBPFO$ )




Figura 73.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 3xBPFO)

Para rodamientos híbridos, el espectro frecuencial se muestra en la Figura 74.

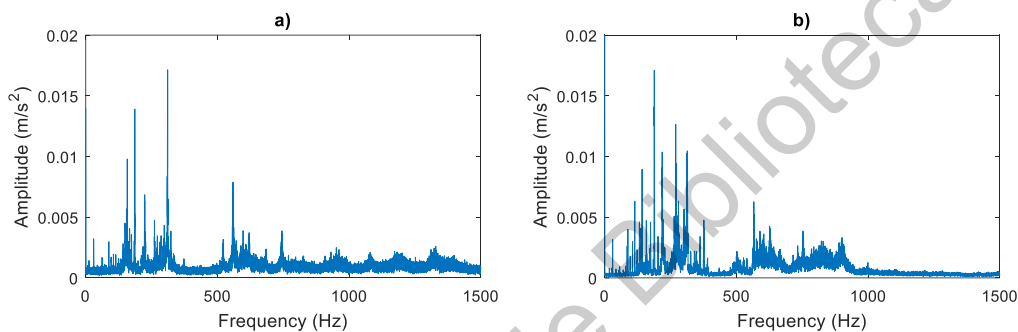


Figura 74.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos híbrido a) HLT-H b) BD-H

Se intentó localizar *BPFO* mostrado en la tabla anterior para identificar la presencia de fallas, sin embargo, no fue posible, pero analizando el segundo y tercer armónico, fue posible identificar un incremento en los respectivos componentes frecuenciales, para ellos se hicieron acercamientos en las zonas y se indicaron con marcadores en las Figuras 75 y 76.




Figura 75.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a 2xBPFO)

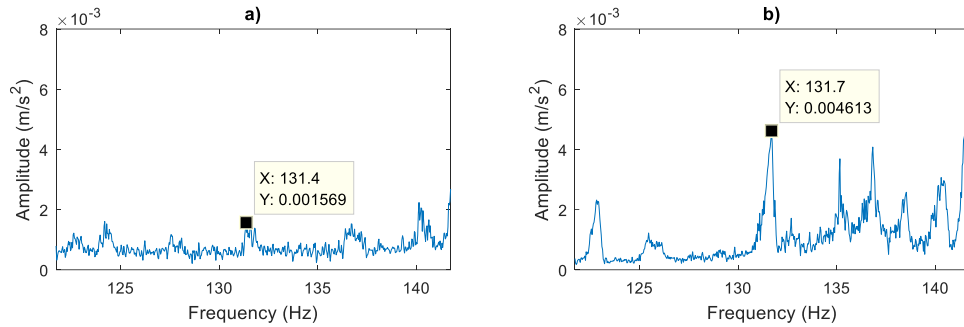


Figura 76.- Espectro de frecuencias del eje Y a 15 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a 3xBPFO)

### 4.5.3 Pruebas de 50 Hz

En la siguiente tabla se muestran los valores de las frecuencias características de falla *BPFO*, así como sus dos armónicos siguientes para todas las condiciones de prueba.

Tabla 40.-Frecuencia de rotación real y *BPFO* para rodamientos metálicos para pruebas de 50 Hz

50 Hz	Fr (Hz)	BPFO (Hz)	2 x BPFO (Hz)	3 x BPFO (Hz)
HLT-M	47.9000	148.9102	297.8205	446.7307
BD-M	47.9591	149.0939	298.1878	447.2817
HLT-C	47.6865	148.2463	296.4927	444.7390
BD-C	48.1406	149.6580	299.3161	448.9741
HLT-H	48.3301	150.2471	300.4943	450.7414
BD-H	48.2891	150.1199	300.2397	450.3596

Para las condiciones generadas utilizando rodamientos metálicos, se produjo el siguiente espectro frecuencial, notando a diferencia de los anteriores de este rodamiento, un incremento de amplitudes en general pero en *HLT-M* comparado contra *BD-M*




Figura 77.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos metálicos a) HLT-M b) BD-M

Dos componentes frecuenciales se localizaron relacionados con este tipo de rodamiento, esto es para *BPFO* (Figura 78) y para *2xBPFO* (Figura 79).




Figura 78.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a *BPFO*)




Figura 79.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a *2xBPFO*)

Por su parte, los rodamientos cerámicos generaron el espectro frecuencial mostrado a continuación, donde por primera vez se logra apreciar un incremento en amplitudes en general cuando una falla está presente en el rodamiento.




Figura 80.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos cerámicos a) HLT-C b) BD-C

Sin embargo, para este caso solo fue posible identificar la frecuencia de característica de fallo en su segundo armónico, tal como se muestra en la Figura 81.




Figura 81.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos cerámicos a) HLT-C b) BD-MC (acercamiento a  $2x\text{BPFO}$ )

Finalmente, para rodamientos híbridos ante la presencia de falla en la pista externa se nota un incremento en las amplitudes del espectro frecuencial, tal como se muestra en la Figura 82.




Figura 82.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos híbridos a) HLT-H b) BD-H

Sin embargo, este aumento de amplitudes no ayudó a la localización de las frecuencias características de falla, lográndose identificar débilmente en el tercer armónico.




Figura 83.- Espectro de frecuencias del eje Y a 50 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a  $3x\text{BPFO}$ )

#### 4.5.4 Pruebas de 60 Hz

En la Tabla 41 se muestran los valores BPFO para cada condición evaluada y sus respectivos armónicos, así como la velocidad real a la cual giraba el motor de inducción de la cadena cinemática al momento de realizar las pruebas.

Tabla 41.-Frecuencia de rotación real y BPFO para rodamientos metálicos para pruebas de 60 Hz

60 Hz	Fr (Hz)	BPFO (Hz)	2 x BPFO (Hz)	3 x BPFO (Hz)
HLT-M	57.6536	17 9.2319	358.4639	537.6958
BD-M	57.5988	179.0614	358.1228	537.1841
HLT-C	57.4348	178.5518	357.1035	535.6553
BD-C	57.7496	179.5303	359.0605	538.5908
HLT-H				
BD-H				

En el caso de rodamientos metálicos, el espectro frecuencial es el que se muestra a continuación, donde las amplitudes son mayores en *BD-M* que en *HLT-M*




Figura 84.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos metálicos a) HLT-M b) BD-M

En este caso, las frecuencias características de falla en la pista externa del rodamiento que mejor se identificaron fueron *BPFO* y su tercer armónico, tal como se muestra en las Figuras 85 y 86, observando un ligero incremento en el primero, sin embargo, la amplitud relacionada con el tercer armónico de *BPFO* probablemente no esté del todo relacionada con la falla, si no que es ruido o vibraciones inherentes al sistema, debido a que la mayoría de los componentes frecuenciales cercanos sufrieron un aumento de amplitud similar.






Figura 85.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a BPFO)




Figura 86.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos metálicos a) HLT-M b) BD-M (acercamiento a 3xBPFO)

La Figura 87 muestra el espectro frecuencial para rodamientos cerámicos en condiciones *HLT-C* y de falla *BD-C*, por su parte en la Figura 88 se observa el incremento de la amplitud de la frecuencia característica de falla en *BD-C* comparado con *HLT-H* de la misma figura, indicando la presencia de una falla en la pista externa del rodamiento cerámico.




Figura 87.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C




Figura 88.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a BPFO)

En la Figura 89 y 90 se muestran los acercamientos para el segundo y tercer armónico de BPFO respectivamente para rodamientos cerámicos, notando un ligero incremento en la amplitud en ambos casos para el espectro en condiciones de falla.




Figura 89.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 2xBPFO)




Figura 90.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos cerámicos a) HLT-C b) BD-C (acercamiento a 3xBPFO)

Finalmente, en la Figura 91, se muestra el espectro frecuencial para rodamientos híbridos cuando el motor de inducción giraba a una velocidad aproximada de 60Hz, mostrando un notable incremento en las amplitudes de la todas las componentes frecuenciales.

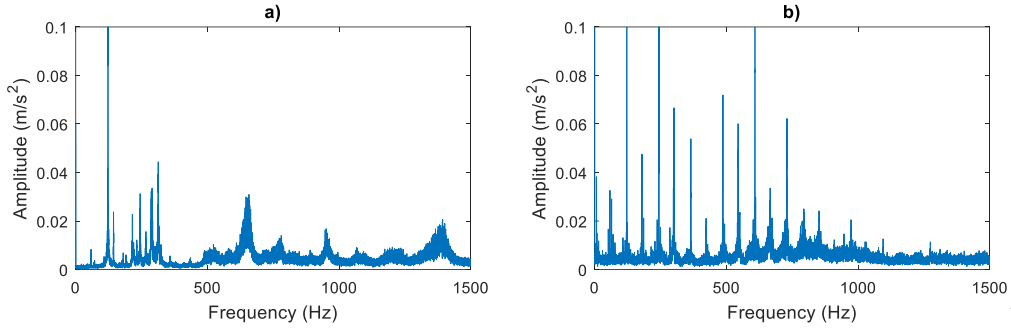


Figura 91.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos híbridos a) HLT-H b) BD-H

Sin embargo, para este caso, las frecuencias de fallo características que se lograron identificar fueron *BPFO* (Figura 92) y para el tercer armónico  $3xBPFO$  (Figura 93).

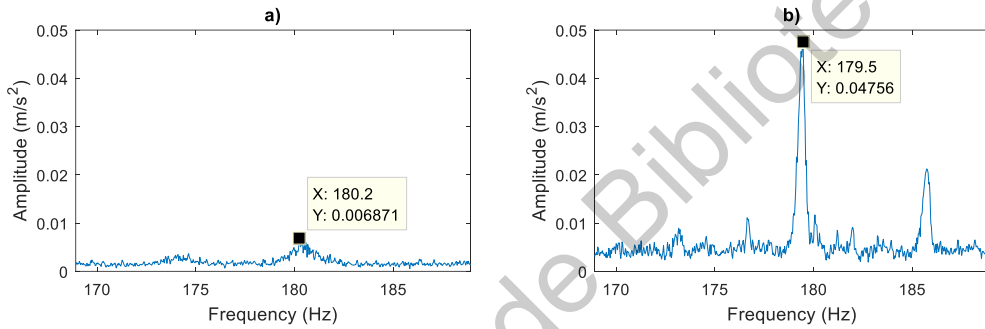


Figura 92.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a *BPFO*)

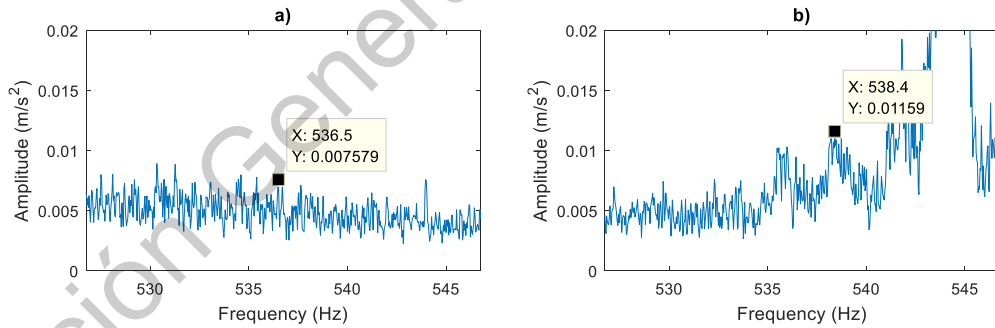


Figura 93.- Espectro de frecuencias del eje Y a 60 Hz de rodamientos híbridos a) HLT-H b) BD-H (acercamiento a  $3xBPFO$ )

# Capítulo V

## 5 Conclusiones

En este trabajo se desarrolló una metodología que permite detectar y clasificar fallas cadenas cinemáticas mediante el uso de la caracterización de señales de vibración mediante indicadores estadísticos, la técnica de reducción de dimensión PCA en conjunto con el método heurístico de clasificación de redes neuronales. Sin embargo, las pruebas realizadas se centraron en el análisis de fallas en la pista externa de rodamientos metálicos, cerámicos e híbridos, donde el motor de inducción en el que estaban montados operaba a diferentes frecuencias de rotación por prueba.

El método desarrollado es un híbrido entre software y hardware, ya que en el primero se lleva a cabo el cálculo de la matriz de transformación que maximiza la varianza entre un conjunto de datos, lo cual es realizado por la técnica de PCA; además en software también se ejecuta el proceso de entrenamiento de las redes neuronales, consiguiendo así los valores de los pesos y bias para cada capa. Luego entonces, en hardware se importan estos datos y se realiza la evaluación de una señal de entrada sin tener que pasar por todo un proceso de reentrenamiento.

Los resultados obtenidos fueron buenos, ya que en todos los casos la varianza acumulada entre los dos primeros componentes principales superó el 85%, lo cual ya es un valor aceptable, incluso algunos de ellos se acercaban al 100%. En cuanto a las redes neuronales, debido a que por medio de PCA se había llevado a cabo una buena agrupación de datos relacionados, el clasificador no fue necesario realizarlo tan complejo, obteniendo aun así porcentajes de entrenamiento y validación en la mayoría de los casos cercanos al 100%

Además se comprobó la efectividad del método en una base de datos diferente, donde las fallas evaluadas fueron otras, incluso se llegó a clasificar la severidad de algunas fallas, mostrando así que el método funciona, además es aplicable para la identificación y clasificación de una mayor cantidad de fallas.

En lo que respecta a la parte del análisis en el dominio de la frecuencia, se pudo observar que es difícil obtener un diagnóstico de los rodamientos empleando solamente este método,

sobre todo a frecuencias de operación bajas, además de que se debe de conocer el comportamiento esperado de la falla en específico para poder identificarlo.

## 6 Prospectivas

Como prospectiva, se podrían agregar más condiciones de prueba, es decir más condiciones de fallo de la cadena cinemática para su discriminación con fallas en baleros, tales como desalineamiento, barras rotas, desbalance, fallas en engranes, etc.; esto con la finalidad de obtener una mayor información respecto al estado general de la cadena cinemática, además se podrían agregar más indicadores estadísticos que ayuden a una mejor caracterización de la señal o incluso eliminar algunos otros que se demuestre no brindan información relevante que indique la presencia de fallas.

En lo que respecta a la implementación, se puede optimizar la descripción en *vhdl*, mejorando las estructuras de los bloques para aprovechar de mejor manera los recursos de las tarjetas FPGA, además, como se mencionó anteriormente se pueden reducir la cantidad de indicadores estadísticos si se demuestra que no brindan suficiente información relevante, ya que este proceso es el que consume la mayor cantidad de recursos y de tiempo. Además, el próximo paso a seguir es, después de optimizarlo, realizar la sintetización en FPGA y lo ideal sería que funcionara en línea, que si bien no sería un diagnóstico en tiempo real, ya que el cálculo de indicadores requiere un conjunto de datos previos, permitiendo obtener un diagnóstico continuo sobre el estado de la cadena cinemática.

Finalmente, para realizar una comparación entre los tres tipos de rodamientos utilizando análisis frecuencial es necesario mejorar el método utilizado, realizando un mayor procesamiento de las señales, para así disminuir la cantidad de ruido y otros factores que afectan este tipo de análisis. Si bien en este proyecto no fue el tema central de estudio y no arrojó los resultados esperados, sería interesante observar si es que existe un patrón de comportamiento que identifique a cada tipo de rodamiento.

## 7 Referencias

- Alsafasfeh, Q., Abdel-Qader, I., & Harb, A. (2010). *Symmetrical Pattern and PCA Based Framework for Fault Detection and Classification in Power Systems*. IEEE.
- Arvizu Torres, M., Moreno Ramírez, M. G., & González Rojano, N. (2007). *Manual de buenas prácticas de laboratorio. Publicación técnica CNM-MRD-PT-008*. Querétaro, México: CENAM.
- Cariño-Corrales, J. A., Saucedo-Dorantes, J. J., Zurita-Millán, D., Delgado-Prieto, M., Ortega-Redondo, J. A., Osornio-Rios, R. A., & Romero-Troncoso, R. (2016). *Vibration-Based Adaptive Novelty Detection Method for Monitoring Faults in a Kinematic Chain*. Hindawi Publishing Corporation.
- Chaouch, H., Ouni, K., & Nabli, L. (2017). *Industrial Process Defect Classification by Exploiting*. IEEE.
- Delgado Prieto, M. (2012). *Contributions to electromechanical systems diagnosis by mean data fusion techniques*. Universidad Politécnica de Cataluña.
- Euro bearings Spain. (2019). *Rodamientos Cerámicos*. Recuperado en Septiembre de 2019, de <https://www.eurobearings.es/rodamientos-ceramicos/>
- Fang Zhong, D. W., & Schuurman, D. C. (2008). *Parallel Architecture for PCA image feature detection using FPGA*. IEEE.
- García Gutierrez, J. A. (2016). *Comenzando con Weka: Filtrado y selección de subconjuntos de atributos basada en su relevancia descriptiva para la clase*. Universidad de Malaga.
- Jasinski, R. (2016). *Effective coding with VHDL : principles and best practice*. Massachusetts: Massachusetts Institute of Technology.
- Kang, M., Jeong, I., & Kim, J.-M. (2014). *Mult-Core Architecture for Real-Time and Energy-Efficient Bearing Fault Diagnosis*. Corea del Sur: University of Ulsan.

Kang, M., Kim, J., Jeong, I.-K., Kim, J.-M., & Pecht, M. (2016). *A Massively Parallel Approach to Real-Time Bearing Fault Detection Using Sub-Band Analysis on an FPGA-Based Multicore System. IEEE Transactions on Industrial Electronics, Vol. 63. N° 10.*

KOYO JTEK Corporation. (2010). *Manual de Rodamientos: Fallas en los rodamientos. Foll. 123 Sp.* Recuperado en Septiembre de 2019

Liu, H., & Setiono, R. (1996). A probabilistic approach to feature selection - a filter solution. *Proceedings of the thirteenth international conference on machine learning*, 319-327.

Motion and Control NSK. (2019). *Manual Rodamientos Híbridos con bola cerámica.* Recuperado el Septiembre de 2019, de <https://www.nskeurope.com>

NTN Corporation. (2004). *Rodamientos de Bolas y de Rodillos CAT. N° 2202-VII/S.* Recuperado en Octubre de 2019, de <http://www.elementosindustriales.com>

Ortech advanced ceramic. (2019). *Full Ceramic Bearings.* Recuperado en Septiembre de 2019, de <https://www.ortechceramics.com>

Picot, A., Rivière, J., & Maussion, P. (2018). *Bearing fault diagnosis based on the analysis of recursive PCA projections. IEEE.*

Rasmus, B., & Age, K. S. (2014). *Tutorial Review: Principal Component Analysis. Analytical Methods*, 2812-2831.

Ritbearing Corporation. (17 de Enero de 2014). *Common causes of bearing failure: Vol I & Vol II.* (W. Chris, Editor) Recuperado en Septiembre de 2019, de Ritbearing Corporation: <https://www.ritbearing.com>

Saucedo Dorantes, J. J. (2017). *Metodologías para mejorar la confiabilidad del diagnóstico de fallas en cadenas cinemáticas basado en algoritmos inteligentes y fusión de datos.* Universidad Autónoma de Querétaro.

Saucedo-Dorantes, J. J., Delgado-Prieto, M., Ortega-Redondo, J. A., Osornio-Rios, R. A., & Romero-Troncoso, R. (2016). *Multiple-Fault Detection Methodology Based on*

*Vibration and Current Analysis Applied to Bearings in Induction Motors and Gearboxes on the Kinematic Chain. Hindawi Publishing Corporation.*

Sharma, A., Jigyasu, R., Mathew, L., & Chatterji, S. (2018). *Bearing Fault Diagnosis Using Weighted K-Nearest Neighbor. Proceedings of the 2nd International Conference on Trends in Electronics and Informatics (ICOEI 2018).*

Shuang, L., & Meng, L. (2007). *Bearing Fault Diagnosis Based on PCA and SVM. International Conference on Mechatronics and Automation.*

Stief, A., Ottewill, J. R., Baranowski, J., & Orkisz, M. (2019). *A PCA and Two Stage Bayesian Sensor Fusion Approach for Diagnosing Electrical and Mechanical Faults in Induction Motors. IEEE Transactions on Industrial Electronics Vol.66 No 12.*

Theodoridis, S., & Koutroumbas, K. (2010). *An Introduction to Pattern Recognition: A MATLAB Approach.* Oxford: Academic Press.

Wan, X., Wang, D., Tse, P., & Zhang, Q. (2016). *A critical study of different dimensionality reduction methods for gear crack degradation assessment under different operating conditions. Measurement vol 78, 138-150.*

## 8 Apéndice

Vibration-based analysis of outer race fault effects on hybrid bearings used in induction motor; CONIIN 2020 XVI International Engineering Congress.