



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL**

**“Detección de barras rotas y fallas en los rodamientos en motores de
inducción mediante inteligencia artificial y análisis de corrientes”**

AUTOR: TOSCANO RECALDE, DAVID SEBASTIÁN

DIRECTOR: ING. CARRERA ERAZO, ENRIQUE VINICIO

SANGOLQUÍ

2019

CERTIFICACIÓN



DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

CERTIFICACIÓN

Certifico que el trabajo de titulación, "*DETECCIÓN DE BARRAS ROTAS Y FALLAS EN LOS RODAMIENTOS EN MOTORES DE INDUCCIÓN MEDIANTE ANÁLISIS DE CORRIENTES E INTELIGENCIA ARTIFICIAL*" realizado por el señor *Toscano Recalde, David Sebastián*, el mismo que ha sido revisado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, Mayo 2019

Firma:

Ing. Enrique Vinicio Carrera Erazo

C. C. 1708792109

AUTORÍA DE RESPONSABILIDAD



DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

AUTORÍA DE RESPONSABILIDAD

Yo, *Toscano Recalde, David Sebastián*, declaro que el contenido, ideas y criterios del trabajo de titulación: "*Detección de barras rotas y fallas en los rodamientos en motores de inducción mediante inteligencia artificial y análisis de corrientes*" es de mi autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Consecuentemente el contenido de la investigación mencionada es veraz.

Sangolquí, Mayo 2019

Firma:

David Sebastián Toscano Recalde

c.c.: 1724071673

AUTORIZACIÓN



DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES

CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

AUTORIZACIÓN

Yo, *Toscano Recalde, David Sebastián* autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: “*Detección de barras rotas y fallas en los rodamientos en motores de inducción mediante inteligencia artificial y análisis de corrientes*”, en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, Mayo 2019

Firma



David Sebastián Toscano Recalde

c.c.: 1724071673.....

DEDICATORIA

Ya estuve harto, sentí la presión y el fracaso pero también el éxito, pienso en todo lo que tuve que hacer y pasar, y ahora que el tiempo ha pasado encuentro todo aquello tan entretenido, sí, hubieron muchos momentos duros y aspectos en los que pude mejorar, pero a pesar de todo, lo hice a siempre a mi manera, guiado por mis fuertes principios y apoyado por las personas que me rodean. Dedico esta tesis de grado a mi familia a quienes amo con toda la fuerza de mi corazón.

David Sebastián Toscano Recalde

AGRADECIMIENTOS

Agradezco a mis padres David Toscano y Sandra Recalde, que me apoyaron y a quienes yo, de igual manera, apoyaré hasta el final.

Agradezco a mis hermanos, Fernanda y Panchito, quienes me vieron crecer y a quienes yo vi crecer y madurar de igual manera.

Agradezco a mis amigos con lo que he compartido grandes experiencias y de los cuales he aprendido mas de ellos de lo que seguramente ellos de mí.

Agradezco a la universidad de las fuerzas armadas y a los docentes que tuve la oportunidad de conocer y especialmente quienes supieron inspirarme para convertirme en quien ahora soy.

Agradezco al Ing. Danny Sotomayor que me permitió utilizar sus equipos para realizar el presente trabajo.

Agradezco al Ing. Vinicio Carrera que supo guiarme concisa y claramente como director de tesis.

David Sebastián Toscano Recalde

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN	i
AUTORÍA DE RESPONSABILIDAD	ii
AUTORIZACIÓN	iii
DEDICATORIA	iv
AGRADECIMIENTOS	v
ÍNDICE DE CONTENIDOS	vi
ÍNDICE DE TABLAS	ix
ÍNDICE DE FIGURAS	xi
LISTADO DE ABREVIATURAS	xiii
RESUMEN	xiv
ABSTRACT	xv
CAPÍTULO 1: INTRODUCCIÓN	1
1.1 ANTECEDENTES.....	1
1.1 JUSTIFICACIÓN.....	4
1.2 ALCANCE DEL PROYECTO	5
1.3 OBJETIVOS	9
1.3.1 Objetivo General.....	9
1.3.2 Objetivos Específicos.....	9
CAPITULO 2: FUNDAMENTACIÓN TEÓRICA	10
2.1 MOTORES DE INDUCCIÓN	10
2.1.1 Partes constitutivas.....	11
2.1.2 Principio de funcionamiento	14
2.1.3 Deslizamiento	14
2.1.4 Velocidad síncrona.....	15
2.1.5 Relación velocidad sincrónica y número de polos	16
2.1.6 Características Velocidad - Par	16
2.2 FALLAS EN MOTORES DE INDUCCIÓN	17
2.2.1 Falla de barras rotas	18
2.2.2 Falla en los rodamientos	21
2.3 APRENDIZAJE DE MAQUINA.....	23

2.3.1 Redes neuronales artificiales.....	24
2.3.2 K-means	30
2.3.3 Mapas auto-organizados	32
CAPÍTULO 3: METODOLOGÍA.....	41
3.1 TOMA DE DATOS	42
3.1.1 Recopilación de información	42
3.1.2 Selección de longitud de la señal y frecuencia de muestreo	43
3.1.3 Método de adquisición de datos.....	43
3.2 OBTENCIÓN DE LOS VECTORES.....	45
3.2.1 Selección de características en el tiempo	45
3.2.2 Selección de características en frecuencia	46
3.3 DETECCIÓN BASADA EN REDES NEURONALES.....	47
3.3.1 Selección de parámetros fundamentales	48
3.3.2 Selección y evaluación.....	48
3.4 DETECCIÓN BASADA EN K-MEANS.....	49
3.4.1 Selección de parámetros para el agrupamiento K-means.....	50
3.4.2 Selección y evaluación.....	50
3.5 DETECCIÓN BASADA EN SOM.....	50
3.5.1 Selección de los parámetros para el agrupamiento SOM.....	51
3.5.2 Selección y evaluación.....	52
CAPITULO 4: RESULTADOS	54
4.1 TOMA DE DATOS.....	54
4.1.1 Recopilación de información	54
4.1.2 Definición de las características de las señales de corriente	56
4.1.3 Adquisición de datos.....	57
4.2 OBTENCIÓN DE LOS VECTORES	58
4.2.1 Selección de características en tiempo	59
4.2.2 Selección de características de frecuencia para barras rotas	59
4.2.3 Selección de características de frecuencia para falla en rodamientos	62
4.3 DETECCIÓN BASADA EN REDES NEURONALES.....	65
4.3.1 Selección y evaluación.....	65
4.3.2 Evaluación final de desempeño.....	67
4.4 DETECCIÓN BASADA EN K-MEANS.....	68
4.4.1 Selección y evaluación.....	68
4.4.2 Evaluación final de desempeño.....	70

4.5 DETECCIÓN BASADA EN SOM.....	70
4.5.1 Selección y evaluación.....	70
4.4.2 Evaluación final de desempeño.....	74
4.4 COMPARACIÓN DE DESEMPEÑO.....	75
CAPITULO 5: CONCLUSIONES Y RECOMENDACIONES.....	77
5.1 CONCLUSIONES	77
5.2 RECOMENDACIONES	78
5.3 TRABAJOS FUTUROS	79
REFERENCIAS	81
ANEXO	87
ANEXO A: DETALLE DE LA METODOLOGÍA PARA LA SELECCIÓN DE K/P	87
ANEXO B: DETALLE DE LA METODOLOGÍA PARA LA SELECCIÓN DE LA WAVELET	87
ANEXO C: CÓDIGO DEL DETECTOR PERCEPTRÓN MULTICAPA	87
ANEXO D: CÓDIGO IMPLEMENTADO DE K-MEANS.....	87
ANEXO E: CÓDIGO DEL DETECTOR BASADO EN K-MEANS.....	87
ANEXO F: CÓDIGO DEL ALGORITMO DE MAPAS AUTOORGANIZADOS	87
ANEXO G: CÓDIGO DEL DETECTOR BASADO EN MAPAS AUTO-ORGANIZADOS	87

ÍNDICE DE TABLAS

Tabla 1 <i>Parámetros elegidos para el algoritmo de mapas auto organizados en la fase de ordenamiento</i>	51
Tabla 2 <i>Parámetros elegidos para el algoritmo de mapas auto organizados en la fase de convergencia</i>	52
Tabla 3 <i>Especificaciones técnicas importantes sobre el motor</i>	54
Tabla 4 <i>Especificaciones técnicas relevantes sobre los rodamientos</i>	55
Tabla 5 <i>Especificaciones técnicas relevantes sobre la pinza amperimétrica usada.</i>	55
Tabla 6 <i>Especificaciones relevantes sobre el equipo de adquisición de datos</i>	56
Tabla 7 <i>Máximo nivel de descomposición recomendado según la wavelet madre seleccionada utilizando el comando “wmaxlev” de matlab para un número de muestras de 100K.....</i>	57
Tabla 8 <i>Descripción de los vectores de entrada seleccionados para la evaluación del desempeño final de los algoritmos.....</i>	59
Tabla 9 <i>Posibles bandas de interés para la caracterización de falla de barras rotas.....</i>	60
Tabla 10 <i>Valores definidos para determinar las frecuencias asociadas a la falla en la pista externa del rodamiento</i>	63
Tabla 11 <i>Valores definidos para determinar las frecuencias asociadas a la falla en la pista externa del rodamiento</i>	63
Tabla 12 <i>Desempeño obtenido según la wavelet madre seleccionada</i>	64
Tabla 13 <i>Tiempo de cómputo para las diferentes condiciones de interés en las cuales se evaluó el algoritmo de redes neuronales</i>	66

Tabla 14 <i>Evaluación final de desempeño del algoritmo de redes neuronales</i>	67
Tabla 15 <i>Evaluación final de desempeño del algoritmo de detección basado en K-means</i>	70
Tabla 16 <i>Configuración de topologías de red propuestas para ser evaluadas</i>	71
Tabla 17 <i>Evaluación final de desempeño del algoritmo de detección basado en K-means</i>	75
Tabla 18 <i>Comparación del desempeño final obtenido por los algoritmo planteados</i>	75
Tabla 19 <i>Comparación la desviación estandar obtenido por los algoritmo planteados</i>	76

ÍNDICE DE FIGURAS

Figura 1. División de los métodos de detección de fallas en motores de inducción	2
Figura 2. Simulación de barras rotas en el rotor	6
Figura 3. Simulación de falla de rodamientos	7
Figura 4. Generador DC para la simulación de carga	7
Figura 5. Partes de un motor jaula de ardilla.....	11
Figura 6. Estator y rotor de un motor de inducción.....	11
Figura 7. Rotor de un motor de inducción antes (derecha) y después (izquierda) de la añadidura química de las laminas	12
Figura 8. Estructura de un rodamiento	13
Figura 9. Gráfica par-velocidad de un motor de inducción típico	17
Figura 10. Descripción de un rodamiento y sus partes y mediciones relevantes.	22
Figura 11. Capas de una red neuronal.....	26
Figura 12. Topologías de red utilizadas como mapas en el algoritmo SOM.....	33
Figura 13. Función de vecindad, considerando $\sigma = 1$. (a) Función gaussiana, (b) función sombrero mexicano, (c) función triangular, (d) función rectangular.....	35
Figura 14. Funciones de tasa de aprendizaje (a) exponencial y (b) lineal vs número de época .	36
Figura 15. Descripción de la metodología planteada	41
Figura 16. Circuito diseñado para la simulación de carga.	44
Figura 17. Especificidad vs sensibilidad para diferentes bandas asociadas a la falla de barras rotas utilizando el algoritmo de detección basado en K-means	61

Figura 18. <i>Especificidad vs sensibilidad para diferentes bandas asociadas a la falla de barras rotas utilizando el algoritmo de detección basado en SOM.</i>	61
Figura 19. <i>Especificidad vs sensibilidad para diferentes bandas asociadas a la falla de barras rotas utilizando el algoritmo de redes neuronales</i>	62
Figura 20. <i>Especificidad vs sensibilidad del algoritmo de redes neuronales para diferentes tasas de aprendizaje y numero de neuronas en la capa intermedia</i>	66
Figura 21. <i>Especificidad vs número de agrupamientos para diferentes valores de sensibilidad permitida utilizando el algoritmo de detección basado en K-means</i>	68
Figura 22. <i>Especificidad vs Sensibilidad, utilizando K-means con 3 agrupamientos</i>	69
Figura 23. <i>Especificidad y Sensibilidad vs “M” utilizando K-means con 3 agrupamientos</i>	69
Figura 24. <i>Especificidad y Sensibilidad vs número de nodos en el mapa para distintas configuraciones de red utilizando el algoritmo de detección basado en SOM considerando una sensibilidad de mínimo 100%</i>	71
Figura 25. <i>Especificidad y Sensibilidad vs número de nodos en el mapa para distintas configuraciones de red utilizando el algoritmo de detección basado en SOM considerando una sensibilidad de mínimo 99.8%</i>	72
Figura 26. <i>Especificidad y Sensibilidad vs número de nodos en el mapa para distintas configuraciones de red utilizando el algoritmo de detección basado en SOM considerando una sensibilidad de mínimo 99.6%</i>	72
Figura 27. <i>Evaluación final del desempeño del algoritmo basado en SOM utilizando una configuración de red de “1 por 50”</i>	73
Figura 28. <i>Especificidad y sensibilidad vs parámetros de diseño del algoritmo de detección de anomalías basado en SOM</i>	74

LISTADO DE ABREVIATURAS

SOM	Mapas auto-organizados
BMU	Mejor unidad coincidente (por sus siglas en inglés “ <i>Best Matching Unit</i> ”)
RNA	Redes neuronales artificiales
DWT	Transformada wavelete discrete (por sus siglas en inglés “ <i>Discrete Wavelet Transform</i> ”)
FT	Transformada de Fourier
MCSA	Análisis de corrientes del motor (por sus siglas en inglés “ <i>Major signature current analysis</i> ”)
PCA	Análisis de componentes principales (por sus siglas en inglés “ <i>Principal Component Analysis</i> ”)
SVM	Maquinas de vectores soporte (por sus siglas en inglés “ <i>support vector machine</i> ”)
PLS	Minimos cuadrados parciales (por sus siglas en inglés “ <i>partial least squares</i> ”)
FL	Lógica difusa (por sus siglas en inglés “ <i>Fuzzy logic</i> ”)
WPD	Descomposición wavelet (por sus siglas en inglés “ <i>Wavelet Packet Decomposition</i> ”)
RMS	Media cuadrática (por sus siglas en inglés “ <i>Root Square Mean</i> ”)
DAC	Conversor análogo digital (por sus siglas en inglés “ <i>Digital-analog Converter</i> ”)

RESUMEN

Los motores de inducción “jaula de ardilla” son los más utilizados actualmente, estos pueden llegar a consumir más del 60% de la energía producida por una nación, por ello existe un énfasis en el estudio de técnicas de mantenimiento preventivo. Una de las variables físicas preferidas para el diagnóstico es la corriente por su naturaleza de medición no invasiva; usualmente se necesita de un experto en mantenimiento para analizar el espectro de la señal y realizar el diagnóstico, sin embargo este experto se puede sustituir por algoritmos de aprendizaje de máquinas. Desafortunadamente el diseño de estos algoritmos se dificulta ya que se necesitan de datos del motor con falla, sin embargo existen estrategias de detección de anomalías basados en algoritmos de aprendizaje no supervisado que solo necesitan datos del motor sin falla para el entrenamiento. El objetivo del presente documento es comparar el desempeño obtenido por dos algoritmos (K-means y SOM) que solo necesitan datos del motor sin falla para su entrenamiento con el desempeño obtenido por un algoritmo (redes neuronales) cuyo entrenamiento necesita de datos etiquetados de motores con y sin falla. Los resultados muestran que la detección de barras rotas y fallas en la pista exterior de los rodamientos se pueden diagnosticar exitosamente mediante SOM, cuyo desempeño es muy ligeramente menor al de RNA.

PALABRAS CLAVE:

- **DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN.**
- **APRENDIZAJE DE MÁQUINAS.**
- **BARRAS ROTAS.**
- **FALLA EN RODAMIENTOS.**

ABSTRACT

Squirrel cage induction motors are the most used, they can consume more than 60% of the electrical energy produced by a nation, and hence there is an emphasis on the study of preventive maintenance techniques. One of the preferred physical variables for diagnosis is the current by its non-invasive measurement nature; usually a maintenance expert is necessary in order to analyze the signal's spectrum and perform the diagnosis, nevertheless this expert can be replaced by a learning machine algorithm. Unfortunately the design of these algorithms is difficult since they need data of the motor with failure; however, there are strategies to detect abnormalities based on unsupervised learning algorithms that only need data tagged of the motor without failure for training. The objective of this document is to compare the performance obtained by two algorithms (K-means and SOM) whose training only needs data tagged of the motor without failure to the performance obtained by an algorithm (neural networks) whose training needs data tagged of the motor with and without failure. The results show that the detection of broken bars and the bearing defect on outer race can be successfully diagnosed by SOM, whose performance is very slightly lower than that obtained by RNA.

PALABRAS CLAVE:

- **INDUCTION MOTOR FAULT DETECTION.**
- **LEARNING MACHINE.**
- **BROKER BARS.**
- **BEARING DEFECTS.**

CAPÍTULO 1: INTRODUCCIÓN

1.1 ANTECEDENTES

Es conocido que los motores de inducción dominan el campo de la conversión de energía electromecánica. Estas máquinas encuentran un amplio rol en la mayoría de las industrias: mineras, petroquímicas, manufactureras, entre otras, así como en equipos aeroespaciales y militares. Por lo tanto, la evaluación de las condiciones de funcionamiento y la fiabilidad de estos sistemas de accionamiento son cruciales para evitar fallas inesperadas y catastróficas. En consecuencia, el mantenimiento preventivo y el diagnóstico no invasivo de la condición de estos es una gran preocupación. Actualmente los métodos de detección y diagnóstico de fallas de motores se pueden dividir en tres categorías principales: basados en modelos, basados en señales y basados en conocimiento (Ince, Kiranyaz, Eren, Askar, & Gabbouj, 2016) como se detalla en la *Figura 1*.

Los métodos basados en modelos utilizan modelos matemáticos que describen las condiciones normales de funcionamiento de los motores de inducción (Giantomassi, Ferracuti, Iarlori, Ippoliti, & Longhi, 2015). En estos métodos, los algoritmos de diagnóstico de fallas se desarrollan para monitorear la consistencia entre los resultados medidos de los sistemas prácticos y los resultados pronosticados por el modelo (Gao, Cecati, & Ding, 2015). La principal ventaja de un método basado en modelos es que el diagnóstico de fallas es sencillo si los coeficientes del modelo tienen un mapeo uno a uno con los coeficientes físicos (Gao & Dai, 2013). Sin embargo la implementación práctica de estos métodos es poco factible ya que se basan en una serie de suposiciones (Soualhi, Clerc, & Razik, 2013).

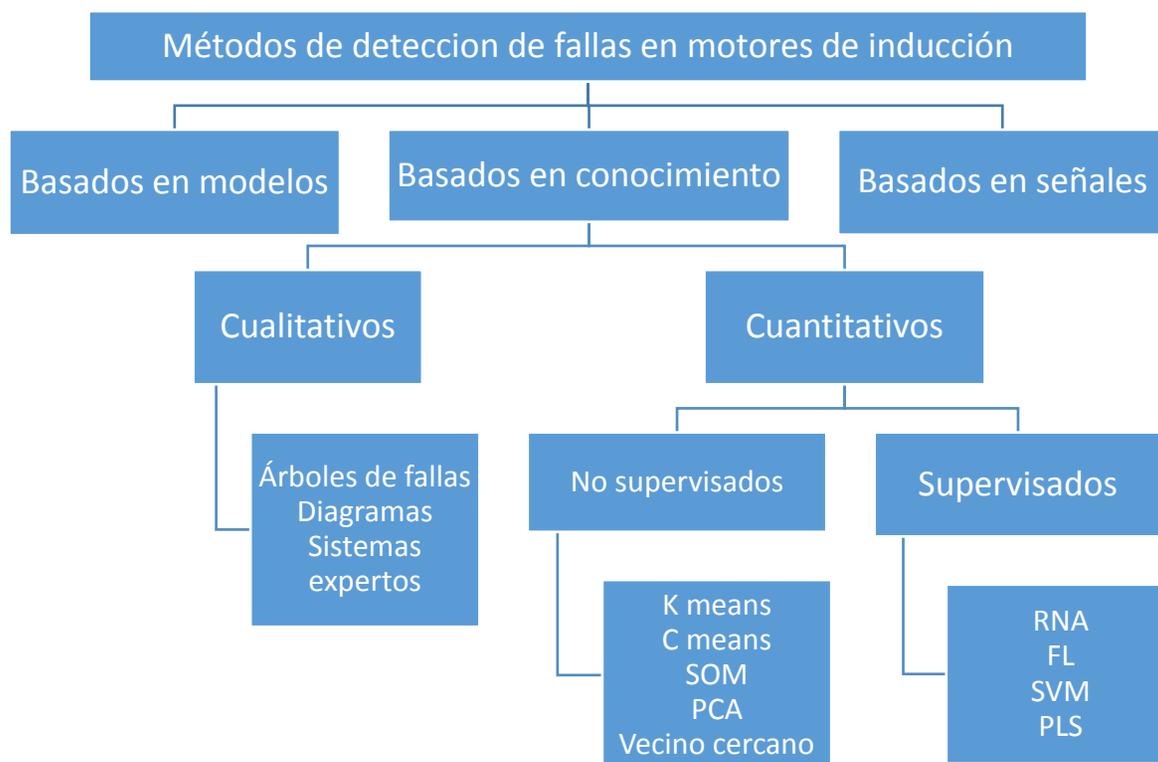


Figura 1. División de los métodos de detección de fallas en motores de inducción

Por otro lado, los métodos basados en señales usualmente emplean una de las cuatro clases principales de técnicas de procesamiento de señales (Filippetti, Bellini, & Capolino, 2013): análisis de dominio de tiempo (Zarei & Poshtan, 2007), (Kral, Habetler, & Harley, 2004), análisis de dominio de frecuencia (Soualhi et al., 2013), (Kliman, Premerlani, Yazici, Koegl, & Mazereeuw, 1997), análisis de frecuencia mejorado (Pons-Llinares et al., 2015), (D. Z. Li, Wang, & Ismail, 2015), y técnicas de análisis de tiempo y frecuencia (L. Eren & Devaney, 2003), (Wang & He, 2007) . Los sistemas basados en señales no requieren un modelo explícito o completo del sistema, pero su rendimiento puede degradarse cuando se trabaja en una condición desconocida o desequilibrada. Dentro de estos métodos se han propuesto diferentes formas de diagnóstico basadas en la medición de diferentes magnitudes físicas: vibraciones, temperatura, parámetros

electromagnéticos del motor, señales de corriente del motor, entre otros; básicamente estos métodos comparan el valor de sus variables medidas hasta que el valor sea poco usual, por ejemplo realizar termografías de los motores periódicamente hasta encontrar que la temperatura de un motor es elevada o medir las corrientes de cada fase del motor hasta detectar un comportamiento anormal en su magnitud, en alguna componente de su espectro, entre otros.

Los sistemas basados en conocimiento básicamente están sustentados en algoritmos de inteligencia artificial, y al igual que los métodos basados en señales utilizan técnicas de análisis en el tiempo y/o frecuencia; caracterizan a las señales de las diferentes magnitudes físicas medidas, por ejemplo la corriente, la vibración, el torque, entre otros (Widodo, Yang, & Han, 2007), (Widodo & Yang, 2007) y se realiza la detección mediante un algoritmo clasificador o detector de fallas. Estos sistemas basados en el conocimiento pueden dividirse en dos grupos: métodos cualitativos basados en inteligencia simbólica y métodos cuantitativos basados en inteligencia de aprendizaje automático (Gao & Dai, 2013). Los métodos cualitativos incluyen árboles de fallas, diagramas y sistemas expertos, mientras que los métodos cuantitativos tienen sistemas de aprendizaje no supervisados como K-medias, C-medias, vecino más cercano, análisis de componentes principales (PCA) y mapas auto organizados (SOM), y sistemas de aprendizaje supervisado con redes neuronales artificiales (ANN), lógica difusa (FL), máquinas de vectores soporte (SVM), mínimos cuadrados parciales (PLS); el desempeño de estos métodos recae en gran parte a las variables de entrada seleccionadas para el algoritmo (Benbouzid & Kliman, 2003).

1.1 JUSTIFICACIÓN

Los motores de inducción son la forma más común de convertir la energía eléctrica en energía mecánica. Consumen más del 60% de la energía eléctrica producida y están presentes en las principales aplicaciones industriales (Cusidó, Romeral, Ortega, Rosero, & Espinosa, 2008). Consecuentemente se necesitan técnicas efectivas de detección y diagnóstico de fallas para reducir los costos de mantenimiento y del tiempo de inactividad de los motores (Seera, Lim, Ishak, & Singh, 2012).

Lastimosamente a nivel del Ecuador se mantienen métodos antiguos como análisis por temperatura, ya que, como se cita en (Farag, Lin, Habetler, & Schlag, 1995): “Los métodos tradicionales basados en el análisis de corrientes necesitan de un experto en mantenimiento que analice los datos del motor en línea recopilados para determinar si el espectro medido es lo suficientemente diferente del de un buen motor para indicar la presencia de una falla.”, sin embargo esta diferenciación y clasificación se pueden realizar mediante algoritmos de inteligencia artificial.

Ya en el campo, el motor trabaja en diferentes condiciones como cargas cíclicas, desbalanceo mecánico u oscilaciones de torque, entre otros que pueden ocasionar efectos similares a los efectos que producen las fallas en las corrientes, así que un método general de detección basado en un modelo único no es viable, de esta forma se debe considerar cuales son las características normales de funcionamiento de cada motor y a partir de estas realizar la comparación y detección.

No obstante es necesario un método que posea la capacidad de aprendizaje, por ello se pretende usar un método de aprendizaje no supervisado ya que su principal ventaja con respecto a un método de aprendizaje supervisado es que no se necesita colocar etiquetas en los datos para que se pueda deducir un determinado patrón o función a partir de estos, y este es el principio fundamental en la metodología que se pretende usar en este proyecto y que se utiliza en (Depren, Topallar, Anarim, & Ciliz, 2005), en la cual se usa una estrategia de detección de anomalías.

Dentro del marco legal, este proyecto se sustenta en el Plan Nacional de Desarrollo 2017 – 2021 – Toda una Vida, instaurado en noviembre de 2017, el cual manifiesta que: se mantendrá un manejo macroeconómico adecuado y transparente, con énfasis en la producción y comercialización de bienes de alto valor agregado, que sostengan la liquidez financiera para el desarrollo con equidad territorial.

Los objetivos del Plan Nacional de Desarrollo 2017-2021 a los que se acoge este trabajo son los 4to y 5to, que son respectivamente: “Consolidar la sostenibilidad del sistema económico, social y solidario y afianzar la dolarización”, e “Impulsar la productividad y competitividad para el crecimiento sostenible, de manera redistributiva y solidaria”.

1.2 ALCANCE DEL PROYECTO

Se toma en cuenta dos tipos de fallas: fallas en los rodamientos y falla de barras rotas. Se realiza la medición de las señales de corriente del motor trifásico. Se debe considerar que:

Para medir las corrientes se utiliza 1 pinza amperimétrica y una tarjeta de adquisición de datos NI cDAQ-9184.

Para medir las corrientes del motor sin fallas se utilizará un motor trifásico ABB de 1HP en buen estado del que se dispone.

Para simular la falla de barra rota, se cuenta con un segundo rotor idéntico al que tiene el motor trifásico ABB pero perforado dos de sus barras, como se muestra en la **Figura 2**, el cual se procede a sustituir con el rotor en buen estado para luego realizar las medidas, de manera que el único componente defectuoso del motor sea el rotor.



Figura 2. Simulación de barras rotas en el rotor
Fuente: (Granda, Arcos-aviles, & Sotomayor, 2018).

Para simular la falla en rodamientos, se cuenta con un segundo rodamiento idéntico al que tiene el motor trifásico, pero perforado en uno de sus anillos, como se muestra en la **Figura 3**, el cual se procede a sustituir con el rodamiento original para luego realizar las medidas, de tal manera que el único componente defectuoso del motor sea el rodamiento.

Para simular los diferentes niveles de carga se cuenta con generador DC el cual está acoplado al eje del motor y un reóstato de potencia conectado como carga del generador como se muestra en la **Figura 4**.

La medición se realiza con el motor en estado estacionario y con torque constante.

El motor funciona alimentado energéticamente por la red eléctrica trifásica, en otras palabras, no se usa variador de frecuencia.



Figura 3. Simulación de falla de rodamientos
Fuente: (Zarei & Poshtan, 2007)



Figura 4. Generador DC para la simulación de carga
Fuente: (Granda et al., 2018).

Una vez con las señales del motor ya adquiridas, se emplean técnicas de análisis en el dominio del tiempo y/o frecuencia con el fin de determinar los parámetros de entrada del algoritmo.

Para la implementación del detector se usarán dos técnicas de aprendizaje no supervisado: K-means y SOM, ya que son técnicas que han demostrado un gran alcance práctico y son ampliamente utilizadas.

Para la evaluación del detector se usa otro detector basado en aprendizaje supervisado que sirve como línea base, se usa la técnica de redes neuronales ya que es una de las más utilizadas por su gran alcance práctico.

En otras palabras, en el algoritmo de detección basado en aprendizaje no supervisado se usa solo datos del motor sin fallas para la fase de aprendizaje pero para la fase de validación se usarán datos etiquetados del motor con y sin falla, y para la implementación del algoritmo de detección basado en aprendizaje supervisado, que sirve como línea base, se utilizarán datos de motor con y sin fallas para la fase de aprendizaje y la fase de validación.

Se aclara que para la evaluación del desempeño del detector no es necesario que el algoritmo basado en técnicas de aprendizaje no supervisado logre clasificar sino solo detectar fallas ya que la detección es lo fundamental de la línea base de comparación y que los diferentes algoritmos son programados en el software Matlab.

1.3 OBJETIVOS

1.3.1 Objetivo General

Implementar un algoritmo basado en técnicas de aprendizaje no supervisadas para la detección de fallas en los rodamientos y fallas de barras rotas en motores de inducción mediante análisis de corrientes.

1.3.2 Objetivos Específicos

- Obtener las señales de corriente del motor en las diferentes condiciones de interés y a varios niveles de cargas de forma segura y fiable para su uso posterior.
- Extraer características mediante el análisis en el dominio del tiempo y/o frecuencia para determinar las variables de entrada del algoritmo.
- Implementar el algoritmo de detección mediante el uso de técnicas de aprendizaje no supervisadas para la posterior comparación.
- Comparar el algoritmo de detección con un algoritmo basado en técnicas de aprendizaje supervisado para evaluar su desempeño.

CAPITULO 2: FUNDAMENTACIÓN TEÓRICA

En este capítulo se presenta el contexto teórico para la comprensión de los capítulos posteriores, se revisa teoría sobre motores de inducción y sus fallas para plantear correctamente las características que sirven como entradas para los algoritmos en el próximo capítulo. Posteriormente se revisa el contexto sobre aprendizaje de máquinas y se detalla la estrategia a utilizar para la detección de fallas utilizando: Redes neuronales, K-means y SOM.

2.1 MOTORES DE INDUCCIÓN

Un motor de inducción pertenece a la categoría de máquinas eléctricas dinámicas, su principal característica es que la corriente en el rotor no proviene de una fuente de energía exterior, sino que proviene de la interacción entre el rotor y el campo magnético giratorio proveniente del estator. Los motores están formados, desde un punto de vista general, de un estator y de un rotor.

Existen dos tipos de rotores de motores de inducción, el rotor jaula de ardilla y el rotor devanado. El rotor jaula de ardilla, conocido así porque su estructura se asemeja a una jaula circular, es simple y robusto, esta es la razón por la cual es el tipo de motor mayormente usado en la industria (Fitzgerald, Kingsley, & Umas, 2003). El rotor devanado presenta terminales de anillos para insertar resistencias con el objetivo de cambiar las características par-velocidad, son en general motores más grandes, cuyos rotores están formados por devanados de cobre esmaltado (Chapman, n.d.).

2.1.1 Partes constitutivas

Un motor de inducción tiene muchos componentes diferentes, sin embargo, para el estudio de esta tesis se les puede clasificar en 4 grupos, como se aprecia en la **Figura 5**:

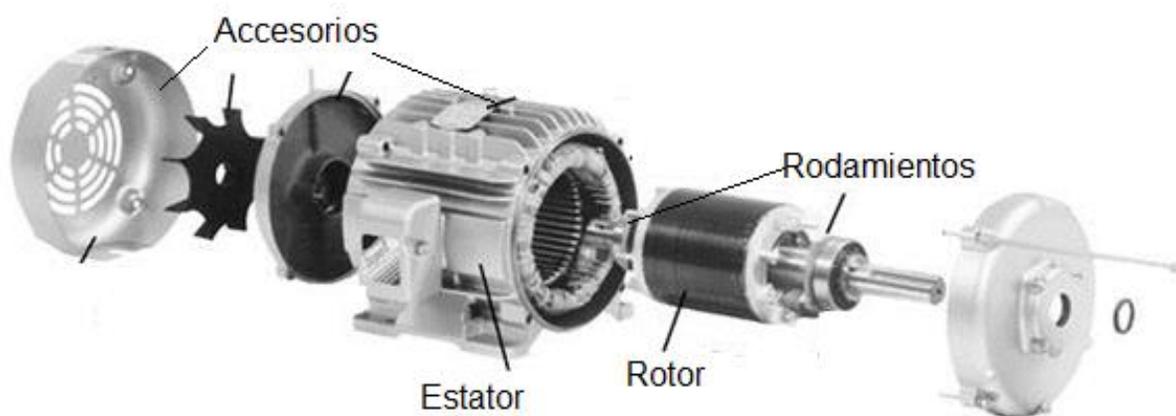


Figura 5. Partes de un motor jaula de ardilla
Fuente: (Wildi, 2007).

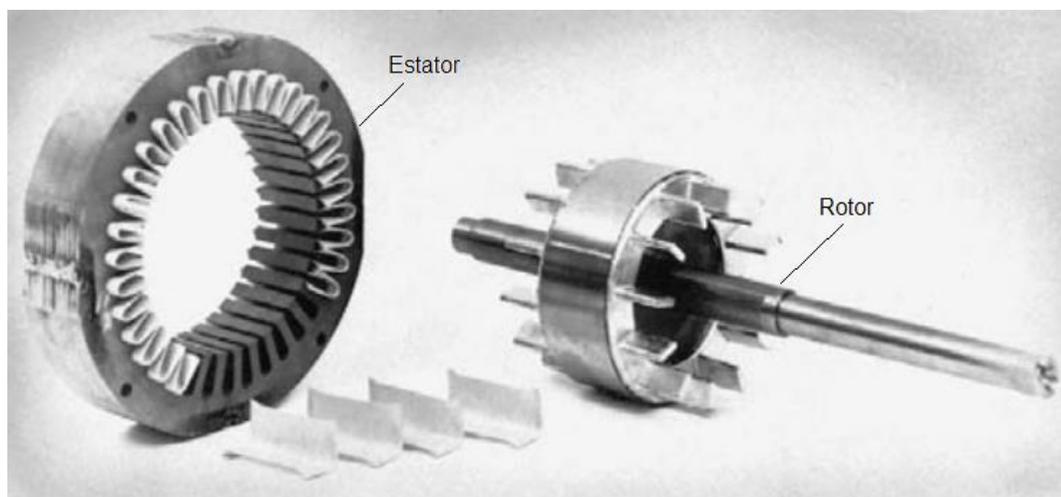


Figura 6. Estator y rotor de un motor de inducción
Fuente: (Wildi, 2007).

2.1.1.1 Estator

El estator, llamado así porque es una pieza estática, recubre al rotor, está formado por un grupo de devanados enrollados en un núcleo de forma circular dispuesto alrededor del rotor, con ranuras para colocar los devanados de cobre de forma tal que el campo magnético producido gire en función de la frecuencia de alimentación, para lograr este efecto se necesita de una fuente de corriente alterna polifásica. El estator es una pieza que rodea al rotor como se aprecia en la *Figura 6*.

2.1.1.2 Rotor

El rotor jaula de ardilla está formado por una estructura similar a una jaula circular y rellena de placas de aluminio que funcionan como núcleo magnético como se muestra en la *Figura 7*, dentro del rotor se pueden distinguir dos estructuras, la primera son las barras y la segunda es los anillos que funcionan como puntos de unión entre barras, toda esta estructura está eléctricamente “corto-circuitada”, la configuración del rotor está diseñada para que las corrientes inducidas en las barras produzcan un torque al interactuar con el campo magnético giratorio.

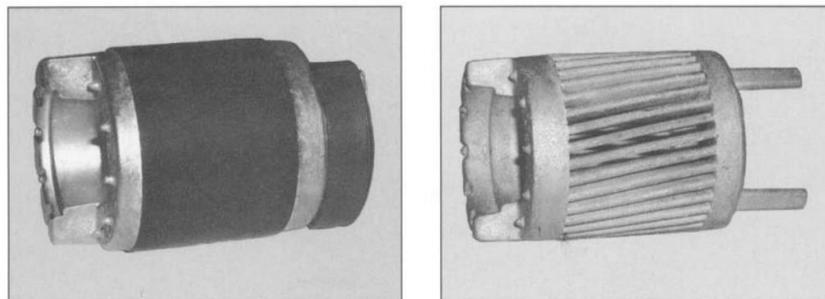


Figura 7. Rotor de un motor de inducción antes (derecha) y después (izquierda) de la añadidura química de las laminas

Fuente: (Fitzgerald et al., 2003)

2.1.1.3 Rodamientos

Los rodamientos son los accesorios que se encuentran en la unión mecánica entre el rotor y el estator, estos típicamente están formados por un anillo exterior, anillo interior, bolas metálicas y una jaula que sostiene las bolas como se aprecia en la *Figura 8*. Su función principal es servir como eje giratorio para el rotor proporcionando el menor desgaste posible y las menores pérdidas en rozamiento.

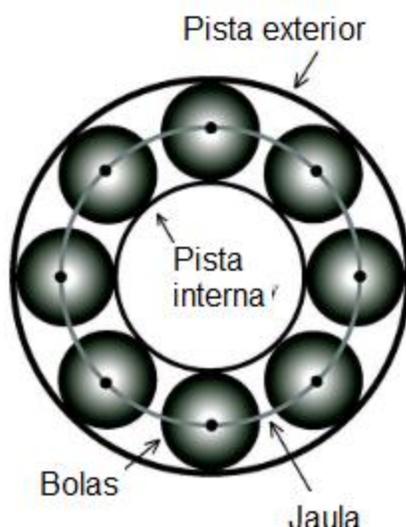


Figura 8. Estructura de un rodamiento
Fuente: (Blodt, Granjon, Raison, & Rostaing, 2008).

2.1.1.4 Accesorios

Los accesorios involucran todas las demás piezas para el correcto funcionamiento del motor, tal como ventilador, tornillos, carcasa, terminales eléctricos de los devanados, etc.

2.1.2 Principio de funcionamiento

El campo magnético giratorio proveniente del estator interactúa con las barras del rotor, generando una diferencia de potencial a lo largo de estas barras, la cual a su vez genera una corriente, esta corriente al interactuar con el campo magnético giratorio genera un torque que acelera el rotor en el mismo sentido que gira el campo magnético, si el rotor alcanza la velocidad de giro del campo entonces la velocidad relativa entre el rotor y el campo se vuelve nula, lo que ocasiona que el voltaje inducido en la barra también sea nulo y el rotor empiece a detenerse por la ausencia de corrientes en las barras, pero si el rotor baja de velocidad de giro con respecto al campo, la velocidad relativa del rotor no es nula, lo que ocasiona un voltaje inducido que produce una corriente que interactúa con el campo y acelera el rotor, este efecto generalmente se ve reflejado en que la velocidad del rotor se estabiliza típicamente en un punto cercano pero menor a la velocidad de giro del campo magnético .

2.1.3 Deslizamiento

El voltaje inducido en las barras del rotor jaula de ardilla depende de la velocidad de giro del rotor con respecto al campo magnético giratorio, así surge el término “velocidad de deslizamiento”, definida básicamente como la diferencia entre la velocidad sincrónica del campo magnético y la velocidad real del rotor (Fitzgerald et al., 2003).

$$n_{des} = n_{sinc} - n_m \quad (1)$$

Dónde:

n_{des} : es la velocidad de deslizamiento.

n_{sinc} : es la velocidad sincrónica del motor.

n_m : es la velocidad mecánica del rotor.

De igual forma, para explicar diferentes fenómenos surge la siguiente definición de deslizamiento. El deslizamiento “s” se define como (Chapman, n.d.):

$$s = \frac{n_{des}}{n_{sinc}} \quad (2)$$

Se puede entender que si el rotor gira exactamente a la velocidad sincrónica entonces $s = 0$, mientras que si el rotor está totalmente estacionario entonces $s = 1$.

La velocidad mecánica n_m del eje en términos de la velocidad sincrónica n_{sinc} está dada por la ecuación (Fitzgerald et al., 2003):

$$n_m = (1 - s)n_{sinc} \quad (3)$$

Esta ecuación se vuelve útil para cálculos relacionados con el par del motor y las relaciones de potencia, además también sirven para determinar las frecuencias asociadas a las fallas de rodamientos.

2.1.4 Velocidad sincrónica

La velocidad sincrónica de un motor está dada por la ecuación (4) (Wildi, 2007), se define en términos sencillos como la velocidad a la que gira el campo magnético producido por el estator.

$$n_{sinc} = \frac{120f_o}{p} \quad (4)$$

Dónde:

s: Es el de deslizamiento.

f_o : Es la frecuencia de alimentación de los devanados del estator.

p : Es el número de polos.

2.1.5 Relación velocidad sincrónica y número de polos

Después de inventar el motor de inducción, se descubrió que la velocidad sincrónica se podía reducir mediante el incremento de polos en la configuración del estator (Wildi, 2007)

La configuración inicial y básica de un motor de inducción es de dos polos ya que para cualquier instante el flujo magnético existen solo dos polos. Para un motor con 4 polos se crea un flujo con varias direcciones, pero que gira a la mitad de la velocidad del equivalente al de 2 polos. Se puede incrementar el número de polos tanto como se desee siempre que existan suficientes ranuras.

2.1.6 Características Velocidad - Par

La explicación de porqué el deslizamiento de un motor de inducción en operación normal es pequeño se explica con el análisis de las curvas de velocidad-par del motor ejemplificada en la **Figura 9**, estas curvas tienen comportamientos similares, pero varían según la geometría de las barras.

Se puede observar en la **Figura 9** que para cargas de 0 a 100% con respecto al torque nominal la velocidad del rotor se encuentra muy cercana a la velocidad sincrónica esto produce que el deslizamiento sea pequeño del orden de 0.1 y que la velocidad del eje sea menor a la velocidad sincrónica pero cerca a este valor.

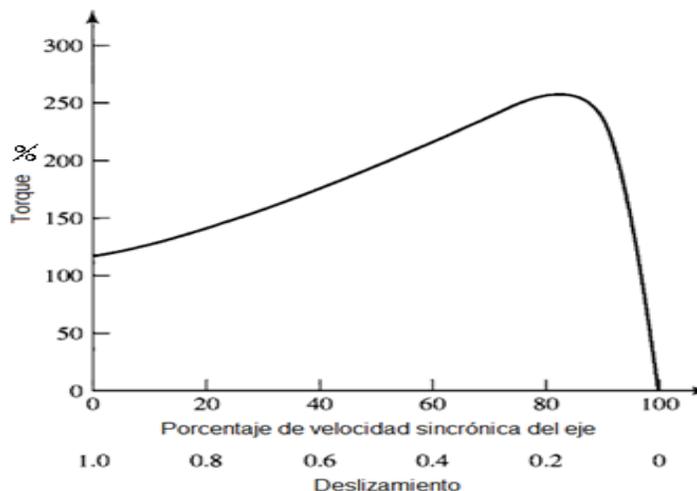


Figura 9. Gráfica par-velocidad de un motor de inducción típico
Fuente: (Fitzgerald et al., 2003)

2.2 FALLAS EN MOTORES DE INDUCCIÓN

Se considera que un motor tiene una falla cuando uno de sus componentes funcionales presenta un defecto, muchas fallas inicialmente presentan cambios ligeros en el comportamiento del motor que progresivamente pueden terminar en la aparición de otras fallas e incluso en la destrucción del motor. Entre estas fallas pueden estar barras rotas, anillos rotos, cortocircuito en el estator, excentricidad dinámica del eje, excentricidad estática del eje, falla en algún componente del rodamiento, voltajes desbalanceados, entre otros.

En términos generales, las fallas son clasificadas en (Thomson & Fenger, 2003):

- Relacionadas con el estator: 38%.
- Relacionadas con el rotor: 10%.
- Relacionadas con los rodamientos: 40%.

- Relacionadas con otros componentes: 12%.

En la revisión bibliográfica se ha encontrado que cada una de las fallas produce cambio en diferentes magnitudes físicas del motor, la falla típica del estator involucra un cortocircuito en el devanado. Una de las estrategia de detección de cortocircuitos se basa en la medición de la corriente de las tres fases del motor, a partir de las cuales se puede calcular el valor eficaz de la secuencia negativa la cual está relacionada proporcionalmente al nivel del cortocircuito, la detección de fallas en los rodamientos y en el estator también se puede detectar analizando las señales de corriente.

A continuación se presenta un contexto teórico sobre las fallas de interés: falla de barras rotas y falla en los rodamientos y el efecto que producen en las corrientes del estator.

2.2.1 Falla de barras rotas

Como se muestra en la *Figura 7* un rotor jaula de ardilla está formado por varias barras, por las cuales circulan corrientes que interactúan con el campo magnético y generan torque y movimiento, dado que estas barras están sujetas a estrés mecánico se pueden romper.

En términos generales esta falla implica una o más barras del rotor quebradas lo cual ocasiona niveles de discontinuidad eléctrica a lo largo de la barra, esto usualmente produce una variación en el flujo magnético que a su vez produce cambios en la corriente del estator, además ocasiona que el motor sea ineficiente y que la corriente de arranque aumente y consecuentemente el factor de potencia descienda (Faiz & Ebrahimi, 2008) y de hecho si la cantidad de barras rotas aumenta podría suceder que el motor no arranque por no producir suficiente torque (Kumar & Sinha, 2012).

Las razones por las que sucede esta falla son (Thomson & Fenger, 2003):

- Ciclos de trabajo con arranque directo para los cuales el rotor no se diseñó. Esto provoca altas temperaturas y estrés mecánico.
- Las cargas mecánicas pulsantes, como los compresores alternativos o las trituradoras de carbón, pueden someter al rotor a alto estrés mecánico.
- Imperfecciones en el proceso de fabricación de la jaula del rotor.

Como se mencionó anteriormente, esta falla produce cambios en el espectro de la corriente del estator, y estas en frecuencias definidas por la siguiente expresión (Benbouzid, 2000):

$$f = f_o \left[k \left(\frac{1-s}{p} \right) \pm s \right] \quad (5)$$

En donde, para una configuración normal de devanados $\frac{k}{p} = 1, 5, 7, 11, 13 \dots$

Sin embargo estas fallas también producen oscilaciones del rotor que a su vez ocasionan armónicos en otras frecuencias diferentes a las definidas por las ecuaciones (5). Este efecto se explica a continuación:

Las corrientes del rotor en un devanado de jaula producen un campo magnético trifásico efectivo que tiene el mismo número de polos que el campo del estator, pero está girando una velocidad de deslizamiento con respecto al rotor giratorio. Cuando el devanado de la jaula es simétrico, solo hay un campo de rotación hacia adelante a una frecuencia de deslizamiento con respecto al rotor. Pero si ocurre una asimetría del rotor, habrá un campo de rotación hacia atrás resultante a una frecuencia de deslizamiento con respecto al rotor que gira hacia adelante. El resultado de esto es que, con respecto al estator estacionario, este campo de rotación hacia atrás a

la frecuencia de deslizamiento produzca una fuerza electro-motriz y una corriente en el devanado del estator a $f_1 = f_o (1 - 2s)$ lo cual es descrito en la ecuación (5). Por lo tanto existe, una variación cíclica de la corriente que causa una pulsación de par a una frecuencia de deslizamiento doble y una correspondiente oscilación de velocidad. Esta oscilación de velocidad puede reducir la magnitud de la banda lateral $f_o (1 - 2s)$ pero se induce un componente de corriente de banda lateral superior en $f_o (1 + 2s)$ en el estator debido a la oscilación del rotor (Thomson & Fenger, 2003).

Por ello la ecuación (6) también se ha usado en forma práctica para poder definir las frecuencias asociadas a la falla de barras rotas es (Filippetti et al., 2013).

$$f_{barras} = f_o(1 \pm 2ks) \quad (6)$$

Considerando $k = 1,2,3 \dots$

La diferencia entre la ecuación (5) y (6) es que básicamente la primera se obtuvo del análisis matemático de los fenómenos que ocurren en el motor cuando existe una asimetría en el rotor, sin embargo no se tomó en cuenta que este fenómeno produce oscilaciones de velocidad que a su vez desencadenaban más efectos armónicos, y la segunda sí lo hace pero solo toma en cuenta los armónicos fundamentales.

De hecho, un efecto interesante es que si existen dos barras rotas separadas $\pi/2$ radianes una de otra, la componente $f_o (1 - 2s)$ no existe (Benbouzid & Kliman, 2003). Se ha demostrado que la FT es una herramienta de análisis en frecuencia exitosa para la detección de barras (Thomson & Fenger, 2003).

2.2.2 Falla en los rodamientos

Un defecto de fallas en los rodamientos en términos generales es el defecto de alguno o varios de sus elementos, los cuales pueden ser: pista exterior, pista interior, jaula y bolas. Estos defectos producen vibraciones mecánicas en el motor en frecuencias específicas.

Las vibraciones mecánicas influyen en la corriente del estator en frecuencias determinadas por la ecuación (10), es por ello que para poder determinar las frecuencias de interés asociadas a una falla de rodamientos en el espectro de la corriente primero se debe determinar las frecuencias de interés con respecto a vibraciones mecánicas.

Las vibraciones mecánicas asociadas a falla en la pista interior del rodamiento está definida por la ecuación (7), las vibraciones asociadas a una falla en la pista exterior están definidas por la ecuación (8) y las vibraciones asociadas a una falla en las bolas están determinadas por la ecuación (9). Estas ecuaciones necesitan información detalla de los rodamientos, la cual se encuentra en la **Figura 10** (Zarei & Poshtan, 2007).

$$f_{pi} = \frac{nf_e}{2} \left(1 + \frac{d}{D} \cos(\alpha) \right) \quad (7)$$

$$f_{pe} = \frac{nf_e}{2} \left(1 - \frac{d}{D} \cos(\alpha) \right) \quad (8)$$

$$f_b = \frac{Df_e}{d} \left(1 - \frac{d^2}{D^2} \cos^2(\alpha) \right) \quad (9)$$

Donde:

D : es el diámetro de la pista eje de las bolas.

f_e : es la velocidad del eje en hertzios.

d : es el diámetro de las bolas.

α : es el ángulo de contacto entre las bolas y las pista.

n : es el número de bolas que contiene el rodamiento.

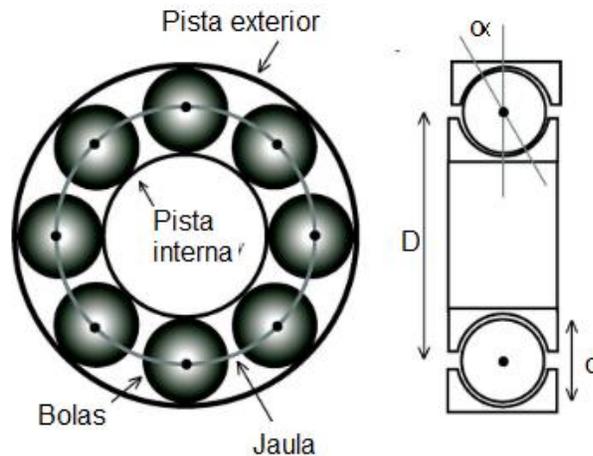


Figura 10. Descripción de un rodamiento y sus partes y mediciones relevantes.
Fuente: (Blodt et al., 2008)

Dado que estas vibraciones mecánicas producen anomalías en la densidad de campo magnético ocasionan cambios en frecuencias de la corriente del estator dadas por la ecuación (10) (Zarei & Poshtan, 2007):

$$f_{\text{rodamiento}} = |f_o \pm kf_v| \quad (10)$$

Donde f_v son las frecuencias definidas por las ecuaciones (7), (8), (9) y $k = 1, 2, 3 \dots$

Sin embargo, el efecto producido en las corrientes es muy tenue, por ello se ha demostrado que la técnica de análisis en frecuencia como la transformada de FT es insuficiente para la detección de anomalías pero que la utilización de DWT si lo es (Zarei & Poshtan, 2007), (Ince et al., 2016), (L. Eren & Devaney, 2003), (Levent Eren, Karahoca, & Devaney, 2004), (Lau & Ngan, 2010).

2.3 APRENDIZAJE DE MAQUINA

En esta sección se describe la información básica sobre el aprendizaje de máquinas, posteriormente se describen los algoritmos utilizados en el presente trabajo: RNA, K-means y SOM.

El aprendizaje de máquinas es una rama científica perteneciente al ámbito de la inteligencia artificial que consiste en el estudio de sistemas capaces de generalizar comportamientos en base a información previamente suministrada. Básicamente estos sistemas son modelos entrenados para resolver una tarea específica como clasificación, regresión, agrupamientos, reducción de dimensionalidad, entre otros.

Puesto que el propósito del presente trabajo es realizar detección se da una breve explicación de los parámetros utilizados para medir el desempeño de un algoritmo, los cuales son sensibilidad y especificidad. La sensibilidad es el porcentaje de valores, que siendo positivos, son clasificados correctamente, mientras que la especificidad es el porcentaje de valores, que siendo negativos, son clasificados correctamente. Depende de la aplicación del clasificador para determinar cuál es más crucial, por ejemplo en el caso de las pruebas de HIV, en donde un falso negativo implicaría la muerte del paciente y la posible transmisión de otras personas. Para realizar la evaluación del desempeño se utiliza la técnica de validación cruzada o K-Fold utilizando generalmente 10 pliegues (Depren et al., 2005).

Existen básicamente 3 tipos de aprendizaje según el tipo de información necesaria para la fase de entrenamiento, estos son:

- Aprendizaje supervisado: En el cual se proveen ejemplos de aprendizaje con valores de entrada y de salida, es decir que son valores de entrada con su respectiva salida, se conoce cuál es el valor del resultado esperado, y en base a estas etiquetas se corrigen los valores del algoritmo para encontrar una función que relacione los valores de entrada con los de salida. Las redes neuronales son algoritmo de aprendizaje supervisado.
- Aprendizaje no supervisado: Solo se tiene información de entrada, pero no información de salida, usualmente los modelos que se entrenan con datos no etiquetados son utilizados para el agrupamiento de los mismos. K-means y SOM son algoritmos de aprendizaje no supervisado.
- Aprendizaje semi-supervisado: Estos algoritmos usan datos etiquetados y no etiquetados para su entrenamiento.

2.3.1 Redes neuronales artificiales

Una Red Neuronal Artificial (RNA) es una estructura matemática que está inspirada en la configuración de los tejidos nerviosos del cerebro, específicamente en las neuronas y en cómo estas procesan la información. El elemento básico constitutivo de una red neuronal artificial es la neurona, básicamente, una red está formada por una o varias neuronas interconectadas entre sí con el fin de obtener una función de forma que dada una entrada “X” se obtenga una salida “Y”.

Una neurona artificial es prácticamente un sumador al que se le aplica una función de activación a posteriori, el procedimiento matemático en detalle comienza cuando se presenta un vector de entrada X , cada entrada tiene una sinapsis asociada llamada peso, es decir, un número multiplicador; para representar estos pesos se usa la matriz W , a cada vector de entrada se le

multiplica por su peso correspondiente y se suma todo añadiendo valor bias u offset, finalmente al valor obtenido de la suma se aplica una función de activación $g(x)$, matemáticamente la salida de la neurona está definida por la ecuación (11).

$$y = g\left(\sum_{1}^n x_i \cdot w_i - \theta\right) \quad (11)$$

A continuación se detallan los parámetros de la neurona, luego se explica el algoritmo de aprendizaje de una red neuronal paso a paso y finalmente se detalla el algoritmo de aprendizaje propuesto.

2.3.1.1 Parámetros de diseño

Los parámetros de diseño para que un algoritmo de redes neuronales funcione correctamente son: función de activación y arquitectura de red y se detallan a continuación. Existen diferentes criterios para la selección de estos parámetros.

- **Función de activación**

Una función de activación está definida como la operación final de transformación de la salida de una neurona, la utilización de una función de activación específica a la red cumplir con su objetivo de diseño ya que esta función le proporciona a la red característica de no linealidad. Las funciones de activación más conocidas son:

- Función escalón: $g(x) = \begin{cases} 1, & x > 0 \\ 0, & \text{otros} \end{cases}$

- Función semilineal: $g(x) = \begin{cases} 1, & x \geq 1 \\ x, & 0 < x < 1 \\ 0, & x \leq 0 \end{cases}$
- Función sigmoide: $g(x) = \frac{a}{1+e^{-bx}}$

- **Arquitectura perceptron multicapa**

La arquitectura de una red neuronal es la disposición de las neuronas, en una red multicapa, las salidas de una capa se vuelven las entradas de la siguiente hasta llegar a la última capa. Usualmente las redes se agrupan por capas, es decir, por grupos de neuronas que comparten las mismas entradas como se aprecia en la **Figura 11**, la configuración típica de una red consta de capas de tres tipos: De entrada: reciben las entradas. De salida: proporcionan la respuesta de la red a los estímulos de la entrada. Intermedias: no reciben ni emiten información directamente del entorno, pero aportan en el procesamiento de la información.

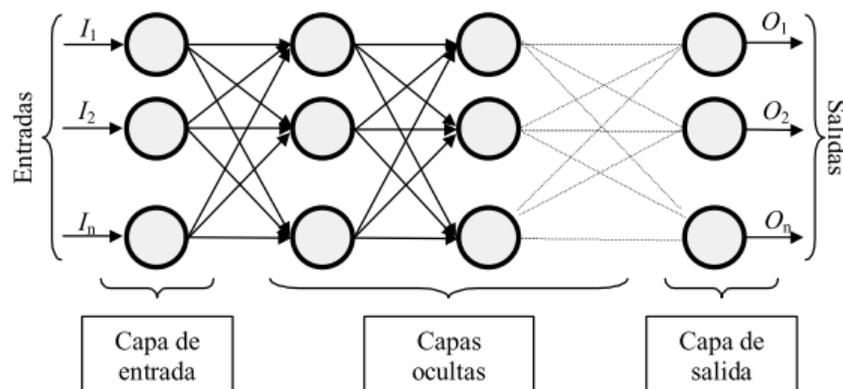


Figura 11. Capas de una red neuronal
Fuente: (Matich, 2002)

Usualmente las conexiones se realizan entre capas y en orden, pero pueden existir conexiones distintas, sin embargo, estas conexiones no son convencionales.

2.3.1.2 Descripción del cálculo de la salida de un perceptrón multicapa

Se explica el algoritmo para determinar la salida en base a la entrada de un perceptrón multicapa con una capa intermedia.

1. Se define el número de entradas y salidas :

i : Es el número de vectores de entrada.

j : Es el número de neuronas en la capa intermedia.

k : Es el número de neuronas en la capa intermedia.

2. Se define la función de activación $g(x)$.
3. Se normalizan los vectores en el rango de -1 a 1.
4. Se inicializan los pesos W de -1 a 1.
5. Se obtiene la salida de la capa intermedia Y_{1xj} .

$$Y_{1xj} = g(X_{1xi} \cdot W_{ixj} - \theta_{1xj}) \quad (12)$$

Donde

X_{1xi} : es el vector de entrada expresado en forma de una matriz, definido por (13).

$$X_{1xi} = [x_1 \ x_2 \ x_3 \ \dots \ x_i] \quad (13)$$

W_{ixj} : es una matriz con los pesos sinápticos que relaciona cada entrada con cada neurona en la capa intermedia, definida por (14).

$$W_{ixj} = \begin{pmatrix} w_{1X1} & \cdots & w_{1Xj} \\ \vdots & \ddots & \vdots \\ w_{iX1} & \cdots & w_{iXj} \end{pmatrix} \quad (14)$$

θ_{1xj} : Es la matriz con los bias de cada neurona, definida por (15).

$$\theta_{1xj} = [\theta_1 \theta_2 \theta_3 \dots \theta_i] \quad (15)$$

6. Finalmente se obtiene la salida el perceptrón Z_{1xk} .

Para obtener la salida, definida en (16), se repite el procedimiento anterior, tomando en cuenta que salida de una capa es la entrada de la siguiente.

$$Z_{1xk} = g(Y_{1xj} \cdot W_{jxk}) \quad (16)$$

Y_{1xj} : es el vector de entrada expresado en forma de una matriz, definido en (17).

$$Y_{1xj} = [y_1 \ y_2 \ y_3 \ \dots \ y_j] \quad (17)$$

W_{jxk} : es una matriz con los pesos sinápticos que relaciona cada entrada con cada neurona en la capa intermedia, definida en (18).

$$W_{jxk} = \begin{pmatrix} w_{1X1} & \cdots & w_{1Xk} \\ \vdots & \ddots & \vdots \\ w_{jX1} & \cdots & w_{jXk} \end{pmatrix} \quad (18)$$

2.3.1.3 Algoritmo de entrenamiento

Existen varios algoritmos de entrenamiento para redes neuronales, sin embargo uno de los más exitosos que soluciona la mayoría de problemas relacionados a redes neuronales es el algoritmo de retro propagación o “backpropagation” el cual se usa en el presente trabajo.

Retro propagación es un algoritmo de aprendizaje para redes neuronales basado en el descenso del gradiente. Se puede describir el principio de este algoritmo mediante la ecuación de corrección y actualización de parámetros:

$$k1(t) = k1(t - 1) + TA \cdot \frac{\partial C(k1, k2, k3..)}{\partial k1} \quad (19)$$

Donde

$k1$: es el parámetro a actualizar, suele ser los pesos o los bias.

TA : es la tasa de aprendizaje, un valor entre 1 y 0.

$\frac{\partial C}{\partial k}$: es la derivada parcial de la función de coste con respecto a la variable a actualizar, es decir básicamente el gradiente.

La función de coste es básicamente una función que mide la diferencia entre la salida obtenida por un vector de entrada y la salida esperada, se puede definir en términos sencillos a la función de coste $C(pesos, bias)$ como el error cuadrático, es decir, el cuadrado del valor obtenido menos el esperado:

$$C(\text{pesos}, \text{bias}) = (f(x) - y)^2 \quad (20)$$

El algoritmo se ejecuta generalmente hasta que el error cuadrático medio de todos los datos de entrada sea menor a un valor o hasta el número de iteraciones llegue a un valor máximo.

Tomando en cuenta lo que se ha explicado sobre retro propagación, se pueden determinar dos parámetros de diseño: el criterio de parada y la tasa de aprendizaje.

2.3.2 K-means

K-means es un algoritmo de agrupamiento que pertenece a los de tipo particional, que son los preferidos para el reconocimiento de patrones. Las razones de su popularidad de uso son su simpleza, eficiencia, y su éxito empírico.(Jain, 2010) .

A continuación, se explica cuáles son los parámetros de diseño, después se explica paso a paso el algoritmo y finalmente se explica el algoritmo para la detección de anomalías, ya que al igual que SOM el algoritmo K-means por sí solo no realiza detección, solo agrupamiento.

2.3.2.1 Parámetros de diseño

El algoritmo K-means requiere tres parámetros especificados por el usuario: número de conglomerados K, inicialización del conglomerado y métrica de distancia (Jain, 2010).

- Número de agrupamientos: Es la elección más importante, no existe un criterio matemático perfecto para obtener un número pero existen diferentes criterios heurísticos.

- Inicialización de los centroides: diferentes inicializaciones de los centroides convergerán en diferentes modelos ya que el algoritmo solo cae en un mínimo local, usualmente los centroides son inicializados de -1 a 1 de forma aleatoria.
- Métrica de distancia: Es la formula usada para determinar la distancia en el espacio vectorial de entrada, existe la métrica euclidiana, la métrica de Manhattan, la métrica de Minkowski, la métrica de Mahalanobis, entre otras. La métrica de distancia más usada es la euclidiana, como resultado se crean clústeres con forma esférica.

2.3.2.2 Descripción del algoritmo paso a paso

Los pasos principales del algoritmo son (Jain, 2010):

1. Normalizar los vectores de entrada de -1 a 1.
2. Seleccionar los parámetros del algoritmo.
3. Generar una nueva partición asignando cada vector de entrada a su centroide más cercano.
4. Calcular nuevos centroides de cada aglomerado utilizando la nueva partición.
5. Repetir el paso 3 y 4 hasta que la posición de los centroides no cambien.

2.3.2.3 Detección de anomalías utilizando K-means

El procedimiento para realizar la detección se resumen a continuación (Kang, Hwang, & Cho, 2007):

Paso 1: Realizar el algoritmo K-Means con los datos de entrenamiento.

Paso 2: Encontrar el centroide más cercano a los datos de prueba.

Paso 3: Definir si el punto está dentro de la zona de seguridad o no. La zona de seguridad está definida como un multiplicador “M” por el promedio de la distancia de los puntos que pertenecen al centroide seleccionado.

2.3.3 Mapas auto-organizados

También llamados mapas de Kohonem, es un algoritmo de aprendizaje no supervisado que reduce la dimensión de grandes conjuntos de datos al agruparlos y organizarlos en una matriz de nodos organizada en forma unidimensional o bidimensional (Natita, Wiboonsak, & Dusadee, 2016) formando una malla llamada mapa o red. Cada nodo tiene una posición fija en el mapa y un conjunto de pesos de igual dimensión de los vectores de entrada del algoritmo (Brauer, 2012). Usualmente para que el modelo converja en forma efectiva y represente los datos de entrada se necesita de dos fases, la fase de ordenamiento y la fase de convergencia; en la fase de ordenamiento los pesos de los nodos se modifican para que la red se disponga dentro del rango de los datos de entrada, mientras que en la fase de convergencia los nodos se acoplan a lo largo de todo el espacio vectorial descrito por los vectores de entrada (Haykin, 2005).

A continuación se explican los parámetros de diseño del algoritmo, posteriormente se define el algoritmo paso a paso, después se realiza un resumen sobre algunos criterios de diseño y finalmente se explica cuál es la estrategia para la detección de anomalías, ya que por sí solo un mapa auto-organizado no realiza detección, solo agrupamiento.

2.3.3.1 Parámetros de diseño

Los parámetros de diseño para la implementación de un algoritmo SOM son: topología y configuración de red, número de épocas, función de vecindad y tasa de aprendizaje.

- **Topología de red**

La topología es la forma en la que los nodos están dispuestos unos con otros. Las topologías utilizadas suelen ser mallas multidimensionales, usualmente puede ser de forma cuadriculada, de forma hexagonal, de forma aleatoria, en forma triangular, y así se pueden definir mallas muy sofisticadas, pero la aproximación de una malla cuadriculada es suficiente para la mayoría de las aplicaciones (Rojas, 1996). En la **Figura 12** se muestran dos ejemplos de topologías.

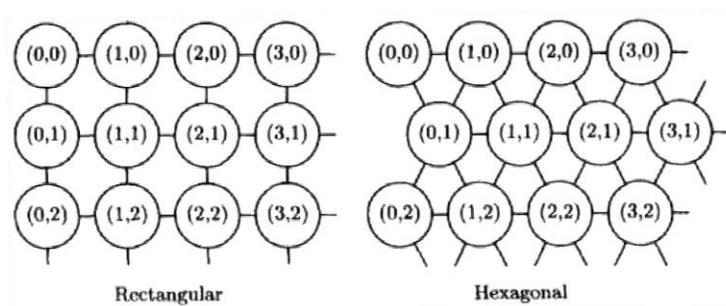


Figura 12. Topologías de red utilizadas como mapas en el algoritmo SOM

Fuente: (Kohonen, 2001)

- **Configuración de red**

Se define como las dimensiones de la topología de red, por ejemplo un red bidimensional puede estar configurada de forma cuadrada “cuatro por cuatro”, es decir una malla de 4 nodos en cada lado con un total de 16, o puede ser una configuración “uno por 10” lo que implicaría

realmente un malla unidimensional de 10 nodos, la configuración de red refleja principalmente la cantidad de nodos que se usan y en qué forma están agrupados.

- **Época**

La época es básicamente un numero entero que funciona como un contador del número de veces que el algoritmo ha sido ejecutado, surge principalmente porque un mapa auto-organizado debe ser ejecutado varias veces con el fin de lograr la convergencia del modelo, pero reduciendo la cantidad de ajuste paulatinamente para lograr un estado real de convergencia y no un meta-estado de convergencia. Es por ello que la función de vecindad y la función de tasa de aprendizaje son una función que decrece en función del número de época.

- **Función de vecindad**

Existen diferentes funciones de vecindad, la más genérica es la función gaussiana, sin embargo existen funciones que son usadas por su simplicidad como la función triangular o rectangular; la función sombrero mexicano tiene la particularidad de que penaliza la neuronas cercanas, el algoritmo original descrito utilizaba esta función (Kohonen, 1982).

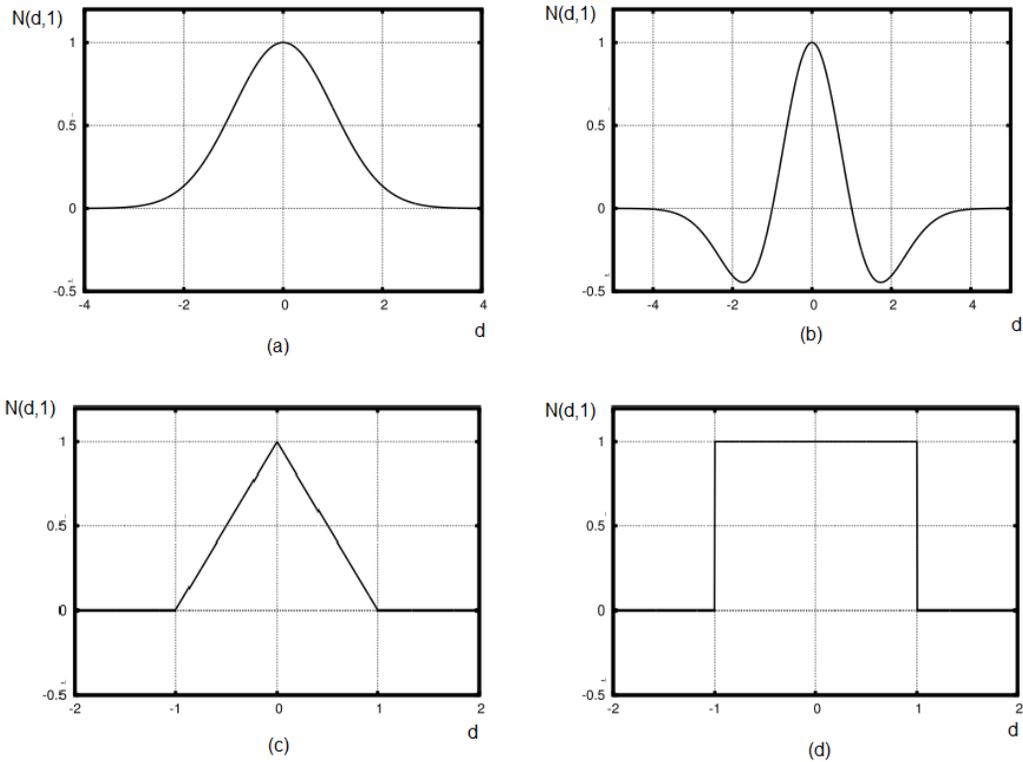


Figura 13. Función de vecindad, considerando $\sigma = 1$. (a) Función gaussiana, (b) función sombrero mexicano, (c) función triangular, (d) función rectangular

Fuente: (Brauer, 2012)

Las funciones de vecindad, véase **Figura 13**, están definidas matemáticamente por:

- Función gaussiana: $N(d, \sigma) = e^{-\frac{d^2}{2\sigma^2}}$
- Función sombrero mexicano: $N(d, \sigma) = \left(1 - \frac{d^2}{\sigma^2}\right) e^{-\frac{d^2}{2\sigma^2}}$
- Función triangular: $N(d, \sigma) = \begin{cases} 1 - \frac{|d|}{\sigma}, & |d| \leq \sigma \\ 0, & \text{otros} \end{cases}$
- Función rectangular: $N(d, \sigma) = \begin{cases} 1, & |d| \leq \sigma \\ 0, & \text{otros} \end{cases}$

Estas funciones están en función de la variable auxiliar σ que a su vez está en función de la época t , por lo tanto se genera una función $\sigma(t)$; este valor usualmente está relacionado con el radio del vecindario, es decir, con la distancia que rodea al BMU en la cual se encuentran los nodos cuyos pesos se modifican en algún grado, dado que esta distancia debe reducirse para lograr la convergencia del modelo se genera la función de $\sigma(t)$ definida usualmente como:

$$\sigma(t) = \sigma_0 e^{-\frac{t \cdot \log(\sigma_0)}{1000}} \quad (21)$$

- Tasa de aprendizaje

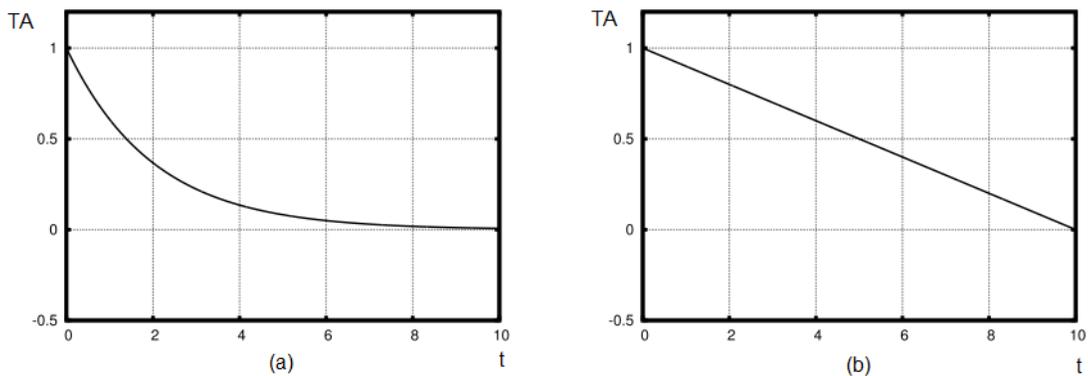


Figura 14. Funciones de tasa de aprendizaje (a) exponencial y (b) lineal vs número de época
Fuente: (Brauer, 2012)

Dado que la tasa de aprendizaje TA también debe reducirse paulatinamente se genera la función $TA(t)$ que decae de forma exponencial o de forma lineal como se muestra en la **Figura 14**.

2.3.3.2 Descripción del algoritmo pasó a paso

1. Se determinan los parámetros de diseño tanto para fase de ordenamiento como para fase de convergencia.
2. Se inicializan los pesos de los nodos aleatoriamente en el rango de -1 a 1.
3. Se normalizan los vectores de entrenamiento con respecto a sus máximos y mínimos en el rango de -1 a 1.
4. Se inicia con la fase de ordenamiento.
 - 4.1. Se inicializa el número de época $t = 0$.
 - 4.2. Se toma un vector de entrada y se compara con los pesos de cada nodo, y se selecciona el nodo cuyos pesos sean más “parecidos” o se encuentren más cerca al vector de entrada, a esto se le llama aprendizaje por competencia, es decir, el nodo cuyos pesos representen una menor distancia euclidiana con respecto al vector de entrada será designado como BMU, por sus siglas en inglés “Best Match Unit” (Kohonen, 2001).
 - 4.3. Una vez seleccionado el BMU, se procede a modificar los pesos de cada uno de los nodos mediante la ecuación (22) (Haykin, 2005).

$$n_{i_{nuevos}}(t) = n_i(t) + TA(t) * N(d, t) * (v - n_i(t)) \quad (22)$$

Donde

$n_{i_{nuevos}}(t)$: Matriz con los pesos asociados a un nodo.

$TA(t)$: Función de tasa de aprendizaje, es un número comprendido entre 1 y 0.

$N(d, t)$: Es la función de vecindad.

$(v - n_i(t))$: Es la diferencia entre el vector de entrada y los pesos asociados al nodo $n_i(t)$.

t : Es el número de época.

d : Distancia euclidiana en la topología de red entre el nodo seleccionado y el BMU.

4.4. Se repite el procedimiento 4.2 y 4.3 para todos los vectores de entrenamiento.

4.5. Se aumenta el número de época $t = t + 1$.

4.6. Se repite el paso 4.2, 4.3, 4.4 y 4.5 hasta que el valor de época llegue a su valor máximo predefinido para esta fase.

5. Se continúa con la fase de convergencia, la cual es igual a la fase de ordenamiento pero con los parámetros definidos para esta fase.

2.3.3.3 Criterios

En la fase de ordenamiento el algoritmo debe tener mínimo 1000 iteraciones o épocas, las consideraciones para la elección de la tasa de aprendizaje y de la función de vecindad son (Haykin, 2005):

1. La tasa de aprendizaje debe empezar en un valor cercano a 0.1 y debe ir decreciendo gradualmente pero mantenerse sobre 0.01. La función deseable que satisface estas condiciones esta definida en la ecuación (23):

$$TA(t) = 0.1 \cdot e^{-\frac{t}{1000}} \quad (23)$$

2. La función de vecindad debe incluir inicialmente a todas las neuronas de la red una vez centrada en el BMU, y reducirse paulatinamente hasta tener pocos vecinos, asumiendo

el uso de una topología de red de dos dimensiones, se debe inicializar σ_0 tal que sea el “radio” de la malla. De esta forma se propone la función de vecindad definida en la ecuación (24):

$$\sigma(t) = \sigma_0 e^{-\frac{t \cdot \log(\sigma_0)}{1000}} \quad (24)$$

Tal que $\sigma_0 = \text{"radio de la red"}$

Para la convergencia el número mínimo de iteraciones o de épocas debe ser de 500 o más, las consideraciones importantes en esta fase son (Haykin, 2005):

1. Para buena exactitud estadística, la tasa de aprendizaje debe mantenerse en un valor pequeño cercano a 0.01, en ningún caso debe decaer a cero.
2. La función de vecindad debe contener solo los vecinos más cercanos a la neurona y eventualmente recaer a uno o cero nodos vecinos.

2.3.3.4 Detección de anomalía utilizando SOM

El siguiente algoritmo es descrito en (Depren et al., 2005):

1. Realizar el algoritmo SOM con los datos de entrenamiento.
2. Encontrar los nodos más cercanos a los datos de prueba.
3. Definir si los datos de prueba están dentro de la zona de seguridad o no. La zona de seguridad está definida de la siguiente forma:
 - a. Es una hiperesfera que rodea a cada nodo con un radio “r”.

- b. “ r ” es la distancia entre el nodo y su vector de entrenamiento más alejado del que es BMU, a menos que este valor sea mayor al valor predefinido como cota, en ese caso $r=cota$.
- c. A todos las zonas de seguridad se le suma un valor llamado margen $r=r+margen$.
- d. Si un nodo no es considerada como BMU para ningún vector de entrenamiento entonces su zona de seguridad es cero, $r=0$.

Los vectores de entrada que están cerca uno del otro se asignan a ubicaciones cercanas en la red, por lo tanto, los vectores que no están en el conjunto de datos de entrenamiento y que son de la misma clase deben ser asignados a los mismos nodos dentro del límite de seguridad .Si es que son asignados a una neurona fuera del límite de seguridad se considera una anomalía.

CAPÍTULO 3: METODOLOGÍA

La metodología planteada está estructurada en 5 apartados: toma de datos, obtención de vectores, detección basada en RNA, detección basada en K-MEANS y detección basada en SOM, los cuales están detallados en la *Figura 15*.

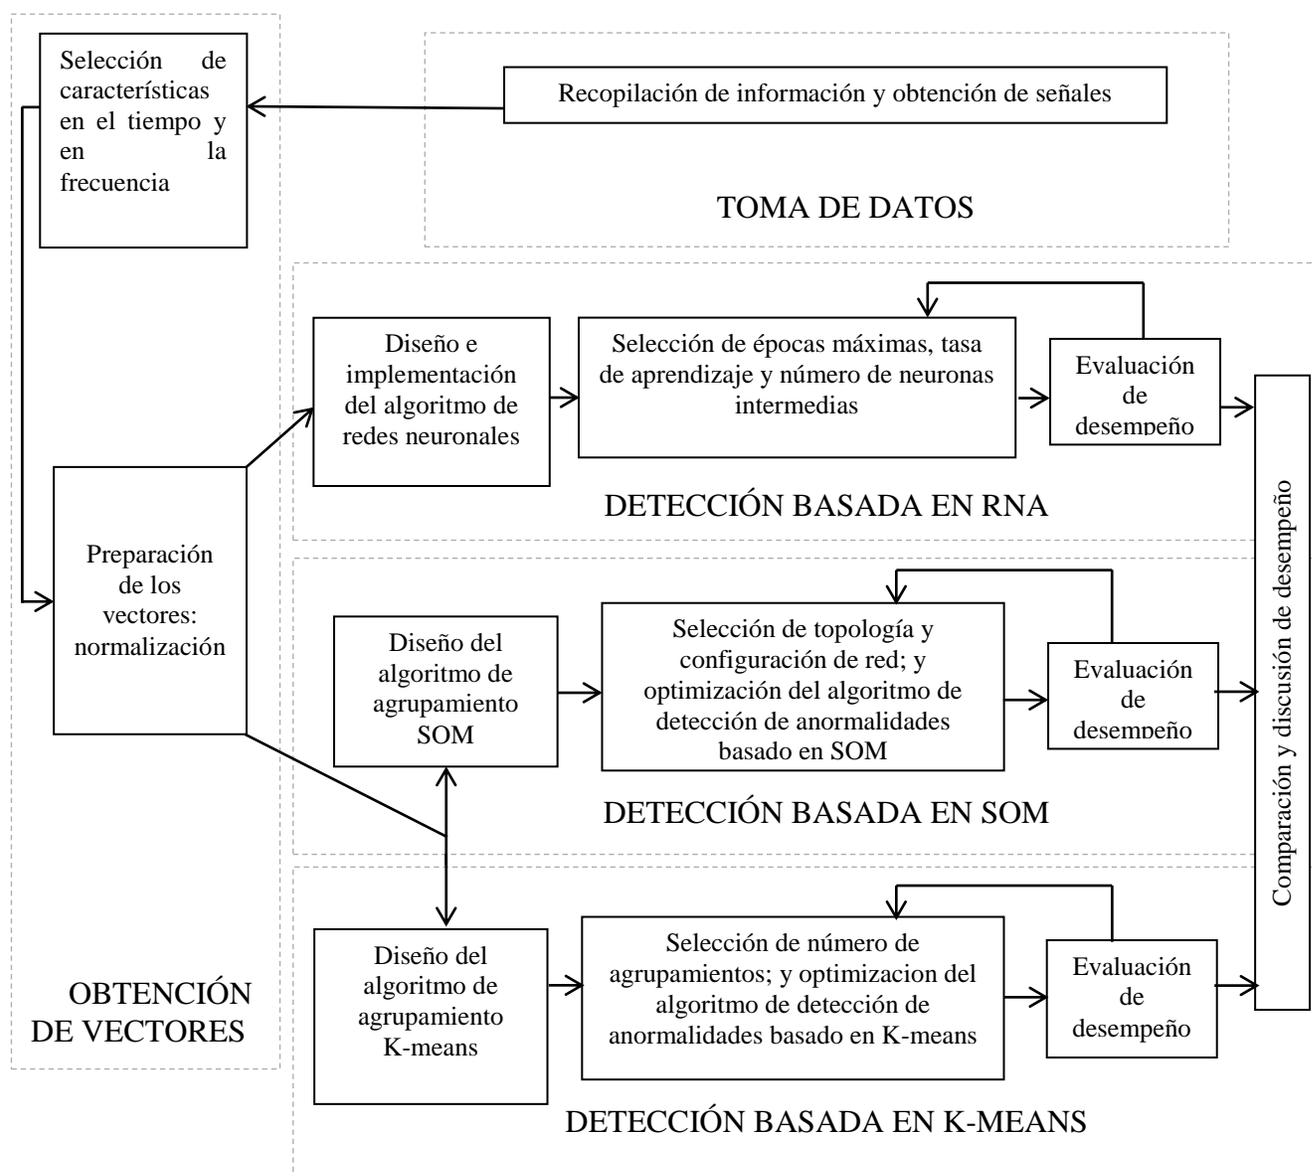


Figura 15. Descripción de la metodología planteada

Para el diseño del algoritmo se debe tener en cuenta la importancia de lograr una alta sensibilidad y/o una alta especificidad. En términos generales la sensibilidad es más importante que la especificidad porque un falso negativo puede causar paradas de los motores y/o la destrucción de los mismos a largo plazo, pero no es tan crucial como por ejemplo el caso de la prueba del VIH que exige una sensibilidad de 100% ya que el número de veces que se realiza la prueba es solo una y las consecuencias de un falso negativo implican hasta la muerte del paciente.

La prueba de naturaleza no invasiva planteada en el presente trabajo permite y facilita su aplicación periódica, además un motor con indicios de una falla sigue trabajando normalmente, el problema de la falla realmente recae en sus efectos largo plazo y en la reducción de eficiencia, así que para el desempeño del algoritmo detector se requiere de una sensibilidad alta no estrictamente del 100% y mantener una especificidad no muy baja porque un falso positivo implica tiempo en realizar pruebas exhaustivas y/o reemplazar al motor en la siguiente parada programada las cuales suelen durar pocos días y darse cada 6 meses o mas.

3.1 TOMA DE DATOS

La obtención de datos principalmente se subdivide en 3 partes: La recopilación de información sobre el motor y los componentes, la selección de la longitud y frecuencia de muestreo de las señales adquiridas y finalmente el planteamiento del procedimiento de adquisición de datos.

3.1.1 Recopilación de información

En primera instancia se debe recopilar la información que se dispone sobre los equipos de medición, por ejemplo ancho de banda, error porcentual, error de offset, frecuencia de muestreo

máxima, rango de medida, es decir los datos que sean necesarios para evitar errores en la adquisición de señales; también se necesita recopilar datos sobre el motor y sus componentes como su corriente nominal, su velocidad sincrónica, su velocidad a plena carga, la geometría de los rodamientos, cualquier dato que se considere útil para la elección de características.

3.1.2 Selección de longitud de la señal y frecuencia de muestreo

Se recomienda plantear la cantidad de muestras cuidadosamente ya que esto afecta al desempeño de los algoritmos. Para ello se debe considerar qué transformada se va a utilizar y cuál es la resolución en frecuencia que se necesita, esto se obtiene de la revisión bibliográfica.

3.1.3 Método de adquisición de datos

Se debe realizar la adquisición de señales bajo las condiciones de interés, es decir, simulando diferentes niveles de carga y diferentes fallas, la forma de simular las fallas esta descrita en el capítulo 1, y la forma de simular diferentes cargas se describe a continuación:

Se realiza el acople del motor en cuestión con un motor DC en configuración de generador, el cual está conectado a una carga resistiva, hay dos formas para cambiar el nivel de carga: se puede cambiar el valor de la resistencia conectada a la armadura del generador o se puede cambiar la corriente del núcleo.

Se plantea el siguiente procedimiento para la medición de las señales:

1. Se procede a realizar el acople de los ejes, para ello se coloca el generador DC con el cojinete y el motor en la estructura soporte y se realiza un acople de ejes inicial y después

se corrige este acople mediante inspección visual e inspección auditiva y se procede a asegurar todos estos componentes con tornillos y tuercas.

2. Se procede a armar el circuito diseñado

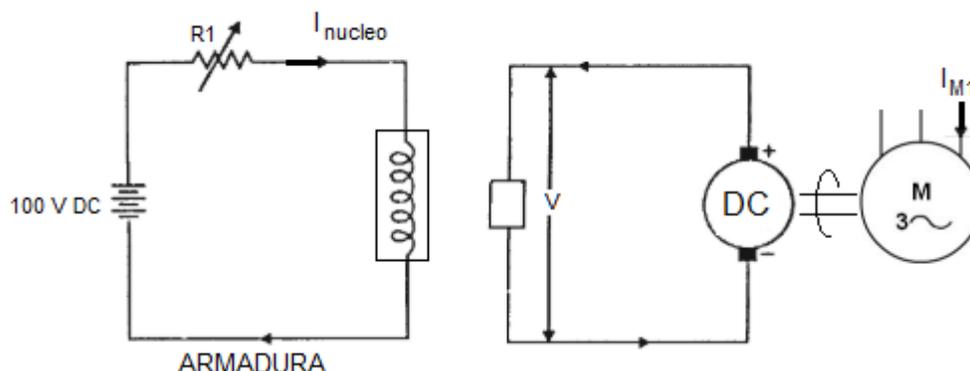


Figura 16. Circuito diseñado para la simulación de carga.

Fuente: (Fitzgerald et al., 2003)

3. Se procede a medir la corriente del motor I_{M1} , y aumentar paulatinamente la corriente del núcleo I_{NUCLEO} desde 0 hasta que la corriente I_{M1} adquiera su valor nominal utilizando el reóstato “R1”. Véase **Figura 16** **Figura 1**. Es necesario verificar si el circuito tiene las protecciones adecuadas y además asegurarse de no superar el nivel de corriente máxima y voltaje máximo para los diferentes elementos a utilizar en el circuito.
4. Se establece un valor I_{NUCLEO} máximo, y se realizan las mediciones para diferentes valores de esta corriente, se recomienda elegir estos valores dispersos para garantizar datos distribuidos a lo largo de la potencia del motor.
5. Realizar el procedimiento de medida nuevamente intercambiando los componentes defectuosos que simulan las fallas.

3.2 OBTENCIÓN DE LOS VECTORES

Esta sección trata básicamente del procedimiento para transformar las señales de las magnitudes físicas medidas en valores numéricos normalizados listos para los algoritmos. Para ello lo primero es seleccionar la forma de caracterizar las señales en tiempo y en frecuencia para posteriormente normalizar estos vectores de -1 a 1.

Transformar las señales medidas en valores numéricos que caracterizan a la señal para poder realizar una correcta detección es usualmente un procedimiento repetitivo que implica seleccionar diferentes características, evaluarlas y volver a seleccionar otras características y así hasta lograr el desempeño deseado. Se recomienda empezar con un algoritmo de detección básico y proponer diferentes parámetros y estrategias de caracterización de las señales, basándose siempre en la bibliografía disponible hasta obtener desempeños con los que se puedan trabajar en ajustes más específicos.

3.2.1 Selección de características en el tiempo

Para realizar la descripción en el tiempo de una señal se puede utilizar: la media, el RMS, el factor de cresta, la desviación estándar, la curtosis, el sesgo, el máximo, entre otros. El valor o conjunto de valores a utilizar depende del diseño y se establecen, como se mencionó, probando diferentes características; seleccionar la mayor cantidad de características no necesariamente mejora el desempeño.

3.2.2 Selección de características en frecuencia

Para extraer las características en frecuencia se debe centralizar la búsqueda en las bandas de frecuencias asociadas a las fallas de interés propuestas, esto se ejemplifica bien en la bibliografía encontrada, puede darse el caso que una magnitud física no pueda entregar información suficiente para realizar la detección ya que las fallas que se desean detectar necesitan tener una relación con las magnitudes físicas medidas comprobada experimentalmente o teóricamente.

De igual forma, se vuelve a recalcar la importancia de la revisión bibliográfica, ya que esta puede advertir que técnicas de análisis en frecuencia son las indicadas y bajo qué estrategias.

3.2.2.1 Selección con respecto a barras rotas

La falla de barras rotas genera armónicos en las frecuencias determinadas por la ecuación (5), esta ecuación tiene varias soluciones, sin embargo se recomienda probar varias de estas soluciones para encontrar la que produce mejores resultados por dos razones:

1. En la banda fundamental, el caso en el que $k/p=1$ de la **Tabla 9**, existe un problema usual pues las fallas no se diferencian por el efecto de la frecuencia fundamental así que, por ejemplo, en un estudio se propone el uso un filtro notch adaptativo para evitar este problema (Kia, Henao, & Capolino, 2009),
2. La falla de barras rotas genera componentes a alta frecuencia relativamente altos (Fitzgerald et al., 2003).

Con respecto a las técnicas de análisis utilizadas en frecuencia, se ha demostrado que la FT es una técnica exitosa en la detección de fallas de barras rotas (Arabacı & Bilgin, 2009).

3.2.2.2 Selección con respecto a fallas en los rodamientos

La falla de rodamientos genera armónicos en las corrientes determinados por las ecuaciones (7), (8), (9) y (10), se ha demostrado que la FT no es una técnica de análisis exitosa para detectar falla de rodamiento, pero si la DWT. La estrategia de detección utilizando DWT consiste en evaluar la energía de los coeficientes que forman parte de las bandas de interés. Por último, la elección de la wavelet madre se realiza experimentalmente al usar diferentes wavelet y comparar el desempeño bajo los tres algoritmos presentados, como se mencionó antes, para realizar esto es suficiente utilizar algoritmos de detección en su forma más simple.

3.3 DETECCIÓN BASADA EN REDES NEURONALES

La metodología utilizada para el diseño del algoritmo de detección basado en redes neuronales se detalla a continuación:

En primera instancia se definen los parámetros fundamentales: arquitectura de red y función de activación, posteriormente se define el número de épocas máximas en función del tiempo del procesamiento, en la siguiente etapa entrena la red bajo diferentes tasas de aprendizaje y bajo diferentes números de neurona en la capa intermedia, a partir de los resultados obtenidos se puede establecer el número ideal de neuronas intermedias y la tasa de aprendizaje. Finalmente se evalúa el desempeño varias veces y se obtiene un promedio. Esta sección está dividida en dos etapas: Selección de parámetros fundamentales y selección y evaluación.

3.3.1 Selección de parámetros fundamentales

Lo primero es definir los parámetros fundamentales de la red, es decir, los parámetros que se recomiendan para cualquier problema de clasificación binaria con redes neuronales los cuales son: función de activación y arquitectura de red. Un detector típicamente está formado por una red con un capa intermedia cuyo número de neuronas está acotado entre el número de neuronas de salida y el número de neuronas de entrada; para un detector binario se usa una neurona de salida, y la función de activación utilizada es la sigmoidea porque es la de uso convencional. Estos parámetros se recomiendan para la mayoría de problemas relacionados con detección usando redes neuronales, si es que el problema lo amerita se pueden cambiar por parámetros más sofisticados. El algoritmo implementado bajo estas consideraciones en el software Matlab se encuentra incluido en el Anexo C.

3.3.2 Selección y evaluación

En esta sección se propone un rango de valores para los diferentes parámetros de diseño del algoritmo y se evaluó el desempeño del algoritmo para determinar los parámetros óptimos. Una red neuronal necesita definir los siguientes parámetros: número de épocas máximas, número de neuronas intermedias y tasa de aprendizaje.

En primera instancia se realiza la selección del número de épocas máximas. El tiempo en el que el algoritmo realiza una época cambia según el número de neuronas, ya que a mas neuronas hay más operaciones matemáticas por realizar. Dado que se habla de redes neuronales sencillas lo recomendable es encontrar un número de épocas máximas que permita la evaluación del algoritmo bajo todas las diferentes condiciones en un tiempo no exageradamente largo. Es

posible que la red no se entrene correctamente, esto puede suceder porque la red es muy compleja, porque el número de épocas es muy corto, porque la capacidad de procesamiento es insuficiente o porque el algoritmo de entrenamiento utilizado no es el indicado.

Posteriormente se realiza la selección del número de neuronas y la tasa de aprendizaje para ello se debe entrenar la red utilizando K-fold con diferentes valores de neuronas intermedias y diferentes tasas de aprendizaje utilizando el número de épocas máximo seleccionado con anterioridad, al observar los resultados se puede analizar el comportamiento general del algoritmo y definir cuál es la tasa de aprendizaje ideal y también se puede definir el número de neuronas intermedias. En términos generales se recomienda usar valores de tasa de aprendizaje entre 0.05 y 0.5 (Rumelhart, Hinton, & Williams, 1986), sin embargo se ve en la bibliografía como tasas de aprendizaje de 0.001 y 0.005 son utilizadas para resolver problemas de características similares (L. Li, Mechefske, & Li, 2004).

3.4 DETECCIÓN BASADA EN K-MEANS

Para realizar la detección de fallas se necesita diseñar dos algoritmos, el primero es el algoritmo de agrupamiento K-means, y el segundo es el algoritmo de detección de anomalía basado en K-means. La metodología de diseño utilizada se detalla a continuación:

Los primero es definir los parámetros fundamentales, estos valores se recomiendan para cualquier problema relacionado con K-means, posteriormente se realiza la selección del número de agrupamientos ideal, por supuesto esto depende de los datos de entrenamiento y cambia con cada problema por ello lo ideal es realizarlo mediante la evaluación del desempeño, y finalmente se realiza la evaluación final del desempeño del algoritmo varias veces para evitar los errores

producidos por la aleatoriedad de la elección de los datos. Esta sección está dividida en dos partes: selección de parámetros para el agrupamiento K-means y selección y evaluación.

3.4.1 Selección de parámetros para el agrupamiento K-means

Estos parámetros permiten que el algoritmo realice agrupamiento de forma correcta y en general se recomiendan para cualquier problema de agrupamiento relacionado con K-means:

- Inicialización de los centroides: de forma aleatoria en el rango de -1 a 1.
- Métrica de distancia: métrica euclidiana porque es la más usada de propósito general

El algoritmo se implementa en el software Matlab y se encuentra en el Anexo D

3.4.2 Selección y evaluación

En esta sección se proponen un rango de valores para los diferentes parámetros de diseño del algoritmo y se evaluó el desempeño del algoritmo para determinar los parámetros óptimos para ello se debe evaluar el algoritmo utilizando diferentes valores de aglomerados y utilizando un rango de modificador “M” el cual es el único parámetro de diseño del algoritmo de detección basado en K-means.

3.5 DETECCIÓN BASADA EN SOM

Para realizar la detección de fallas se necesita diseñar dos algoritmos, el primero es el algoritmo de agrupamiento SOM, y el segundo es el algoritmo de detección de anomalía basado en SOM. La metodología de diseño utilizada se detalla a continuación:

Lo primero es definir los parámetros fundamentales del algoritmo de agrupamiento de mapas auto organizado, es decir aquellos valores o funciones que permiten realizar el agrupamiento de los vectores de datos correctamente, los parámetros que se definen en esta sección se recomiendan para cualquier problema relacionado con SOM. Posteriormente se realiza la selección de la configuración de red adecuada (número y disposición de nodos), esto por supuesto depende de los datos de entrenamiento y cambia con cada problema por ello lo ideal es realizarlo mediante la evaluación de desempeño del detector, finalmente se selecciona los parámetros óptimos del algoritmo de detección de anomalía basado en SOM. Esta sección está organizada en dos secciones: selección de los parámetros para el algoritmo de agrupamiento SOM y selección y evaluación.

3.5.1 Selección de los parámetros para el agrupamiento SOM

Tabla 1

Parámetros elegidos para el algoritmo de mapas auto organizados en la fase de ordenamiento

Función/ Valor elegido	Parámetros	Criterio
Tasa de aprendizaje $TA = TA_0 e^{-\frac{t}{t_{max}}}$	$TA_0 = 0.1$ $t = 0, 1, 2..$	La tasa de aprendizaje debe empezar en un valor cercano a 0.1 y debe decrecer gradualmente pero permanecer encima de 0.01 (Haykin, 2005).
Función de vecindad $N(d, \sigma) = \begin{cases} 1 - \frac{ d }{\sigma}, & d \leq \sigma \\ 0, & \text{otros} \end{cases}$		La función debe incluir inicialmente la mayoría de neuronas de la red y decaer paulatinamente a unos pocos vecinos o únicamente a la neurona ganadora (Haykin, 2005). Se elige la función triangular porque es la función más sencilla que cumple este requerimiento.
Función sigma $\sigma(t) = \sigma_0 e^{-\frac{t \log(\sigma_0)}{1000}}$	$\sigma_0 =$ "máxima distancia euclidiana entre dos neuronas en la topología de red" $t = 0, 1, 2..$	El valor σ_0 debe ser aproximadamente el radio de la red, y se sugiere la ecuación de la forma $(t) = \sigma_0 e^{-\frac{t \log(\sigma_0)}{1000}}$ (Haykin, 2005).
Número de épocas t	Número de máximo de épocas $t_{max} = 1000$ $t = 0, 1, 2..(t_{max} - 1)$	El número de épocas recomendado para la fase de ordenamiento es de al menos 1000 y t debe iniciar desde cero (Haykin, 2005).

Tabla 2

Parámetros elegidos para el algoritmo de mapas auto organizados en la fase de convergencia

Función/ Valor elegido	Parámetros	Criterio
Tasa de aprendizaje $TA = TA_0 e^{-\frac{t}{t_{max}}}$	$TA_0 = 0.05$ $t = 0, 1, 2..(t_{max} - 1)$	Para la correcta convergencia del modelo, la tasa de aprendizaje debe mantenerse valores pequeños del orden de 0.01 y no decrecer a cero (Haykin, 2005). Además la tasa es mucho más pequeño que el de la fase de ordenamiento (Depren et al., 2005).
Función de vecindad $N(d, \sigma) = \begin{cases} 1 - \frac{ d }{\sigma} & d \leq \sigma \\ 0, & \text{otros} \end{cases}$		La función debe incluir inicialmente solo algunos vecinos y decaer a uno o a cero. Se elige la función triangular porque es la más sencilla que cumple con esta condición (Haykin, 2005).
Función sigma $\sigma(t) = \frac{\sigma_0(t_{max} - t)}{t_{max}}$	$\sigma_0 = 0.2$ *"máxima distancia euclidiana entre dos neuronas en la topología de red"	La función debe incluir inicialmente solo algunos vecinos y decaer a uno o a cero vecinos. Se propone esta ecuación porque cumple con el requerimiento y por su sencillez (Haykin, 2005).
Número de épocas t	Número de máximo de épocas $t_{max} = 500$ $t = 0, 1, 2..(t_{max} - 1)$	El número de épocas recomendado para la fase de convergencia es de al menos 500 (Haykin, 2005).

El algoritmo de agrupamiento SOM se realiza en dos fases, y cada una tiene sus propios parámetros de diseño, para ello se toma en cuenta varios criterios que han sido resumidos la **Tabla 1** y la **Tabla 2**. Se usa la topología de red de malla cuadrada por ser sencilla y de uso general. El algoritmo se implementa en el software Matlab y se encuentra en el Anexo F.

3.5.2 Selección y evaluación

En primera instancia se debe seleccionar el número y la configuración de red. En general se puede tener una red lineal, rectangular y cuadrada. Para ello se procede a evaluar el desempeño del algoritmo utilizando diferentes configuraciones, por ejemplo, se podría evaluar la configuración lineal con 1, 2, 3... 10 nodos, es decir un red de la forma "1 por K" con K=1, 2, 3... 10, a la par se puede evaluar una configuración cuadrada con número de nodos de 1, 4, 9, 16, 25... 100, es decir un red de la forma "K por K" con K=1, 2, 3... 10. La manera correcta de

encontrar la configuración adecuada es probar el algoritmo bajo diferentes configuraciones por ejemplo las detalladas en la **Tabla 16** y seleccionar una configuración de red que se considere apropiada según los resultados. La única consideración que se debe tener es que generalmente el número de nodos totales es mucho menor al número de vectores de entrenamiento.

CAPITULO 4: RESULTADOS

En este capítulo se aplica la metodología descrita en el capítulo 3 al motor en cuestión con la finalidad de obtener resultados y seleccionar los valores de diseño que se consideren adecuados. Los detectores usualmente funcionan con los datos del motor con el que fueron entrenados y no deben ser utilizados en otro motor, lo que sí se puede generalizar es la metodología de diseño del algoritmo detector.

4.1 TOMA DE DATOS

Como se menciona en el capítulo 3, primero se realiza una recopilación de información relevante, luego se realiza la selección de la longitud de las muestras y la frecuencia de muestreo, y finalmente se detalla la metodología utilizada en la toma.

4.1.1 Recopilación de información

Se cuenta con un motor ABB, cuyo código de producto es 3GQA 082302 – AXA. De donde se obtienen las especificaciones técnicas de importancia descritas en la **Tabla 3**.

Tabla 3

Especificaciones técnicas importantes sobre el motor

Característica	Valor
Velocidad sincrónica	1800 rpm
Velocidad a plena carga	1705 rpm
Tipo de rodamiento	6204-2RSH/C3
Frecuencia de alimentación	60Hz
Número de polos	4

Dado que se dispone del código de rodamiento marca SKF 6204-2RSH/C3, las dimensiones se pueden obtener ya que existen planos de los rodamientos en archivos .CAD provenientes del fabricante, de donde se obtiene los datos detallados en la **Tabla 4** que son de importancia para determinar las bandas de frecuencias asociadas a la falla en estos componentes:

Tabla 4

Especificaciones técnicas relevantes sobre los rodamientos

Característica	Valor
Número de bolas	8
Diámetro de bolas	7.94 mm
Diámetro “pitch” de rodamiento	33.7 mm

Para medir la corriente se utilizará una pinza amperimétrica “Fluke i200s AC Current Clamp”, en la **Tabla 5** se detallan las características técnicas importantes del equipo.

Tabla 5

Especificaciones técnicas relevantes sobre la pinza amperimétrica usada.

Característica	Valor
Ancho de banda	40Hz a 40Khz
Rango de medida	0.1 - 24 A
Error de ganancia	<15%
Error offset	0.5 A

Se cuenta con un chasis CDAQ-9184 y una tarjeta NI9215 (BNC), de donde se obtienen los parámetros definidos en la **Tabla 6**

Tabla 6*Especificaciones relevantes sobre el equipo de adquisición de datos*

Característica	Detalle
Versión de NI-DAQmx	NI-DAQmx 9.6
DAC resolución	16 bits
Tiempo de conversión	4,4 us
Máximo error de ganancia	1.05%
Máximo error de offset	0.82%
Muestras máximas por segundo	100K/s/canal

4.1.2 Definición de las características de las señales de corriente

Las señales utilizadas son adquiridas con una frecuencia de muestreo de 50K y con una duración de 2 segundos para el presente trabajo, la razón de esta elección se detalla a continuación:

Las fallas en los rodamientos son más difíciles de detectar que la falla de barras rotas cuando se utiliza señales de corriente así que se prioriza la estrategia utilizada para detectar esta falla la cual se basa en DWT, la resolución usada en la bibliografía típicamente es del orden de los pocos hercios, por ejemplo de 3.9 Hz (Zarei & Poshtan, 2007) o de 7.5 Hz, (Levent Eren et al., 2004), considerando que la máxima frecuencia de muestreo es de 50 KHz y que se pueden lograr resoluciones del orden deseado con un nivel de descomposición de 12 (6.10 Hz de resolución) o de 13 (3.05 Hz de resolución) se propone utilizar un numero de muestras de $N=100000$ ya que este valor nos permite realizar 12 y 13 niveles de descomposición en la gran mayoría de las wavelets madres discretas, como se aprecia en la **Tabla 7**.

4.1.3 Adquisición de datos

Se realiza el procedimiento detallado la sección 3.1.3 en el cual se determina que el motor llega a su valor de corriente nominal cuando $I_{NUCLEO} = 0.56$ amperios. Por lo tanto se establece la siguiente metodología de toma de datos:

Tabla 7

Máximo nivel de descomposición recomendado según la wavelet madre seleccionada utilizando el comando “wmaxlev” de matlab para un número de muestras de 100K

Wavelet madre	Nivel de descomposición máxima sugerida	Wavelet madre	Nivel de descomposición máxima sugerida
Db1	16	Bior2.4	13
Db2	15	Bior2.8	12
Db3	14	Bior3.1	15
Db4	13	Bior3.3	13
Db5	13	Bior3.5	13
Db6	13	Bior3.7	12
Coif1	14	Bior3.9	12
Coif2	13	Bior4.4	13
Coif3	12	Bior5.5	13
Coif4	12	Bior6.8	12
Sym1	16	Rbio1.1	16
Sym2	15	Rbio1.3	14
Sym3	14	Rbio1.5	13
Sym4	13	Rbio2.2	14
Sym5	13	Rbio2.4	13
Dmey	9	Rbio2.8	12
Fk4	15	Rbio3.1	15
Fk6	14	Rbio3.3	13
Fk8	13	Rbio3.5	13
Bior1.1	16	Rbio3.7	12
Bior1.3	14	Rbio3.9	12
Bior1.5	13	Rbio4.4	13
Bior2.2	14	Rbio5.5	13
Bior2.4	13	Rbio6.8	12

Se realiza la puesta del motor sin fallas y se varía la corriente I_{NUCLEO} en forma ascendente desde 0 hasta 0.59 amperios. Véase **Figura 16**. En pasos de 0.01 amperios, y se adquieren 5 señales en cada paso, luego se lo realiza de forma descendente tomando 5 señales más en cada paso.

Posteriormente se intercambian los componentes defectuosos para realizar otras 600 mediciones simulando un motor con barras rotas y otras 600 medidas con un motor con falla en rodamientos.

En resumen, se obtienen 1800 muestras (600 para cada caso) de longitud 100 K y a una frecuencia de muestreo de 50 KHz.

4.2 OBTENCIÓN DE LOS VECTORES

En primera instancia se define el deslizamiento máximo porque es un valor importante para definir las frecuencias de interés como se aprecia en las ecuaciones (5), (6), (7), (8) y (9) . Se conoce por el detalle técnico descrito en la **Tabla 3** que la velocidad a plena carga es de 1705 rpm, y que la velocidad sincrónica es de 1800 rpm, lo que implica que el deslizamiento a plena carga del motor es de $s_{plenacarga} = \frac{1800-1705}{1800} = 0.053$ sin embargo se establece un valor de deslizamiento máximo conservador de $s = 0.06$

Los vectores finales utilizados que sirven como entradas para los algoritmos constan prácticamente de 3 secciones, los relacionados con el tiempo, los relacionados con barras rotas y los relacionados con fallas en los rodamientos los cuales están detallados en la **Tabla 8**. La forma de selección de las características se detalla a continuación:

Tabla 8

Descripción de los vectores de entrada seleccionados para la evaluación del desempeño final de los algoritmos

Segmento	Características	Número de valores
Análisis del tiempo	RMS de la señal en el tiempo	1
	Curtosis de la señal en el tiempo	1
	Desviación estándar de la señal en el tiempo	1
Análisis de barras rotas	Promedio de los coeficientes de la transformada de Fourier de la banda de interés aislada	1
	Los 4 valores más altos de la transformada de Fourier de la banda de interés aislada	4
Análisis de fallas en los rodamientos	Energía de los nodos de la descomposición wavelet de interés	6
TOTAL		14

4.2.1 Selección de características en tiempo

La selección de las características asociadas al tiempo proviene de realizar varias evaluaciones del desempeño utilizando diferentes combinaciones, usualmente este procedimiento requiere probar varias combinaciones de características utilizando versiones sencillas de los algoritmos de detección.

4.2.2 Selección de características de frecuencia para barras rotas

Se proponen bandas de interés partiendo la ecuación de asimetrías en el rotor (5) usadas exitosamente para determinar las frecuencias asociadas a barras rotas:

Se dispone a resolver los rangos de interés para las condiciones considerando que la frecuencia de alimentación es $f_o = 60 \text{ Hz}$, el deslizamiento máximo $s_{\text{maximo}} = 0.06$, y que $\frac{k}{p} = 1, 5, 7, 11$, los cuales se resumen en la **Tabla 9**.

Para caracterizar estas bandas se propone seleccionar los coeficientes de la transformada de Fourier que están dentro de la banda de interés y obtener el promedio y los 4 valores más altos.

Para evitar la redundancia de información y reducir la dimensión de los vectores de entrada, se propone elegir uno de los valores de k/p definidos en la **Tabla 9**, para ello se evalúa el desempeño logrado en cada uno de los 3 algoritmos propuestos, como se plantea anteriormente es suficiente utilizar versiones sencillas de los algoritmos de detección. Los parámetros utilizados y la forma de obtener los resultados se detallan en el Anexo A. Los resultados obtenidos con respecto al desempeño del detector se aprecian en la **Figura 17**, **Figura 18** y **Figura 19**, en las cuales se puede apreciar como el caso en el que $k/p=7$ es el óptimo.

Tabla 9

Posibles bandas de interés para la caracterización de falla de barras rotas

Ecuación	Valores usados	Bandas
$f = f_o \left[k \left(\frac{1-s}{p} \right) \pm s \right]$	$f_o = 60 \text{ Hz}, s = 0.08, \frac{k}{p} = 1$	50.4 Hz – 60 Hz
$f = f_o \left[k \left(\frac{1-s}{p} \right) \pm s \right]$	$f_o = 60 \text{ Hz}, s = 0.08, \frac{k}{p} = 5$	271.2 Hz – 300 Hz
$f = f_o \left[k \left(\frac{1-s}{p} \right) \pm s \right]$	$f_o = 60 \text{ Hz}, s = 0.08, \frac{k}{p} = 7$	381.6 Hz – 420 Hz
$f = f_o \left[k \left(\frac{1-s}{p} \right) \pm s \right]$	$f_o = 60 \text{ Hz}, s = 0.08, \frac{k}{p} = 11$	602.4 Hz – 660 Hz

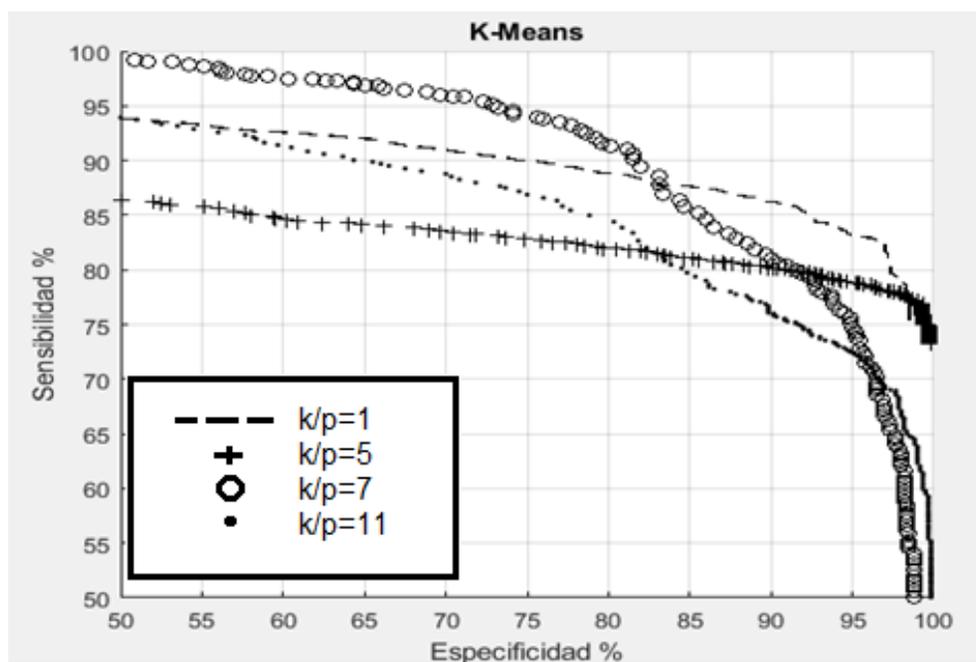


Figura 17. Especificidad vs sensibilidad para diferentes bandas asociadas a la falla de barras rotas utilizando el algoritmo de detección basado en K-means

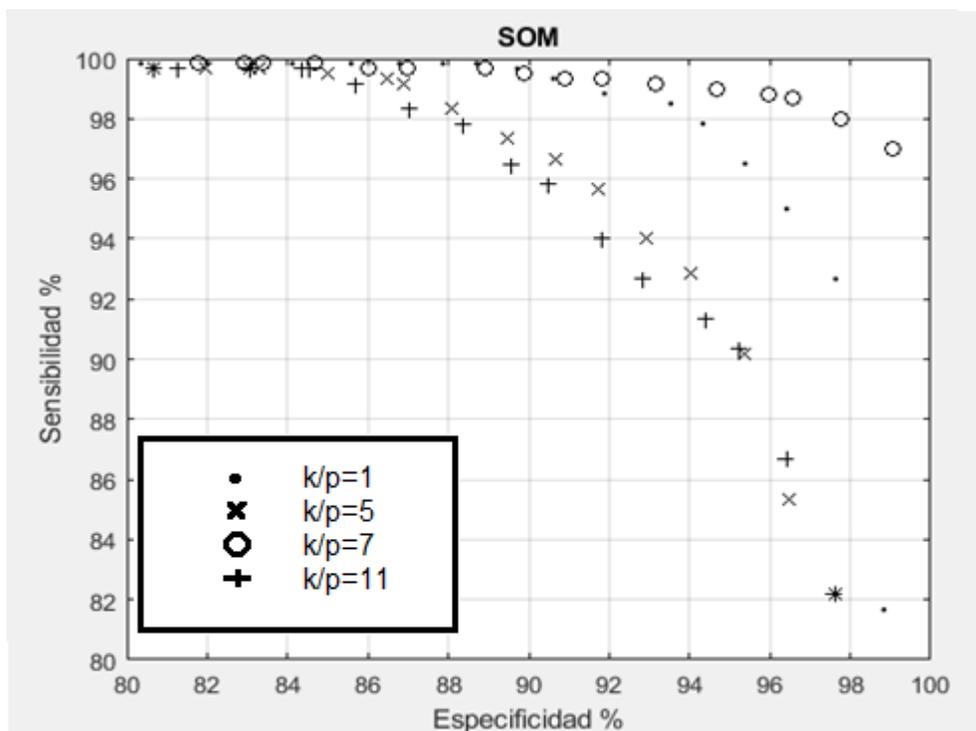


Figura 18. Especificidad vs sensibilidad para diferentes bandas asociadas a la falla de barras rotas utilizando el algoritmo de detección basado en SOM.

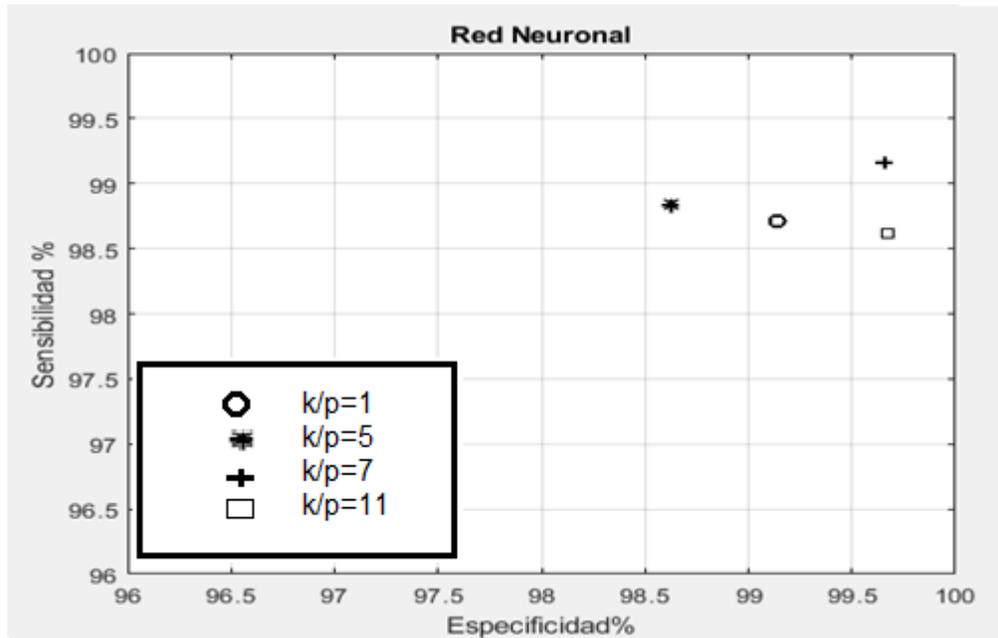


Figura 19. Especificidad vs sensibilidad para diferentes bandas asociadas a la falla de barras rotas utilizando el algoritmo de redes neuronales

4.2.3 Selección de características de frecuencia para falla en rodamientos

Se define la frecuencia de giro del eje en hertzios, se junta la ecuación (1) y (4), y se obtiene la ecuación (25).

$$f_e = (1 - s) \frac{120f_o}{p} * \frac{rev}{min} * \frac{min}{60s} = (1 - s) \frac{2f_o}{p} \text{ Hz} \quad (25)$$

Reemplazando la ecuación (25) en la ecuación (8) se obtiene las frecuencias mecánicas debidas a falla en la pista exterior de los rodamientos descrita por la ecuación (26).

$$f_{pe} = n \cdot (1 - s) \frac{f_o}{p} \cdot \left(1 - \frac{d}{D} \cos(\alpha)\right) \quad (26)$$

Y reemplazando la ecuación (26) en (10), se obtiene las frecuencias en la corriente del estator asociadas a la falla en la pista exterior de los rodamientos definida por la ecuación (27).

$$f_{\text{rodamiento}} = \left| f_o \pm k \cdot n \cdot (1 - s) \cdot \frac{f_o}{p} \cdot \left(1 - \frac{d}{D} \cos(\alpha) \right) \right| \quad (27)$$

Para resolver la ecuación (27) se utiliza la información resumida en la **Tabla 10** obteniendo los resultados mostrados en la **Tabla 11**.

Tabla 10

Valores definidos para determinar las frecuencias asociadas a la falla en la pista externa del rodamiento

Variable	Valor	Detalle
f_o	60Hz	Frecuencia de alimentación.
n	8 bolas	Numero de bolas del rodamiento.
D	33.7 mm	Diámetro “pitch” del rodamiento
d	7.94 mm	Diámetro de las bolas del rodamiento
p	4	Numero de polos del motor
α	0	Angulo de contacto entre la falla y la bola.
s	De 0 a 0.06	Deslizamiento del motor en diferentes cargas
k	± 1	Variable asociada al armónico.

Tabla 11

Valores definidos para determinar las frecuencias asociadas a la falla en la pista externa del rodamiento

Valor	Rango de frecuencias de interés obtenido de la ecuación (27)	Nodos de la descomposición wavelet de interés	Frecuencias relacionadas con los nodos
$k = -1$	26.22 a 31.73 Hz	(13,8)	24.41 Hz - 27.47Hz
		(13,9)	27.47 Hz - 30.52 Hz
		(13,10)	30.52 Hz - 33.57 Hz
$k = +1$	146.22 a 151.73 Hz	(13,47)	143.43 Hz – 146.48 Hz
		(13,48)	146.48 Hz – 149.54 Hz
		(13,49)	149.54 Hz – 152.59 Hz

Tabla 12*Desempeño obtenido según la wavelet madre seleccionada*

WAVELET MADRE	SOM	K-MEANS	RED NEURONAL	
	ESPECIFICIDAD (sensibilidad 100%)	ESPECIFICIDAD (sensibilidad 100%)	SENSIBILIDAD	ESPECIFICIDAD
Db1	86.8	9.2	100	99.82
Db2	69.7	11.0	99.66	99.33
Db3	60.8	17.3	99.35	99.67
Db4	59.7	9.8	99.51	99.52
Db5	23.3	2.7	97.67	96.33
Coif1	63.7	13.0	100	99.67
Coif2	19.0	1.3	96.33	98.33
Coif3	11.3	2.8	96.54	96.32
Coif4	19.5	2.3	97.65	96.73
Sym1	86.3	9.7	100	99.68
Sym2	69.8	9.2	99.66	98.88
Sym3	68.2	14.2	99.52	99.82
Dmey	1.5	0	91.94	97.17
Fk4	66.8	8.7	99.03	99.35
Fk6	64.7	12.8	99.49	99.66
Fk8	38.2	7.0	98.05	98.47
Bior1.1	87.5	8.7	100	99.67
Bior1.3	30.0	4.7	99.01	99.68
Bior1.5	19.5	3.5	99.67	98.50
Bior2.2	66.0	8.5	99.50	99.51
Bior2.4	52.5	7.0	99.48	99.50
Bior2.8	39.2	1.8	99.34	98.17
Bior3.1	22.3	5.2	99.31	96.52
Bior3.3	3.5	1.3	90.42	94.88
Bior3.5	7.7	0	97.82	97.16
Bior3.7	12.7	0.3	97.98	96.10
Bior3.9	17.3	0.7	98.69	95.46
Bior4.4	68.7	5.2	98.88	99.12
Bior5.5	35.8	3.8	99.33	98.36
Bior6.8	77.3	7.5	99.84	100
Rbio1.1	86.5	8.2	100	99.83
Rbio1.3	95.8	24.5	100	100
Rbio1.5	82.8	18.8	99.67	100
Rbio2.2	77.0	11.3	100	99.85
Rbio2.4	98.8	25.2	99.83	100
Rbio2.8	83.8	14.3	99.84	100
Rbio3.1	13.2	0	98.00	98.16
Rbio3.3	82.0	23.2	100	99.82
<u>Rbio3.5</u>	<u>99.5</u>	<u>40.3</u>	<u>100</u>	<u>100</u>
Rbio3.7	98.2	29.0	99.83	100
Rbio3.9	91.0	20.2	100	100
Rbio4.4	79.2	4.7	100	99.84
Rbio5.5	31.3	11.2	99.83	99.83
Rbio6.8	78.8	9.3	99.83	100

Una vez que ya se conocen los nodos de interés, se necesita definir cuál es la wavelet madre indicada para ello se evalúa el desempeño logrado en cada uno de los 3 algoritmos propuestos, como se plantea anteriormente es suficiente utilizar versiones sencillas de los algoritmos de detección. Los parámetros utilizados y la forma de obtener los resultados se detallan en el Anexo B. Los resultados obtenidos se aprecian en la **Tabla 12** los cuales muestran como la wavelet biortogonal inversa 3.5 es la que mejores resultados produce.

4.3 DETECCIÓN BASADA EN REDES NEURONALES

4.3.1 Selección y evaluación

Se selecciona un número de neuronas intermedias de 8, una tasa de aprendizaje de 0.0005 y un número máximo de épocas de 100 000, el porqué de la elección se detalla a continuación:

Como se menciona lo ideal es probar el comportamiento general del algoritmo bajo diferentes condiciones hasta encontrar un número de épocas que permita entrenar la red correctamente y también permita evaluarla bajo diferentes condiciones de interés, no es recomendable, por ejemplo, proponer un tiempo de entrenamiento de 5 minutos si las condiciones de evaluación son tan diversas que al realizar este entrenamiento usando validación cruzada y probarla para diferente cantidad de neuronas intermedias se deba utilizar a la final varias horas o incluso días para obtener los resultados no es factible. El algoritmo utilizado para evaluar el comportamiento del detector considerando diferentes valores de agrupamientos se encuentra en el Anexo C.

Tabla 13

Tiempo de cómputo para las diferentes condiciones de interés en las cuales se evaluó el algoritmo de redes neuronales

Tasa de aprendizaje	Número de épocas	K-Fold	Número de neuronas	Tiempo
0.0005	100 000	K=5	De 1 a 14	5089 segundos
0.005	100 000	K=5	De 1 a 14	4849 segundos
0.05	100 000	K=5	De 1 a 14	4953 segundos
0.5	100 000	K=5	De 1 a 14	4962 segundos
Total				331 minutos

En la **Tabla 13** se aprecia el tiempo que se tomó realizar la evaluación el algoritmo utilizando diferentes tasas de aprendizaje y diferentes números de neuronas intermedias proponiendo un número de épocas de 100 000 y utilizando K-fold con K=5, y en la **Figura 20** se muestran los resultados obtenidos.

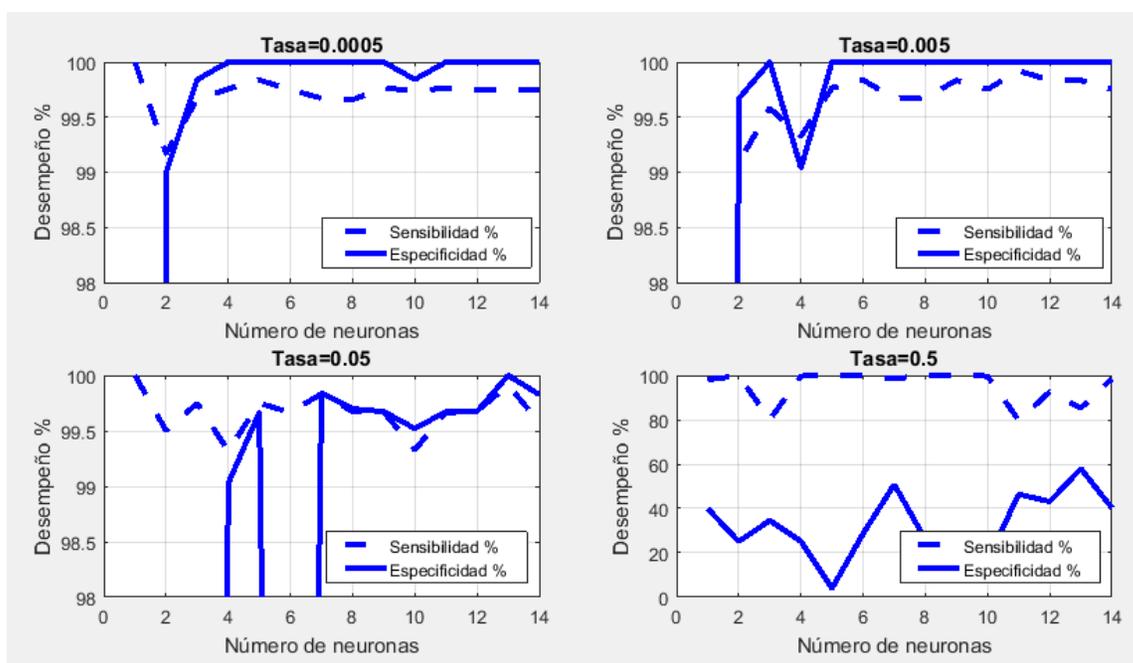


Figura 20. Especificidad vs sensibilidad del algoritmo de redes neuronales para diferentes tasas de aprendizaje y número de neuronas en la capa intermedia

Analizando los resultados presentados en la **Figura 20** se aprecia que a más neuronas el desempeño no mejora, pero sí puede pasar que al usar pocas neuronas el desempeño decaiga, en general con 8 neuronas ya se obtiene buenos resultados; también se aprecia como para tasas de 0.005 o menos se puede obtener valores de sensibilidad y especificidad mayores a 99.5%.

4.3.2 Evaluación final de desempeño

En esta sección se toman los parámetros seleccionados anteriormente y se evaluó el algoritmo con el fin de obtener el desempeño final a base de un valor promedio.

La evaluación final del algoritmo se realiza utilizando K-Fold con K=10, y se lo realiza 5 veces, los resultados se muestran en la **Tabla 14**. El desempeño final obtenido es de 99.75% de sensibilidad y de 99.97% de especificidad.

Tabla 14

Evaluación final de desempeño del algoritmo de redes neuronales

Numero	Sensibilidad	Especificidad
1	99.68%	99.85%
2	99.75%	100%
3	99.67%	100%
4	99.84%	100%
5	99.84%	100%
Promedio	99.75%	99.97%
Desviación estándar	0.0842%	0.0688%

4.4 DETECCIÓN BASADA EN K-MEANS

4.4.1 Selección y evaluación

Se evaluó el desempeño del algoritmo utilizando K-Fold con $K=10$ bajo diferentes número de agrupamientos, el algoritmo utilizado para evaluar el comportamiento del detector considerando diferentes valores de agrupamientos se encuentra en el Anexo E. Los resultados obtenidos se muestran en la *Figura 21* y se aprecia que el número óptimo de agrupamientos es de 3.

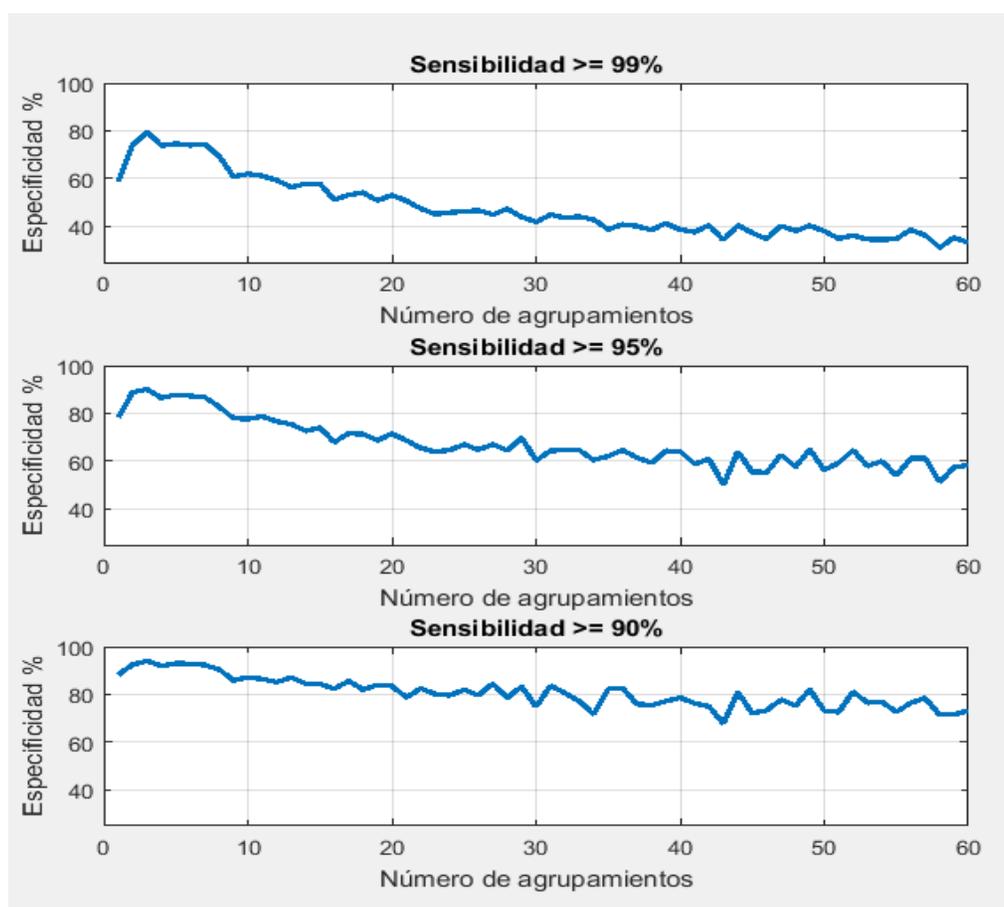


Figura 21. Especificidad vs número de agrupamientos para diferentes valores de sensibilidad permitida utilizando el algoritmo de detección basado en K-means

Para realiza la selección del parámetro “M” se evalúa el algoritmo utilizando K-Fold con $K=300$ y los resultados se muestran en la **Figura 22** y en la **Figura 23** en la cual se muestra cómo cambia el valor de sensibilidad y especificidad según este parámetro.

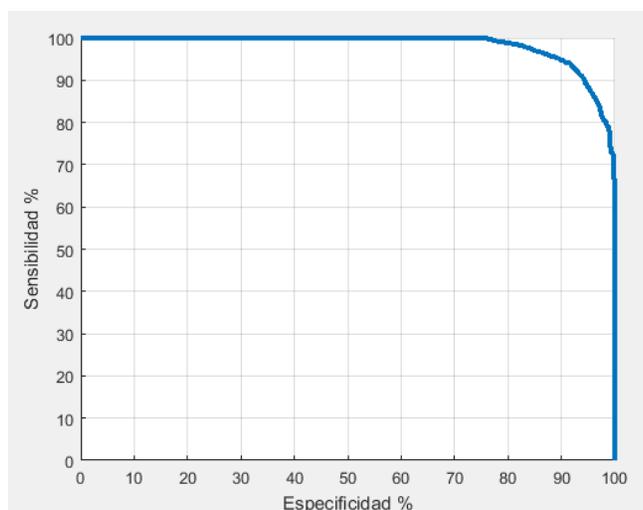


Figura 22. Especificidad vs Sensibilidad, utilizando *K-means* con 3 agrupamientos

Los resultados muestran que el desempeño del algoritmo es apenas aceptable, además se aprecia en la **Figura 23** como para valores de sensibilidad de 100% la especificidad es demasiado baja cercana al 60%, por ello se elige un valor de $M=0.743$.

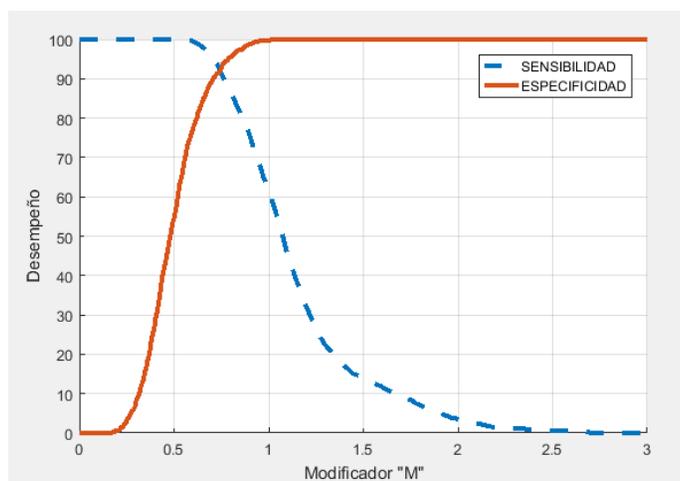


Figura 23. Especificidad y Sensibilidad vs “M” utilizando *K-means* con 3 agrupamientos

4.4.2 Evaluación final de desempeño

En esta sección se toman los parámetros seleccionados anteriormente y se evaluó el algoritmo con el fin de obtener el desempeño final a base de un valor promedio.

La evaluación final del algoritmo se realiza utilizando K-Fold con K=10, y se lo realiza 5 veces, los resultados se muestran en la **Tabla 15**. El desempeño final obtenido es de 92.08% de sensibilidad y de 92.83% de especificidad.

Tabla 15

Evaluación final de desempeño del algoritmo de detección basado en K-means

Numero	Sensibilidad	Especificidad
1	92.05%	93.00%
2	92.16%	92.50%
3	92.05%	92.67%
4	92.95%	92.83%
5	92.21%	93.17%
Promedio	92.08%	92.83%
Desviación estándar	0.1016%	0.2635%

4.5 DETECCIÓN BASADA EN SOM

4.5.1 Selección y evaluación

En primera instancia se selecciona el número y la configuración de red, posteriormente se selecciona el valor de cota y de margen que son los parámetros de diseño del algoritmo de detección basado en SOM.

Al seleccionar la configuración de dimensiones, en general se puede tener una red lineal (“1 por a”), rectangular (“2 por a, 4 por a”) y cuadrada (“a por a”). Para ello se procedió a realizar la

evaluación de desempeño utilizando diferentes redes descritas en la **Tabla 16** y los resultados se muestran en la **Figura 24**, en la **Figura 25** y en la **Figura 26**. El algoritmo utilizado para evaluar el detector considerando diferentes valores de agrupamientos se encuentra en el Anexo G.

Tabla 16

Configuración de topologías de red propuestas para ser evaluadas

Configuración	Valores
1xA	A=8, 16, 24, 32, 40, 48, 56, 64, 72, 80
2xA	A=4, 8, 12, 16, 20, 24, 28, 32, 36, 40
4xA	A=2, 4, 6, 8, 10, 12, 14, 16, 18, 20
AxA	A=2, 3, 4, 5, 6, 7, 8, 9

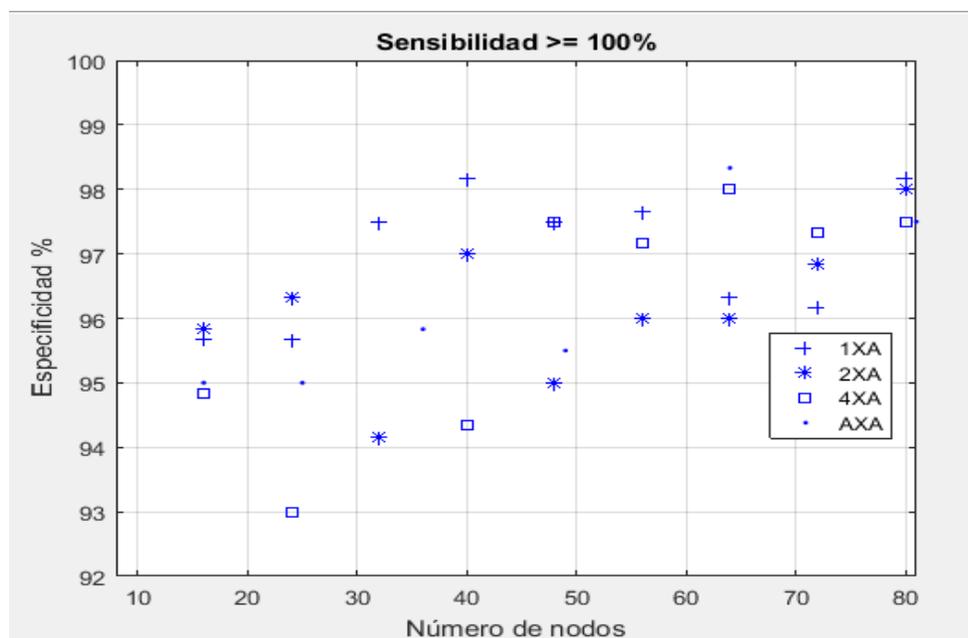


Figura 24. Especificidad y Sensibilidad vs número de nodos en el mapa para distintas configuraciones de red utilizando el algoritmo de detección basado en SOM considerando una sensibilidad de mínimo 100%

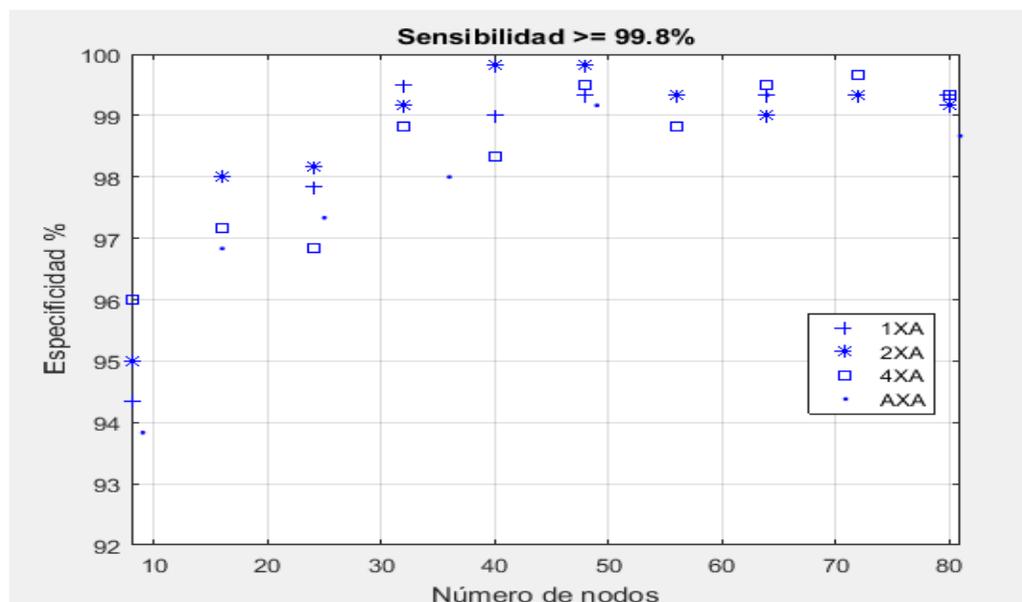


Figura 25. Especificidad y Sensibilidad vs número de nodos en el mapa para distintas configuraciones de red utilizando el algoritmo de detección basado en SOM considerando una sensibilidad de mínimo 99.8%

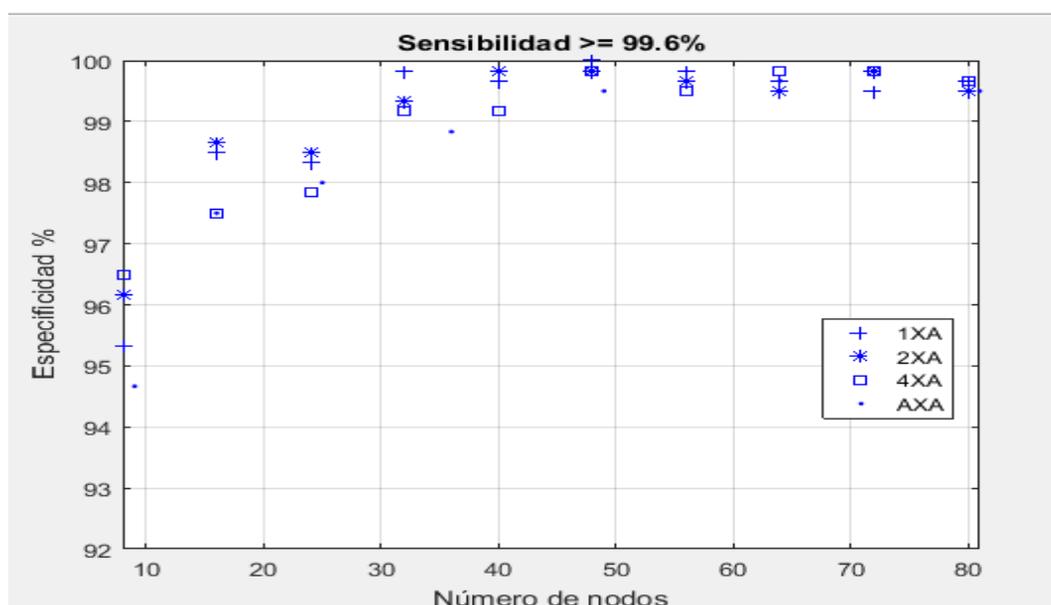


Figura 26. Especificidad y Sensibilidad vs número de nodos en el mapa para distintas configuraciones de red utilizando el algoritmo de detección basado en SOM considerando una sensibilidad de mínimo 99.6%

En general se observa que la configuración de la red no afecta el desempeño siempre y cuando el número de nodos utilizado sea de aproximadamente 45. Por ello se elige una red lineal de “1 por 45”.

Para realiza la evaluación del desempeño del algoritmo se utiliza K-Fold con K=10 y los resultados se muestran en la **Figura 22**, además se muestran en la **Figura 23** como cambia el valor de sensibilidad y especificidad según los parámetros de diseño del algoritmo de detección de anomalía basado en SOM, es decir la cota y el margen.

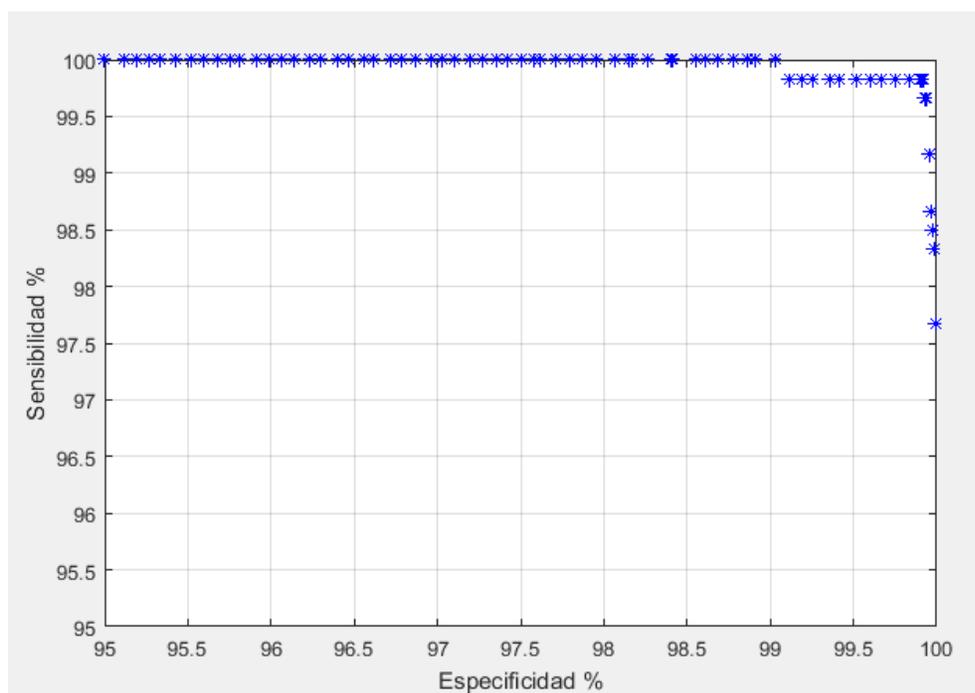


Figura 27. Evaluación final del desempeño del algoritmo basado en SOM utilizando una configuración de red de “1 por 50”

En la **Figura 28** se aprecia que la interacción entre la sensibilidad y la especificidad tienen un comportamiento inverso, en general cuando la especificidad es alta la sensibilidad no y viceversa;

sin embargo existen puntos en donde ambas tienden valores altos y precisamente esos son los puntos óptimos de trabajo.

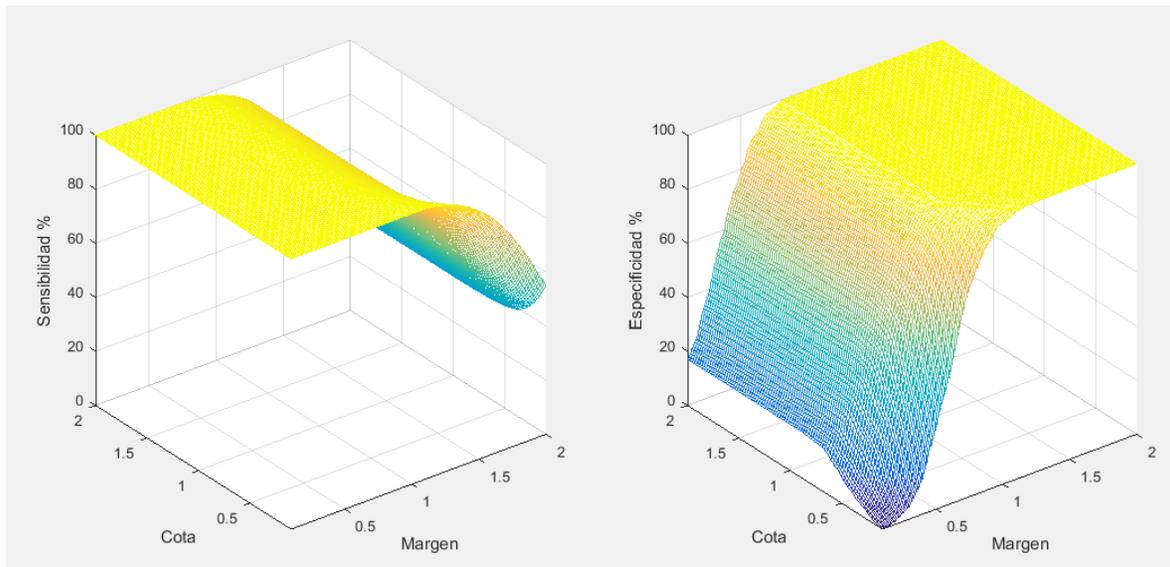


Figura 28. Especificidad y sensibilidad vs parámetros de diseño del algoritmo de detección de anomalías basado en SOM

Analizando la **Figura 27** se plantea elegir el punto de desempeño de 99.03% de especificidad y 100% de sensibilidad. A partir de este desempeño se encuentran los valores de cota y margen, los cuales son margen=1.0556 y cota=0.3125.

4.4.2 Evaluación final de desempeño

En esta sección se toman los parámetros seleccionados anteriormente y se evaluó el algoritmo con el fin de obtener el desempeño final a base de un valor promedio.

La evaluación final del algoritmo se realiza utilizando K-Fold con K=10, y se lo realiza 5 veces, los resultados se muestran en la **Tabla 17**. El desempeño final obtenido es de 98.89% en sensibilidad y de 99.67% en especificidad.

Tabla 17

Evaluación final de desempeño del algoritmo de detección basado en K-means

Numero	Sensibilidad	Especificidad
1	98.91%	99.33%
2	98.78%	99.83%
3	98.92%	99.83%
4	98.91%	99.67%
5	98.90%	99.67%
Promedio	98.89%	99.67%
Desviación estándar	0.0576%	0.2041%

4.4 COMPARACIÓN DE DESEMPEÑO

EL desempeño obtenido por el algoritmo basado en SOM y el obtenido por algoritmo de redes neuronales son similares pero el SOM tiene una desviación estándar considerablemente más alta especialmente en la especificidad. El desempeño obtenido por K-means es inferior con valores cercanos al 92% y una desviación estándar similar a la obtenida por SOM. El resumen de desempeño se muestra en la **Tabla 18** y la **Tabla 19**.

Tabla 18

Comparación del desempeño final obtenido por los algoritmo planteados

	Sensibilidad	Especificidad
Redes neuronales	99.75%	99.97%
K-means	92.08%	92.83%
Mapas auto-organizados	98.89%	99.67%

Tabla 19

Comparación la desviación estándar obtenido por los algoritmo planteados

	Sensibilidad	Especificidad
Redes neuronales	0.0842%	0.0688%
K-means	0.1016%	0.2635%
Mapas auto-organizados	0.0576%	0.2041%

CAPITULO 5: CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

Los algoritmos de detección de anomalías basados en los modelos no supervisados de aprendizaje utilizados tienen flexibilidad en su desempeño, es decir, permiten aumentar o disminuir la sensibilidad para aumentar o disminuir la especificidad.

Cuando se pretende lograr un 100% de sensibilidad en un algoritmo cuyo principio de comportamiento es estadístico, como K-means o SOM, se obtienen valores de especificidad dispersos, varían alrededor de 5%, a comparación de los que se obtienen cuando la sensibilidad pretendida es ligeramente menor como por ejemplo 99%, en donde varían menos de 1%, esto se aprecia en la *Figura 24*, en la *Figura 25* y en la *Figura 26*.

El algoritmo para la detección de anomalía basado en K-means presenta un desempeño inferior, mientras que la red neuronal y la detección de anomalías basada en SOM tienen desempeños mejores y muy similares entre ellos. El desempeño obtenido en cada algoritmo se detalla en la **Tabla 18**.

El desempeño obtenido del algoritmo SOM y del K-means presenta un comportamiento cambiante mayor al obtenido por redes neuronales, como se muestra en la **Tabla 19**.

El número de nodos, con respecto al algoritmo SOM (45 nodos), y el número de aglomerados con respecto al algoritmo K-Means (3 aglomerados), es mucho menor al número de datos de entrenamiento (600), sin embargo SOM permite un número mucho mayor de nodos de los que permite el algoritmo K-means.

El número de neuronas óptimas en la capa intermedia para la red neuronal se encuentra entre el número de neuronas de entrada y el número de neuronas de salida, lo que confirma el criterio del triángulo geométrico para la elección de neuronas de un detector basado en RNA.

A más número de neuronas intermedias en la red neuronal el algoritmo no mejora su desempeño, pero si existe un número mínimo para el cual el desempeño obtenido decae considerablemente como se aprecia en la *Figura 20*.

A más número de conglomerados el algoritmo K-means empeora su desempeño, siendo 3 nodos el valor óptimo como se aprecia en la *Figura 21*.

La configuración de red con respecto al mapa utilizado en SOM tiene a mejorar ligeramente al utilizar configuraciones lineales y rectangulares más que configuraciones cuadradas.

La wavelet madre óptima para la detección de fallas en los rodamientos es la Wavelet Biortogonal Reversa 3.5 considerando un número de muestras de 100K y una frecuencia de muestreo de 50KHz.

De entre las bandas de frecuencias definidas por la ecuación (5) que describen los efectos producidos por la falla de barras rotas, la que produce mejores resultados bajo la estrategia de caracterización descrita es la relacionada con $\frac{k}{p} = 7$.

5.2 RECOMENDACIONES

Al realizar el uso de wavelets lo recomendable es definir que wavelet madre es la ideal, para ello se debe realizar una prueba con todas las wavelet disponibles.

Al realizar un algoritmo de detección lo recomendable es iniciar eligiendo características básicas de las señales que permitan trabajar en ajustes más específicos mediante la evaluación del desempeño del algoritmo en su forma más básica.

Los algoritmos basados en K-means y SOM no se recomiendan para casos en los cuales el desempeño del algoritmo exija 100% de sensibilidad o de especificidad ya que su desempeño tiene un comportamiento aleatorio que dificulta obtener desempeños tan altos.

5.3 TRABAJOS FUTUROS

Los posibles trabajos futuros pueden ser varios, ya que existen varios tipos de falla, diferentes estrategias de detección, además el motor puede estar en diferentes estados, no solo estado estacionario, puede estar en arranque o en velocidad no constante, incluso el uso de variador de frecuencia cambia considerablemente la metodología.

Se plantea investigar otras fallas como: desbalanceo de voltajes, corto circuito en el estator, excentricidades. En el presente trabajo se investigó una falla en rodamientos enfocándose en la pista exterior, sin embargo los rodamientos también pueden fallar en sus otros componentes como la pista interior, las bolas o la jaula.

Se propone la implementación de un hardware que permita realizar la detección online, para ello se propone la instrumentación que permita la medición de la corriente de forma no intrusiva y la medición de voltaje también, tentativamente se podría usar una tarjeta basada en un FPGA.

Se plantea un detector similar pero en estado no estacionario, es decir en arranque y/o velocidad variante (utilizando variador de frecuencia).

Se propone la comparación de dos detectores, uno basado en medición de señales de corriente y voltaje, y otro basado en la medición de solo señales de vibración.

REFERENCIAS

- Arabacı, H., & Bilgin, O. (2009). Neural Network Classification and Diagnosis of Broken Rotor Bar Faults by Means of Short Time Fourier Transform. *Computer*, *I*(1), 2–6.
- Benbouzid, M. E. H. (2000). A review of induction motors signature analysis as a medium for faults detection. *IEEE Transactions on Industrial Electronics*, *47*(5), 984–993. <https://doi.org/10.1109/41.873206>
- Benbouzid, M. E. H., & Kliman, G. B. (2003). What stator current processing-based technique to use for induction motor rotor faults diagnosis? *IEEE Transactions on Energy Conversion*, *18*(2), 238–244. <https://doi.org/10.1109/TEC.2003.811741>
- Blodt, M., Granjon, P., Raison, B., & Rostaing, G. (2008). Models for bearing damage detection in induction motors using stator current monitoring. *IEEE Transactions on Industrial Electronics*, *55*(4), 1813–1822. <https://doi.org/10.1109/TIE.2008.917108>
- Brauer, C. (2012). An Introduction to Self-Organizing Maps Proseminar Artificial Intelligence, (6280610).
- Chapman, S. (n.d.). *Maquinas Electricas* (3th ed.).
- Cusidó, J., Romeral, L., Ortega, J. A., Rosero, J. A., & Espinosa, A. G. (2008). Fault Detection in Induction Machines Using Power Spectral Density in Wavelet Decomposition. *Ieee Transactions on Industrial Electronics*, *55*(2), 633–643. <https://doi.org/10.1109/TIE.2007.911960>
- Depren, O., Topallar, M., Anarim, E., & Ciliz, M. K. (2005). An intelligent intrusion detection

- system (IDS) for anomaly and misuse detection in computer networks. *Expert Systems with Applications*, 29(4), 713–722. <https://doi.org/10.1016/j.eswa.2005.05.002>
- Eren, L., & Devaney, M. J. (2003). Bearing damage detection via wavelet packet, 53(2), 109–113. <https://doi.org/10.1109/imtc.2002.1006824>
- Eren, L., Karahoca, A., & Devaney, M. J. (2004). Neural network based motor bearing fault detection. *Conference Record - IEEE Instrumentation and Measurement Technology Conference*, 3(May), 1657–1660. <https://doi.org/10.1109/IMTC.2004.1351399>
- Faiz, J., & Ebrahimi, B. M. (2008). A new pattern for detecting broken rotor bars in induction motors during start-up. *IEEE Transactions on Magnetics*, 44(12), 4673–4683. <https://doi.org/10.1109/TMAG.2008.2002903>
- Frag, S., Lin, B. K., Habetler, T. G., & Schlag, J. H. (1995). An Unsupervised, On-Line System for Induction Motor Fault Detection Using Stator Current Monitoring. *IEEE Transactions on Industry Applications*, 31(6), 1280–1286. <https://doi.org/10.1109/28.475698>
- Filippetti, F., Bellini, A., & Capolino, G. A. (2013). Condition monitoring and diagnosis of rotor faults in induction machines: State of art and future perspectives. *Proceedings - 2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis, WEMDCD 2013*, 196–209. <https://doi.org/10.1109/WEMDCD.2013.6525180>
- Fitzgerald, A. E., Kingsley, Charles J., & Umas, S. D. (2003). *Electric machinery*. *Journal of the Franklin Institute* (Vol. 319). [https://doi.org/10.1016/0016-0032\(85\)90014-6](https://doi.org/10.1016/0016-0032(85)90014-6)
- Gao, Z., Cecati, C., & Ding, S. X. (2015). A survey of fault diagnosis and fault-tolerant techniques-part I: Fault diagnosis with model-based and signal-based approaches. *IEEE*

Transactions on Industrial Electronics, 62(6), 3757–3767.

<https://doi.org/10.1109/TIE.2015.2417501>

Gao, Z., & Dai, X. (2013). From model, signal to knowledge: a data-driven perspective of fault detection and diagnosis. *IEEE Transactions on Industrial Informatics*, 9(4), 2226–2238.

Retrieved from <http://nrl.northumbria.ac.uk/12695/>

Giantomassi, A., Ferracuti, F., Iarlori, S., Ippoliti, G., & Longhi, S. (2015). Electric motor fault detection and diagnosis by kernel density estimation and kullback-leibler divergence based on stator current measurements. *IEEE Transactions on Industrial Electronics*, 62(3), 1770–1780. <https://doi.org/10.1109/TIE.2014.2370936>

Granda, D., Arcos-aviles, D., & Sotomayor, D. (2018). Analysis of signal processing techniques commonly used for broken bars detection on induction motors Análisis de las Técnicas de Procesamiento de Señal comúnmente, (June).

Haykin, S. (2005). *Neural Networks - A Comprehensive Foundation* - Simon Haykin.pdf.

Ince, T., Kiranyaz, S., Eren, L., Askar, M., & Gabbouj, M. (2016). Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks. *IEEE Transactions on Industrial Electronics*, 63(11), 7067–7075. <https://doi.org/10.1109/TIE.2016.2582729>

Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666. <https://doi.org/10.1016/j.patrec.2009.09.011>

Kang, P., Hwang, S., & Cho, S. (2007). Continual Retraining of Keystroke Dynamics Based Authenticator. *Advances in Biometrics*, 1203–1211. https://doi.org/10.1007/978-3-540-74549-5_125

- Kia, S. H., Henao, H., & Capolino, G. A. (2009). Diagnosis of broken-bar fault in induction machines using discrete wavelet transform without slip estimation. *IEEE Transactions on Industry Applications*, 45(4), 1395–1404. <https://doi.org/10.1109/TIA.2009.2018975>
- Kliman, G. B., Premerlani, W. J., Yazici, B., Koegl, R. A., & Mazereeuw, J. (1997). Sensorless, online motor diagnostics. *IEEE Computer Applications in Power*, 10(2), 39–43. <https://doi.org/10.1109/67.582451>
- Kohonen, T. (1982). *Self-organized formation of topologically correct feature maps. Biological Cybernetics* (Third edit, Vol. 43). <https://doi.org/10.1007/BF00337288>
- Kohonen, T. (2001). *Self-Organizing Maps* (Third).
- Kral, C., Habetler, T. G., & Harley, R. G. (2004). Detection of mechanical imbalances of induction machines without spectral analysis of time-domain signals. *IEEE Transactions on Industry Applications*, 40(4), 1101–1106. <https://doi.org/10.1109/TIA.2004.830762>
- Kumar, A., & Sinha, M. (2012). A New Burg Method based Approach to MeSA for.
- Lau, E. C. C., & Ngan, H. W. (2010). Detection of motor bearing outer raceway defect by wavelet packet transformed motor current signature analysis. *IEEE Transactions on Instrumentation and Measurement*, 59(10), 2683–2690. <https://doi.org/10.1109/TIM.2010.2045927>
- Li, D. Z., Wang, W., & Ismail, F. (2015). An Enhanced Bispectrum Technique with Auxiliary Frequency Injection for Induction Motor Health Condition Monitoring. *IEEE Transactions on Instrumentation and Measurement*, 64(10), 2679–2687. <https://doi.org/10.1109/TIM.2015.2419031>

- Li, L., Mechefske, C. K., & Li, W. (2004). Electric motor faults diagnosis using artificial neural networks. *Insight: Non-Destructive Testing and Condition Monitoring*, 46(10), 616–621. <https://doi.org/10.1784/insi.46.10.616.45210>
- Matich, D. J. (2002). *Redes Neuronales: Conceptos Básicos y Aplicaciones*, 6. Retrieved from https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_ano/orientadora1/monograis/matich-redesneuronales.pdf
- Natita, W., Wiboonsak, W., & Dusadee, S. (2016). Appropriate Learning Rate and Neighborhood Function of Self-organizing Map (SOM) for Specific Humidity Pattern Classification over Southern Thailand. *International Journal of Modeling and Optimization*, 6(1), 61–65. <https://doi.org/10.7763/ijmo.2016.v6.504>
- Pons-Llinares, J., Antonino-Daviu, J. A., Riera-Guasp, M., Lee, S. Bin, Kang, T. J., & Yang, C. (2015). Advanced induction motor rotor fault diagnosis via continuous and discrete time-frequency tools. *IEEE Transactions on Industrial Electronics*, 62(3), 1791–1802. <https://doi.org/10.1109/TIE.2014.2355816>
- Rojas, R. ul. (1996). *Networks book*. [https://doi.org/10.1016/0893-6080\(94\)90051-5](https://doi.org/10.1016/0893-6080(94)90051-5)
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning internal representations by error propagation (No. ICS-8506). *California Univ San Diego La Jolla Inst For Cognitive Science*, 1, 318–362. <https://doi.org/10.1016/B978-1-4832-1446-7.50035-2>
- Seera, M., Lim, C. P., Ishak, D., & Singh, H. (2012). Fault detection and diagnosis of induction motors using motor current signature analysis and a hybrid FMM-CART Model. *IEEE Transactions on Neural Networks and Learning Systems*, 23(1), 97–108.

<https://doi.org/10.1109/TNNLS.2011.2178443>

- Soualhi, A., Clerc, G., & Razik, H. (2013). Detection and diagnosis of faults in induction motor using an improved artificial ant clustering technique. *IEEE Transactions on Industrial Electronics*, 60(9), 4053–4062. <https://doi.org/10.1109/TIE.2012.2230598>
- Thomson, W. T., & Fenger, M. (2003). Case histories of current signature analysis to detect faults in induction motor drives. *IEMDC 2003 - IEEE International Electric Machines and Drives Conference*, 3(August), 1459–1465. <https://doi.org/10.1109/IEMDC.2003.1210644>
- Wang, X. H., & He, Y. G. (2007). Fuzzy neural network based on-line stator winding turn fault detection for induction motors. *ICIEA 2007: 2007 Second IEEE Conference on Industrial Electronics and Applications*, 2461–2464. <https://doi.org/10.1109/ICIEA.2007.4318852>
- Widodo, A., & Yang, B. S. (2007). Application of nonlinear feature extraction and support vector machines for fault diagnosis of induction motors. *Expert Systems with Applications*, 33(1), 241–250. <https://doi.org/10.1016/j.eswa.2006.04.020>
- Widodo, A., Yang, B. S., & Han, T. (2007). Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors. *Expert Systems with Applications*, 32(2), 299–312. <https://doi.org/10.1016/j.eswa.2005.11.031>
- Wildi, T. (2007). *Máquinas Eléctricas y Sistemas de Potencia. Máquinas Eléctricas y Sistemas de Potencia.*
- Zarei, J., & Poshtan, J. (2007). Bearing fault detection using wavelet packet transform of induction motor stator current. *Tribology International*, 40(5), 763–769. <https://doi.org/10.1016/j.triboint.2006.07.002>

ANEXO

Anexo A: Detalle de la metodología para la selección de k/p

Anexo B: Detalle de la metodología para la selección de la wavelet

Anexo C: Código del detector perceptrón multicapa

Anexo D: Código implementado de K-means

Anexo E: Código del detector basado en K-means

Anexo F: Código del algoritmo de mapas autoorganizados

Anexo G: Código del detector basado en mapas auto-organizados