

MODELO PARA ANÁLISIS DE RIESGO EN LAS BOMBAS DEL SISTEMA DE
ENFRIAMIENTO MEDIANTE EL USO DE REDES NEURONALES

HOGO ALFREDO PÉREZ CALDERÓN

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRÍA EN GERENCIA DE MANTENIMIENTO
BUCARAMANGA

2017

MODELO PARA ANÁLISIS DE RIESGO EN LAS BOMBAS DEL SISTEMA DE
ENFRIAMIENTO MEDIANTE EL USO DE REDES NEURONALES

HOGO ALFREDO PÉREZ CALDERÓN

Trabajo de grado presentado como requisito para optar el título de
Magíster en Gerencia de Mantenimiento

Director

CARLOS BORRÁS PINILLA

Ph. D. Ingeniero Mecánico

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRÍA EN GERENCIA DE MANTENIMIENTO
BUCARAMANGA

2017

DEDICATORIA

A Dios por permitirme cumplir con esta nueva meta

*A mi esposa e hija por su constante apoyo y motivación
en el cumplimiento de mis objetivos personales*

A mis padres y hermanos por siempre estar prestos a colaborarme y apoyarme

A mi tía Viviana por su fortaleza en los tiempos difíciles.

AGRADECIMIENTOS

A la empresa Vidrio Andino S.A. por su apoyo en el desarrollo de este proyecto.

Al Ing. Carlos Borrás Pinilla, por su constante apoyo y motivación para realizar este proyecto bajo la óptica de la ingeniería y la practicidad, así como sus aportes y revisiones al desarrollo de este proyecto.

A mis compañeros de trabajo por su motivación y colaboración en el desarrollo de esta meta.

A todos los docentes de la Universidad Industrial de Santander, por su enseñanza durante el transcurso de la maestría.

Al ing. Edwin Quintero, por sus aportes al desarrollo de este proyecto

A mis compañeros de clase, por su entusiasmo y compañerismo.

TABLA DE CONTENIDO

	pág.
INTRODUCCIÓN	15
1. REDES NEURONALES ARTIFICIALES	17
1.1 GENERALIDADES	17
1.2 HISTORIA DE LAS REDES NEURONALES	18
1.3 FUNCIONAMIENTO DE UNA RED NEURONAL	22
1.4 ESTRUCTURA DE LAS REDES NEURONALES ARTIFICIALES.....	25
1.4.1 Redes Monocapa	26
1.4.2 Redes Multicapa	27
1.5 APRENDIZAJE DE LAS REDES NEURONALES.....	28
1.5.1 Entrenamiento Supervisado.....	29
1.5.2 Entrenamiento no supervisado	30
1.6 SELECCIÓN DE LA RED NEURONAL ARTIFICIAL	31
2. EL PERCEPTRÓN.....	33
2.1 PERCEPTRÓN SIMPLE	33
2.2 PERCEPTRÓN MULTICAPA.....	36
2.2.1 Arquitectura del perceptrón multicapa	36
2.2.2 Aprendizaje del perceptrón multicapa.....	37
3. ANÁLISIS DE VIBRACIONES	43
3.1 GENERALIDADES	43
3.2 CLASIFICACIÓN DE LAS VIRACIONES MECÁNICAS.....	44
3.3 VIBRACIONES SIMPLES	45
3.3.1 Características principales de las vibraciones simples	46

3.3.1.1 Frecuencia	46
3.3.1.2 Amplitud.....	46
3.3.1.3 Velocidad	46
3.3.1.4 Aceleración	47
3.3.1.5 Desplazamiento	47
3.3.1.6 Spike Energy.....	47
3.4 VIBRACIONES COMPUESTAS	48
3.5 VIBRACIONES ALEATORIAS O INTERMITENTES	49
3.6 TRANSFORMADA DE FOURIER.....	49
3.7 ANÁLISIS ESPECTRAL	52
3.8 ANÁLISIS DE PRINCIPALES FALLOS EN BOMBAS CENTRÍFUGAS.....	54
3.8.1 Fallos en rodamientos.....	54
3.8.1.1 Fallos en pista interna	55
3.8.1.2 Fallos en pista externa	56
3.8.1.3 Fallos en elementos rodantes	56
3.8.1.4 Fallos en la jaula	57
3.8.2 Fallos por lubricación inadecuada.....	58
3.8.3 Fallos por desalienación	58
3.8.3.1 Desalineación angular	58
3.8.3.2 Desalineación paralela.....	59
3.8.4 Fallas por soldaduras mecánicas.....	60
3.8.4.1 Tipo A.....	60
3.8.4.2 Tipo B.....	60
3.8.4.3 Tipo C	60
3.8.5 Problemas por cavitación.....	61
3.8.6 Fallos en rotor	62
3.8.7 Fallos en barras del motor	63
3.9 CRITERIOS DE EVALUACIÓN DE VIBRACIONES	64
4. DESARROLLO DEL MODELO	68

4.1 DEFINICIÓN DE PUNTOS DE MEDICIÓN.....	68
4.2 DEFINICIÓN DE VARIABLES	69
4.3 RECOPIACIÓN DE LA INFORMACIÓN	70
4.4 DESCRIPCIÓN DE FALLOS	71
4.5 DESCRIPCIÓN DE CATEGORÍAS.....	71
4.6 DESCRIPCIÓN DE VARIABLES DE ENTRADA	72
4.7 RELACIÓN CATEGORIAS - FALLOS	73
4.8 ARQUITECTURAS DE RED NEURONAL.....	73
4.10 RED NEURONAL PERCEPTRÓN.....	73
4.11 RED NEURONAL <i>FEEDFORWARD</i>	75
4.12 ENTRENAMIENTO DE LAS REDES NEURONALES	76
4.13 ENTRENAMIENTO RED NEURONAL PERCEPTRÓN.....	76
4.14 ENTRENAMIENTO RED NEURONAL <i>FEEDFORWARD</i>	77
5. RESULTADOS.....	80
5.1 COMPARACIÓN DE LOS MODELOS DESARROLLADOS	80
5.2 ANÁLISIS DE RESULTADOS.....	81
5.3 VALIDACIÓN DEL MODELO.....	83
6. CONCLUSIONES	89
BIBLIOGRAFÍA.....	92

LISTA DE FIGURAS

	pág.
Figura 1. Red neuronal.	24
Figura 2. Redes monocapa.....	26
Figura 3. Redes multicapa.	27
Figura 4. Clasificación del perceptrón simple.	34
Figura 5. Arquitectura del perceptrón simple.	35
Figura 6. Proceso de aprendizaje.	35
Figura 7. Arquitectura perceptrón multicapa	36
Figura 8. Función sigmoidal.....	38
Figura 9. Función tangente hiperbólica.....	38
Figura 10. Sistema de vibración simple.	45
Figura 11. Parámetros de vibración.	47
Figura 12. Vibración compuesta.	48
Figura 13. Vibración aleatoria o intermitente,	49
Figura 14. Transformación de señales mediante Fourier.....	52
Figura 15. Análisis espectral amplitud - frecuencia.....	53
Figura 16. Frecuencias de deterioro de rodamientos.....	55
Figura 17. Espectro fallo pista interna.....	55
Figura 18. Espectro fallo pista externa.....	56
Figura 19. Espectro fallo elementos rodantes.....	57
Figura 20. Espectro fallo en la jaula.....	57
Figura 21. Desalineación angular.	59
Figura 22. Desalineación paralela.....	59
Figura 23. Espectros soldadura mecánica.....	61
Figura 24. Espectro por problemas de cavitación.....	62
Figura 25. Espectro por fallos en rotor.....	63

Figura 26. Fallos en barras del motor.	64
Figura 27. Clasificación equipos Norma ISO 10816-3.	66
Figura 28. Puntos de medición definidos.	69
Figura 29. Arquitectura red neural perceptrón.	75
Figura 30. Funciones de activación de la red Multicapas.	76
Figura 31. Evolución del entrenamiento red neuronal Perceptrón.	77
Figura 32. Arquitectura red neuronal feedforward.....	78
Figura 33. Evolución del entrenamiento red neuronal Feedforward.....	78
Figura 34. Evolución del error cuadrático en el entrenamiento.	79
Figura 35. Error por patrón de entrenamiento – red neuronal Perceptrón.	82
Figura 36. Error por patrón de entrenamiento – red neuronal Feedforward.....	83
Figura 37. Test 1.....	85
Figura 38. Test 2.....	85
Figura 39. Test 3.....	86
Figura 40. Test 4.....	86
Figura 41. Test 5.....	87
Figura 42. Test 6.....	87
Figura 43. Test 7.....	88
Figura 44. Test 8.....	88

LISTA DE TABLAS

	pág.
Tabla 1. Tipos de redes neuronales.....	32
Tabla 2. Clasificación equipos Norma ISO 10816-3.	65
Tabla 3. Convención de colores Norma ISO 10816-3.....	67
Tabla 4. Definición de variables.	69
Tabla 5. Mediciones del motor.	70
Tabla 6. Mediciones de la bomba.	70
Tabla 7. Descripción de fallos.	71
Tabla 8. Categorías de fallas.	72
Tabla 9. Variables de entrada.	72
Tabla 10. Relación categorías-fallos.	73
Tabla 11. Patrones de falla.	74
Tabla 12. Comparativo de las redes modelo.	81
Tabla 13. Datos validación red Feedforward.	84
Tabla 14. Resumen modos de fallo y categorías.	84

RESUMEN

TÍTULO: MODELO PARA ANÁLISIS DE RIESGO EN LAS BOMBAS DEL SISTEMA DE ENFRIAMIENTO MEDIANTE EL USO DE REDES NEURONALES.¹

AUTOR: HUGO ALFREDO PÉREZ CALDERÓN.²

PALABRAS CLAVES: RED NEURONAL, PERCEPTRÓN, PERCEPTRÓN MULTICAPA, RED FEEDFORWARD, ANÁLISIS DE VIBRACIONES, ESPECTROS.

DESCRIPCIÓN O CONTENIDO:

En el presente trabajo se desarrolla un modelo basado en redes neuronales artificiales para diagnosticar fallas en los componentes de las bombas del sistema de enfriamiento dada su importancia dentro de la planta de producción de vidrio plano, utilizando como información de entrada a la red valores medidos tanto en el motor como en la bomba, mediante la técnica predictiva de análisis de vibraciones mecánicas.

Se desarrollan dos modelos uno basado en el perceptrón y el otro en la red feedforward; posterior a esto se comparan y aunque los resultados con ambas redes son satisfactorios se valida patrones con la red neuronal feedforward por tener un mejor comportamiento durante las fase de desarrollo y presentar menos errores en comparación con la otra red, llegando a demostrar la efectividad de las redes neuronales en el diagnóstico de fallos y la importancia que tiene el uso de este tipo de metodologías para mejorar a confiabilidad, disponibilidad y mantenibilidad de los equipos, por ende los resultados en los indicadores de las áreas de mantenimiento, confirmando que las redes neuronales artificiales son un poderosa herramienta en el seguimiento, diagnóstico e inclusive la predicción de fallos en equipos, abriendo una gran puerta al uso de técnicas modernas en la planeación estratégica de las áreas de mantenimiento, con el fin de atender con criterios de alta ingeniería las nuevas tecnologías instaladas en los diferentes procesos productivos.

¹ Trabajo de grado.

² Facultad de Ingenierías Físico Mecánicas. Escuela de Ingeniería Mecánica. Maestría en Gerencia de Mantenimiento. Director: Carlos Borrás Pinilla, PhD. Ingeniero Mecánico.

SUMMARY

TITLE: MODEL FOR THE RISK ANALYSIS IN THE PUMPS OF THE COOLING SYSTEM USING NEURAL NETWORKS.³

AUTHOR: HUGO ALFREDO PÉREZ CALDERÓN. ⁴

KEYWORDS: NEURONAL NETWORK, PERCEPTRON, MULTILAYER PERCEPTRON, RED FEEDFORWARD, VIBRATION ANALYSIS, SPECTROS.

DESCRIPTION OR CONTENTS:

In the present work a model based on artificial neural networks is developed to diagnose faults in the components of the cooling system pumps given their importance within the flat glass production plant, using as input to the network measured values both in the motor as in the pump, by means of the predictive technique of mechanical vibration analysis.

Two models are developed, one based on the perceptron and the other on the feedforward network; after this, they are compared and although the results with both networks are satisfactory, patterns with the feedforward neural network are validated for having a better behavior during the development phase and presenting fewer mistakes compared to the other network, reaching to demonstrate the effectiveness of the neural networks in the diagnosis of failures and the importance of the use of this type of methodologies to improve the reliability, availability and maintainability of the equipment, therefore the results in the indicators of maintenance areas, confirming that artificial neural networks are a powerful tool in the monitoring, diagnosis and even the prediction of failures in equipment, opening a great door to the use of modern techniques in the strategic planning of the maintenance areas, in order to meet with high engineering criteria the new technologies installed in the different production processes.

³ Work of degree.

⁴ Faculty of Engineering Physics and Mechanics. Mechanical Engineering School. Mastery in Maintenance Management. Director: Carlos Borrás Pinilla, PhD. Mechanical Engineer.

INTRODUCCIÓN

Dentro de la planta de producción de vidrio hay varias zonas o áreas críticas, una de ellas es la correspondiente a utilidades o área de equipos auxiliares y dentro de esta está el sistema de enfriamiento por agua, conformado básicamente por un tanque acumulador, bombas, líneas de conducción a cada equipo, torres de enfriamiento, es considerado un sistema cerrado, cualquier falla en este sistema puede llegar a ser muy catastrófico para los equipos ubicados en áreas de alta temperatura de la planta.

Las bombas objeto de estudio del presente proyecto toman agua del tanque acumulador del sistema cerrado y la envían al interior de la planta para refrigerar los equipos que intervienen dentro del proceso productivo, son consideradas equipos muy críticos y a pesar que son objeto de intervenciones preventivas y predictivas, no se tienen dentro de un programa que permita mediante una técnica avanzada de mantenimiento poder monitorearlas y diagnosticar fallos para poder anticipar y programar las respectivas intervenciones, mejorando la confiabilidad, disponibilidad y mantenibilidad, incidiendo sobre la estabilidad del proceso y la gestión del departamento de mantenimiento de la planta.

Es por esto que el presente trabajo busca desarrollar un modelo computacional basado en redes neuronales que permita diagnosticar fallos que pueden llegar a ocurrir en las bombas del sistema de enfriamiento, tomando como base los valores tomados dentro de las rutas predictivas de análisis de vibraciones mecánicas, igualmente se pretende dar los primeros pasos en la aplicación de técnicas muy avanzadas para el diagnóstico de fallos en los equipos importantes de la línea de producción de vidrio plano.

Este trabajo pretende demostrar una vez más la aplicación de las redes neuronales en el diagnóstico de fallas en equipos, contribuyendo a la expansión de este tipo de técnicas en la gestión de mantenimiento, generando un documento de consulta y referencia para aplicaciones similares en otros procesos productivos, abrir la puerta a que otros profesionales de las diferentes áreas de mantenimiento conozcan e inicien a utilizar esta u otras técnicas avanzadas como herramientas que permitan incrementar la confiabilidad, tener mayores disponibilidades y mejorar la mantenibilidad de los equipos de sus planta productivas.

El desarrollo del trabajo se realiza mediante la investigación, recopilación, selección y análisis de la teoría expuesta tanto en libros, tesis o monografías y artículos tomados de internet relacionados con la aplicación de redes neuronales que mejor se ajusten a los objetivos y plan de trabajo del presente proyecto, de igual forma se toma como base la teoría sobre análisis de vibraciones mecánicas por ser la información o tomar para alimentar el modelo de redes neuronales.

Para la información de las variables a tomar como entrada a la red, se utilizará el histórico de las mediciones de vibraciones realizadas en las bombas del sistema de enfriamiento que permitan poder identificar a la salida parámetros de diagnóstico y detección de posibles fallos en estos equipos.

Luego de concluir mediante el análisis de la teoría recopilada, la mejor opción a seguir se realizará el algoritmo de entrenamiento y supervisión, definiendo la estructura de la red que mejor se acomode a las necesidades planteadas y apoyados en el software Matlab se realizará las respectivas simulaciones para probar la eficacia de la red.

1. REDES NEURONALES ARTIFICIALES

1.1 GENERALIDADES

Las redes neuronales artificiales o inteligencia artificial están inspiradas en el funcionamiento biológico del cerebro humano siendo hasta ahora el sistema más complejo conocido por el hombre, a través de la historia ha sido motivo de inspiración de muchos científicos, el entender y poder copiar o modelar la capacidad que tiene el cerebro de recordar, pensar, resolver problemas procesando gran cantidad de información proveniente de los sentidos a una alta velocidad, comparándola con información almacenada para dar respuestas adecuadas a situaciones o problemas, cabe resaltar la capacidad que tiene el cerebro para aprender a representar la información necesaria para desarrollar tales habilidades, sin instrucciones explícitas para ello.⁵

En esa carrera por llegar a simular las funciones del cerebro, los científicos inician con la invención de las computadoras las cuales han sido pilar fundamental en el desarrollo y aplicación de las redes neuronales, ya que han permitido su aplicación en diversos campos como la ingeniería, economía, la predicción del estado del clima, facilitando el desarrollo de complejos sistemas de cálculo en un corto tiempo, de esta manera las redes neuronales son un sistema computacional muy avanzado inspirado en el cerebro humano, siendo estas una parte fundamental en el desarrollo de la inteligencia artificial, tienen la bondad de poderse combinar con otras técnicas como la lógica difusa, algoritmos.⁶

⁵ LIU, Jinkun. Radial Basis Function (RBF) Neural Network Control for Mechanical Systems. Berlín, Alemania: Springer-Verlag, 2013. 365 p. ISBN 978-3642-43455-6.

⁶ OROZCO, David. Aproximación del uso de redes neuronales en mantenimiento. [En línea]. Trabajo de Grado Maestría en Ingeniería. Medellín: Universidad EAFIT. Escuela de Ingeniería. Departamento de Ingeniería Mecánica, 2013. 151 p.

1.2 HISTORIA DE LAS REDES NEURONALES

Las redes neuronales nacen con la necesidad que tiene el hombre de resolver situaciones complejas donde trata de simular el funcionamiento del cerebro en cuanto procesamiento de gran cantidad de información, los primeros en dar explicaciones teóricas sobre el cerebro y el pensamiento fue Platón (427 – 347 A.C.) al igual que Aristóteles (348 – 422 A.C.) y Descartes (1569 – 1650), desde entonces el hombre ha seguido investigando y dando los primeros pasos en la denominada inteligencia artificial.

Pasando a tiempos más recientes se le atribuye a Alan Turing (1936) los primeros estudios del cerebro como una unidad computacional.

En 1943 el neurofisiólogo y el matemático Warren McCulloch y Walter Pitts elaboran las primeras teorías de los fundamentos de la computación y lanzan una teoría acerca de la forma en que las neuronas trabajan, modelando una red neuronal simple mediante circuitos eléctricos, siendo la base para los estudios posteriores como son los ordenadores Digitales (John Von Neuman), la Inteligencia Artificial (Marvin Minsky con los Sistemas Expertos) y el funcionamiento del ojo (Frank Rosenblatt con la famosa red llamada Perceptron).

Pasando a 1949 el Fisiólogo Donald Hebb escribió el libro “The Organization of Behavior” siendo el primero en explicar los procesos del aprendizaje, basándose en investigaciones psicofisiológicas introduce dos conceptos: el aprendizaje se localiza en las sinapsis o conexiones entre neuronas y la información es representada en el cerebro mediante un conjunto de neuronas activas o inactivas actualmente es el fundamento de la mayoría de las funciones de aprendizaje utilizadas en una red neuronal, el trabajo realizado por este fisiólogo forma las bases de la teoría de las redes neuronales, la principal regla dada por Hebb dice que los cambios en los pesos de las sinapsis se basan en la interacción entre las neuronas pre y

postsinapsitcas o básicamente concluye que el aprendizaje ocurre cuando ciertos cambios en una neurona eran activados.⁷

1950 - Karl Lashley. En sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro sino que era distribuida encima de él.

La primera máquina de redes neuronales es montada por Minsky y Edmons en 1951, la cual constaba principalmente de 300 tubos de vacío y un piloto automático de un avión bombardero, esta máquina fue llamada "Sharc" siendo una red que constaba de 40 neuronas artificiales que imitaban al cerebro de una rata.

Minsky, Mccarthy, Rochester, Shanon organizaron la primera conferencia de inteligencia artificial en el año de 1956, esta conferencia se desarrolló en la localidad Inglesa de Darmouth, y es conocida como el nacimiento de la inteligencia artificial, durante esta conferencia el grupo de investigación de IBM encabezado por Nathaural Rochester presentó un modelo de una red neuronal y puede considerarse como el primer software de simulación de redes neuronales artificiales.

Sin duda una de las etapas más importantes dentro de la historia de las redes neuronales artificiales se da con Frank Rosenblatt (1957) quien presentó una red neuronal con autoaprendizaje supervisado llamado Perceptron, tiene como fundamento una regla de aprendizaje planteada por Hedd, el perceptrón es conocido como la red neuronal más antigua con capacidad de identificar patrones geométricos y abstractos, Este modelo es capaz de generalizar es decir después de haber aprendido una serie de patrones podría reconocer otros similares aunque no se le hubiesen presentado en el entrenamiento. El primer perceptrón era capaz

⁷ BALLESTEROS, Alfonso. Neural Networks Framework. [En línea]. [Consultado el: 20 de enero de 2017]. Disponible en: <http://www.redes-neuronales.com.es/index.htm>

de aprender algo y era robusto, de forma que su comportamiento variaba sólo si resultaban dañados los componentes del sistema. Además presentaba la característica de ser flexible y comportarse correctamente después de que algunas celdas fueran destruidas. Sin embargo, tenía una serie de limitaciones, identificadas años más tarde por Minsky y Papert, por ejemplo, su incapacidad para resolver el problema de la función OR-exclusiva y en general, era incapaz de clasificar clases no separables linealmente. Aunque a lo largo de la década de los 60 se han realizado notorios cambios y se desarrollaron sistemas multicapa que pueden aprender y categorizar datos complejos.

Entre 1959 – 1960 Bernard Widrow desarrolla la teoría sobre la adaptación neuronal o elemento adaptativo lineal llamado “Adaline” y “Madaline”. Inicialmente fueron utilizadas en distintas aplicaciones como reconocimiento de voz y caracteres, predicción del tiempo, en realidad es la primera aplicación de las redes a problemas reales

A mediados de los años 60 Marvin Minsky y Seymour Papert, realizaron estudios profundos sobre la aplicabilidad del perceptrón concluyendo que dada su naturaleza lineal tenía bastantes limitaciones, probando matemáticamente que el perceptrón no era capaz de resolver problemas relativamente fáciles y pudieron demostrar que el perceptrón era débil pues las funciones no lineales son extensamente aplicadas en computación, además de la imposibilidad de resolver problemas del mundo cotidiano. Como resultado de este trabajo publicaron el libro llamado “Perceptrón”, prácticamente sentenciaron la caída y muerte de la aplicación y estudio de las redes neuronales artificiales.

Sin embargo en la década de los 70 Paul Werbos da una voz de aliento a las redes neuronales artificiales mediante el desarrollo de la idea básica del algoritmo de aprendizaje hacia atrás o Backpropagation como es conocido actualmente esta teoría quedó definitivamente aclarada en 1985. De la misma manera Teuvo

Kohonen de la universidad de Helsinki mediante un profundo estudio aporta principalmente dos fundamentos sobre las reglas adaptativas en las que las conexiones ponderadas se modifican de una forma dependiente de los valores anteriores y posteriores y el otro principio tiene que ver con el aprendizaje competitivo, en el cual los elementos compiten por responder a un estímulo de entrada siendo el ganador quien se adapta a sí mismo para responder con mayor efecto al estímulo. Durante esta década también fue expuesta la teoría de resonancia adaptada por Stephen Grossberg (1977) siendo una red diferente a todas las demás, simulando otras habilidades del cerebro por ejemplo la de memoria a corto y largo plazo, Grossberg basa sus postulados en estudios fisiológicos del cerebro, utilizó datos de la neurología para construir modelos de computación neuronal.⁸

Durante los años 80 a John Hopfield se le atribuye el renacimiento de las redes neuronales con la publicación del libro "Computación Neuronal de Decisiones en Problemas de Optimización" además se le atribuye la invención del algoritmo de Backpropagation tomando como base los estudios realizados por Paul Werbos en la década anterior, devolviendo al mundo científico el interés por el estudio y la aplicación de las redes neuronales, fundamentalmente Hopfield presenta un sistema de computación neuronal con elementos procesadores interconectados trabajando a un mínimo de energía, este trabajo es sin duda el aporte actual más importante que se ha dado a las redes neuronales artificiales y es la base de los estudios modernos.⁹

⁸ MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. [En línea]. Rosario, Argentina: Universidad Tecnológica Nacional. Facultad Regional Rosario. Departamento de Ingeniería Química, 2001. 55 p. [Consultado el: 25 de febrero de 2017]. Disponible en: https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora/1/monograis/matich-redesneuronales.pdf

⁹ BASOGAIN, Xabier. Redes neuronales artificiales y sus aplicaciones. [En línea]. Bilbao: El autor. 79 p. [Consultado el: 5 de febrero de 2017]. Disponible en: http://www.ciberesquina.una.edu.ve:8080/2014_2/350_E.pdf

En la actualidad son muchos los grupos de trabajo alrededor del mundo que buscan seguir aportando al estudio y aplicación de las redes neuronales, las grandes empresas de tecnología las están utilizando para reconocimiento de patrones, sistemas de control, simuladores, predicciones de variables económicas, predicción de las condiciones del clima, entre otras.¹⁰

Pasando al campo del mantenimiento en los últimos años los ingenieros e investigadores han encontrado en las redes neuronales un gran apoyo y herramienta, mediante el uso de los diferentes tipos de redes o algoritmos se puede llegar a diagnosticar o predecir fallos en equipos por consiguiente aumentar la disponibilidad, mantenibilidad y confiabilidad de los sistemas, impactando directamente sobre los indicadores de las áreas de mantenimiento y por consiguiente la rentabilidad de las empresas.¹¹

1.3 FUNCIONAMIENTO DE UNA RED NEURONAL

Al igual que el cerebro donde hay millones de neuronas interconectadas entre sí, organizadas en circuitos microscópicos que a su vez se ordenan en sistemas sucesivos cada vez más grandes y complejos donde la función principal es captar y procesar rápidamente las señales o estímulos recibidos de las diferentes fuentes de entrada generalmente son señales recibidas de sensores en el caso de sistemas biológicos corresponderían a los órganos de los sentidos, posterior a esto vendría el tratamiento de la información, la comparación contra unos patrones ya establecidos y posteriormente una salida o decisión.

¹⁰ FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

¹¹ BALLESTEROS, Alfonso. Neural Networks Framework. [En línea]. [Consultado el: 20 de enero de 2017]. Disponible en: <http://www.redes-neuronales.com.es/index.htm>

Sin duda la parte fundamental es la neurona la cual se puede definir como la unidad básica fundamental encargada de excitarse con algún tipo de impulso eléctrico permitiendo no solo la recepción de los estímulos sino también la conducción de estos entre las propias neuronas de forma que se produzca una acción o reacción a los impulsos de entrada, a nivel biológico básicamente en las neuronas se puede distinguir tres partes: cuerpo celular, el axón y las dendritas, la unión o sinapsis de las neuronas forman complejas redes con capacidad de comunicarse de una forma muy precisa y a una alta velocidad.¹²

Cada neurona percibe por medio del cuerpo celular los diferentes impulsos transmitiéndolos por una parte alargada llamada axón al final de este son transmitidas a la siguiente neurona por medio de las dendritas, la neurona receptora puede recibir señales provenientes de una o muchas sinapsis combinándolas consiguiendo un cierto nivel de estimación o potencial, emitiendo unos impulsos o señales eléctricas con una intensidad determinada llamada tasa de disparo.

El funcionamiento de una red neuronal artificial es muy similar a las redes neuronales biológicas, los científicos a lo largo del tiempo han tratado de copiar su funcionamiento y por medio de complejos algoritmos han logrado llegar a modelos que copian y se comportan como las redes neuronales biológicas.¹³

De forma similar en las redes neuronales artificiales la principal unidad se puede llamar neurona artificial siendo esta una unidad procesadora con posibilidad de

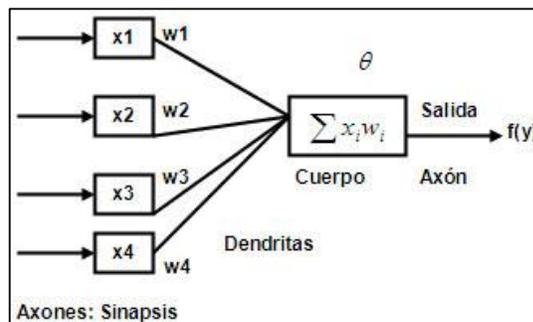
¹² BORRÁS PINILLA, Carlos. Pattern recognition in hydraulic cylinders with backlash using neural network. Tesis de maestría. Oklahoma: University of Oklahoma. School of Aerospace and Mechanical Engineering, 2001, 113 p.

¹³ MUHAMAD, Abd Kadir; SHARIFAH, Saon y HIYAMA, Takashi. Predicting remaining useful life of rotating machinery based artificial neural network. [En línea]. En: ELSEVIER, Computer and Mathematics with Applications, 2010, vol. 60, no. 4, pp. 1078 - 1087. [Consultado el: 28 de enero de 2017]. Disponible en: <https://core.ac.uk/download/pdf/82394785.pdf>

combinar muchas entradas sumadas entre sí, siendo modificada por medio de una función de transferencia para pasar directamente a la entrada de otra neurona si es necesario.

Cada neurona artificial consta de una serie de entradas X_i siendo equivalentes a las dendritas en las neuronas biológicas de donde se reciben los pulsos de entrada ponderadas por unos pesos W_i , los cuales representan como los impulsos de entrada son evaluados y combinados con la función de la red dando los niveles de potencial de la neurona, las entradas X_i son valores que pueden ser enteros, reales o binarios, los pesos que hay en las sinapsis W_i equivalen a los mecanismos para transmitir las señales y la unión de X_i con W_i equivale a las señales excitadoras que se dan en la sinapsis y que inducen a la neurona a cambiar su comportamiento.¹⁴

Figura 1. Red neuronal.



Fuente: MARADEY, Jessica; BORRÁS, Carlos y ROA, Sebastián. A Survey of Approaches For Fault Diagnosis In Axial Piston Pumps. ASME 2016 – International Mechanical Engineering Congress and Exposition (4: 11, noviembre, 2016: Tampa, USA: ASME). Tampa, USA: ASME, 2016, pp. 52-65.

¹⁴ BORRÁS PINILLA, Carlos. Material docente de la asignatura Técnicas Avanzadas en Mantenimiento. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Físico-mecánicas, Escuela de Ingeniería Mecánica. Maestría en Gerencia de Mantenimiento, 2016. 194 p.

Estas señales son la entrada de la función de ponderación llamado típicamente el potencial que en la neurona biológica equivale al total de señales que le llegan a la neurona por las dendritas, la función de ponderación es conocida como la suma de las entradas y los sinápticos.

Realizando una comparación entre los sistemas biológicos y los artificiales, las neuronas biológicas equivales a las neuronas artificiales, las conexiones sinápticas equivales a las conexiones ponderadas, la efectividad de la sinapsis biológica equivale al peso de las conexiones, el efecto excitador de una conexión equivale en el sistema artificial al signo de peso de una conexión, el efecto combinado de la sinapsis es equivalente a la función de propagación y la activación es igual en las redes artificiales a la salida.

En resumen si se aplica un conjunto de entradas a una neurona cada una de las cuales puede ir a la entrada de otra neurona multiplicando cada una por un respectivo peso ponderación, todas las entradas se sumarian determinando el nivel de excitación o activación de la neurona esto se puede expresar matemáticamente mediante la siguiente ecuación:

$$S = X * W$$

Dónde:

S = Salida

X = Es el vector de entrada

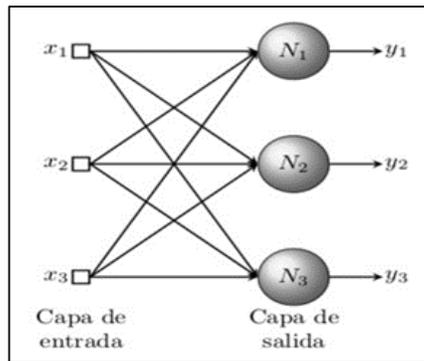
W = Vector de peso

1.4 ESTRUCTURA DE LAS REDES NEURONALES ARTIFICIALES

La distribución de las neuronas dentro de la red neuronal básicamente se realiza por medio de capas o niveles formando así redes monocapa o redes multicapa.

1.4.1 Redes Monocapa. Las redes neuronales monocapa son las redes más simples, para unirse las neuronas crean conexiones laterales para conectar con las demás neuronas de la capa, las redes más representativas dentro de este grupo están la red Hopfield, la red de memoria asociativa, también se encuentra las máquinas estocásticas de Botzmann y Cauchy, dentro de este grupo existen algunas que permiten que las neuronas tengan conexiones a sí mismas denominadas autorecurrentes.

Figura 2. Redes monocapa.

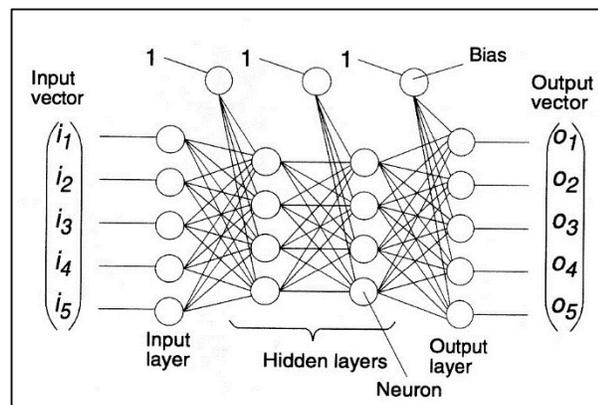


Fuente: MARADEY, Jessica; BORRÁS, Carlos y ROA, Sebastián. A Survey of Approaches For Fault Diagnosis In Axial Piston Pumps. ASME 2016 – International Mechanical Engineering Congress and Exposition (4: 11, noviembre, 2016: Tampa, USA: ASME). Tampa, USA: ASME, 2016, pp. 52-65.

Generalmente son utilizadas en circuitos eléctricos, por su tipología son adecuadas para que sean implementadas mediante hardware utilizando matrices de diodos que sirven para ver las conexiones entre neuronas

1.4.2 Redes Multicapa. Son las redes más utilizadas por su capacidad de cálculo, su potencia computacional proviene de las múltiples conexiones que pueden existir entre las neuronas de las diferentes capas, están formadas por varias capas o niveles de neuronas imitando la configuración existente en el cerebro, usualmente las capas están ordenadas por el orden en que reciben la señal desde la entrada hasta la salida formando capas simples en cascada la salida de una capa es la entrada de la siguiente capa, normalmente las redes con múltiples capas son más complejas y más grandes pero en contraprestación ofrecen mejor desempeño en el cálculo computacional comparadas con las redes monocapa.

Figura 3. Redes multicapa.



Fuente: MARADEY, Jessica; BORRÁS, Carlos y ROA, Sebastián. A Survey of Approaches For Fault Diagnosis In Axial Piston Pumps. ASME 2016 – International Mechanical Engineering Congress and Exposition (4: 11, noviembre, 2016: Tampa, USA: ASME). Tampa, USA: ASME, 2016, pp. 52-65.

Dentro de las redes neuronales multicapa se pueden distinguir dos tipos de acuerdo a la conexión: las redes con conexiones hacia adelante o redes feedforward, algunos ejemplos de estas son el perceptrón, adaline, madaline, backpropagation, los modelos LQV y TMP de Kohonen y las redes de conexiones tanto hacia adelante

como atrás o feedforward/feedback, dentro de estas están: las redes ART, bidireccional associative memory y la red cognitron, entre otras.¹⁵

1.5 APRENDIZAJE DE LAS REDES NEURONALES

Dentro de los procesos más importantes desarrollados dentro de una red neuronal artificial se encuentra el proceso de aprendizaje o entrenamiento el cual básicamente busca conseguir que la red aprenda a calcular la salida correcta para cada valor de entrada, el proceso de aprendizaje de una red es muy similar al proceso de aprendizaje o desarrollo intelectual de los seres humanos, donde se reciben una serie de condiciones o reglas que equivalen a las entradas de la red para que sean grabadas y posteriormente utilizadas al momento de tomar una correcta decisión respecto a un nuevo valor, parámetro o situación de entrada.

Obligatoriamente las redes neuronales requieren unos valores que sirvan de base para su entrenamiento o aprendizaje y mediante una serie de algoritmos son procesados y grabados para la toma de futuras decisiones.¹⁶

El proceso de entrenamiento consiste en la aplicación secuencial de conjuntos de valores o datos de entrada los cuales son llamados patrones o muestra de entrenamiento, con esta información se van ajustando los pesos de las sinapsis según el tipo de algoritmo utilizado los cuales son basados en fórmulas matemáticas, durante esta serie de operaciones los pesos cambian gradualmente hacia los valores que se requieren como salida deseada ajustándose hasta obtener

¹⁵ BORRÁS PINILLA, Carlos y STALFORD, Harold. Pattern recognition in hydraulic backlash using neural network. En: Proceedings of the 2002 American Control Conference (1: 8-10, mayo, 2002: Anchorage, USA). Anchorage, USA: IEEE, 2002, pp. 400-405.

¹⁶ BALLESTEROS, Alfonso. Neural Networks Framework. [En línea]. [Consultado el: 20 de enero de 2017]. Disponible en: <http://www.redes-neuronales.com.es/index.htm>

los valores deseados,¹⁷ los algoritmos ejecutan los patrones de forma iterativa cambiando los pesos hasta que convergen a un conjunto de pesos óptimos que representan las respuestas correctas al conjunto de patrones de entrenamiento que se la ha dado.¹⁸

Se puede considerar que el proceso de aprendizaje es satisfactorio o ha terminado cuando los valores de los pesos permanecen estables después de realizar varias iteraciones.

Los procedimientos de aprendizaje de acuerdo al tipo de algoritmo se clasifican en dos: supervisados y no supervisados.

1.5.1 Entrenamiento Supervisado. Este tipo de entrenamiento consiste en presentar un vector de entrada a la red, luego se calcula la salida, se compara contra el valor deseado, el error o diferencia presentada se utiliza para retroalimentarla, cambiando los pesos según el algoritmo utilizado hasta que el valor del nuevo error tienda a cero, dicho en otras palabras en el entrenamiento supervisado se realiza mediante un supervisor o agente externo el cual se utiliza para determinar la respuesta que debería generar la red tan pronto se aplica un valor determinado a la entrada.

La función principal del supervisor es comparar el valor dado por la red contra el valor verdadero, cuantificar la diferencia y proceder a modificar los pesos de las conexiones hasta conseguir que la nueva salida se aproxime a la salida, realiza este

¹⁷ FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

¹⁸ HAGAN, Martin, et al. Neural Network Design, Second Edition. Oklahoma, USA: El autor, 2014. 1012 p. ISBN 097-17321-1-6

procedimiento tantas veces hasta que la diferencia obtenida sea lo menor posible o esté dentro de los límites aceptados según el algoritmo o los resultados esperados.¹⁹

El aprendizaje supervisado se puede llevar a cabo mediante tres formas principales:

1. Aprendizaje por corrección de error
2. Aprendizaje por esfuerzo
3. Aprendizaje estocástico

1.5.2 Entrenamiento no supervisado. A diferencia de entrenamiento supervisado este tipo de entrenamiento no requiere que se muestren los patrones objetivo, para ver la salida, pues el algoritmo junto con la regla de modificación de las conexiones producen patrones de salida consistentes.

Estos modelos o algoritmos fueron desarrollados en 1984 por Kohonen, quien afirma que los modelos no supervisados no requieren de un vector o valor de salida deseado por consiguiente no se realiza ninguna comparación entre los valores de salida y los esperados, reduciendo el aprendizaje solo a los valores de entrada, los algoritmos utilizados para el entrenamiento modifican los pesos de la red de tal forma que en la salida se tengan valores consistentes a los esperados, es decir solo con el conjunto de patrones de entrada sin dar las características ni categorías posibles, la red es capaz de diferenciar ambas cosas y al final los valores o patrones los agrupa en categorías.²⁰

¹⁹ OVIEDO, Silvia; QUIROGA, Jabid y BORRÁS, Carlos. Experimental evaluation of motor current signature and vibration analysis for rotor broken bar detection in an induction motor. En: 2011 International Conference on Power Engineering, Energy and Electrical Drives (1: 11-13, mayo, 2011: Malaga, España). Malaga, España: IEEE, 2011, pp. 1 - 6.

²⁰ OVIEDO, Silvia; QUIROGA, Jabid y BORRÁS, Carlos. Motor current signature analysis and negative sequence current based stator winding short fault detection in an induction motor. En: DYNA. 2011, vol. 78, nro. 170, pp. 214 – 220. ISSN 0012-7353.

En la actualidad hay muchos tipos de algoritmos de entrenamiento no supervisado entre los más comunes están el aprendizaje por componentes principales y el aprendizaje competitivo los cuales extraen las propiedades estadísticas del conjunto de valores de entrada o entrenamiento y agrupa en clases los valores similares.

1.6 SELECCIÓN DE LA RED NEURONAL ARTIFICIAL

En el siguiente cuadro se muestran los principales algoritmos o redes neuronales artificiales más utilizadas en la actualidad en los sistemas de computación neuronal, se puede ver el tipo de red, su principal característica, el tipo al que pertenece y la clasificación según el aprendizaje; tal como se aprecia en la tabla 1.

Tabla 1. Tipos de redes neuronales.

TIPO DE RED	DISEÑADOR	CARACTERISTICA	AÑO	TIPO	APRENDIZAJE
Adaline madaline	Bernard Widrow	Técnicas de Adaptación para el Reconocimiento de Patrones	1960	Predicción	Supervisado
Adaptive Resonance Theory Networks (ART)	Carpenter, Grossberg	Reconocimiento de Patrones y Modelo del Sistema Neuronal. Concepto de Resonancia Adaptativa	1960 1986	Conceptualización	No supervisada
Back-Propagation	Rumelhart y Parker	Solución a las limitaciones de su red predecesora el Perceptron	1985	Clasificación	Supervisado
Bi-Directional Associative Memory (BAM) Networks	Bart Kosko	Inspirada en la red ART	1987	Asociación	No supervisada
Brain-State-in a Box	James Anderson	Red Asociativa Lineal	1970 1986	Asociación	No supervisada
Counter-Propagation	Hecht-Nielsen	Clasificación Adaptativa de Patrones	1987	Clasificación	No supervisada
Functional-link Networks (FLN)	Pao	Versión mejorada de la red Backpropagation	1989	Clasificación	Supervisado
Hopfield Networks	Hopfield	Concepto de la red en términos de energía	1982	Optimización	No supervisada
Learning Vector Quantization (LVQ) Networks	Kohonen	Red Clasificadora	1988	Clasificación	Supervisado
Perceptron Networks	Rosenblatt	Primer modelo de sistema Neuronal Artificial	1950	Predicción	Supervisado
Probabilistic Neural Network (PNN)	Spetcht	Clasificación de Patrones utilizando métodos estadísticos	1988	Asociación	Supervisado
Recirculation Networks	Hinton y McClelland	Alternativa a la red Backpropagation	1988	Filtrado	Supervisado
Self-Organizing Maps (SOM)	Kohonen	Aprendizaje sin supervisión	1979 1982	Conceptualización	No supervisada

Fuente: BASOGAIN, Xabier. Redes neuronales artificiales y sus aplicaciones. [En línea]. Bilbao: El autor. 79 p. [Consultado el: 5 de febrero de 2017]. Disponible en: http://www.ciberesquina.una.edu.ve:8080/2014_2/350_E.pdf

2. EL PERCEPTRÓN

Desarrollado en los años 50 por Frank Rosenblatt, es considerada la primera red neuronal artificial, consta de un número arbitrario de capas, puede entenderse como la unidad básica de inferencia capaz de generar criterios suficientes para seleccionar un subgrupo a partir de un grupo de componentes, partiendo de un algoritmo desarrollado para tal fin.²¹

Aunque el perceptrón tiene muchos aspectos similares a la red desarrollada por Warren McCulloch y Walter Pitts, Rosenblatt adicionó una regla de aprendizaje que permitía entrenar la red para solucionar problemas de reconocimiento de modelos, sin embargo a pesar de este avance el perceptrón presentaba limitaciones siendo incapaz de solucionar problemas con lagunas funciones elementales demostradas por Minsky y papert en el libro Perceptron²², posterior a esto en los años ochenta se crean nuevos algoritmos facilitando el uso del perceptrón, convirtiéndolo en una de las redes más importantes y utilizadas en la actualidad por su versatilidad y fácil acoplamiento a otras redes para poder solucionar problemas de alta complejidad.²³

2.1 PERCEPTRÓN SIMPLE

Es la unidad fundamental desarrollada por Rosenblatt consta básicamente está constituido por un conjunto de sensores que reciben los patrones de entrada a reconocer o clasificar y una neurona de salida que se encarga de clasificar a los

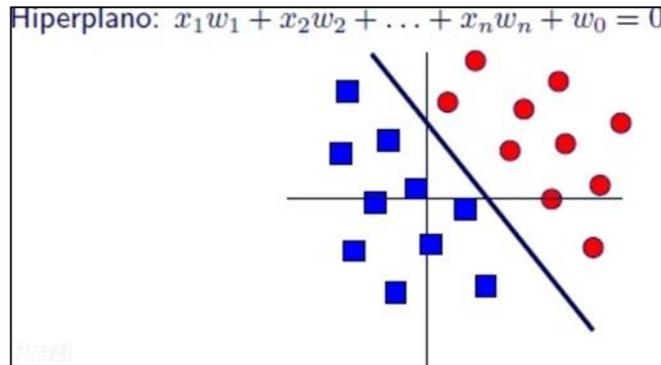
²¹ DÁVILA, Esteban, et al. Perceptrón Simple. [En línea]. [Consultado el: 22 de enero de 2017]. Disponible en: <https://prezi.com/i4m0jqipqrgj/perceptron-simple/>

²² FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

²³ HAGAN, Martin, et al. Neural Network Design, Second Edition. Oklahoma, USA: El autor, 2014. 1012 p. ISBN 097-17321-1-6

patrones de entrada en dos clases, dado un conjunto de datos determina el plano o clasifica la información en dos grupos según sus características.

Figura 4. Clasificación del perceptrón simple.

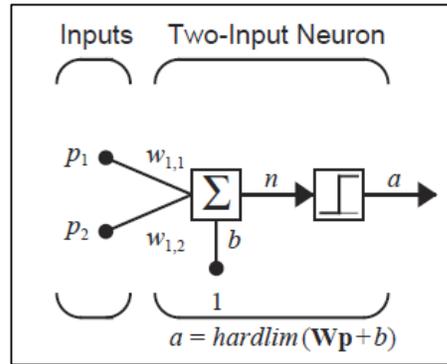


Fuente: DÁVILA, Esteban, et al. Perceptrón Simple. [En línea]. [Consultado el: 22 de enero de 2017]. Disponible en: <https://prezi.com/i4m0jqipqrgj/perceptron-simple/>

El perceptrón simple es capaz de clasificar patrones de forma automática, a partir de un número de ejemplos dados, puede utilizarse como neurona dentro de una red neuronal, es de aprendizaje supervisado, tiene conexiones en un solo sentido, el perceptrón simple es reconocido por su capacidad de aprender a reconocer patrones, generalmente está constituido por dos capas de neurona, en cuanto a su arquitectura se puede ver en la siguiente figura, consta básicamente de una entrada (p), una función de transferencia (a) y una salida.²⁴

²⁴ HAGAN, Martin, et al. Neural Network Design, Second Edition. Oklahoma, USA: El autor, 2014. 1012 p. ISBN 097-17321-1-6

Figura 5. Arquitectura del perceptrón simple.



Fuente: HAGAN, Martin, et al. Neural Network Design, Second Edition. Oklahoma, USA: El autor, 2014. 1012 p. ISBN 097-17321-1-6

El aprendizaje de este tipo de neuronas es iterativo supervisado de presentación de patrones modificando los parámetros como son los pesos y los umbrales hasta encontrar un hiperplano discriminante como se muestra en la figura 6.

Figura 6. Proceso de aprendizaje.

Entrada: conjunto de pares $\langle \vec{x}, d(\vec{x}) \rangle$, donde

- ★ $\vec{x} = (x_1, \dots, x_n)$
- ★ Salida deseada, $d(\vec{x})$, donde:
 - * Si $d(\vec{x}) = 1$ entonces $\vec{x} \in C_1$
 - * Si $d(\vec{x})$ entonces $\vec{x} \in C_2$

Salida del proceso de aprendizaje:

- ★ Pesos y umbral, w_0, \dots, w_n

Fuente: DÁVILA, Esteban, et al. Perceptrón Simple. [En línea]. [Consultado el: 22 de enero de 2017]. Disponible en: <https://prezi.com/i4m0jqipqrgj/perceptron-simple/>

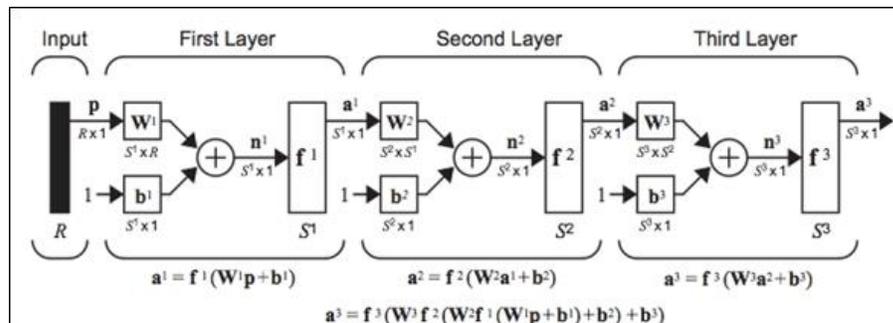
2.2 PERCEPTRÓN MULTICAPA

En una red neuronal conformada por múltiples capas esto le permite resolver problemas de gran complejidad que no son linealmente separables, desventaja que presenta el perceptrón simple.

Es una de las redes más utilizadas en este momento dada su versatilidad, consigue trabajar con múltiples capas y con funciones de activación no lineales, considerado el aproximador universal.

2.2.1 Arquitectura del perceptrón multicapa. Se caracteriza por tener las neuronas agrupadas en capas de diferentes niveles distinguiéndose básicamente tres capas: la capa de entrada, las capas ocultas y las capas de salida, las ubicadas en la capa de entrada no trabajan como neuronas propiamente dichas ya que son las encargadas de recibir las señales de entrada o patrones y propagarlas a las neuronas de las capas siguientes, la capa de salida es en realidad la salida de la red, generando la información de salida deseada de la red o entregando la salida a cada uno de los patrones de entrada.

Figura 7. Arquitectura perceptrón multicapa



Fuente: HAGAN, Martin, et al. Neural Network Design, Second Edition. Oklahoma, USA: El autor, 2014. 1012 p. ISBN 097-17321-1-6

2.2.2 Aprendizaje del perceptrón multicapa. El principal objetivo del aprendizaje o del entrenamiento es ajustar los parámetros tanto pesos y umbrales con el fin que las entradas produzcan las salidas deseadas disminuyendo la función de error.

Específicamente, se describe a continuación el proceso de entrenamiento de la red perceptrón multicapa con algoritmo de retropropagación.

Partiendo de tener:

$$\{(X(n), S(n)), n$$

$= 1 \dots N\}$ Como el conjunto de muestras o patrones del problema a resolver

$X(n) = (x_1(n), \dots, x_{n1}(n))$ Patrones de entrada a la red

$S(n) = (s_1(n), \dots, s_{nc}(n))$ Salidas deseadas

N número de patrones disponibles

1. Inicialmente se dan valores a los pesos y umbrales muy cercanos a cero .

2. Se utiliza un patrón de los datos de entrenamiento correspondientes a $(X(n), S(n))$ y se propaga hacia la salida de la red, el vector de entrada $X(n)$ utilizando las siguientes ecuaciones, obteniendo la respuesta de la red para el valor de entrada $Y(n)$.

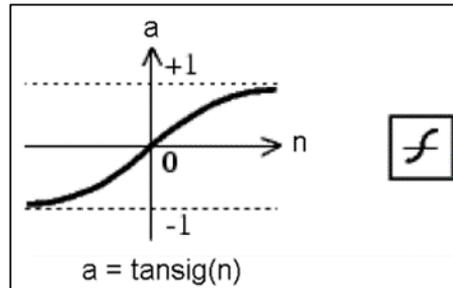
Las funciones de activación f más utilizadas para el perceptrón multicapa son:²⁵

- Función sigmoideal, tiene intervalos con valores continuos entre $[0,1]$, gráficamente se expresa en la figura 8; cuya ecuación característica es:

$$f_{sigm}(x) = \frac{1}{1 + e^{-x}}$$

²⁵ FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

Figura 8. Función sigmoidal.

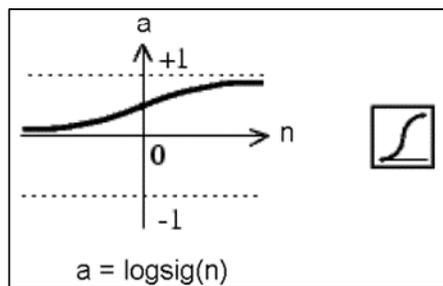


Fuente: FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

- Función tangente hiperbólica, tiene intervalos con valores continuos entre $[-1, 1]$, gráficamente se expresa en la figura 9; cuya ecuación característica es:

$$f_{thip}(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

Figura 9. Función tangente hiperbólica.



Fuente: FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

2.1. Activación de las neuronas de la capa de entrada (a_i^1)

$$a_i^1 = x_i \text{ para } i = 1, 2, \dots, n_1$$

Dónde: $X = (x_1, x_2, \dots, x_n)$ vector patrón de entrada a la red.

2.2. Activación de las neuronas de la capa oculta c (a_i^c), las neuronas ocultas procesan la información aplicando la función de activación f a las sumas de los productos de las activaciones que recibe por sus correspondientes pesos

$$a_i^c = f \left(\sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_j^{c-1} + u_i^c \right) \text{ para } i = 1, 2, \dots, n_c \text{ y } c = 2, 3, \dots, C - 1$$

Dónde: a_j^{c-1} son las activaciones de las neuronas de la capa $c - 1$

2.3. Activación de las neuronas de la capa de salida (a_i^C), este grupo de neuronas se activa con la función de activación f , aplicada a la suma de los productos de las entradas que recibe por sus correspondientes pesos.²⁶

$$y_i = a_i^C = f \left(\sum_{j=1}^{n_{C-1}} w_{ji}^{C-1} a_j^{C-1} + u_i^C \right) \text{ para } i = 1, 2, \dots, n_c$$

Dónde: $Y = (y_1, y_2, \dots, y_{n_c})$ es el vector de salida de la red

²⁶ PÉREZ, Jesús. Herramienta MATLAB para la selección de entradas y predicción neuronal de valores de bolsa, Volumen 1. [En línea]. Trabajo de Grado Ingeniería de Telecomunicaciones. Sevilla: Universidad de Sevilla. Departamento de Ingeniería de Sistemas y Automática, 2013. 144 p. [Consultado el: 12 de febrero de 2017]. Disponible en: <http://bibing.us.es/proyectos/abreproy/12166/direccion/Volumen+1+-+Memoria+descriptiva+del+proyecto%252F>

3. Evaluar el error cuadrático generado por la red patrón mediante la siguiente ecuación:

$$e(n) = \frac{1}{n_C} \sum_{i=1}^{n_C} (s_i(n) - y_i(n))^2$$

Dónde: $Y(n) = (y_1(n), \dots, y_{n_C}(n))$ y $S(n) = (s_1(n), \dots, s_{n_C}(n))$ son los vectores de salida de la red y salidas deseadas para el patrón n , respectivamente.

El objetivo deseado es que la salida de la red sea lo más próxima posible a la salida deseada entonces el aprendizaje de la red es en realidad un problema de minimización así:

$$\text{Min } w^E$$

Dónde: W es el conjunto de parámetros: pesos – umbrales y E la función de error que evalúa la salida de la red contra la salida deseada, generalmente se utiliza la siguiente expresión para calcular E

$$E = \frac{1}{N} \sum_{n=1}^N e(n)$$

Siendo N el número de patrones o de muestras y $e(n)$ es el error cometido por la red para el patrón n

4. Aplicar la regla delta generalizada para modificar los pesos y umbrales de la red.²⁷

²⁷ PÉREZ, Jesús. Herramienta MATLAB para la selección de entradas y predicción neuronal de valores de bolsa, Volumen 1. [En línea]. Trabajo de Grado Ingeniería de Telecomunicaciones. Sevilla: Universidad de Sevilla. Departamento de Ingeniería de Sistemas y Automática, 2013. 144 p. [Consultado el: 12 de febrero de 2017]. Disponible en: <http://bibing.us.es/proyectos/abreproy/12166/direccion/Volumen+1+-+Memoria+descriptiva+del+proyecto%252F>

4.1 Calcular los valores de δ para todas las neuronas de la capa de salida mediante la siguiente ecuación:

$$\delta_i^C(n) = -(s_i(n) - y_i(n))f' \left(\sum_{j=1}^{n_{C-1}} w_{ji}^{C-1} a_j^{C-1} + u_i^C \right)$$

4.2 Calcular los valores de δ para el resto de las neuronas de la red, empezando desde la última capa oculta y retropropagando dichos valores hacia la capa de entrada, mediante la ecuación:

$$\delta_j^{c+1}(n) = f' \left(\sum_{k=1}^{n_c} w_{kj}^c a_k^c + u_j^c \right) \sum_{i=1}^{n_{c+1}} \delta_i^{c+2}(n) w_{ji}^c$$

4.3.1. Modificar los pesos y umbrales de la red mediante la ecuación:

$$w_{ji}^{C-1}(n) = w_{ji}^{C-1}(n-1) + \alpha \delta_i^C(n) a_j^{C-1}$$

para $j = 1, 2, \dots, n_{C-1}$ $i = 1, 2, \dots, n_C$

4.3.2. Modificar los pesos y umbrales de la capa de salida mediante la ecuación:

$$u_i^C(n) = u_i^C(n-1) + \alpha \delta_i^C(n) \text{ para } i = 1, 2, \dots, n_C$$

4.3.3 Para los demás parámetros de la red se utiliza las ecuaciones:

$$w_{kj}^c(n) = w_{kj}^c(n-1) + \alpha \delta_j^{c+1}(n) a_k^c(n)$$

para $k = 1, 2, \dots, n_c$, $j = 1, 2, \dots, n_{c+1}$ y $c = 1, 2, \dots, C-2$

$$u_j^{c+1}(n) = u_j^{c+1}(n-1) + \alpha \delta_j^{c+1}(n)$$

para $j = 1, 2, \dots, n_{c+1}$ y $c = 1, 2, \dots, C-2$

5. Repetir los pasos 2, 3 y 4 para todos los patrones de entrenamiento completando así un ciclo de entrenamiento

6. Evaluar el error total cometido por la red, es conocido también como el error de entrenamiento ya que es calculado mediante el uso de los patrones de entrenamiento.

$$E = \frac{1}{N} \sum_{n=1}^N e(n)$$

7. Repetir los pasos 2, 3, 4, 5, y 6 hasta que el error de entrenamiento sea mínimo.

Realizar el entrenamiento de una red neuronal para aprender patrones presentes en datos de entrada implica presentarle de forma iterativa ejemplos con respuestas correctas conocidas, de tal forma que al final del proceso se encuentren un conjunto de pesos y umbrales que determinen un error global mínimo.

3. ANÁLISIS DE VIBRACIONES

3.1 GENERALIDADES

Uno de los aspectos importantes dentro de la gestión de mantenimiento en las empresas es el análisis de vibraciones como eje fundamental del mantenimiento predictivo, debido a la evolución en las diferentes estrategias de las áreas de mantenimiento que cada día buscan mejorar los indicadores de confiabilidad, mantenibilidad y disponibilidad ha hecho que desde varias décadas a tras el análisis de vibraciones haya evolucionado como herramienta fundamental en la supervisión de sistemas mecánicos de equipo rotativo principalmente, haciendo parte fundamental de los planes de mantenimiento y con esto los equipos utilizados para la toma de mediciones de vibración, cada día la tecnología va entregando equipos analizadores con software más fáciles de interpretar y más accesibles a los presupuestos de las empresas favoreciendo el uso de estas técnicas.²⁸

El análisis de vibraciones está dentro de las técnicas de detección de fallos no destructivas, permitiendo diagnosticar el estado de un componente mientras funcionan normalmente, permitiendo programar su intervención sin llegar a una situación catastrófica o poder monitorear un componente para llevarlo a su máxima vida sin afectar las condiciones de seguridad o afectación del proceso productivo.

Todo equipo en movimiento presenta una serie de vibraciones normales a su naturaleza, por medio de estas señales vibratorias se puede llegar a conocer el

²⁸ PALOMINO, Evelio. La medición y el análisis de vibraciones en el diagnóstico de máquinas rotativas. [En línea]. La Habana, Cuba: Centro de Estudios Innovación y Mantenimiento, 1997. 113 p. [Consultado el: 20 de febrero de 2017]. Disponible en: http://grupovirtus.org/moodle/pluginfile.php/5510/mod_resource/content/1/Documentos/Analisis_de_Vibraciones_en_Maquinarias_rotatorias.pdf

estado de sus componentes, cuando un equipo o uno de sus componentes falla las características de estas vibraciones lógicamente cambian mediante el estudio detallado de las gráficas generadas por los análisis vibratorios se puede llegar a identificar el tipo u origen de la falla.²⁹

La vibración es el movimiento de vaivén de una máquina o elemento de ella en cualquier dirección desde su posición cero o de equilibrio, estos movimientos se traducen en fuerzas que cambian de dirección e intensidad debidas al movimiento rotatorio de los componentes de las máquinas, todos los cuerpos presentan una señal de vibración en la cual se encuentran cada una de sus características, gracias a estos movimientos se pueden llegar a identificar problemas mecánicos como desgastes o deterioro de rodamientos, engranajes desgastados o dañados, desalineaciones entre ejes o problemas de tipo eléctrico como daño en las barras de los motores o incidencias de los variadores electrónicos de velocidad, una señal medida en una máquina es la suma vectorial de la vibración de cada uno de sus componentes.³⁰

3.2 CLASIFICACIÓN DE LAS VIRACIONES MECÁNICAS

Las vibraciones mecánicas se clasifican en tres clases:

- Vibraciones simples.
- Vibraciones compuestas.

²⁹ MOSQUERA, Genaro; PIEDRA, Margarita y ARMAS, Raúl. Las vibraciones mecánicas y su aplicación al mantenimiento predictivo. Caracas: Universidad Central de Venezuela. Consejo de Desarrollo Científico y Humanístico. Instituto Superior de Ciencias y Tecnologías Nucleares, 2000. 226 p. ISBN 980-07-5678-7.

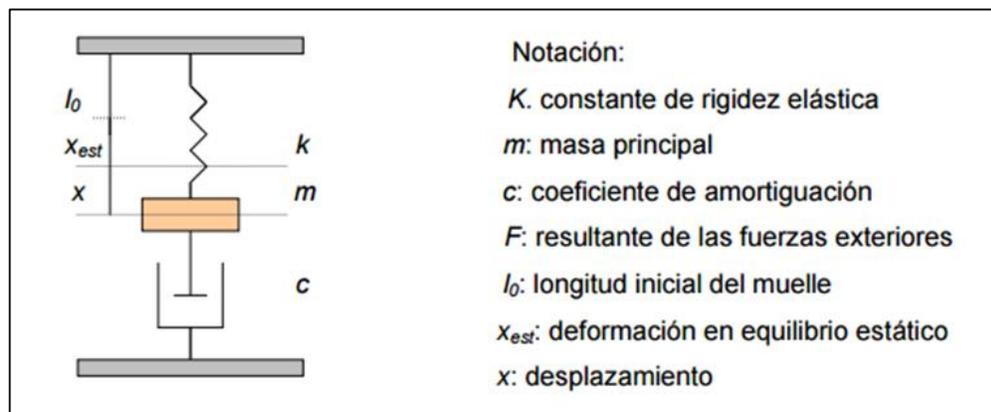
³⁰ A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

- Vibraciones aleatorias o intermitentes.

3.3 VIBRACIONES SIMPLES

Las ondas sinusoidales son la base de las señales de vibración en el dominio tiempo, estas oscilaciones pueden físicamente representarse mediante un sistema con una masa suspendida de un resorte como el de la figura 10.³¹

Figura 10. Sistema de vibración simple.



Fuente: PRUFTECHNIK. Tutoriales Análisis de Vibraciones. [En línea]. Barcelona: La compañía, 2017. [Consultado el 20 de enero de 2017]. Disponible en: <http://blog.pruftechnik.es/unidades-de-vibracion-para-el-analisis-de-vibraciones-mecanicas>

³¹ PRUFTECHNIK. Tutoriales Análisis de Vibraciones. [En línea]. Barcelona: La compañía, 2017. [Consultado el 20 de enero de 2017]. Disponible en: <http://blog.pruftechnik.es/unidades-de-vibracion-para-el-analisis-de-vibraciones-mecanicas>

Este sistema está formado por una masa m , un resorte k y un dispositivo amortiguador de constante c , al aplicarse una fuerza sobre la masa m se efectuará un movimiento armónico simple que tendrá una amplitud o desplazamiento x , el movimiento permanente de la masa hace que se describa una serie de movimientos constantes, el tiempo que tarda la masa en subir y bajar a una velocidad constante se puede definir como el periodo de oscilación.

3.3.1 Características principales de las vibraciones simples. La incidencia de las diferentes variables o características dentro del análisis de vibraciones de se puede ver a continuación.

3.3.1.1 Frecuencia. Inverso del periodo, es una característica simple pero muy significativa dentro del análisis vibracional, generalmente se expresa en ciclos por minuto, junto con la velocidad angular de los elementos rotativos podrá identificar el problema y la pieza responsable de la vibración esto debido a que las fuerzas cambian de dirección y amplitud de acuerdo a la velocidad de giro.

3.3.1.2 Amplitud. Se mide generalmente en valores pico-pico para desplazamiento y valores cero-pico y RMS para velocidad y aceleración, la amplitud de la vibración indica la importancia, gravedad o severidad del problema debido a que la velocidad de vibración tiene en cuenta el desplazamiento y la frecuencia.

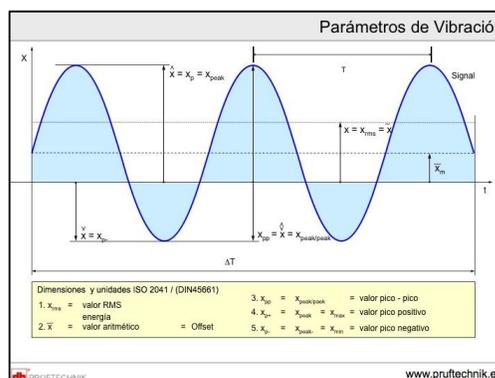
3.3.1.3 Velocidad. Se mide en mm/s en SI, in/s en S. Inglés, del pico mayor de todo el recorrido que realiza el elemento al vibrar, es el parámetro que siempre se mide por la relación directa que tiene con la severidad de la vibración.

3.3.1.4 Aceleración. Está relacionada con la fuerza que provoca la vibración sin importar que tanto velocidad como desplazamiento sean de valores pequeños.

3.3.1.5 Desplazamiento. Medido en mm ó μm en SI, mils en S. Inglés es importante para reconocer patrones que están a muy baja frecuencia. Los picos de vibración que están al comienzo del espectro son mejor resaltados. Esta es una medida especial para hallar anomalías en chumaceras de aceite, muy utilizadas en turbo-maquinaria.

3.3.1.6 Spike Energy. Es también conocido como energía de los impulsos, es una variable muy importante en el análisis de vibraciones, básicamente mide los impulsos de energía de breve duración con los cuales se puede llegar a detectar defectos en las superficies de los rodamientos o engranajes, cavitación en bombas, este parámetro es básicamente un valor de aceleración pero medido en g-SE.

Figura 11. Parámetros de vibración.



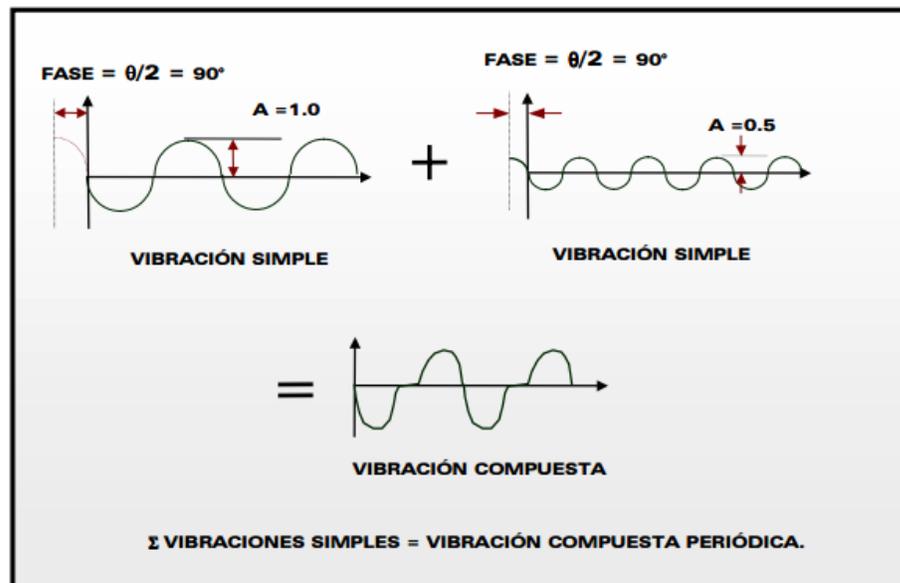
Fuente: PRUFTECHNIK. Tutoriales Análisis de Vibraciones. [En línea]. Barcelona: La compañía, 2017. [Consultado el 20 de enero de 2017]. Disponible en: <http://blog.prufttechnik.es/unidades-de-vibracion-para-el-analisis-de-vibraciones-mecanicas>.

3.4 VIBRACIONES COMPUESTAS

La vibración compuesta se define como la suma de varias vibraciones simples o la sumatoria de varias señales sinusoidales las cuales contienen cada uno de los componentes encontrados en las máquinas sumado a todos los efectos producidos por golpeteos o vibraciones producidas por otros componentes cercanos.

En realidad las máquinas producen vibraciones de tipo compuesto más no de tipo simple debido a la cantidad de elementos que las constituyen internamente, por tanto su señal de onda no será de tipo sinusoidal sino que presentará señales muy complejas dependiendo de la cantidad de componentes que tenga o de la influencia de otros equipos cercanos siendo en muchos casos muy difícil su interpretación.

Figura 12. Vibración compuesta.

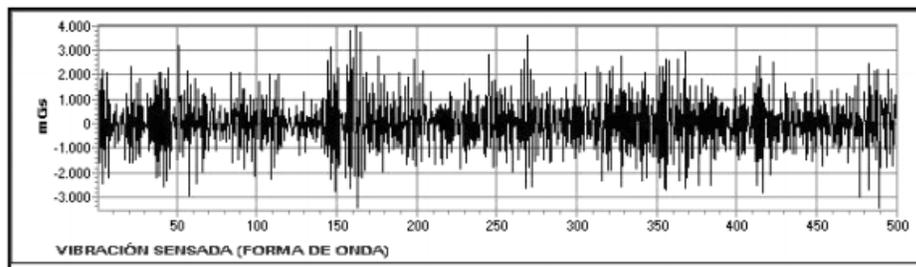


Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.5 VIBRACIONES ALEATORIAS O INTERMITENTES

Este tipo de vibraciones no cumple con un patrón de repetición constante siendo difícil poder definir donde inicia y termina un ciclo, generalmente son los patrones encontrados en turbulencias de ventiladores, bombas, deficiencias en lubricación, problemas asociados a cavitación o contacto metal-metal, estos golpeteos se asocian a señales repetitivas producto de engranajes, se evidencias en el paso de las aspas de un impulsor o rotor de un ventilador, por su complejidad es mejor analizarlos como espectro y no en la onda de tiempo.

Figura 13. Vibración aleatoria o intermitente,



Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.6 TRANSFORMADA DE FOURIER

Jean Baptiste Fourier (1768 – 1830) matemático Francés, desarrolló una serie de ecuaciones que permiten representar una señal compleja en el dominio del tiempo por medio de una serie de curvas con valores de amplitud y frecuencias específicas.

Las señales recopiladas en los análisis de vibración están cargadas de mucha información en forma muy compleja, siendo difícil poder distinguir a simple vista a cual componente de la máquina corresponde y por ende dar un diagnóstico del estado de cada uno de las partes de los equipos.³²

Las máquinas generan vibraciones tanto compuestas como aleatorias es decir la sumatoria de una gran cantidad de señales simples todas superpuestas, si se analizan solo en el dominio del tiempo no es útil para la supervisión de los equipos haciendo difícil distinguir las fallas entre los diferentes componentes, tomando como ejemplo práctico las bombas centrifugas objeto del presente trabajo cada parte tiene un comportamiento particular tanto los rodamientos, el rotor, el motor, la unión motor bomba, genera unas señales vibratorias de onda con amplitud y frecuencia diferentes entre sí.³³

Gracias a la transformada de Fourier es posible descomponer las señales de dominio de tiempo, facilitando el análisis de cada uno de los componentes de las máquinas, como resultado de la transformada de Fourier es posible pasar de dominio de tiempo al dominio de la frecuencia, conocido también como espectro de frecuencia o gráficas de amplitud Vs. frecuencia donde los diferentes componentes de las señales vibratorias puede ser distinguidas y medidas para cuantificar el valor de cada variable facilitando su interpretación.³⁴

³² PALOMINO, Evelio. La medición y el análisis de vibraciones en el diagnóstico de máquinas rotativas. [En línea]. La Habana, Cuba: Centro de Estudios Innovación y Mantenimiento, 1997. 113 p. [Consultado el: 20 de febrero de 2017]. Disponible en: http://grupovirtus.org/moodle/pluginfile.php/5510/mod_resource/content/1/Documentos/Analisis_de_Vibraciones_en_Maquinarias_rotatorias.pdf

³³ SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

³⁴ UNIVERSIDAD DE NAVARRA. Vibraciones en máquinas. Mantenimiento predictivo. [En línea]. Navarra: Universidad de Navarra. Departamento de Ingeniería Mecánica, Energética y de Materiales. 54 p. [Consultado el: 28 de enero de 2017]. Disponible en: http://www.imem.unavarra.es/EMyV/pdfdoc/vib/vib_predictivo.pdf

Matemáticamente se expresan de la siguiente forma:

Esta expresión permite calcular $F(\omega)$ dominio de la frecuencia a partir de $f(t)$ dominio del tiempo:

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt$$

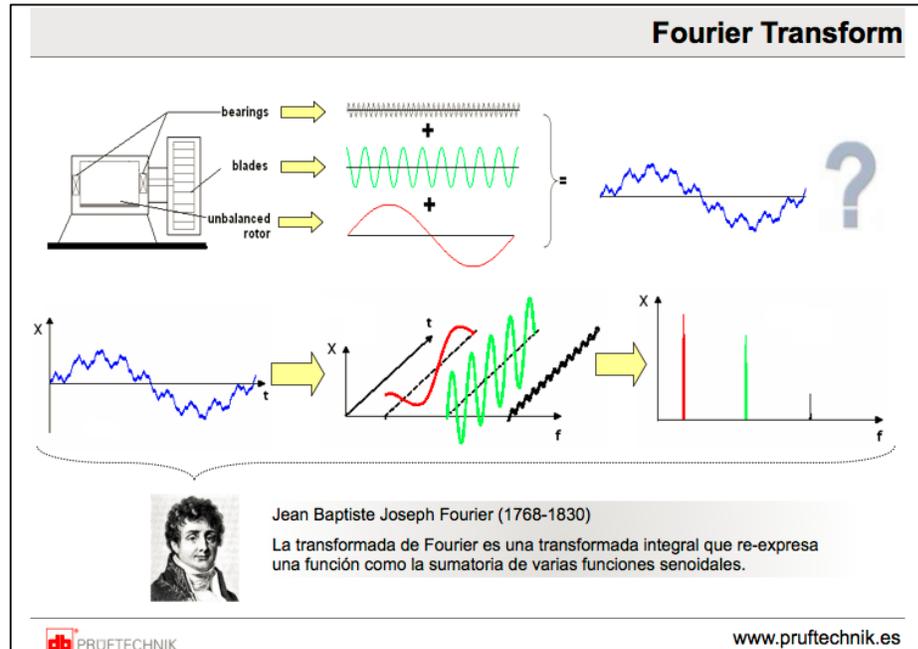
La ecuación inversa o anti-transformada de Fourier sería:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega)e^{i\omega t} d\omega$$

Los equipos modernos utilizados para el análisis de vibraciones ya traen implícitas las ecuaciones de las series de Fourier, capturan las señales de las máquinas, calculan todas las series de señales sinusoidales mostrándolas en forma individual en el eje X de la frecuencia. A través del tiempo se han clasificado los diferentes espectros asociados a cada componente y tipo de fallas mostrándolas en guías para el análisis predictivo de maquinaria, uno de estos ejemplos son las tablas de Charlotte.

En la figura 14 se resume el proceso de una toma de vibraciones, donde las señales son tomadas de los equipos, luego el analizador aplica las transformadas de Fourier para separar las señales de los diferentes componentes, posterior a esto llevarlas a espectros y poder ser interpretados para conocer el estado de cada uno de los elementos de la máquina.

Figura 14. Transformación de señales mediante Fourier.



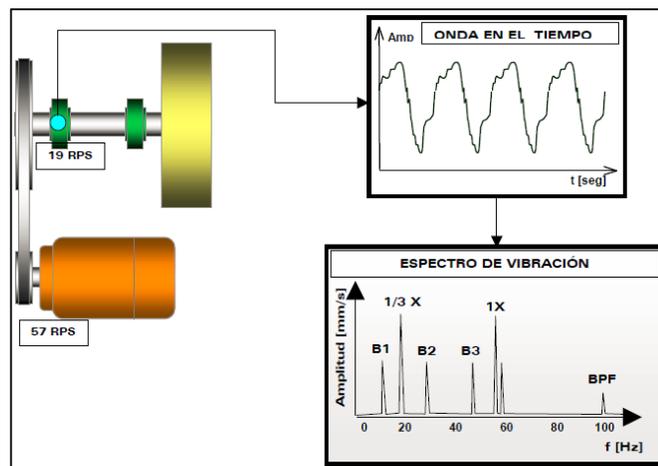
Fuente: PRUFTECHNIK. Tutoriales Análisis de Vibraciones. [En línea]. Barcelona: La compañía, 2017. [Consultado el 20 de enero de 2017]. Disponible en: <http://blog.pruftechnik.es/unidades-de-vibracion-para-el-analisis-de-vibraciones-mecanicas>.

3.7 ANÁLISIS ESPECTRAL

La esencia del análisis espectral es descomponer la señal vibratoria en el dominio del tiempo en sus componentes espectrales en frecuencia, esto permite correlacionar las vibraciones medidas con posibles fallos en sus componentes, estas señales están cargadas de mucha información en forma muy compleja resultando imposible distinguir a simple vista sus comportamientos característicos, dentro del estudio de vibraciones se encuentra analizar las señales en el dominio de la frecuencia para esto se emplea la gráfica de amplitud frente a frecuencia o espectro.

El éxito del análisis espectral está en la correcta interpretación de los espectros con respecto a las condiciones de operación del equipo, identificando los picos de variación en el espectro es decir identificar el pico de primer orden (1x), si se trata de una bomba normalmente puede haber un pico fuerte hasta en 6x dependiendo de la cantidad de álabes, posteriormente se realiza el diagnóstico determinando la gravedad de los problemas basándose en las amplitudes y la relación entre los picos de vibración para finalmente dar las recomendaciones de las intervenciones según el problema encontrado.

Figura 15. Análisis espectral amplitud - frecuencia.



Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.8 ANÁLISIS DE PRINCIPALES FALLOS EN BOMBAS CENTRÍFUGAS

A continuación se detallan los principales espectros de fallos presentes en bombas centrífugas, para este caso en particular se analizarán los más relevantes.

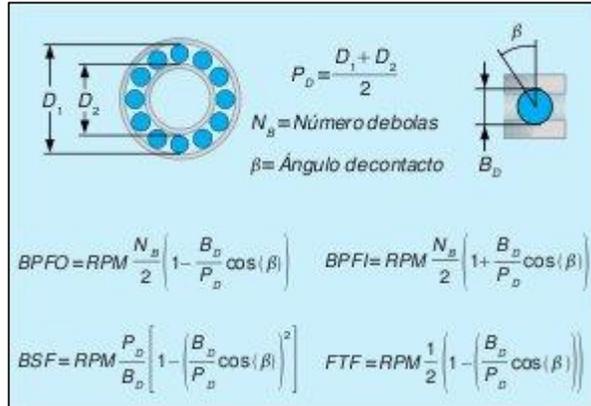
3.8.1 Fallos en rodamientos. Los rodamientos son sin duda uno de los principales componentes de máquinas rotativas y es justamente donde el análisis de vibraciones ha demostrado ser muy eficaz al momento de detectar los fallos, están compuestos por principalmente por la pista exterior, los elementos rodantes, la jaula y la pista interna, cada uno de estos componentes genera una o varias frecuencias de fallo permitiendo su fácil identificación.³⁵

Las principales frecuencias de deterioro de un rodamiento son:

- BPFO o frecuencia de deterioro de la pista exterior. Físicamente es el número de elementos rodantes que pasan por un punto de la pista exterior cada vez que el eje realiza un giro completo, se calcula mediante la expresión:
- BPFI o frecuencia de deterioro de la pista interior. Físicamente es el número de bolas o rodillos que pasan por un punto de la pista interior cada vez que el eje realiza un giro completo.
- BSF o frecuencia de deterioro de los elementos rodantes. Físicamente es el número de giros que realiza uno de los elementos rodantes del rodamiento cada vez que el eje realiza un giro completo.
- FTF o frecuencia fundamental de tren o de deterioro de la jaula. Físicamente es el número de giros que realiza la jaula del rodamiento cada vez que el eje realiza un giro completo.

³⁵ SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

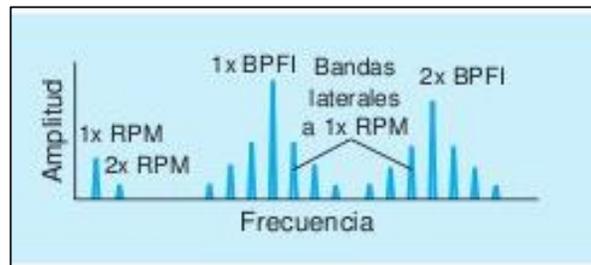
Figura 16. Frecuencias de deterioro de rodamientos.



Fuente: SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

3.8.1.1 Fallos en pista interna. Normalmente se presentan entre 8 y 10 armónicos de la BPFI, modulados por bandas laterales a 1xRPM, asociados a agrietamientos del material, lubricación deficiente por evidenciar contacto metal-metal entre elementos rodantes, las pistas producen pulsos en el dominio del tiempo del orden de 1 a 10 KHz.

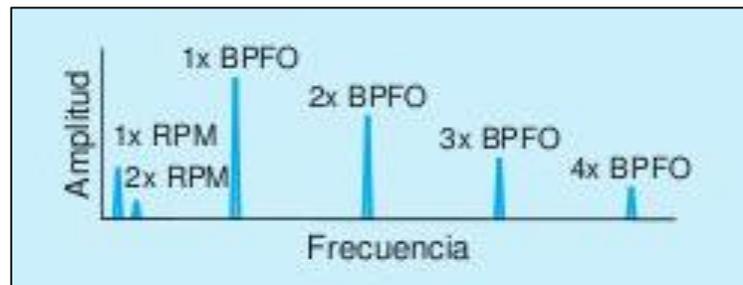
Figura 17. Espectro fallo pista interna.



Fuente: SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

3.8.1.2 Fallos en pista externa. Se presentan entre 8 a 10 armónicos de la BPFO, asociados a agrietamientos del material producidos por malos montajes, sobreesfuerzos, corrosión lubricación deficiente por contacto metal-metal, las pistas producen pulsos en el dominio del tiempo del orden de 1 a 10 KHz.

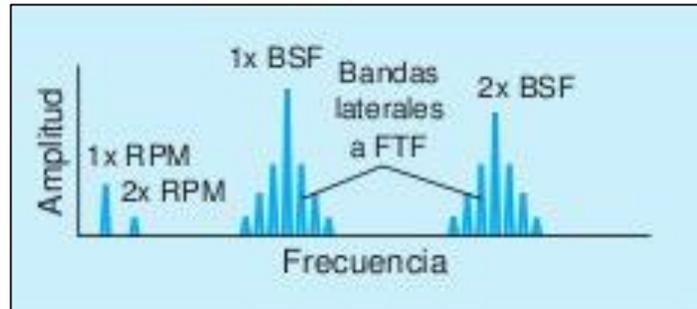
Figura 18. Espectro fallo pista externa.



Fuente: SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

3.8.1.3 Fallos en elementos rodantes. Estos fallos están asociados al deterioro en los elementos rodantes ya sea bolas o rodillos producidos por errores de montaje, sobrecargas, corrosión, rompimiento de la película lubricante, se caracterizan por presentar en los espectros frecuencias de deterioro (BSF), generalmente van acompañados por defectos o deterioro de las pistas.

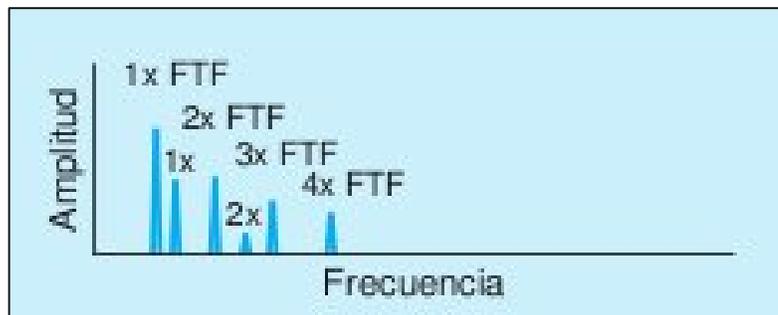
Figura 19. Espectro fallo elementos rodantes.



Fuente: SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

3.8.1.4 Fallos en la jaula. Originados por deformaciones en la jaula que mantiene la posición de los elementos rodantes, por lo general van acompañados por deterioro en las pistas, son calculadas mediante el FTF.

Figura 20. Espectro fallo en la jaula.



Fuente: SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

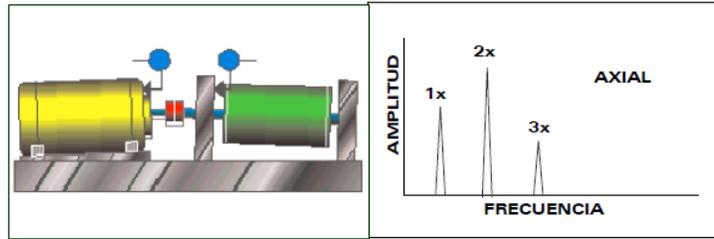
3.8.2 Fallos por lubricación inadecuada. La lubricación inadecuada por defecto o exceso o el uso de lubricantes incorrectos ocasiona problemas de vibraciones entre las pistas y los elementos rodantes, los espectros producidos se caracterizan por presentar vibración a altas frecuencias entre 50000 a 100000 CPM presentando bandas de picos distanciadas entre sí, no es muy probable que dicha frecuencia sea algún múltiplo integral de las rpm del eje de manera que no es de esperarse ningún tipo de patrón.

3.8.3 Fallos por desalienación.

3.8.3.1 Desalineación angular. Caracterizada por una alta vibración axial, ocurre cuando el eje del motor y el eje conducido unidos en el acople, no son paralelos, es muy común observarlos en 1x RPS y 2x RPS con desfase de 180° a través del acople.³⁶

³⁶ A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

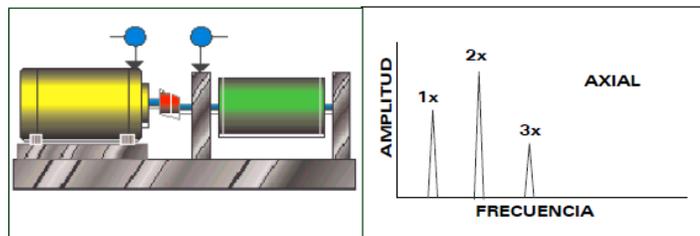
Figura 21. Desalineación angular.



Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.8.3.2 Desalineación paralela. Los ejes del motor y del rotor conducido están paralelos, pero no son colineales, posee síntomas de vibración similares a la angular pero muestra una alta vibración radial. Se pueden detectar altas vibraciones radiales a 2X RPS, predominante, y a 1X RPS, con desfase de 180 grados a través del acople. Cuando aumenta la severidad, genera picos en armónicos superiores (4X, 8X).

Figura 22. Desalineación paralela.



Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.8.4 Fallas por soldaduras mecánicas. Son clasificadas en espectros de vibración tipo A, B o C.

3.8.4.1 Tipo A. Son causada por soldadura/debilitamiento estructural del pie de la máquina, la placa base o cimentación, también por una sedimentación deteriorada, soldadura de los pernos que sujetan a la base y distorsión del bastidor o base (Ej. pata floja). El análisis de fase puede revelar una diferencia de 90° a 180° entre la medición Vertical de los pernos, pie de máquina, placa base o la base misma.³⁷

3.8.4.2 Tipo B. Son generalmente causada por soldadura de los pernos de la bancada, fisuras en la estructura del bastidor o en el pedestal del cojinete.³⁸

3.8.4.3 Tipo C. Son normalmente generada por un ajuste inadecuado entre las partes componentes, que puede causar numerosas armónicas debidas a respuestas no lineales de partes flojas a fuerzas dinámicas del rotor. Causa un truncamiento de la onda de Tiempo y un ruido elevado en el suelo del espectro. La tipo C es causada con frecuencia por el aflojamiento de un cojinete en su caja, por un espacio excesivo en la camisa o los elementos rodantes del rodamiento, un impulsor o eje flojo, etc.

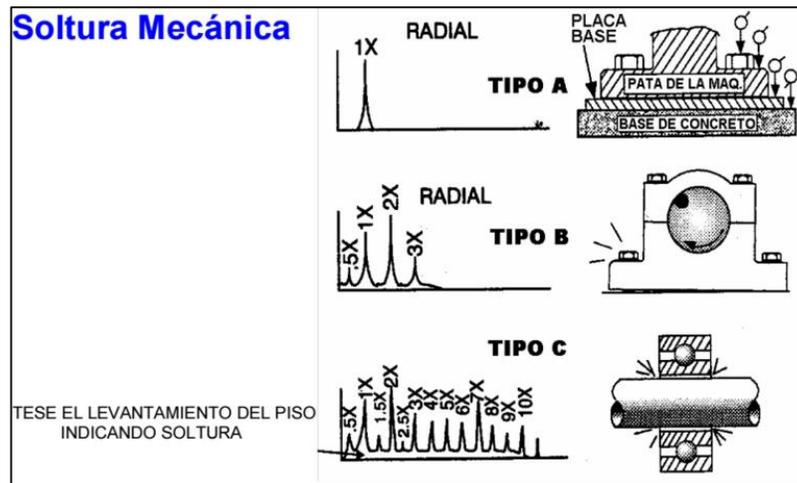
La fase tipo C es con frecuencia inestable y puede variar ampliamente de un arranque al siguiente. La soldadura mecánica es a menudo altamente direccional y puede causar lecturas notablemente diferentes si se comparan niveles en incrementos de 30° en dirección radial alrededor de la carcasa del rodamiento.

³⁷ ADEMINSA COLOMBIA S.A.S. Carta ilustrada de diagnóstico de vibración, tablas de Charlotte. Bogotá: La compañía. 2016.

³⁸ *Ibíd.*

También nótese que la soldura podrá causar múltiples sub-armónicas exactamente a $1/2$ o $1/3$ XRPM (0.5X, 1.5X, 2.5X, etc.).³⁹

Figura 23. Espectros soldura mecánica.

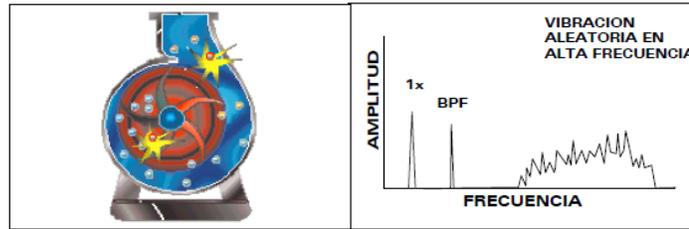


Fuente: ADEMINSA COLOMBIA S.A.S. Carta ilustrada de diagnóstico de vibración, tablas de Charlotte. Bogotá: La compañía. 2016.

3.8.5 Problemas por cavitación. Ocurre cuando la presión de fluido es menor que la presión de vapor a esta temperatura, causa erosión en los álabes del impulsor por consiguiente destrucción a las partes internas de la bomba, genera normalmente una energía de banda ancha de frecuencia muy alta y aleatoria sobrepasando en algunos casos las frecuencias armónicas de paso de álabes, El espectro muestra una vibración caótica que se presenta a altas frecuencias (del orden de 2000 Hz).

³⁹ ADEMINSA COLOMBIA S.A.S. Carta ilustrada de diagnóstico de vibración, tablas de Charlotte. Bogotá: La compañía. 2016.

Figura 24. Espectro por problemas de cavitación.

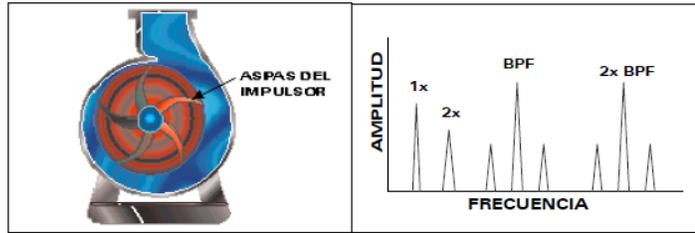


Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.8.6 Fallos en rotor. La Frecuencia de Paso de Alabes (BPF)=N° de Alabes X RPM, las BPF (y armónicas) de gran amplitud pueden ser generadas en la bomba si el espacio entre los alabes de rotación y los difusores no es igual en todas ellas. También las BPF (o armónicas) pueden coincidir en ocasiones con una frecuencia natural del sistema causando alta vibración.

Una BPF alta puede ser generada si el impulsor desgasta los anillos de agarre al eje o si falla la soldadura que sostiene a los alabes del difusor, o si el rotor se encuentra excéntrico dentro de la carcasa de la bomba o ventilador, en caso de aumento en la BPF se debe revisar posibles obstrucciones parciales en la descarga de la bomba.

Figura 25. Espectro por fallos en rotor.

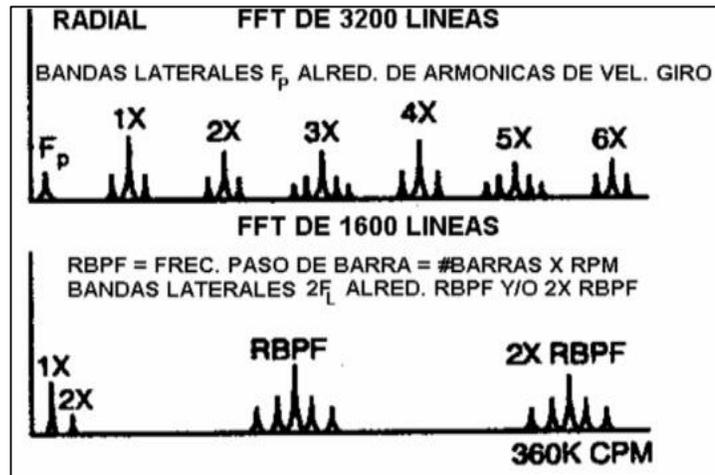


Fuente: A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

3.8.7 Fallos en barras del motor. Unas Barras del rotor rotas o agrietadas o anillos en corto; juntas malas entre las barras del rotor y los anillos en corto o laminaciones del rotor en corto pueden producir una vibración a velocidad de giro 1X con bandas laterales a la frecuencia de paso de polo (FP). Además estos problemas generaran a menudo bandas laterales de paso de polo FP alrededor de las segunda, tercera, cuarta y quinta armónica de la velocidad de giro.

Barras del rotor flojas o abiertas con son indicadas por bandas laterales a 2X la frecuencia de línea (2FL) rodeando a la Frecuencia de Paso de Barra del Rotor (RBPF) y/o sus armónicas (RBPF = Número de barras X RPM). A menudo causaran altos niveles a 2XRBPF con solo una pequeña amplitud a 1XRBPF. Un arqueamiento inducido eléctricamente entre las barras flojas del rotor y los anillos a menudo mostraran altos niveles a 2XRBPF (con bandas laterales a 2FL); pero muy poco o casi ningún incremento en amplitud a 1XRBPF.

Figura 26. Fallos en barras del motor.



Fuente: ADEMINS A COLOMBIA S.A.S. Carta ilustrada de diagnóstico de vibración, tablas de Charlotte. Bogotá: La compañía. 2016.

3.9 CRITERIOS DE EVALUACIÓN DE VIBRACIONES

Para la evaluación de las diferentes variables de vibraciones y poder determinar el grado de severidad de los valores obtenidos se utiliza la norma ISO 10816-3 la cual establece dependiendo del grado al que pertenece los equipos los máximos valores permitidos.⁴⁰

⁴⁰ INTERNATIONAL ORGANIZATION FOR STANDARIZATION. Mechanical Vibration - Evaluation of Machine Vibration by Measurements on non-rotating parts - General Guidelines. ISO 10816-1. Ginebra, Suiza: El Instituto, 1995. 24 p.

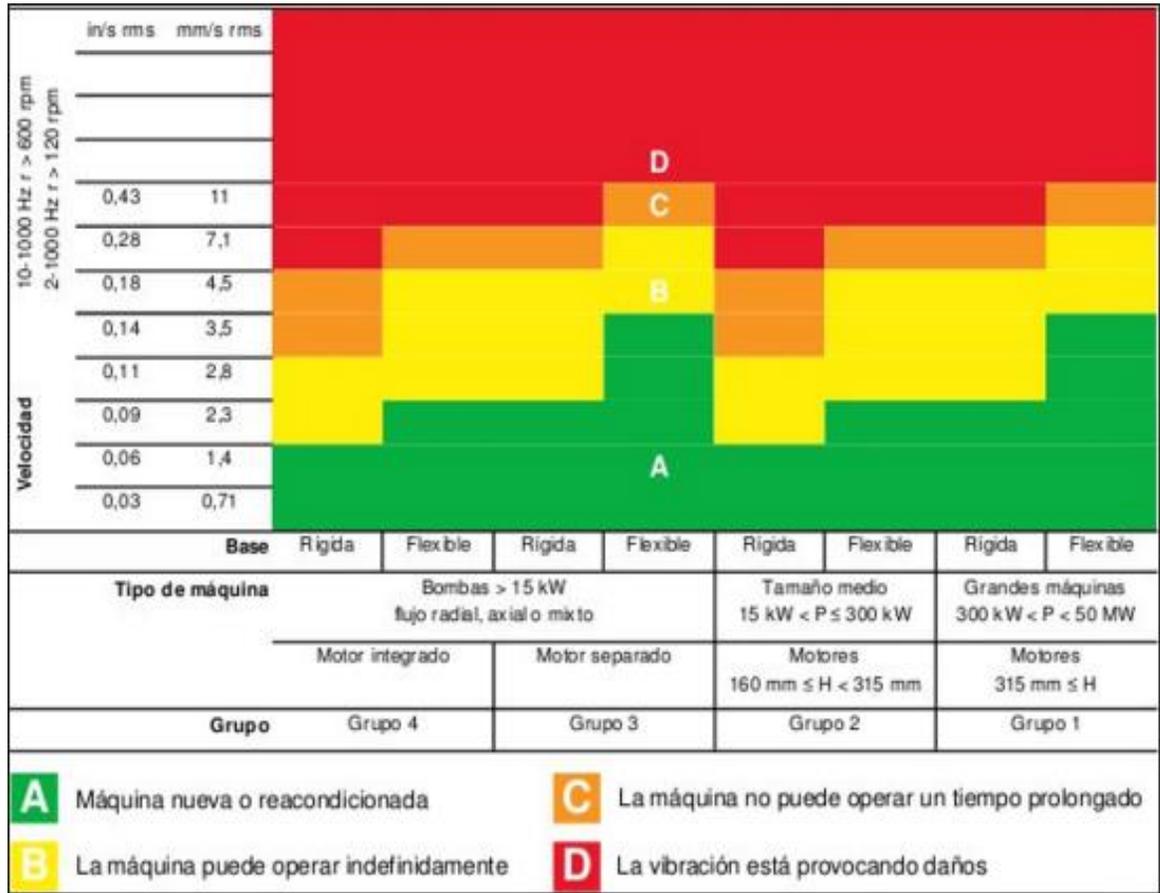
Tabla 2. Clasificación equipos Norma ISO 10816-3.

4-1	Rotor directo sobre eje motor
	Fundación Rígida
	Potencia menor a 15 KW (20 HP)
4-2	Rotor directo sobre eje motor
	Fundación Flexible
	Potencia menor a 15 KW (20 HP)
3-1	Rotor acoplado a motor
	Fundación Rígida
	Potencia menor a 15 KW (20 HP)
3-2	Rotor acoplado a motor
	Fundación Flexible
	Potencia menor a 15 KW (20 HP)
2-1	Altura hasta centro de eje entre 160 y 315 mm
	Fundación Rígida
	Potencia entre 15 KW (20 HP) y 300 KW (400 HP)
2-2	Altura hasta centro de eje entre 160 y 315 mm
	Fundación Flexible
	Potencia entre 15 KW (20 HP) y 300 KW (400 HP)
1-1	Altura hasta centro de eje mayor a 315 mm
	Fundación Rígida
	Potencia entre 300 KW (400 HP) y 50 MW (67000 HP)
1-2	Altura hasta centro de eje mayor a 315 mm
	Fundación Flexible
	Potencia entre 300 KW (400 HP) y 50 MW (67000 HP)

Fuente: INTERNATIONAL ORGANIZATION FOR STANDARIZATION. Mechanical Vibration - Evaluation of Machine Vibration by Measurements on non-rotating parts. ISO 10816. Ginebra, Suiza: El Instituto, 1995.

Luego de ubicar el equipo en la tabla anterior se procede a cruzar esta información contra la tabla siguiente con el fin de ubicar la zona en la que está de acuerdo al valor medido.

Figura 27. Clasificación equipos Norma ISO 10816-3.



Fuente: INTERNATIONAL ORGANIZATION FOR STANDARIZATION. Mechanical Vibration - Evaluation of Machine Vibration by Measurements on non-rotating parts. ISO 10816. Ginebra, Suiza: El Instituto, 1995.

La descripción de cada uno de los colores se muestra en la tabla 3.

Tabla 3. Convención de colores Norma ISO 10816-3.

NIVEL DE EMERGENCIA	Valor referencial de vibración peligrosa, indica que el equipo dinámico se encuentra operando en forma Inaceptable, podría ocasionar daños tanto al equipo como al personal operativo, por lo cual es recomendable ponerlo fuera de operación y proceder con la corrección de las fallas diagnosticadas.
NIVEL DE PRECAUCIÓN	Valor referencial de operación continua no recomendada, que indica que el equipo dinámico se encuentra con limitaciones en su operación, por lo cual debe ser considerado dentro de los planes del próximo Mantenimiento Preventivo.
NIVEL DE OBSERVACIÓN	Valor referencial de operación continua sin restricciones, que indica que el equipo dinámico se encuentra en condición de funcionamiento aceptable bajo observación programada.
NIVEL NORMAL	Valor referencial de operación puesta en marcha, que indica que el equipo dinámico se encuentra en condiciones normales de operación y no necesita intervención.

Fuente: INTERNATIONAL ORGANIZATION FOR STANDARIZATION. Mechanical Vibration - Evaluation of Machine Vibration by Measurements on non-rotating parts. ISO 10816. Ginebra, Suiza: El Instituto, 1995.

4. DESARROLLO DEL MODELO

Partiendo del objetivo general del presente proyecto, el cual busca desarrollar un modelo computacional basado en redes neuronales que permita diagnosticar y predecir los riesgos de fallos que pueden llegar a ocurrir en las bombas del sistema de enfriamiento, dada su criticidad en la planta de producción de vidrio plano, cuyos objetivos específicos son:

- Desarrollar la arquitectura de autoaprendizaje y algoritmo de detección de daños utilizando redes neuronales de tipo supervisadas, y definir los parámetros o variables críticas de entrada a utilizar para la configuración de la red.
- Definir la metodología de medición y recolección de datos de los parámetros funcionales a tener en cuenta como información de entrada a la red y validar la funcionalidad de la red neuronal de detección con datos experimentales tomados por el departamento de ingeniería de la empresa
- Validar el modelo computacional propuesto.

Se desarrolló toda la metodología necesaria para llegar al cumplimiento tanto del objetivo general como de los objetivos específicos.

4.1 DEFINICIÓN DE PUNTOS DE MEDICIÓN

Se toma como objeto de estudio el sistema motor-bomba y dentro de este se analizará y procesará la información recopilada en las diferentes mediciones de vibraciones realizadas tanto en los puntos de medición del motor como los puntos de la bomba, la siguiente figura muestra la numeración y ubicación de los sitios donde se tomaron las diferentes mediciones.

Figura 28. Puntos de medición definidos.



4.2 DEFINICIÓN DE VARIABLES

Las variables vibracionales definidas a medir en cada uno de los puntos asociadas al sistema de estudio y que permiten detectar fallos como: daño en rodamientos motor-bomba, deficiencia de lubricación y roses, problema eléctrico – barras, soltura mecánica, problema de anclaje, desalineamiento, desbalanceo del impulsor, y problema de cavitación, son mostradas en la tabla 4.

Tabla 4. Definición de variables.

MOTOR									
PUNTO 1					PUNTO 2				
MI 01HE3 (gE) Envolvente Horizontal	MI 1HA Aceleración Horizontal	MI 01HFD (gHFD) High Frequency Detection	MI 01HV (mm/s) Velocidad Horizontal	MI 01AV (mm/s) Velocidad Axial	MI 01VV (mm/s) Velocidad Vertical	MI 02HE3 (gE) Envolvente Horizontal	MI 02HFD (gHFD) High Frequency Detection	MI 02HV (mm/s) Velocidad Horizontal	MI 02VV (mm/s) Velocidad Vertical
BOMBA									
PUNTO 3					PUNTO 4				
MI 03HE3 (gE) Envolvente Horizontal	MI 03HFD (gHFD) High Frequency Detection	MI 03HV (mm/s) Velocidad Horizontal	MI 03AV (mm/s) Velocidad Axial	MI 03VV (mm/s) Velocidad Vertical	MI 04HE3 (gE) Envolvente Horizontal	MI 04HFD (gHFD) High Frequency Detection	MI 04HV (mm/s) Velocidad Horizontal	MI 04HA Aceleración Horizontal	MI 04VV (mm/s) Velocidad Vertical

4.3 RECOPIACIÓN DE LA INFORMACIÓN

Los datos tomados para el desarrollo del presente modelo corresponden a la información recopilada durante un año de mediciones, teniendo en cuenta y realizando el tratamiento descrito en los fundamentos sobre análisis de vibraciones descritos en el capítulo 3, obteniendo como resultado los valores mostrados en las tablas 5 y 6.

Tabla 5. Mediciones del motor.

MOTOR									
PUNTO 1						PUNTO 2			
MI 01HE3 (gE) Envolvente Horizontal	MI 1HA Aceleración Horizontal	MI 01HFD (gHFD) High Frequency Detection	MI 01HV (mm/s) Velocidad Horizontal	MI 01AV (mm/s) Velocidad Axial	MI 01VV (mm/s) Velocidad Vertical	MI 02HE3 (gE) Envolvente Horizontal	MI 02HFD (gHFD) High Frequency Detection	MI 02HV (mm/s) Velocidad Horizontal	MI 02VV (mm/s) Velocidad Vertical
3.787	2.055	0.564	0.944	1.282	0.817	3.816	0.717	1.651	0.769
4.257	1.981	0.565	1.522	1.166	0.995	3.786	0.665	2.09	0.541
5.712	2.075	0.686	0.832	0.853	0.748	4.41	0.727	1.631	1.069
5.6	2.66	0.948	1.138	0.822	0.991	4.655	0.507	1.255	0.899
4.833	3.086	0.696	0.84	0.886	1.55	5.603	0.566	1.271	0.925
6.063	2.228	0.793	1.302	0.891	1.25	3.951	0.619	1.292	0.981
4.975	2.847	0.678	1.244	0.919	0.607	4.259	0.468	1.255	0.794
3.241	2.686	0.394	1.294	0.943	0.458	5.702	0.809	1.447	0.523

Tabla 6. Mediciones de la bomba.

BOMBA									
PUNTO 3					PUNTO 4				
MI 03HE3 (gE) Envolvente Horizontal	MI 03HFD (gHFD) High Frequency Detection	MI 03HV (mm/s) Velocidad Horizontal	MI 03AV (mm/s) Velocidad Axial	MI 03VV (mm/s) Velocidad Vertical	MI 04HE3 (gE) Envolvente Horizontal	MI 04HFD (gHFD) High Frequency Detection	MI 04HV (mm/s) Velocidad Horizontal	MI 04HA Aceleración Horizontal	MI 04VV (mm/s) Velocidad Vertical
4.268	0.873	5.12	1.695	2.599	5.334	1.417	3.694	1.581	1.632
3.91	0.811	5.161	2.186	2.997	4.933	1.246	3.991	1.399	1.743
4.03	1.078	8.055	2.181	5.831	4.302	1.266	5.616	1.601	3.314
4.056	1.617	2.534	1.576	1.605	4.946	1.972	2.583	1.813	1.48
4.641	0.935	1.989	1.375	1.438	5.194	1.088	1.215	1.404	1.421
3.541	1.821	1.609	1.011	1.986	4.285	2.669	1.744	2.037	1.198
4.53	1.059	2.328	2.197	1.74	6.449	1.019	0.764	1.563	1.136
3.937	0.987	2.152	2.561	1.65	4.058	1.083	0.731	1.463	1.056

4.4 DESCRIPCIÓN DE FALLOS

Teniendo en cuenta los principales modos de fallos encontrados en el sistema motor-bomba se clasifican y codifican, esta información será la salida que se espera sea entregada por la red neuronal.⁴¹

Tabla 7. Descripción de fallos.

DESCRIPCION DE FALLOS	
COD.	DESCRIPCION
B1	DAÑO RODAMIENTOS MOTOR
B2	DEFICIENCIA DE LUBRICACIÓN Y ROSES
B3	PROBLEMAS ELECTRICO - BARRAS
B4	SOLTURA MECANICA
B5	PROBLEMA DE ANCLAJE BASE
B6	DESALINEAMIENTO
B7	DESBALANCEO DEL IMPULSOR
B8	PROBLEMAS D ECAVITACIÓN
B9	DAÑO RODAMIENTOS BOMBA

4.5 DESCRIPCIÓN DE CATEGORÍAS

En la tabla 8 se puede observar las cuatro categorías utilizadas para el desarrollo del presente modelo, estas están asociadas a los puntos donde se realizaron las mediciones y serán las partes del sistema donde la red clasifique las fallas.

⁴¹ BORRÁS PINILLA, Carlos y STALFORD, Harold. Pattern recognition in hydraulic backlash using neural network. En: Proceedings of the 2002 American Control Conference (1: 8-10, mayo, 2002: Anchorage, USA). Anchorage, USA: IEEE, 2002, pp. 400-405.

Tabla 8. Categorías de fallas.

CATEGORIAS DE FALLOS	
1	PROBLEMAS EN MOTOR
2	PROBLEMAS EN BOMBA
3	PROBLEMAS EN MOTOR- BOMBA
4	SIN FALLAS

4.6 DESCRIPCIÓN DE VARIABLES DE ENTRADA

Las variables de entrada a la red son tomadas de las variables definidas anteriormente, son codificadas para facilitar el procesamiento por la red neuronal, corresponden a las 20 variables medidas en total tanto en los puntos del motor como de la bomba.

Tabla 9. Variables de entrada.

VARIABLES DE ENTRADA	
COD	DESCRIPCION
M1	Envolvente horizontal motor P1
M2	Aceleración horizontal motor P1
M3	HFD motor P1
M4	Velocidad horizontal motor P1
M5	Velocidad axial motor P1
M6	Velocidad vertical motor P1
M7	Envolvente horizontal motor P2
M8	HFD motor P2
M9	Velocidad horizontal motor P2
M10	Velocidad vertical motor P2
M11	Envolvente horizontal bomba P3
M12	HFD bomba P3
M13	Velocidad horizontal bomba P3
M14	Velocidad axial bomba P3
M15	Velocidad vertical bomba P3
M16	Envolvente horizontal bomba P4
M17	Aceleración horizontal bomba P4
M18	HFD bomba P4
M19	Velocidad horizontal bomba P4
M20	Velocidad vertical bomba P4

4.7 RELACIÓN CATEGORIAS - FALLOS

Hace referencia a la relación existente entre los modos de fallo y las partes del sistema donde se pueden llegar a presentar, corresponde al proceso interno que realiza la red de clasificación según los valores de entrada.

Tabla 10. Relación categorías-fallos.

RELACIÓN DE CATEGORIAS - FALLOS			
COD.	CATEGORIAS		FALLOS
1	1	PROBLEMAS EN MOTOR	B1, B2, B3, B4
2	2	PROBLEMAS EN BOMBA	B2, B7, B8, B9
3	3	PROBLEMAS EN MOTOR- BOMBA	B5, B6,
4	4	SIN FALLAS	

4.8 ARQUITECTURAS DE RED NEURONAL

Para el desarrollo del modelo de detección de fallas en sistema motor-bomba se estudiaron dos tipos de arquitectura de red neuronal: la red neuronal Perceptrón y la red neuronal alimentada hacia adelante (feedforward); las cuales fueron implementadas en el programa Matlab, utilizando la librería de redes neuronales del mismo.

4.10 RED NEURONAL PERCEPTRÓN

Es la red neuronal más sencilla, de una sola capa, empleada para clasificación binaria, la cual divide el espacio de entradas con una frontera lineal de decisión. La ventaja de esta red es que emplea una regla de aprendizaje sencilla. Para su

implementación se especificaron las salidas de la red como salidas binarias para cada una de las fallas, 1 si existe la falla y 0 si no, para un total de 9 salidas asociadas con las fallas.

Las cuatro categorías se identificaron mediante dos salidas binarias estandarizadas de la siguiente manera:

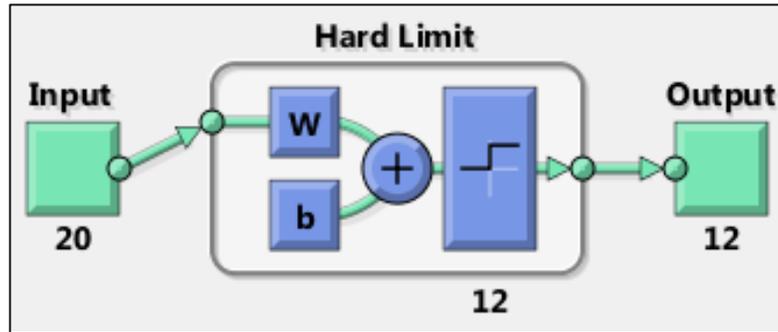
Tabla 11. Patrones de falla.

PATRÓN	CATEGORÍA DE FALLA
0 0	PROBLEMAS EN MOTOR
1 0	PROBLEMAS EN BOMBA
0 1	PROBLEMAS EN MOTOR- BOMBA
1 1	SIN FALLAS

Además, se colocó una salida adicional, para identificar si el sistema motor-bomba se encuentra en condición de alarma, es decir, si existe algún parámetro por encima de un valor límite crítico, que exige una intervención inmediata de mantenimiento del equipo.

Por lo tanto, el modelo que se diseñó, basado en red neuronal Perceptrón, tiene un total de 20 entradas y 12 salidas, como muestra la siguiente figura, empleando 12 neuronas para la capa oculta con función de activación Hard Limit.

Figura 29. Arquitectura red neural perceptrón.



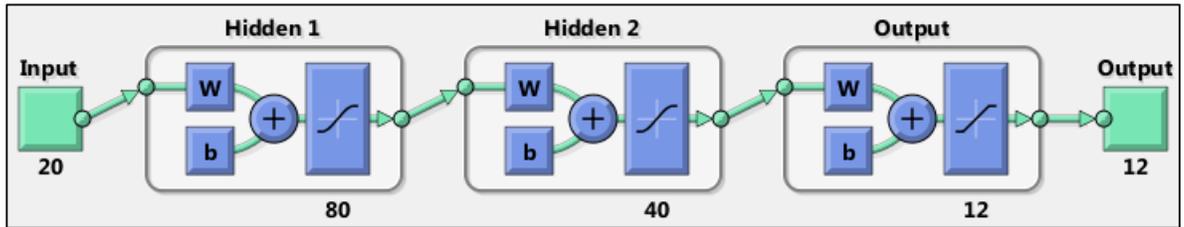
4.11 RED NEURONAL *FEEDFORWARD*

Consiste en una serie de capas, la primera capa tiene una conexión con la capa de entrada y cada una de las capas subsecuentes tiene conexión con la capa previa. La capa final produce la salida de la red neuronal. Una red feedforward con una capa oculta y suficientes neuronas en esta, puede ajustarse a cualquier problema finito de mapeo entrada – salida. Este tipo de red es entrenada por medio del algoritmo back propagation, el cual calcula los gradientes locales de cada neurona y gradualmente va ajustando sus pesos y byas para minimizar el error cuadrático.

Esta arquitectura emplea una función de activación de tipo tan-sigmoid para las capas ocultas y una función satlins para la capa de salida. Además, mediante código se aplicó una decisión booleana ($y_s = y_s \geq 0.5$;) para convertir la respuesta de la red neuronal a salida binaria de 0 y 1 con frontera de 0.5, es decir, si es mayor o igual a 0.5, lo convierte a 1 y si es menos lo convierte a 0.

La figura 30 muestra la arquitectura de red neuronal Multicapas, donde se muestra el número de neuronas pro cada capa usada, creada por el autor para clasificación y reconocimiento de patrones de fallas entrenados a la red.

Figura 30. Funciones de activación de la red Multicapas.



4.12 ENTRENAMIENTO DE LAS REDES NEURONALES

Para entrenar los dos modelos de predicción de fallas en sistemas motor-bomba basados en red neuronal artificial, se creó una base de datos en Excel, empleada para alimentar las redes neuronales, proporcionando un total de 82 patrones de entrenamiento, con sus correspondientes targets u objetivos. Cada patrón de entrenamiento con sus 20 valores de los puntos de medición y cada target con sus 12 valores de salida. Estos patrones automáticamente son divididos en unos patrones de entrenamiento y unos de prueba para validar el entrenamiento de la red neuronal.

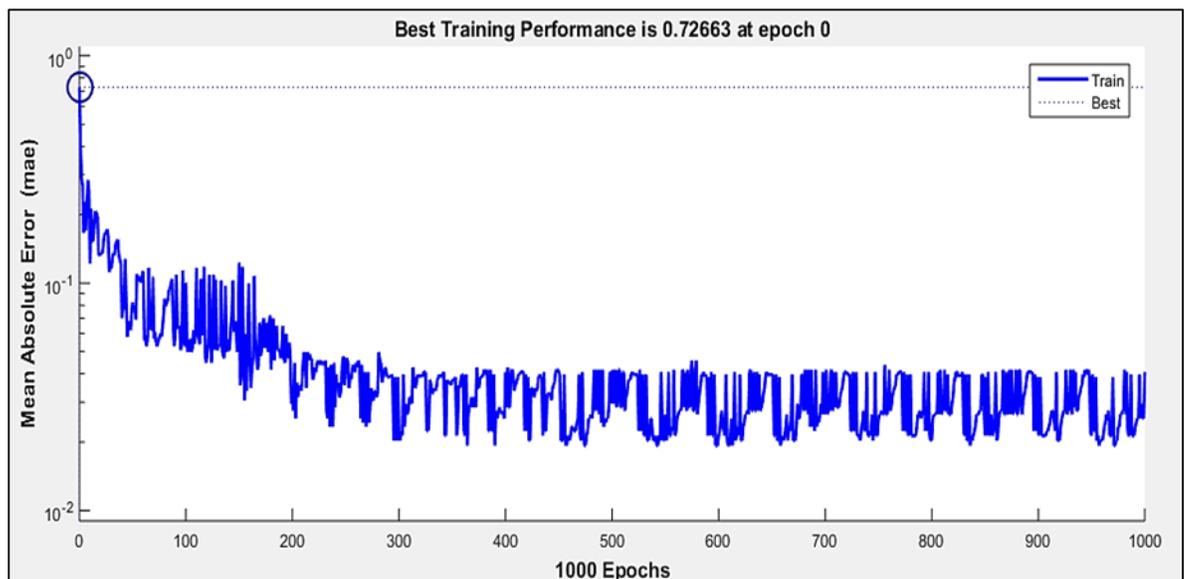
Normalización de datos: mediante código estos datos de entrenamiento fueron normalizados en un rango entre 0 y 1 para cada una de las 20 columnas de la base de datos, para mejorar el entrenamiento de la red neuronal y prevenir que unas columnas tengan más peso que otras al generar la salida de la red (ver código de programa de Matlab).

4.13 ENTRENAMIENTO RED NEURONAL PERCEPTRÓN

Al entrenar la red neuronal Perceptrón se observan que esta requiere de largo tiempo de entrenamiento y por más iteraciones que realice, no es capaz de llevar el

error a cero, requiriendo de las 1000 épocas que vienen por defecto en Matlab, para su entrenamiento. Sin embargo, esta red neuronal da muy buenos resultados. La figura siguiente muestra la evolución del entrenamiento de la red neuronal Perceptrón con un error final de alrededor de 0,05. [14],[20]

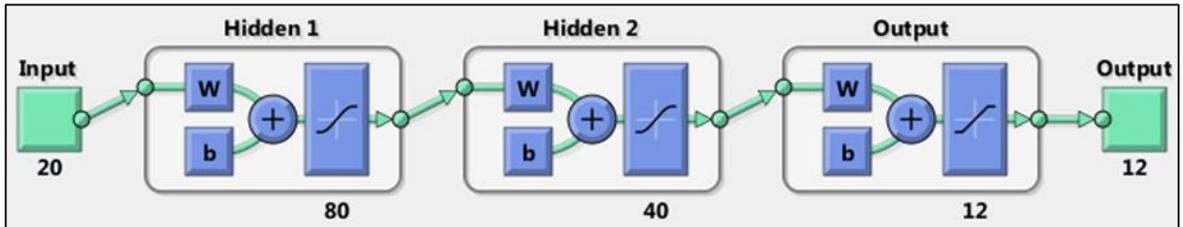
Figura 31. Evolución del entrenamiento red neuronal Perceptrón.



4.14 ENTRENAMIENTO RED NEURONAL *FEEDFORWARD*

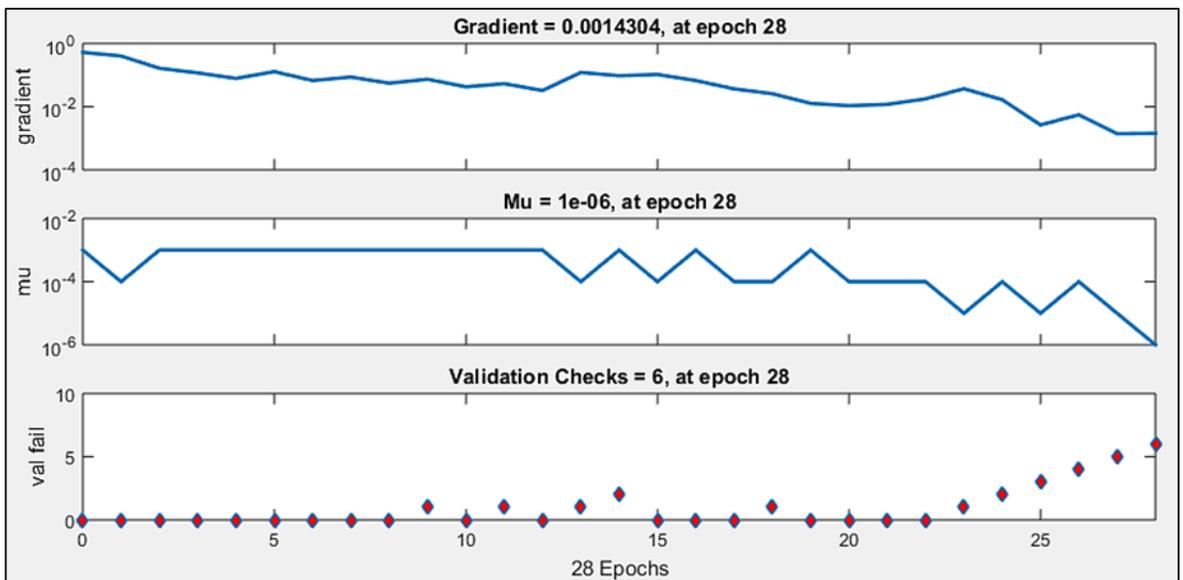
Para el entrenamiento de la red neuronal feedforward se realizaron pruebas con múltiples arquitecturas, variando tanto el número de capas ocultas de la red neuronal, como el número de neuronas por capa. Finalmente, con base en el desempeño de la red neuronal y un tiempo de entrenamiento prudencial, se escogió una arquitectura de cuatro capas: una capa de entrada de 20 neuronas, una primera capa oculta de 80 neuronas, una segunda capa oculta de 40 neuronas y una capa de salida de 12 neuronas. La figura muestra la arquitectura de la red neuronal empleada.

Figura 32. Arquitectura red neuronal feedforward.



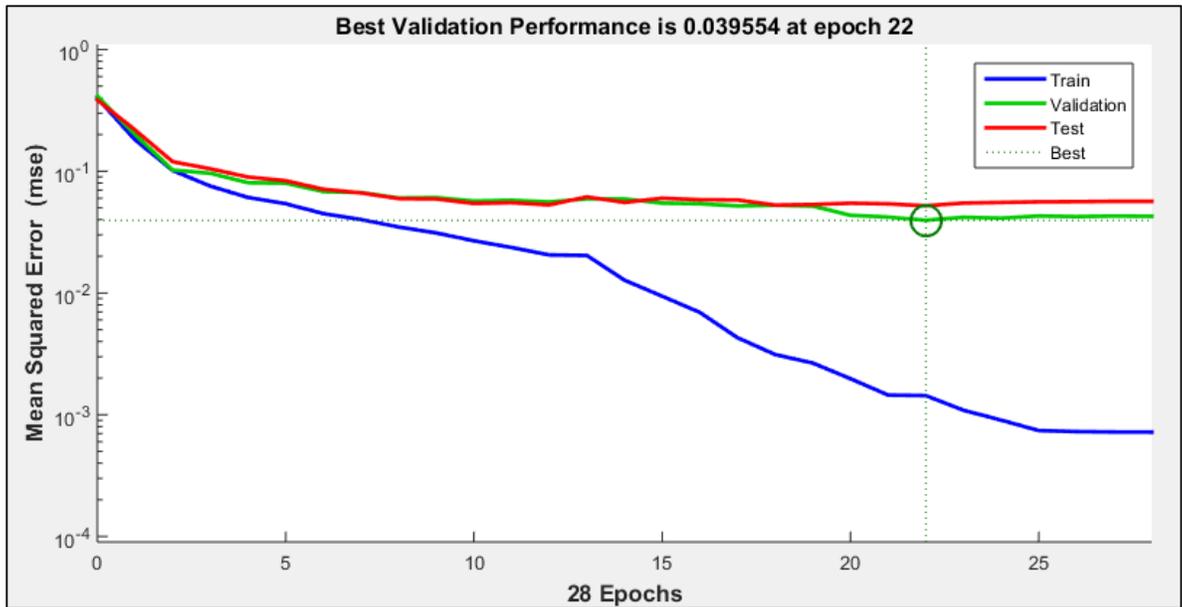
La figura 33 muestra la evolución del entrenamiento de la red neuronal feedforward, en la cual, el valor del gradiente se estabiliza alrededor de 10^{-3} , la variable Mu se estabiliza en 10^{-6} y se realiza la validación de la red. Cabe destacar que el número de épocas que requiere la red para realizar el entrenamiento y minimizar el error cuadrático mediante el algoritmo de back propagation es de 28 épocas.

Figura 33. Evolución del entrenamiento red neuronal Feedforward.



La figura 34 muestra la evolución del error cuadrático durante el entrenamiento, en el estado final el error de los patrones de entrenamiento es del orden de 10^{-3} , mejor que lo mostrado por la red neuronal Perceptrón.

Figura 34. Evolución del error cuadrático en el entrenamiento.



5. RESULTADOS

5.1 COMPARACIÓN DE LOS MODELOS DESARROLLADOS

Los dos modelos desarrollados tanto el correspondiente a la red perceptrón como el de red *feedforward* fueron puestos a prueba con cinco patrones de falla reales del sistema motor-bomba estudiado, seleccionados aleatoriamente, de los cuales ya se conocían las fallas previamente, para verificar su funcionamiento es decir la asertividad en el diagnóstico de las fallas. Los resultados obtenidos se muestran en la tabla comparativa 12.

Por lo tanto, en la prueba y validación de los modelos, se obtuvieron resultados idénticos para los dos tipos de red neuronal, Perceptrón y Feedforward, con excelentes respuestas ante los patrones de prueba, con error cero para las dos. Lo cual indica que el entrenamiento fue satisfactorio y los dos modelos funcionan correctamente.

Los dos modelos clasifican adecuadamente las categorías para cada uno de los patrones presentados y de igual forma diagnostican la falla presente dependiendo si es en el motor, la bomba o las fallas que pueden llegar a incidir sobre el conjunto motor – bomba, según los datos de entrada suministrados.

Tabla 12. Comparativo de las redes modelo.

PATRON	RED PERCEPTRON	RED FEEDFORWARD
1	<p>Command Window</p> <p>Categoría: 2. PROBLEMAS EN BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DESBALANCEO DEL IMPULSOR</p> <p>$f_x \gg$</p>	<p>Command Window</p> <p>Categoría: 2. PROBLEMAS EN BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DESBALANCEO DEL IMPULSOR</p> <p>$f_x \gg$</p>
	RESULTADO = OK - EROR = 0	RESULTADO = OK - EROR = 0
2	<p>Command Window</p> <p>;ALARMA!.. URGENTE!!</p> <p>Categoría: 3. PROBLEMAS EN MOTOR-BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR PROBLEMA DE ANCLAJE - BASE DESALINEAMIENTO DESBALANCEO DEL IMPULSOR</p> <p>$f_x \gg$ </p>	<p>Command Window</p> <p>;ALARMA!.. URGENTE!!</p> <p>Categoría: 3. PROBLEMAS EN MOTOR-BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR PROBLEMA DE ANCLAJE - BASE DESALINEAMIENTO DESBALANCEO DEL IMPULSOR</p> <p>$f_x \gg$ </p>
	RESULTADO = OK - EROR = 0	RESULTADO = OK - EROR = 0
3	<p>Command Window</p> <p>Categoría: 1. PROBLEMAS EN MOTOR</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR PROBLEMA ELÉCTRICO - BARRAS</p> <p>$f_x \gg$</p>	<p>Command Window</p> <p>Categoría: 1. PROBLEMAS EN MOTOR</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR PROBLEMA ELÉCTRICO - BARRAS</p> <p>$f_x \gg$</p>
	RESULTADO = OK - EROR = 0	RESULTADO = OK - EROR = 0
4	<p>Command Window</p> <p>Categoría: 3. PROBLEMAS EN MOTOR-BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR DEFICIENCIA DE LUBRICACIÓN Y ROSES</p> <p>$f_x \gg$ </p>	<p>Command Window</p> <p>Categoría: 3. PROBLEMAS EN MOTOR-BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR DEFICIENCIA DE LUBRICACIÓN Y ROSES</p> <p>$f_x \gg$ </p>
	RESULTADO = OK - EROR = 0	RESULTADO = OK - EROR = 0
5	<p>Command Window</p> <p>Categoría: 3. PROBLEMAS EN MOTOR-BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DESALINEAMIENTO DAÑO EN RODAMIENTOS - BOMBA</p> <p>$f_x \gg$</p>	<p>Command Window</p> <p>Categoría: 3. PROBLEMAS EN MOTOR-BOMBA</p> <p>SE RECOMIENDA REALIZAR MANTENIMIENTO PREVENTIVO DEL EQUIPO</p> <p>Descripción de fallas: DAÑO EN RODAMIENTOS - MOTOR DEFICIENCIA DE LUBRICACIÓN Y ROSES</p> <p>$f_x \gg$ </p>
	RESULTADO = OK - EROR = 0	RESULTADO = OK - EROR = 0

5.2 ANÁLISIS DE RESULTADOS

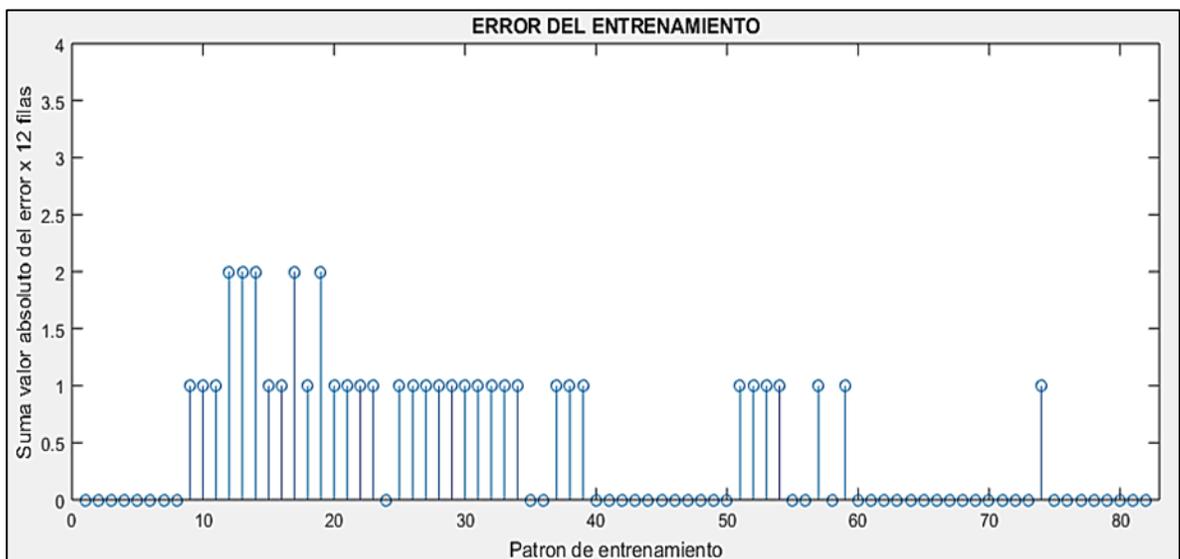
Para evaluar los resultados de los dos tipos de red neuronal, Perceptrón y Feedforward, se calculó la sumatoria del valor absoluto del error, entre los resultados generados por la red neuronal y los targets ($\sum |y_s - t|$). Esta sumatoria se realizó para cada uno de los 82 patrones de entrenamiento, sumando los errores

de las doce salidas binarias de la red neuronal. Además, mediante la variable `error_total`, se calculó la sumatoria del error total para las dos redes.

La Figura 35 muestra la sumatoria del error de cada uno de los patrones de entrenamiento para la red neuronal Perceptrón. Con una sumatoria de error total de 40 unidades, sobre los 984 datos (82x12), es decir, un porcentaje de error del 4,07 %.

$$\%error = \frac{40}{984} * 100 = 4,07\%$$

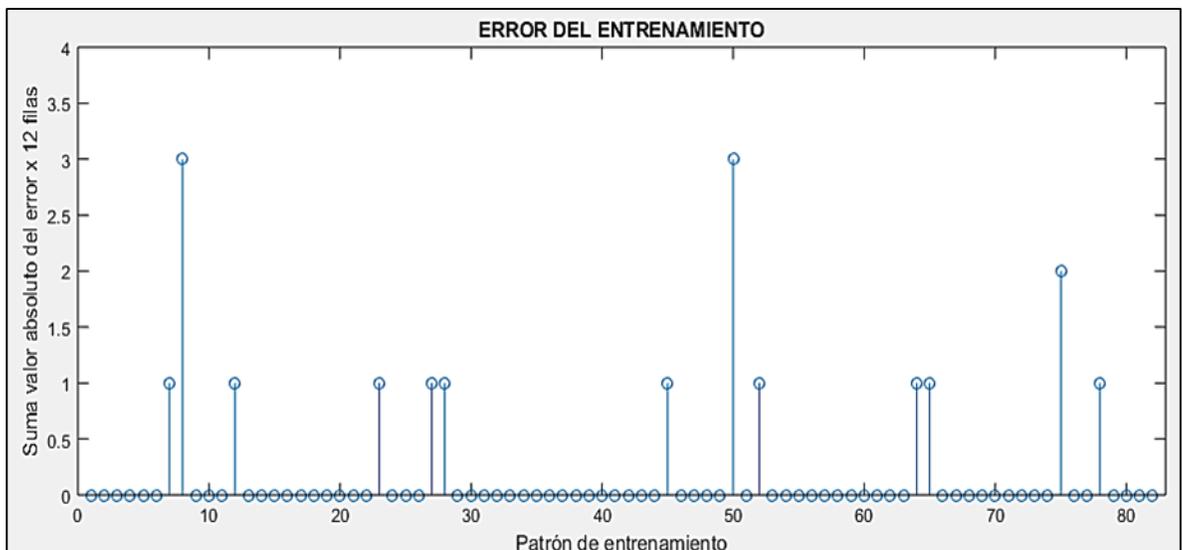
Figura 35. Error por patrón de entrenamiento – red neuronal Perceptrón.



Por otro lado, la figura 36 muestra la sumatoria del error de cada uno de los patrones de entrenamiento para la red neuronal Feedforward. Con una sumatoria de error total de 18 unidades, sobre los 984 datos (82x12), es decir, un porcentaje de error del 1,83 %.

$$\%error = \frac{18}{984} * 100 = 1,83\%$$

Figura 36. Error por patrón de entrenamiento – red neuronal Feedforward.



5.3 VALIDACIÓN DEL MODELO

Se tomó la red neuronal feedforward por presentar un mejor comportamiento dentro de la etapa de desarrollo y comparación con la red perceptrón para validar nuevos datos y verificar que está en capacidad de diagnosticar fallas según la información de nuevos valores, la tabla 13 muestra los datos utilizados, en tabla 14 están los tipos de fallo y características, posteriormente, en las figuras 37 a 44 se muestran los comportamientos de clasificación según los vectores de entrada.

Tabla 13. Datos validación red Feedforward.

MODOS Fallos	Salida RED NN Y1	Salida RED NN Y2	Salida RED NN Y3	Salida RED NN Y4	Salida RED NN Y5	Salida RED NN Y6	Salida RED NN Y7	Salida RED NN Y8
B1	0.00	0.00	1.00	1.00	1.00	1.00	0.00	1.00
B2	0.00	0.00	0.00	1.00	0.00	1.00	0.00	0.00
B3	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.00
B4	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
B5	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
B6	0.00	1.00	1.00	0.00	0.00	0.00	1.00	1.00
B7	1.00	1.00	1.00	0.00	0.00	0.00	0.00	1.00
B8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
B9	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
CATA	0.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
CATB	1.00	1.00	1.00	1.00	0.00	1.00	1.00	1.00
ALARM	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00

Tabla 14. Resumen modos de fallo y categorías.

MODOS FALLOS
B1='DAÑO EN RODAMIENTOS - MOTOR
B2='DEFICIENCIA DE LUBRICACIÓN Y ROCES
B3='PROBLEMA ELÉCTRICO - BARRAS
B4='SOLTURA MECÁNICA
B5='PROBLEMA DE ANCLAJE - BASE
B6='DESALINEAMIENTO
B7='DESBALANCEO DEL IMPULSOR
B8='PROBLEMA DE CAVITACIÓN
B9='DAÑO EN RODAMIENTOS - BOMBA
CAT A=1 & CAT B=0 : PROBLEMAS MOTOR
CAT A=0 & CAT B=1 : PROBLEMAS BOMBA
CAT A=1 & CAT B=1 : PROBLEMAS MOTOR-BOMBA
CAT A=0 & CAT B=0 : SIN FALLAS
ALARM=1.0 ACTIVADA.

Figura 37. Test 1.

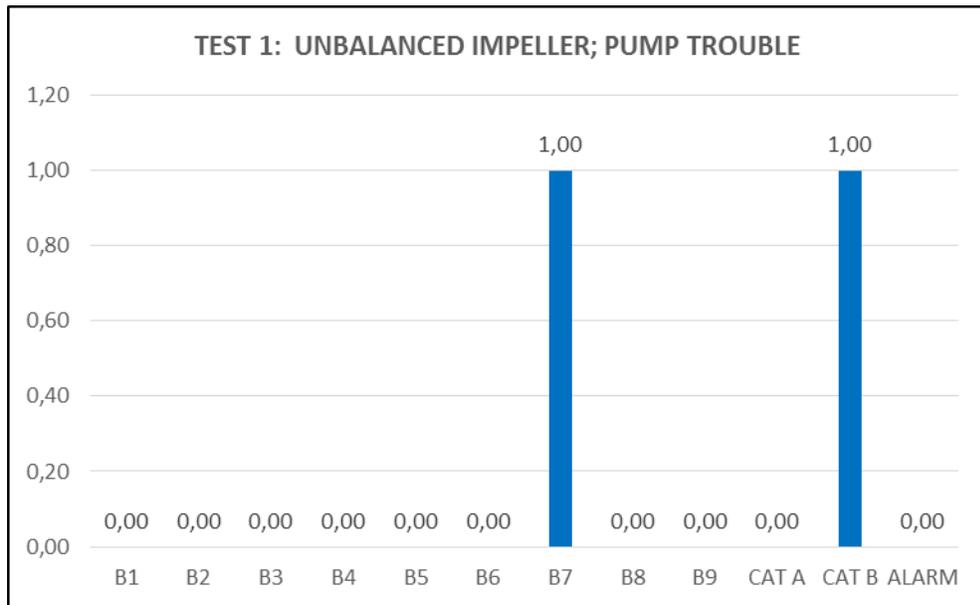


Figura 38. Test 2.

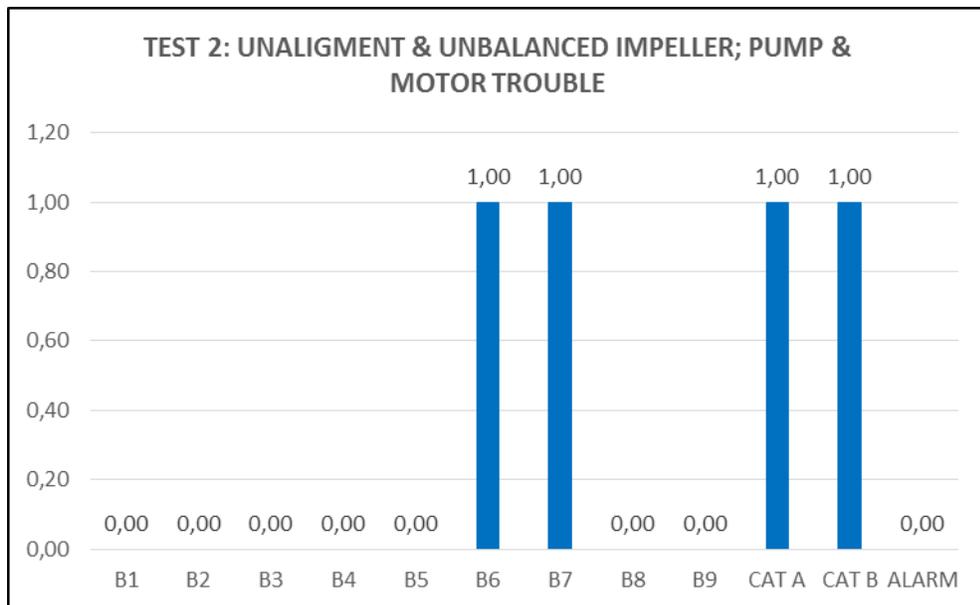


Figura 39. Test 3.

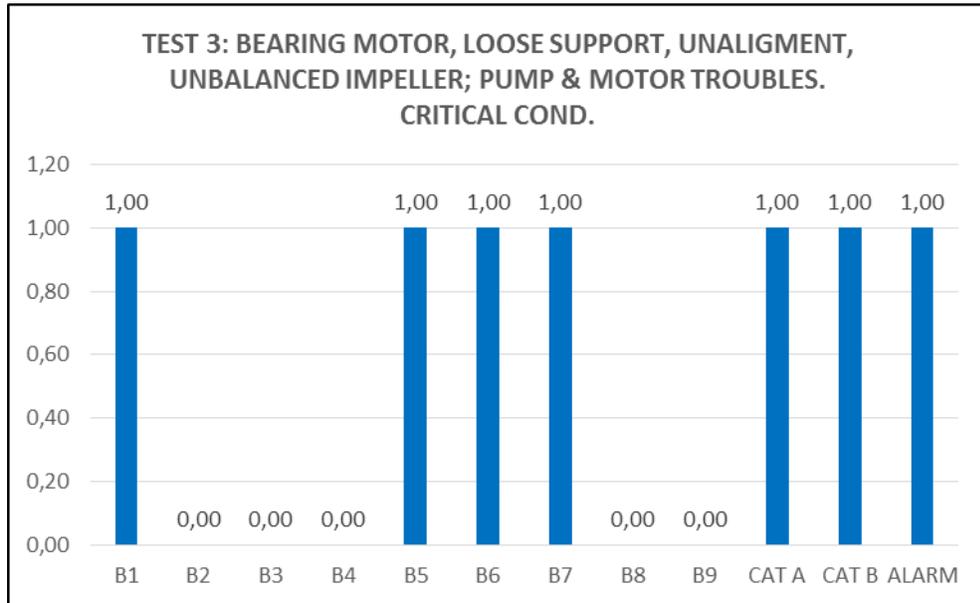


Figura 40. Test 4.

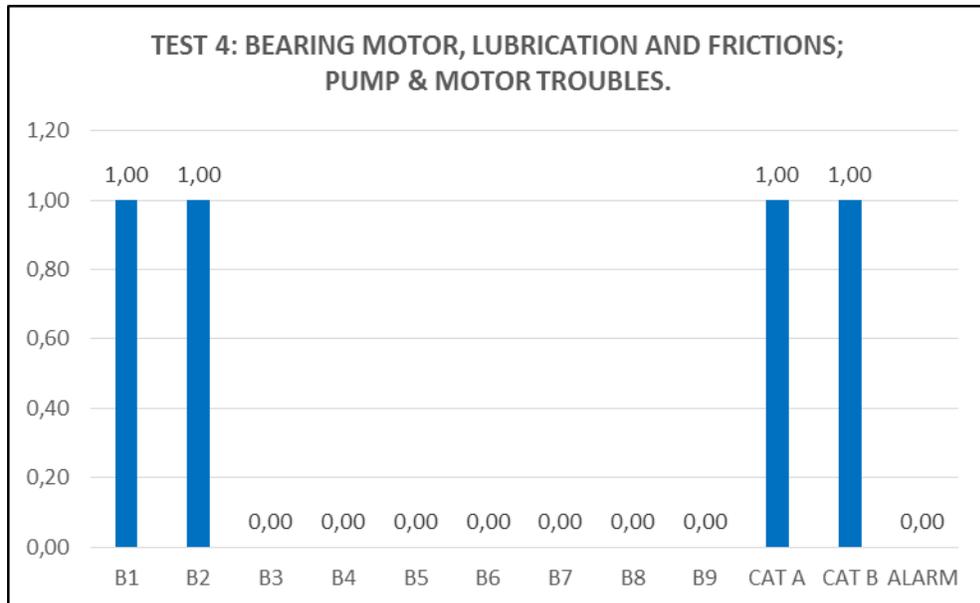


Figura 41. Test 5.

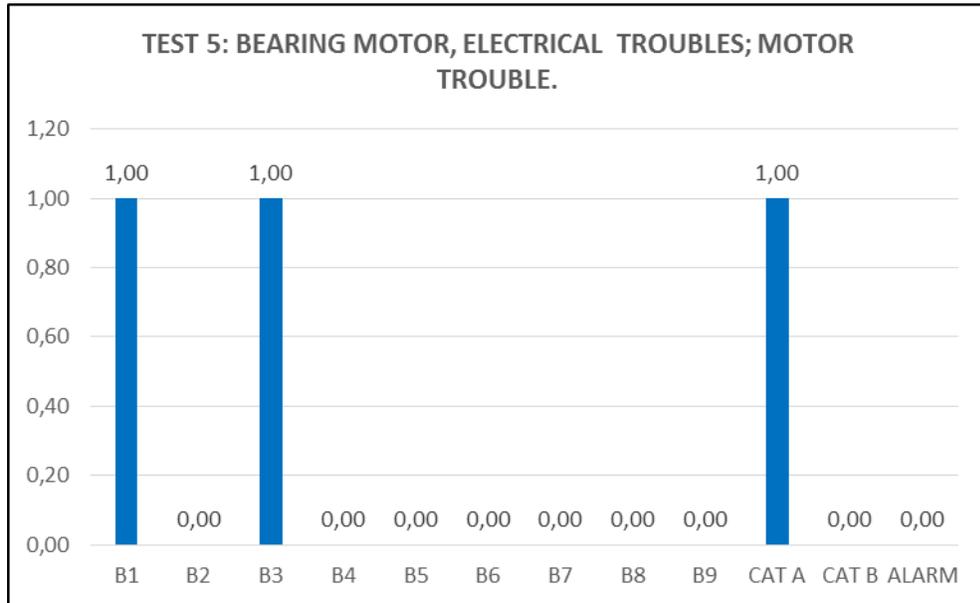


Figura 42. Test 6.

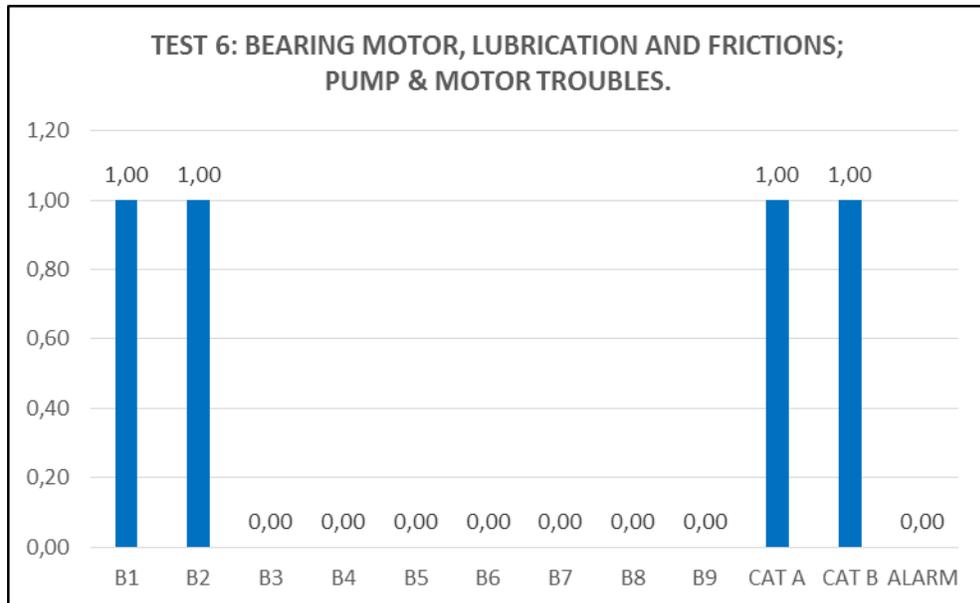


Figura 43. Test 7.

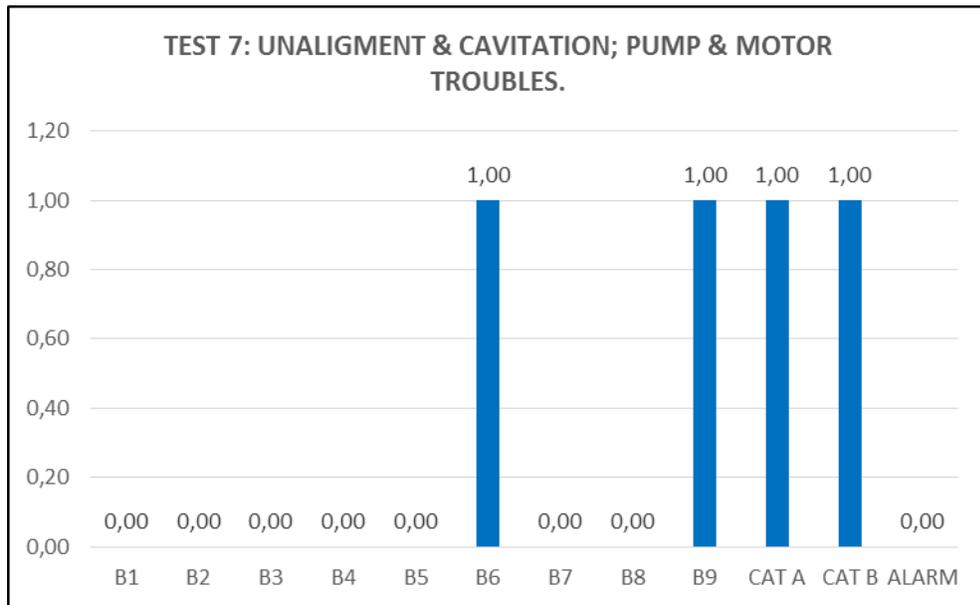
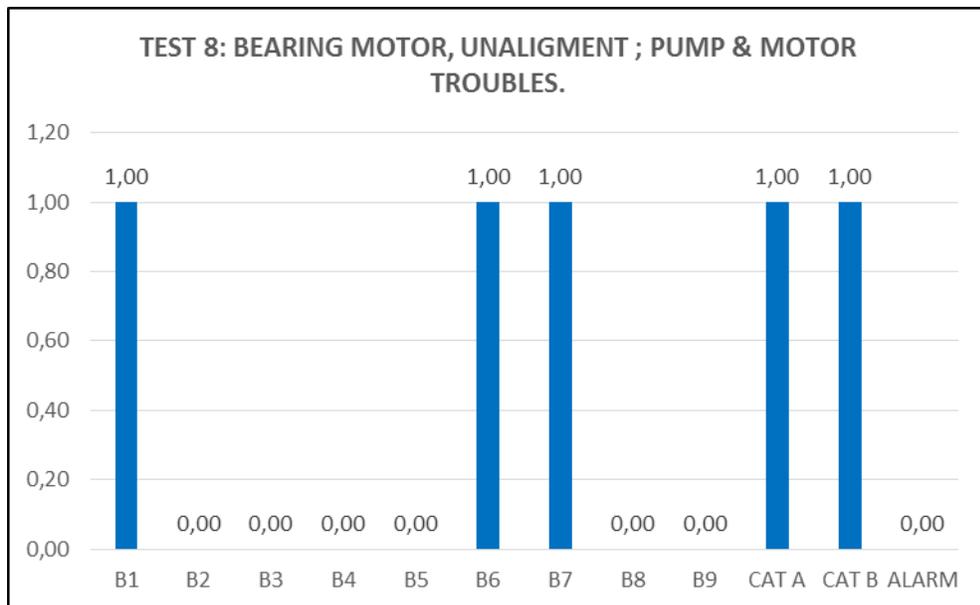


Figura 44. Test 8.



6. CONCLUSIONES

En términos generales, los resultados obtenidos mediante los dos tipos de red neuronal Perceptrón y Feedforward, son bastante similares en cuanto a un porcentaje de error total de la red bajo, sin embargo, la red neuronal feedforward genera mejores resultados, cometiendo únicamente 18 errores sobre los 984 datos totales, para un porcentaje de error del 1,83%; frente al 4,07% de la red neuronal Perceptrón, que presentó 40 errores.

Por otro lado, observando las figuras 35 y 36, se podría decir que el error en la red neuronal Perceptrón es un poco más estable y constante que en la red neuronal Feedforward, con un máximo de errores por patrón de dos, los cuales se pueden presentar o en la detección de la falla o en la detección de la categoría o en la alarma. Mientras que la red neuronal Feedforward muestra un comportamiento un poco más inestable, presentando picos de tres errores o más, para algunos patrones. Además, al realizar diferentes entrenamientos de la red neuronal Feedforward, el error es variable; contrario a la red Perceptrón que siempre da el mismo resultado. Además, podría darse el caso de que aumente el error al introducir valores nuevos, reales, diferentes a los utilizados en el entrenamiento de la red.

Por lo tanto, se pueden utilizar cualquiera de las dos redes neuronales, Perceptrón y Feedforward, para la implementación del modelo de predicción de fallas en el sistema motor-bomba, o aún mejor, emplearlos ambos, uno como soporte del otro para verificación de los resultados obtenidos del modelo.

Es muy importante resaltar que de acuerdo a lo visto durante el proceso desarrollado en el capítulo cuatro y el análisis de los resultados en el capítulo cinco, efectivamente se puede confirmar que las redes neuronales artificiales si pueden ser utilizadas como una técnica avanzada para el diagnóstico de fallos en equipos rotativos.

Durante el desarrollo de las diferentes etapas del proyecto se pudo constatar que las redes neuronales artificiales atadas a una gran técnica predictiva como es el análisis de vibraciones mecánicas pueden llevar la gestión de las áreas de mantenimiento a otra dimensión muy superior, ya que permiten realizar con gran exactitud diagnósticos del estado de las partes de las máquinas e intervenirlas en el momento adecuado, para enfocarse en los elementos que presentan deterioro o que pueden llegar a provocar una parada abrupta de los equipos.

Como se pudo corroborar durante el desarrollo de los objetivos propuestos, las arquitecturas de redes neuronales artificiales del perceptrón o del feedforward se puede utilizar en el diagnóstico de fallos e inclusive realizando algunas modificaciones a los algoritmos poder además de conocer los elementos que presentan desgastes o deterioros, poder llegar a predecir el tiempo en que estos fallarán y así poder optimizar la planeación de las intervenciones, mejorando indicadores claves como la confiabilidad, la disponibilidad y la mantenibilidad.

Con el presente proyecto pudo confirmarse que la combinación de técnicas predictivas como el análisis de vibraciones mecánicas o inclusive las termografías con redes neuronales artificiales de clasificación o predicción abren una gran ventana a lo que se podría llamar como la automatización de la gestión de mantenimiento, de gran importancia en la actualidad debido al alto grado de

automatización de los procesos y de la exigencia por la optimización de los recursos, la reducción de las paradas o intervenciones sobre los equipos y la afectación sobre el costo de los productos por parte de las áreas de mantenimiento.

BIBLIOGRAFÍA

ADEMINSA COLOMBIA S.A.S. Carta ilustrada de diagnóstico de vibración, tablas de Charlotte. Bogotá: La compañía. 2016.

A-MAQ S.A. Tutorial de vibraciones mantenimiento mecánico. [En línea]. Medellín: La compañía, 2005. 41 p. Consultado el 02 de febrero de 2017]. Disponible en: http://www.mantenimientoplanificado.com/art%C3%ADculos%20PREDICTIVO_archivos/CURSO%20A%20MAQ.COM.pdf

BALLESTEROS, Alfonso. Neural Networks Framework. [En línea]. [Consultado el: 20 de enero de 2017]. Disponible en: <http://www.redes-neuronales.com.es/index.htm>

BASOGAIN, Xabier. Redes neuronales artificiales y sus aplicaciones. [En línea]. Bilbao: El autor. 79 p. [Consultado el: 5 de febrero de 2017]. Disponible en: http://www.ciberesquina.una.edu.ve:8080/2014_2/350_E.pdf

BORRÁS PINILLA, Carlos. Material docente de la asignatura Técnicas Avanzadas en Mantenimiento. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Físico-mecánicas, Escuela de Ingeniería Mecánica. Maestría en Gerencia de Mantenimiento, 2016. 194 p.

_____ . Pattern recognition in hydraulic cylinders with backlash using neural network. Tesis de maestría. Oklahoma: University of Oklahoma. School of Aerospace and Mechanical Engineering, 2001, 113 p.

BORRÁS PINILLA, Carlos y STALFORD, Harold. Pattern recognition in hydraulic backlash using neural network. En: Proceedings of the 2002 American Control Conference (1: 8-10, mayo, 2002: Anchorage, USA). Anchorage, USA: IEEE, 2002, pp. 400-405.

DÁVILA, Esteban, et al. Perceptrón Simple. [En línea]. [Consultado el: 22 de enero de 2017]. Disponible en: <https://prezi.com/i4m0jqipqrgj/perceptron-simple/>

FAUSETT, Laurence. Fundamentals of Neural Networks. New Jersey, USA: Prentice Hall International, 1994. 296 p. ISBN 013-04225-0-9

HAGAN, Martin, et al. Neural Network Design, Second Edition. Oklahoma, USA: El autor, 2014. 1012 p. ISBN 097-17321-1-6

INTERNATIONAL ORGANIZATION FOR STANDARIZATION. Mechanical Vibration - Evaluation of Machine Vibration by Measurements on non-rotating parts - General Guidelines. ISO 10816-1. Ginebra, Suiza: El Instituto, 1995. 24 p.

_____ . Condition monitoring and diagnostics of machines -
Vibration condition monitoring - General procedures. ISO 13373-1. Ginebra, Suiza:
El Instituto, 2002. 51 p.

ISERMANN, Rolf. Fault-Diagnosis Systems. Berlín, Alemania: Springer-Verlag,
2006. 475 p. ISBN 978-3-540-24112-6

LIU, Jinkun. Radial Basis Function (RBF) Neural Network Control for Mechanical
Systems. Berlín, Alemania: Springer-Verlag, 2013. 365 p. ISBN 978-3642-43455-6

MARADEY, Jessica; BORRÁS, Carlos y ROA, Sebastián. A Survey of Approaches
For Fault Diagnosis In Axial Piston Pumps. ASME 2016 – International Mechanical
Engineering Congress and Exposition (4: 11, noviembre, 2016: Tampa, USA:
ASME). Tampa, USA: ASME, 2016, pp. 52-65.

MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. [En
línea]. Rosario, Argentina: Universidad Tecnológica Nacional. Facultad Regional
Rosario. Departamento de Ingeniería Química, 2001. 55 p. [Consultado el: 25 de
febrero de 2017]. Disponible en:
https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monografias/matich-redesneuronales.pdf

MOORE, Holly. Matlab para ingenieros. México: Pearson educación, 2007. 624 p.
ISBN 978-970-26-1082-3.

MOSQUERA, Genaro; PIEDRA, Margarita y ARMAS, Raúl. Las vibraciones mecánicas y su aplicación al mantenimiento predictivo. Caracas: Universidad Central de Venezuela. Consejo de Desarrollo Científico y Humanístico. Instituto Superior de Ciencias y Tecnologías Nucleares, 2000. 226 p. ISBN 980-07-5678-7.

MUHAMAD, Abd Kadir; SHARIFAH, Saon y HIYAMA, Takashi. Predicting remaining useful life of rotating machinery based artificial neural network. [En línea]. En: ELSEVIER, Computer and Mathematics with Applications, 2010, vol. 60, no. 4, pp. 1078 - 1087. [Consultado el: 28 de enero de 2017]. Disponible en: <https://core.ac.uk/download/pdf/82394785.pdf>

OROZCO, David. Aproximación del uso de redes neuronales en mantenimiento. [En línea]. Trabajo de Grado Maestría en Ingeniería. Medellín: Universidad EAFIT. Escuela de Ingeniería. Departamento de Ingeniería Mecánica, 2013. 151 p. [Consultado el: 12 de febrero de 2017]. Disponible en: https://repository.eafit.edu.co/bitstream/handle/10784/2856/David_OrozcoAlvarez_2013.pdf?sequence=1

OVIEDO, Silvia; QUIROGA, Jabid y BORRÁS, Carlos. Experimental evaluation of motor current signature and vibration analysis for rotor broken bar detection in an induction motor. En: 2011 International Conference on Power Engineering, Energy and Electrical Drives (1: 11-13, mayo, 2011: Malaga, España). Malaga, España: IEEE, 2011, pp. 1 - 6.

_____ . Motor current signature analysis and negative sequence current based stator winding short fault detection in an induction motor. En: DYNA. 2011, vol. 78, nro. 170, pp. 214 – 220. ISSN 0012-7353.

PALOMINO, Evelio. La medición y el análisis de vibraciones en el diagnóstico de máquinas rotativas. [En línea]. La Habana, Cuba: Centro de Estudios Innovación y Mantenimiento, 1997. 113 p. [Consultado el: 20 de febrero de 2017]. Disponible en: http://grupovirtus.org/moodle/pluginfile.php/5510/mod_resource/content/1/Documentos/Analisis_de_Vibraciones_en_Maquinarias_rotatorias.pdf

PALUSZEK, Michael y THOMAS, Stephanie. MATLAB Recipes: A Problem Solution Approach. New Jersey, USA: Apress, 2015. 297 p. ISBN 978-14842056-0-0

PÉREZ, Jesús. Herramienta MATLAB para la selección de entradas y predicción neuronal de valores de bolsa, Volumen 1. [En línea]. Trabajo de Grado Ingeniería de Telecomunicaciones. Sevilla: Universidad de Sevilla. Departamento de Ingeniería de Sistemas y Automática, 2013. 144 p. [Consultado el: 12 de febrero de 2017]. Disponible en: <http://bibing.us.es/proyectos/abreproy/12166/direccion/Volumen+1++Memoria+descriptiva+del+proyecto%252F>

PRUFTECHNIK. Tutoriales Análisis de Vibraciones. [En línea]. Barcelona: La compañía, 2017. [Consultado el 20 de enero de 2017]. Disponible en: <http://blog.pruftechnik.es/unidades-de-vibracion-para-el-analisis-de-vibraciones-mecanicas/>

RAJAKARUNAKARAN, Sivaprakasam, et al. Artificial neural network approach for fault detection in rotary system. [En línea]. En: ELSEVIER, Applied Soft Computing, 2008, vol. 8, no. 1, pp. 740 - 748. [Consultado el: 29 de enero de 2017]. Disponible en:
<https://pdfs.semanticscholar.org/af7f/248874290c2ca62d9579cb52c25fc9ea0459.pdf>

SINAIS. Curso de vibraciones. [En línea]. Pontevedra, España: La empresa. [Consultado el 25 de enero de 2017]. Disponible en: <http://www.sinais.es/curso-vibraciones.html>

UNIVERSIDAD DE NAVARRA. Vibraciones en máquinas. Mantenimiento predictivo. [En línea]. Navarra: Universidad de Navarra. Departamento de Ingeniería Mecánica, Energética y de Materiales. 54 p. [Consultado el: 28 de enero de 2017]. Disponible en: http://www.imem.unavarra.es/EMyV/pdfdoc/vib/vib_predictivo.pdf

VILLADA, Fernando; MUÑOZ, Wilson y HENAO, María. Aplicación de las redes neuronales a la ingeniería y economía. [En línea]. Medellín: Universidad de Antioquia. 15 p. [Consultado el: 5 de febrero de 2017]. Disponible en: <http://studyres.es/doc/465024/aplicaciones-de-las-redes-neuronales-en-la-ingenier%C3%ADa-y-l...>