

**Universidad Internacional de La Rioja (UNIR)**

**ESIT**

**Máster Universitario en Inteligencia Artificial**

# Detección y Diagnóstico de Fallas en Rodamientos con Velocidad Variable Aplicando Aprendizaje Profundo

**Trabajo Fin de Máster**

**Presentado por:** Arias Cijanes, Cesar Augusto

**Director/a:** García Martínez, Yamila

Ciudad: Bogotá

Fecha: Julio 20 de 2020

## Resumen

Detectar potenciales anomalías en rodamientos de equipos rotativos, minimiza el riesgo de pérdidas de lucro cesante, costos de reparación y afectación de seguridad de procesos como consecuencia de una falla. Los rodamientos son un componente esencial en cualquier equipo rotativo, su capacidad de carga y confiabilidad son importantes para el desempeño general del equipo.

La mayoría de métodos de detección y diagnóstico de fallas de rodamientos fundamentan sus modelos a una determinada velocidad de rotación y no tienen la capacidad de cuantificar el daño en tiempo real, sin embargo en la realidad los equipos rotativos trabajan a velocidad variable. En este escenario operativo, la precisión de estos métodos de detección es baja y se necesitan ajustes complejos de sus parámetros.

El presente trabajo de fin de master se desarrolla un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos, aplicando Aprendizaje Profundo basado en una Red Neuronal Convolutiva sobre un Escalograma de Transformada Wavelet Continua y Árbol de Decisión, el cual sirve de soporte al personal técnico para la toma de decisiones oportunas en escenarios operativos. En esta propuesta innovadora se resalta la combinación de métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación, simulando condiciones de operación real añadiendo una mayor complejidad en la caracterización y clasificación de las averías. Los resultados de la evaluación y predicción del modelo fueron satisfactorios cumpliendo con los objetivos planteados.

La aplicación de técnicas de sistemas cognitivos artificiales es relevante para solucionar este tipo de problemas debido a la alta capacidad de identificación de características y clasificación que poseen, además abre la puerta para el uso de teorías de transferencia de aprendizaje en donde se extrapolan las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

**Palabras clave:** *Red Neuronal Convolutiva, Fallas, Aprendizaje Automático, Detección, Diagnóstico, Rodamiento, Aprendizaje Profundo, Transferencia de Aprendizaje.*

## Abstract

Detect possible anomalies in rotating equipment bearings, minimize the risk of loss of lost profits, repair costs and process safety impairment as a consequence of a failure. Bearings are an essential component in any rotating equipment, their load capacity and reliability are important to the overall performance of the equipment.

Most methods of detection and diagnosis of bearing failures support their models at a certain speed of rotation and do not have the ability to quantify damage in real time, but in reality rotating equipment operated at variable speed. In this operational scenario, the accuracy of these detection methods is low and complex parameter adjustments are required.

This thesis develop a software for the detection and diagnosis of failures in rotating equipment bearings, applying Deep Learning based on a Convolutional Neural Network on a Continuous Wavelet Transform Scalogram and Decision Tree, which serves as support technical staff for timely decision making in operational situations. This innovative proposal highlights the combination of computational perception methods, artificial cognitive systems, and machine learning to detect faults and damage severity of a bearing, under different rotational speed variations, simulating real operating conditions, adding greater complexity to the characterization and classification of faults. The results of the evaluation and prediction of the model were satisfactorily meeting the stated objectives.

The application of artificial cognitive systems techniques is relevant to solve these types of problems due to the high capacity for identifying characteristics and classification that they require, and it also opens the door for the use of learning transfer theories where the proposed solutions are extrapolated. with experimental data on similar problems present in industrial settings.

**Keywords:** Convolutional Neural Network, Failures, Machine Learning, Detection, Diagnosis, Deep Learning, Transfer Learning.

# Índice de contenidos

<b>1. INTRODUCCIÓN .....</b>	<b>9</b>
1.1 Justificación .....	9
1.2 Planteamiento del trabajo .....	10
1.3 Estructura de la memoria .....	12
<b>2. CONTEXTO Y ESTADO DEL ARTE DE LAS APLICACIONES DE APRENDIZAJE AUTOMÁTICO EN EL DIAGNÓSTICO INTELIGENTE DE FALLAS EN RODAMIENTOS .14</b>	
2.1 Vida nominal del rodamiento.....	14
2.2 Conceptualización de Transformada Wavelet Continua.....	16
2.3 Investigaciones de redes neuronales convolucionales aplicadas a la detección y diagnóstico inteligente de fallas en equipos rotativos.....	18
2.4 Inteligencia Artificial, Aprendizaje Automático y Aprendizaje Profundo .....	24
2.5 Conceptualización de redes neuronales convolucionales .....	28
2.6 Framework de Aprendizaje Profundo .....	31
<b>3. OBJETIVOS CONCRETOS Y METODOLOGÍA DE TRABAJO .....</b>	<b>33</b>
3.1. Objetivo general.....	33
3.2. Objetivos específicos .....	33
3.3. Metodología del trabajo .....	34
3.3.1. Obtención de datos en vibración en el tiempo .....	35
3.3.2. Determinación de la frecuencia de corte y segmentación de señal de vibración..	37
3.3.3. Predicción del tipo de falla del rodamiento con una red neuronal convolucional profunda.....	39
3.3.4. Predicción de vida útil del rodamiento .....	40
3.3.5. Diagnóstico Integral de la condición del rodamiento .....	42
<b>4. DESARROLLO ESPECÍFICO DE LA CONTRIBUCIÓN.....</b>	<b>43</b>
4.1 Identificación de requisitos.....	44
4.2 Descripción del sistema desarrollado.....	44
4.2.1. Módulo de base de datos .....	45

4.2.2. Módulo de predicción inteligente de tipo de falla .....	47
4.2.3. Módulo de predicción de vida útil del rodamiento .....	53
4.2.4 Módulo Principal.....	54
4.3 Evaluación .....	58
<b>5. CONCLUSIONES Y TRABAJO FUTURO .....</b>	<b>61</b>
5.1. Conclusiones .....	61
5.2. Líneas de trabajo futuro .....	62
<b>6. BIBLIOGRAFÍA .....</b>	<b>63</b>
<b>7. ANEXO .....</b>	<b>69</b>
7.1 Anexo 1 Artículo Científico.....	69

## Índice de tablas

Tabla 1. Algunas definiciones de inteligencia artificial. (Russell & Norvig, 2008) .....	24
Tabla 2. Tabla de especificación de datos de rodamiento. (Huang & Baddour, 2018) .....	35
Tabla 3. Parámetros de los rodamientos usados en la recolección de los datos. (Huang & Baddour, 2018) .....	36
Tabla 4. Valores máximos de vibración que presenta cada señal analizada. ....	40
Tabla 5. Plan de trabajo para el desarrollo del software para la detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo .....	43
Tabla 6. Estructura de base de datos de señales de vibración de rodamiento .....	47
Tabla 7. Resumen de datos de la señales de vibración para segmentación.....	49
Tabla 8. Características de las señales utilizadas para la evaluación del sistema desarrollado .....	58

## Índice de figuras

Figura 1. Rodamiento en buenas condiciones. (NSK Literature, 2010). La visualización gráfica del rodamiento permite reconocer sus principales partes. ....	14
Figura 2. Estadística de fallas en rodamientos. (SKF, 2015). Esta información describe las principales causas raíces que afectan la condición funcional de los rodamientos. ....	15
Figura 3. Falla en pista interna y externa por desgaste debido a problemas de lubricación (NSK). Con la visualización de estas fallas frecuentes en rodamientos se logra detallar el comportamiento y análisis de forma de la onda.....	15
Figura 4. Formas de onda de wavelet madre Sobrero Mexicano, Morlet y Gaussiano. Visualización para identificar la Wavelet con mayor entropía de energía de Shannon. ....	18
Figura 5. Historia de publicaciones para Diagnóstico Inteligente de Fallas utilizando técnicas de aprendizaje automático. (Lei, y otros, 2019). Esta información permite identificar los principales enfoques desarrollados para el área de estudio de la presente investigación.....	21
Figura 6. Relación entre inteligencia artificial, aprendizaje automático y aprendizaje profundo. (Chollet, 2018). Esta gráfica sitúa de aprendizaje profundo dentro de los métodos de inteligencia artificial. ....	27
Figura 7. Ejemplo de convolución aplicado a un tensor de dos dimensiones. (Goodfellow, Bengio, & Courville, 2016). Visualización gráfica simplificada del proceso de convolución dentro una imagen. ....	29
Figura 8. Modelo general de arquitectura de una red neuronal convolucional. (Crispi, 2019). Esta representación permite identificar el proceso y las partes que componen una red neuronal convolucional.....	30
Figura 9. Flujograma de la metodología del trabajo propuesto. Esta representación permite identificar el desarrollo metodológico del sistema desarrollado y resaltar el innovador aporte de solución planteada en el campo de investigación de la inteligencia artificial.....	34
Figura 10. Señal de vibración completa y su segmentación. Representación gráfica de extracción de características de la señal de vibración cruda .....	38
Figura 11. Arquitectura de una red neuronal convolucional. (Sánchez Loja, 2017) .....	39
Figura 12. Árbol de decisión para asignación de valores de $k$ . Representación gráfica del árbol de decisión en donde se válida la su utilidad para tareas simples de clasificación. ....	42

Figura 13. Arquitectura del software de detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo. Visualización de los procesos construidos en sistema desarrollado. ....	45
Figura 14. Proceso de creación de base de datos. Representación de creación de base de datos con archivos reales para el sistema desarrollado. ....	46
Figura 15. Proceso de tratamiento de datos y creación del modelo predictivo basado en red neuronal convolucional. Visualización de creación del modelo predictivo inteligente con archivos reales. ....	48
Figura 16. Flujograma del algoritmo de segmentación de la señal de vibración y creación de las imágenes con el Escalograma de la Transformada Wavelet Continua. Descripción del proceso constructivo del código para segmentación de señales y creación de imágenes. ...	50
Figura 17. Arquitectura de la red neuronal convolucional para la detección del estado funcional de rodamientos. Representación gráfica de las principales partes que componen la red convolucional profunda generada para la predicción inteligente de condición del rodamiento. ....	51
Figura 18. Flujograma del código de ejecución del modelo predictivo basado en una red neuronal convolucional profunda. Descripción del proceso constructivo del algoritmo para predecir el estado funcional del rodamiento. ....	52
Figura 19. Flujograma del código desarrollado para la predicción de la vida útil del rodamiento. Descripción del proceso constructivo del algoritmo utilizado para determina la severidad de daño del rodamiento. ....	53
Figura 20. Árbol de decisión decisión para asignar el coeficiente multiplicador para determinar la severidad de daño. ....	54
Figura 21. Interfaz gráfica del software de detección y diagnóstico de fallas en rodamientos con velocidad variables aplicando aprendizaje profundo. Permite evidenciar la materialización del cada uno de los algoritmos predictivos desarrollados. ....	55
Figura 22. Barra menú base de datos .....	55
Figura 23. Barra Menú Detección & Diagnóstico. ....	55
Figura 24. Barra Menú Ayuda. ....	55
Figura 25. Barra de información del rodamiento .....	56
Figura 26. Área de árbol de señales de vibración.....	56

Figura 27. Área de representación de equipo rotativo y monitoreo continuo de datos de vibración y velocidad (a) Rodamiento Sano (b) Falla en Pista Interna (c) Falla en Pista Externa.....	57
Figura 28. Monitoreo de la señal de vibración e imagen del Escalograma de la Transformada Wavelet Continua.....	57
Figura 29. Área de publicación del estado funcional del rodamiento y predicción de vida útil remanente.....	58
Figura 30. Estadísticas de pruebas realizadas con el sistema desarrollado para detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo. ....	59
Figura 31. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Sano del rodamiento. ....	59
Figura 32. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Falla en Pista Interna del rodamiento.....	60
Figura 33. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Falla en Pista Externa del rodamiento.....	60

# 1. INTRODUCCIÓN

Anticiparnos a la materialización de fallas en una máquina rotativa es de vital importancia para garantizar una operación confiable y segura de una instalación industrial. Detectar oportunamente potenciales anomalías en un equipo, minimiza el riesgo de pérdidas de lucro cesante, costos de reparación y afectación de seguridad de procesos como consecuencia de una falla. Estudios recientes cuantifican la afectación de daños de rodamientos entre USD \$25,000 y USD \$50,000 dólares por hora en Estados Unidos, en pérdida de productividad, costos de reparación y tiempo de inactividad. (IBT Industrial Solution, 2018).

La mayoría de métodos de detección y diagnóstico de fallas de rodamientos fundamentan sus modelos a una determinada velocidad de rotación y no tienen la capacidad de cuantificar el daño en tiempo real, sin embargo en la realidad los equipos rotativos trabajan a velocidad variable. En este escenario operativo, la precisión de estos métodos de detección es baja y se necesitan ajustes complejos de sus parámetros.

Para dar respuesta a este problema, el presente trabajo de fin de master se desarrolla un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos, aplicando Aprendizaje Profundo basado en una Red Neuronal Convolucional sobre un Escalograma de Transformada Wavelet Continua y Árbol de Decisión, el cual sirve de soporte al personal técnico para la toma de decisiones oportunas en escenarios operativos. En esta propuesta innovadora se resalta la combinación de métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación, simulando condiciones de operación real añadiendo una mayor complejidad en la caracterización y clasificación de las averías. Los resultados de la evaluación y predicción del modelo fueron satisfactorios cumpliendo con los objetivos planteados.

## 1.1 Justificación

La detección y diagnóstico de fallas cumple una función importante en la relación entre los datos de monitoreo y la condición de confiabilidad e integridad de los equipos rotativos. Tradicionalmente, esta relación se encuentra cubierta por el conocimiento experto de analistas de señales vibratorias. (Ramirez, 2005).

Las exigentes condiciones reales operativas, requieren oportunidad y precisión en la detección y diagnóstico de defectos presentes en los equipos rotativos, por lo tanto, se hace

necesario recurrir a métodos automáticos para acortar el ciclo de mantenimiento y mejorar la precisión del diagnóstico. En particular, con la ayuda de inteligencia artificial, se espera que el proceso de detección y diagnóstico de fallas sea lo suficientemente inteligente para detectar y reconocer automáticamente el estado de salud de los equipos rotativos. (López Cataldo, 2016)

Los métodos de aprendizaje profundo pueden reconocer entradas complejas de alta dimensión, eliminando la dependencia de las técnicas de procesamiento de señales y los algoritmos de extracción de características diseñados manualmente. Con estas ventajas, se han introducido métodos de aprendizaje profundo para el diagnóstico de fallas equipo rotativo, como la red neuronal convolucional, las redes de creencias profundas y las redes neuronales recurrentes.

La mayoría de los métodos de detección de fallas en equipo rotativo funcionan bien cuando se procesan datos a una determinada velocidad de rotación. Sin embargo, en la realidad operativa, la mayoría de la maquinaria trabaja a una velocidad de rotación variable. En la academia existen pocos estudios que midan el desempeño de los métodos que procesen datos en esta condición y adicionalmente tiene restricciones para el uso en ambientes industriales. Por lo tanto, se propone el desarrollo de un método basado en aprendizaje profundo y árbol de decisión, que pueda manejar datos en todo el rango de velocidad de un equipo rotativo sin ajustes complejos de parámetros, identificando la condición funcional de un rodamiento y el grado de severidad de daño.

La aplicación de técnicas de sistemas cognitivos artificiales es relevante para solucionar este tipo de problemas debido a la alta capacidad de identificación de características y clasificación que poseen, además abre la puerta para el uso de teorías de transferencia de aprendizaje en donde se extrapolan las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

## **1.2 Planteamiento del trabajo**

Los rodamientos son componentes principales de los equipos rotativos y en múltiples ocasiones son causantes de paradas no programadas debido a fallas intrínsecas no previstas oportunamente. Esta situación ampliamente conocida en la industria, ha requerido la implementación de técnicas de mantenimiento predictivo que en ocasiones no resultan tan eficaces ni oportunas, debido a que personal experto de manera offline, analiza la información luego de ser almacenada en un sistema especializado; por lo tanto se hace

necesaria la instalación de sensores en estos componentes que monitoricen de manera permanente su condición funcional. En este escenario se generan grandes volúmenes de datos que deben ser procesados de manera oportuna y precisa para detectar y diagnosticar fallas incipientes.

Las teorías tradicionales para la detección y el diagnóstico de fallas en equipos rotativos, incluye en la extracción de características, el análisis en el dominio del tiempo, de la frecuencia y tiempo-frecuencia; utilizando filtros, envolventes y métodos para identificar comportamientos de los datos de vibración. Estas funciones limpian la señal haciendo foco en información única que representa un estado determinado, mejorando el resultado de la detección y el diagnóstico. (Lei, He, Yanyang, & Qiao, 2007).

Este preprocesamiento puede consumir gran cantidad de recurso computacional en escenarios de Big Data, lo cual se vuelve ineficiente e inviable; es por esto que los modelos de diagnóstico basados en aprendizaje profundo se vuelven relevantes y aplicables para este problema, debido a que pueden aprender directamente de las características del monitoreo sin el preprocesamiento de datos, dado que capturan la variación de las propiedades de los datos directamente de la entrada. (Yin, Li, Gao, & Kaynak, 2015)

Los sistemas inteligentes tradicionales generalmente constan de tres partes principales: adquisición de datos, extracción y selección de características, y clasificación de datos. Los sistemas de detección de fallas de rodamientos generalmente emplean redes neuronales artificiales para la extracción, selección de características y clasificación, los cuales operan como sistemas de soporte de decisiones. Cada vez que se ejecuta todo el proceso de detección y diagnóstico con estos sistemas inteligentes tradicionales requieren una cantidad significativa de esfuerzo computacional. Adicionalmente, la selección de características ineficientes puede provocar una degradación del rendimiento de los sistemas de soporte de decisiones. (Lei, y otros, 2019)

Las teorías tradicionales de detección y el diagnóstico de fallas en el escenario de Big Data no resultan apropiadas, debido a la alta complejidad de la extracción de características, por lo tanto se hace necesario implementar algoritmos de aprendizaje automático profundo. (Lei, y otros, 2019)

Existen múltiples métodos para el análisis de señales de vibración de equipos rotativo; entre ellos se encuentra la transformada wavelet continua, que es una función matemática basada en la escala y la posición de los datos, la cual ofrece ventajas importantes sobre otras

técnicas ante la variabilidad de frecuencia. Este método es el utilizado en la solución planteada en el presente trabajo en conjunto con el escalograma de transformación de wavelet continua que contiene todos los coeficientes de señal de transformación de wavelet continua madre y al aplicarlos sobre los datos con velocidad de rotación variable se generan gráficas de tamaño diferente utilizando el mismo rango de multiplicación de frecuencia de rotación. Con esta técnica se genera la segmentación de imágenes de la señal de vibración para ser analizadas por una red convolucional y posteriormente realizar la detección y el diagnóstico de fallas del rodamiento.

Para la cuantificar la severidad de daño del rodamiento se plantea el análisis de forma de onda, identificando la vibración y velocidad crítica, los picos máximos de las señales segmentadas y las frecuencias de impacto. Esta información se utiliza como base para el análisis matemático de cargas dinámicas y estáticas del rodamiento y para la predicción de observaciones futuras mediante el árbol de decisión.

## **1.3 Estructura de la memoria**

En esta sección se describe a de manera general la forma en que se distribuyen los capítulos de este trabajo de fin de master, así como una breve descripción del contenido de cada uno de ellos.

### **CAPÍTULO 1**

En la introducción se desarrolla una visión general de la importancia del tema de investigación, se describe el problema, la motivación y su justificación.

### **CAPÍTULO 2**

Se presentará toda la base teórica del documento, en donde se exponen las diferentes vistas científicas del tema de investigación, las cuales soportan la importancia de la realización de la solución planteada. De igual manera se muestra la evolución de las técnicas utilizadas en el diagnóstico inteligente de fallas.

### **CAPÍTULO 3**

Se muestran los objetivos planteados para el desarrollo de la propuesta de investigación. De igual manera se describe la metodología de diseño y construcción del software planteado para la detección y diagnóstico inteligente de fallas.

#### **CAPÍTULO 4**

Se describe el paso a paso de la construcción de la solución planteada involucrando la organización, visualización y análisis de los datos, el desarrollo del algoritmo de aprendizaje automático profundo basado en redes neuronales convolucionales, y la interfaz gráfica de usuario.

#### **CAPÍTULO 5**

Consta de las conclusiones del sistema desarrollado, resaltando la importancia del trabajo propuesto y los próximos pasos derivados de la presente investigación.

#### **CAPÍTULO 6**

Es la bibliografía empleada para el documento.

## 2. CONTEXTO Y ESTADO DEL ARTE DE LAS APLICACIONES DE APRENDIZAJE AUTOMÁTICO EN EL DIAGNÓSTICO INTELIGENTE DE FALLAS EN RODAMIENTOS

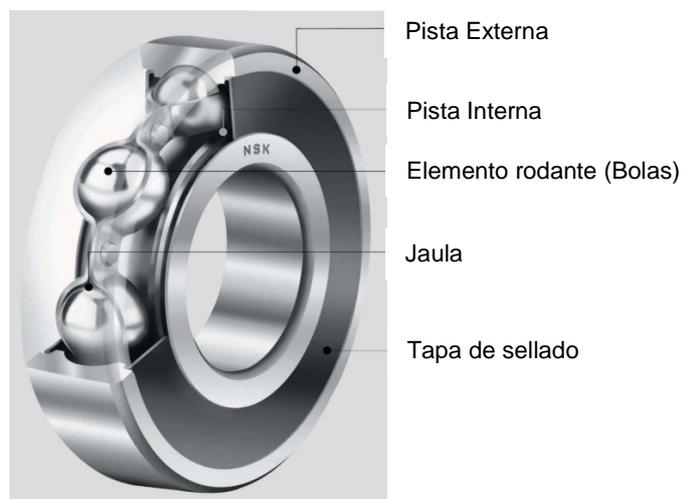
En este capítulo se presentará toda la base teórica del documento, en donde se definen conceptos clave y se exponen las diferentes vistas científicas del tema de investigación, las cuales soportan la importancia de la realización de la solución planteada. De igual manera se muestra la evolución de las técnicas utilizadas en el diagnóstico inteligente de fallas.

### 2.1 Vida nominal del rodamiento

Los rodamientos son un componente esencial en cualquier equipo rotativo, su capacidad de carga y confiabilidad son importantes para el desempeño general del equipo.

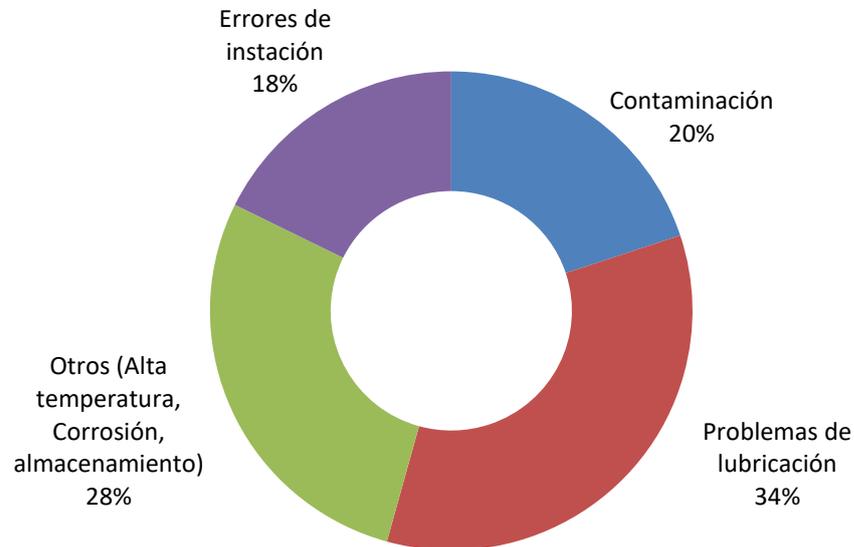
La función de los diferentes tipos de rodamientos en motores eléctricos es proporcionar el deslizamiento del rotor dentro del estator manteniendo un espacio de aire uniforme. La detección y diagnóstico de fallas en las primeras etapas de desarrollo de una anomalía en estos componentes, son necesarios para evitar su mal funcionamiento durante su operación.

En la figura 1 se muestra las partes de un rodamiento.



*Figura 1. Rodamiento en buenas condiciones. (NSK Literature, 2010). La visualización gráfica del rodamiento permite reconocer sus principales partes.*

La estadística mostrada en la figura 2 describe una distribución de las causas de falla de los rodamientos (SKF, 2015). Se puede ver que la mayoría de los rodamientos no llegan a cumplir su vida útil siendo afectados por factores externos.



*Figura 2. Estadística de fallas en rodamientos. (SKF, 2015). Esta información describe las principales causas raíces que afectan la condición funcional de los rodamientos.*

Las causas anteriores generan daños en las diferentes partes de los rodamientos: pista interna, pista externa, esferas o bolas y jaula.

Las condiciones analizadas en el presente trabajo son: rodamiento sano, rodamiento con falla en pista interna y rodamiento con falla en pista externa. En las figuras 3a y 3b se muestran imágenes de fallas de rodamientos.



a. Falla pista interna



b. Falla pista externa

*Figura 3. Falla en pista interna y externa por desgaste debido a problemas de lubricación (NSK). Con la visualización de estas fallas frecuentes en rodamientos se logra detallar el comportamiento y análisis de forma de la onda.*

La vida nominal de un rodamiento (definida en las normativas ISO y ABMA) está basada en la vida alcanzada o sobrepasada por el 90% de los rodamientos aparentemente idénticos de un grupo suficientemente representativo. La vida útil representa la vida real de un rodamiento bajo condiciones reales de funcionamiento antes de fallar o cuando se estima necesario que sea sustituido por cualquier razón. (Snyder)

En 2007, la Organización Internacional de Normalización, ISO, publicó la norma ISO-281 revisada, que presentaba las posibilidades de cálculo de vida, incluyendo una tensión límite de fatiga del material de los rodamientos y un factor del efecto que ejerce la contaminación sólida con distintos sistemas de lubricación (grasa, circulación de aceite, baño de aceite, y otros) sobre la vida de los rodamientos.

La capacidad de carga dinámica se usa para los cálculos de vida de rodamientos sometidos a esfuerzos dinámicos, como los que giran bajo carga. Esta capacidad, definida en la norma ISO 281, expresa la carga del rodamiento que ofrecerá una vida nominal ( $L_{10}$ ) de un millón de revoluciones. Las cargas que actúan sobre un rodamiento se pueden calcular según la mecánica clásica, si las fuerzas externas se conocen o se pueden calcular. Entre las fuerzas externas pueden encontrarse las fuerzas resultantes de la transmisión de potencia, los apoyos de ejes o soportes, o las fuerzas de inercia.

El método más sencillo para calcular la vida de los rodamientos está representado por la ecuación (1) para la vida nominal de las normas ISO 281 o ABMA 9 y 11:

$$L_{10h} = \frac{10^6}{60 * n} \left( \frac{C}{P} \right)^p \quad (1)$$

Donde:

$L_{10h}$  = vida nominal, millones de revoluciones

$C$  = capacidad de carga dinámica de rodamiento

$P$  = carga dinámica equivalente del rodamiento

$p$  = exponente de la ecuación de la vida (3 para los rodamientos de bolas)

$n$  = velocidad del rodamiento

## 2.2 Conceptualización de Transformada Wavelet Continua

El análisis tradicional de señales de vibración se fundamenta en el espectro de la Transformada de Fourier o Transformada Rápida de Fourier, el cual descompone una señal

de frecuencia mediante el uso de una serie de ondas sinusoidales, ayudando a la transición entre el dominio del tiempo y la frecuencia. Este análisis es adecuado para el procesamiento de señales con velocidad constante o estacionaria, pero tiene una pobre representación con señales variables en el tiempo. Esta limitación es cubierta con herramientas de procesamiento de señales el dominio frecuencia-tiempo o escala de tiempo, como las basadas en la Transformada Wavelet.

Las Wavelet son funciones matemáticas utilizadas para analizar señales variables en el tiempo. Existen diferentes formas, las cuales de acuerdo al problema a solucionar se selecciona la que más entregue información de las características de la señal. Las Wavelet más comunes son la Transformada Wavelet Discreta (DWT), Descomposición de paquetes Wavelet (WPD) y Transformada Wavelet Continua (CWT).

La transformación de wavelet continua (CWT) ha demostrado ser un método útil para analizar señales de vibración variables en el tiempo (YanPing, ShuHong, JingHong, Tao, & Wei, 2005). Este método de análisis en el dominio frecuencia-tiempo, contiene la información completa y evita la pérdida de información de la señal original.

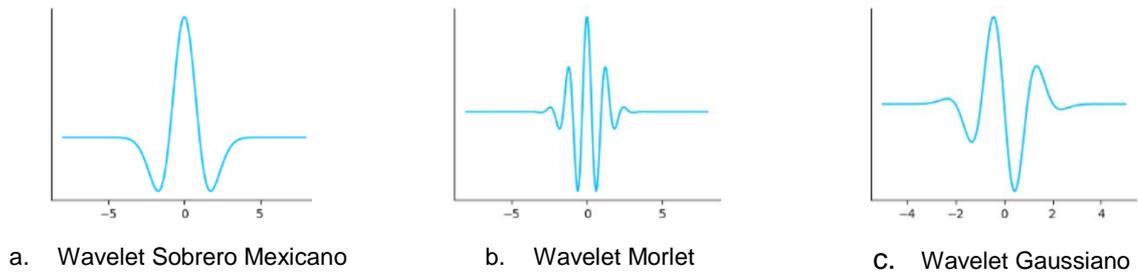
La Transformada Wavelet Continua descompone una señal en el dominio de frecuencia-tiempo mediante el uso de una familia de funciones wavelet para obtener valores característicos. Luego, al analizar los coeficientes continuos de wavelets o usar el algoritmo de clasificación, se obtiene información las características que identifican una determinada condición de la señal. Las ecuaciones (2) y (3) describe la teoría de la Transformada Wavelet Continua:

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R} \quad a \neq 0 \quad (2)$$

$$C_a(k) = \int x(t) \bar{\psi}_{a,b}(t) dt \quad (3)$$

Donde  $\psi_{a,b}$  es una función wavelet cuya forma y desplazamiento están determinados por el parámetro de escala "a" y el parámetro de posición "b".  $C_a(k)$  es el coeficiente wavelet de  $x(t)$  en la evaluación de la escala "a";  $k$  es el tiempo y  $\bar{\psi}_{a,b}(t)$  es el completo conjugado de función wavelet.

Las funciones de Transformada Wavelet Continua más comunes son: Sombrero Mexicano, Morlet y Gaussiano. A continuación en las figuras 4a, 4b y 4c se muestran las formas de onda de estas señales.



*Figura 4. Formas de onda de wavelet madre Sobrero Mexicano, Morlet y Gaussiano. Visualización para identificar la Wavelet con mayor entropía de energía de Shannon.*

Para el presente trabajo se escoge la wavelet Morlet debido a que tiene la relación de entropía de energía Shannon más alta que las demás familias wavelet, el cual mide el desempeño de las mismas.

El escalograma es el valor absoluto de la Transformada Wavelet Continua (CWT) de una señal, trazada en función del tiempo y la frecuencia. El escalograma es útil para analizar señales con características que ocurren a diferentes escalas y cuando se requiere la localización del tiempo de eventos de corta duración y alta frecuencia como también de eventos de baja frecuencia y mayor duración.

## **2.3 Investigaciones de redes neuronales convolucionales aplicadas a la detección y diagnóstico inteligente de fallas en equipos rotativos**

El presente trabajo de fin de máster fundamenta su desarrollo en las técnicas actuales para la detección y diagnóstico inteligente de fallas, específicamente las basadas en redes neuronales convolucionales, como aporte el área de aprendizaje profundo en escenarios de big data y en diferentes condiciones funcionales de equipo rotativo; abriendo la puerta para el uso de teorías de transferencia de aprendizaje en donde se extrapolan las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

Las técnicas de detección y diagnóstico inteligente de fallas hacen parte de las teorías de aprendizaje automático. Estas técnicas han sido ampliamente aplicadas en escenarios industriales, como herramientas analíticas que ayudan a mejorar las condiciones funcionales de los equipos rotativos, reconociendo de forma automática su estado operativo. Dichas

técnicas han sido el objetivo de múltiples propuestas investigativas en las últimas tres décadas. (Lei, y otros, 2019)

En el pasado, las teorías tradicionales de aprendizaje automático aplicado al diagnóstico de condición de maquinaria, contribuyeron de forma significativa en la reducción de la intervención humana en esta tarea, trayendo la era de la inteligencia artificial. Las técnicas utilizadas en esta época fueron:

- Máquinas de Soporte Vectorial (Cortes & Vapnik, 1995), (Widodo & Yang, 2007)
- Redes Neuronales Artificiales (Schmidhuber, 2015)
- Sistemas Expertos (Arias Cijanes, Aranguren Zambrano, & Tarantino Alvarado, 2012), (Yang, Pen, Wang, & Chang, 2016), (Liao, 2005)
- Árboles de decisión (Yang, Lim, & Chiow Tan, 2005)
- Modelo gráfico probabilístico (Koller & Friedman, 2010)
- Clasificadores Naive Bayes y k-Nearest neighbour (Liu, Yang, Zio, & Chen, 2018), (Cover & Hart, 1967)

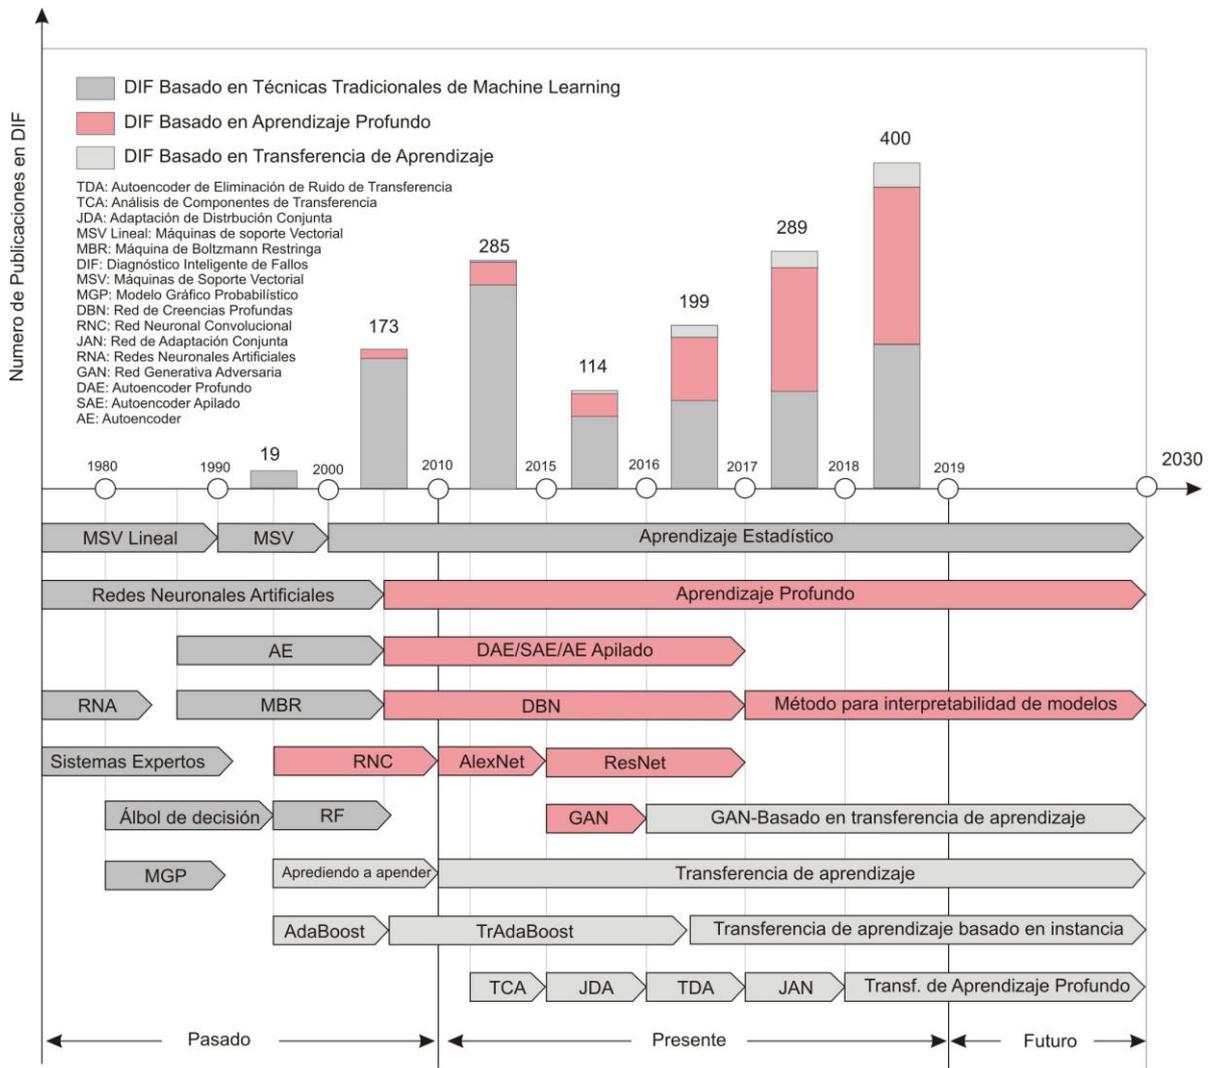
En los últimos 10 años, las teorías de aprendizaje profundo han reforzado la asistencia artificial, lo que motiva la construcción de soluciones tecnológicas que involucren la relación entre grandes volúmenes de datos de monitoreo y la condición de los equipos. Las técnicas actualmente usadas en el diagnóstico inteligente de fallas son:

- Redes Neuronales Convolucionales (Duan, Xie, Wang, & Bai, 2018)
- Red Neuronal Convolutiva AlexNet (Krizhevsky, Sutskever, & Hinton, 2017)
- Red Neuronal Convolutiva Res Net (He, Zhang, Ren, & Sun, 2016)
- Red Neuronal Profunda Basada en Autoencoder (Haidong, Hongkai, Ke, Dongdong, & Xingqiu, 2018)
- Red Neuronal Profunda Basada en Autoencoder Apilada (Li, Li, He, & Qu, 2019)
- Red Neuronal Profunda de Creencia (Chen & Li, 2017)
- Red Neuronal Profunda Generativa Adversaria (Guo, Lei, Xing, Yan, & Li, 2018)

En el futuro, las teorías de transferencia de aprendizaje propone utilizar el conocimiento de una o múltiples tareas del diagnóstico probadas en escenarios experimentales hacia escenarios productivos reales, superando de forma prospectiva las limitaciones de las aplicaciones investigativas. Las técnicas propuestas a utilizar son:

- Red Neuronal Profunda Generativa Adversaria Basada en Transferencia de Aprendizaje. (Guo, Lei, Xing, Yan, & Li, 2018)
- Transferencia de Aprendizaje Basado en clasificadores “Boosting”. (Dai, Yang, Xue, & Yu, 2007)
- Transferencia de Aprendizaje Basado en Instancia (Shen, Chen, Yan, & Gao, 2015)
- Transferencia de Aprendizaje Basado en Autoencoder de Eliminación de Ruido (Long, Wang, Cao, Sun, & Yu, 2016)
- Transferencia de Análisis de Componentes (Pan, Tsang, Kwok, & Yang, 2011)
- Adaptación de Distribución Conjunta (Long, Zhu, Wang, & Jordan, 2017)
- Transferencia de Aprendizaje Profunda (Long, Wang, Cao, Sun, & Yu, 2016)

En la figura 5 se muestra la línea del tiempo de investigaciones sobre el diagnóstico inteligente de fallas utilizando machine learning. Se resalta la evolución de los trabajos científicos enmarcados dentro del aprendizaje profundo.



*Figura 5. Historia de publicaciones para Diagnóstico Inteligente de Fallas utilizando técnicas de aprendizaje automático. (Lei, y otros, 2019). Esta información permite identificar los principales enfoques desarrollados para el área de estudio de la presente investigación.*

A continuación se describen algunos trabajos científicos recientes aplicados al diagnóstico inteligente de fallas en equipos rotativos, utilizando métodos de aprendizaje profundo.

Según (Eren, Ince, & Kiranyaz, 2018), la oportunidad y precisión en la detección y el diagnóstico de fallas en sistemas industriales es importante para su desempeño confiable y seguro. En esta investigación, se estudia el rendimiento de un novedoso sistema de diagnóstico de fallas de rodamientos en tiempo real, el cual utiliza un clasificador de red neuronal convolucional adaptativo compacto de una dimensión 1D.

En (Wen, Li, Gao, & Zhang, 2017) el diagnóstico de fallas es fundamental en sistemas industriales, ya que las detecciones tempranas sobre algún problema pueden ahorrar tiempo y costo. El aprendizaje profundo proporciona una forma efectiva de extraer automáticamente las características de los datos sin procesarlos; para ello se utilizan las redes neuronales convolucionales. En esta investigación, se propone una nueva red neuronal convolucional basada en LeNet-5 para el diagnóstico de fallas, a través de un método que convierte señales en imágenes de 2 dimensiones (2D), el cual se prueba sobre tres conjuntos de datos de: cojinetes de motor, bomba centrífuga y bomba hidráulica de pistones axiales, alcanzando una precisión de predicción de 99.79%, 99.481% y 100% respectivamente.

En (Guo, Yang, Gao, & Zhang, 2018) el diagnóstico de fallas es básico para garantizar la seguridad y el funcionamiento confiable de los equipos rotativos. En este estudio, se propone un nuevo método de diagnóstico que involucra el uso de una red neuronal convolucional (CNN) para clasificar directamente del Escalograma de Transformada Wavelet Continuo (CWTS), que es una transformación de dominio frecuencia-tiempo de la señal original y contiene la mayor parte de la información de las señales de vibración.

En (Li, Li, He, & Qu, 2019) define la red de creencias profundas (DBN) como un método de aprendizaje profundo utilizado para el diagnóstico de fallas. Este trabajo propone la unión de las técnicas de codificador automático apilado (SAE) y la máquina de Boltzmann restringida por Gauss-Binary (GBRBM) para el diagnóstico temprano de fallas en engranajes con señales de vibración sin procesar como entradas directas.

En (Fuan, Hongkai, Haidong, Wenjing, & Shuaipeng, 2017) las condiciones de trabajo de los rodamientos suelen ser muy complejas, lo que hace difícil diagnosticar sus fallas. En este artículo, se estudia un novedoso método llamado red neuronal convolucional profundo adaptativo. Se propone la integración de una red neuronal convolucional unido con los métodos de optimización de partículas de enjambre y t-distribuida estocástica vecina embebida (t-SNE) para diagnosticar fallas de los rodamientos. Los resultados demuestran que es más efectivo y robusto que otros métodos inteligentes.

En (Li, Liu, Tang, Lu, & Hu, 2017) el monitoreo inteligente de la condición funcional de los equipos rotativos y el diagnóstico de fallas son cada vez más importantes para la industria. En este artículo, se desarrolla un novedoso algoritmo para el diagnóstico de fallas de rodamientos basado en redes neuronales convolucionales profundas en conjunto con una teoría mejorada Dempster-Shafe. Las redes neuronales convolucionales toman como entrada los mapas de raíz media cuadrática (RMS) de las señales de vibración en el dominio de la frecuencia. La teoría D-S se implementa a través de la matriz de distancia de las evidencias y el índice modificado de Gini. El resultado muestra un mejor rendimiento de diagnóstico de fallas que los métodos existentes de aprendizaje automático.

En (Guo, Yang, Gao, & Zhang, 2018) comenta que se han introducido métodos de aprendizaje profundo para el diagnóstico de fallas de maquinaria rotativa. La mayoría de estos tienen un buen rendimiento al procesar datos de rodamientos a una determinada velocidad de rotación. Sin embargo, la mayoría de los equipos rotativos en la realidad industrial tiene una velocidad de trabajo variable. Al procesar los datos del rodamiento con velocidad de rotación variable, los métodos existentes tienen una precisión baja o necesitan ajustes de parámetros complejos. Para resolver este problema, en este trabajo propone un método de diagnóstico de fallas basado en un Escalograma de Transformada Wavelet Continuo (CWTS) y la red neuronal convolucional de agrupación piramidal espacial de Pitágoras (PSPP-CNN). Según los resultados del experimento, este método tiene una precisión de diagnóstico más alta con velocidad de rotación variable con respecto a otros métodos.

En (Haidong, Hongkai, Xingqiu, & Shuaipeng, 2017) el aprendizaje no supervisado de características de los datos de vibración es un gran desafío para el diagnóstico inteligente de fallas de los rodamientos. En este artículo, propone un método novedoso llamado Codificador Automático Wavelet Profundo (DWAE) con aprendizaje automático extremo (ELM) para el diagnóstico inteligente de fallas de los rodamientos. Los resultados confirman

que el método propuesto es superior a los tradicionales y al estándar de aprendizaje profundo.

Según (Appana, Prosvirin, & Kim, 2018) determinar las características óptimas bajo variaciones de velocidad de los rodamientos es una tarea difícil. Para abordar este problema, el artículo propone un diagnóstico de falla de rodamiento basado en análisis de emisión acústica (AE) bajo fluctuaciones invariantes de las velocidades de rotación utilizando espectros envolventes (ES) y una red neuronal convolucional (CNN) para extraer automáticamente características de alta calidad y clasificar los defectos. Los resultados experimentales muestran que el método propuesto es efectivo en la detección de fallas en los rodamientos, proporciona una precisión de clasificación promedio de aproximadamente 86% bajo RPM variable.

En (Lu, Wang, & Zhou, 2017) expone que un sistema electromecánico, los rodamientos son los componentes con mayor susceptibilidad a fallas debido a las condiciones de trabajo con altas velocidades y carga. En esta investigación, desarrolla un método de aprendizaje profundo basado en una red neuronal convolucional (CNN) y la teoría de la computación cognitiva para el diagnóstico de fallas.

En (Ahmed, Dennis Wong, & Nandi, 2016) la detección automática y clasificación de fallas en los rodamientos es un tema importante para el monitoreo de los equipos rotativos. Este artículo, propone un método de clasificación de fallas basado en una red neuronal profunda con 3 capas ocultas y una arquitectura de codificación automática apilada. Aquí se estudia el rendimiento de la clasificación utilizando la red neuronal profunda y la propagación hacia atrás y los efectos sobre la precisión de la clasificación de la red neuronal profunda variando algunos parámetros.

Según (Wang, Xiang, Zhong, & Zhou, 2017) las señales de vibración que generan los rodamientos en falla, generalmente presentan características no lineales y no estacionarias causadas por su entorno de trabajo. Es difícil desarrollar un método robusto para detectar fallas en rodamientos, basado en técnicas de procesamiento de señales. En este documento, se presentan un modelo de Markov oculto unido con una red neuronal convolucional (CNN –HMM) para clasificar múltiples fallas en un sistema mecánico. Los resultados de la clasificación confirman un rendimiento superior del modelo comparando con otros basados en: red neuronal convolucional puro, máquina de soporte vectorial (SVM) y una red neuronal de propagación inversa (BP). Se muestra una precisión promedio de

clasificación de 98.125% y 98% para dos series de datos con reducciones aceptables de tasa de error.

## 2.4 Inteligencia Artificial, Aprendizaje Automático y Aprendizaje Profundo

Para abordar el desarrollo de algoritmos de aprendizaje profundo es indispensable conocer las definiciones conceptuales entre inteligencia artificial, aprendizaje automático y aprendizaje profundo.

**Inteligencia Artificial (Artificial Intelligence):** Existen varias definiciones de inteligencia artificial y en (Russell & Norvig, 2008) se enmarcan en 3 dimensiones humanas: *procesos mentales, razonamiento y conductas*. El enfoque de aplicaciones esta dado mediante una combinación de las matemáticas e ingeniería. Las definiciones de la parte superior de la tabla 1, hacen referencia a procesos mentales mientras que en la parte inferior a aluden a la conducta.

Sistemas que piensan como humanos	Sistemas que piensan racionalmente
<p>“El nuevo y excitante esfuerzo de hacer que los computadores piensen... máquinas con mentes, en el más amplio sentido literal”, (Haugeland, 1985)</p> <p>“[La automatización de] actividades que vinculamos con procesos de pensamiento humano, actividades como toma de decisiones, resolución de problemas aprendizaje...” (Bellman, 1978)</p>	<p>“El estudio de las facultades mentales mediante el uso de modelos computacionales”. (Charniak &amp; McDermontt, 1985)</p> <p>“El estudio de cálculos que hacen posible percibir, razonar y actuar” (Winston, 1992)</p>
Sistemas que actúan como humanos	Sistemas que actúan racionalmente
<p>“El arte de desarrollar máquinas con capacidad para realizar funciones que cuando son realizadas por personas requieren de inteligencia” (Kurzweil, 1992)</p> <p>“El estudio de cómo lograr que los computadores realicen tareas que, por el momento, los humanos hacen mejor”. (Rich &amp; Knight, 1991)</p>	<p>“la inteligencia Computacional es el estudio del diseño de agentes inteligentes”. (Poole, Mackworth, &amp; Goebel, 1198)</p> <p>“IA... está relacionada con conductas inteligentes en artefactos”. (Nilsson, 1998)</p>

Tabla 1. Algunas definiciones de inteligencia artificial. (Russell & Norvig, 2008)

Resumiendo las anteriores definiciones, se puede decir que la inteligencia artificial es: *la ciencia de la computación que mediante la implementación de algoritmos matemáticos y de ingeniería permiten que las máquinas logren en cierta medida pensar y actuar racionalmente como humanos.*

**Aprendizaje Automático (Machine Learning):** Según (Goodfellow, Bengio, & Courville, 2016) el aprendizaje automático es esencialmente una forma de estadística aplicada con énfasis en el uso de computadores para estimar funciones complejas con sus respectivos intervalos de confianza. Un algoritmo de aprendizaje automático es aquel que puede aprender de los datos. La mayoría de los algoritmos de aprendizaje automático se pueden dividir en las categorías de aprendizaje supervisado y aprendizaje no supervisado.

El aprendizaje automático surge a partir de estas preguntas:

- ¿Podría un computador ir más allá de "lo que nosotros sabemos realizar" y aprender por sí mismo cómo realizar una tarea específica?
- ¿Podría un computador comprender situaciones? En lugar de que los programadores creen procesamiento de datos a mano mediante reglas.
- ¿Podría un computador aprender estas reglas automáticamente al observar los datos?

El aprendizaje automático descubre reglas para ejecutar una tarea de procesamiento de datos, con ejemplos de lo que se espera. Para lograr este objetivo se necesitan tres elementos: *Datos de entrada, ejemplo de la salida esperada y una forma de medir si el algoritmo está haciendo un buen trabajo.* (Chollet, 2018)

El aprendizaje automático es una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permiten que las máquinas aprendan mediante algoritmos que extraen información clave de los datos y encuentre soluciones a problemas. (Russell & Norvig, 2008). Los tipos de algoritmos de aprendizaje automático son:

- **Aprendizaje supervisado:** Este algoritmo necesita datos previamente etiquetados o conocidos para aprender a realizar su trabajo. Con base en estos datos, el algoritmo tiene la capacidad de aprender a resolver problemas similares en el futuro. (Russell & Norvig, 2008)
- **Aprendizaje no supervisado:** Este algoritmo necesita indicaciones previas, que le enseñan a comprender y analizar información, para resolver problemas similares en el futuro. No necesita datos previamente etiquetados o conocidos. (Russell & Norvig, 2008)

- **Aprendizaje por refuerzo:** este algoritmo aprende por su cuenta, basado en conocimientos previamente ingresados y la práctica que realiza sobre los problemas, aprendiendo en función del éxito o fracaso que obtiene al resolver dichos los problemas. (Russell & Norvig, 2008)

Resumiendo las anteriores definiciones, el aprendizaje automático consiste en: *una serie de métodos, modelos y algoritmos que se utilizan para el análisis de datos; como una disciplina para representar el conocimiento, basado en modelos estadísticos, matemáticos y técnicas heurísticas (sistemas expertos, redes neuronales, arboles de decisión, entre otros). El énfasis de éxito o fracaso de predicciones recae sobre los datos disponibles, que son los que determinan la calidad del resultado, más que la elección de los algoritmos que se utilicen.* (Redman, 2018). *El aprendizaje automático se centra en buscar patrones en los datos para elaborar predicciones sobre lo que pasará en el futuro.*

**Aprendizaje Profundo (Deep Learning):** El aprendizaje profundo es un subcampo específico del aprendizaje automático, como una forma de representar el conocimiento a partir de datos, mediante capas sucesivas de redes neuronales que suministran en cada iteración la identificación de características significativas. Otro nombre apropiado para este campo podría ser aprendizaje de representación en capas o aprendizaje de representaciones jerárquicas. (Chollet, 2018).

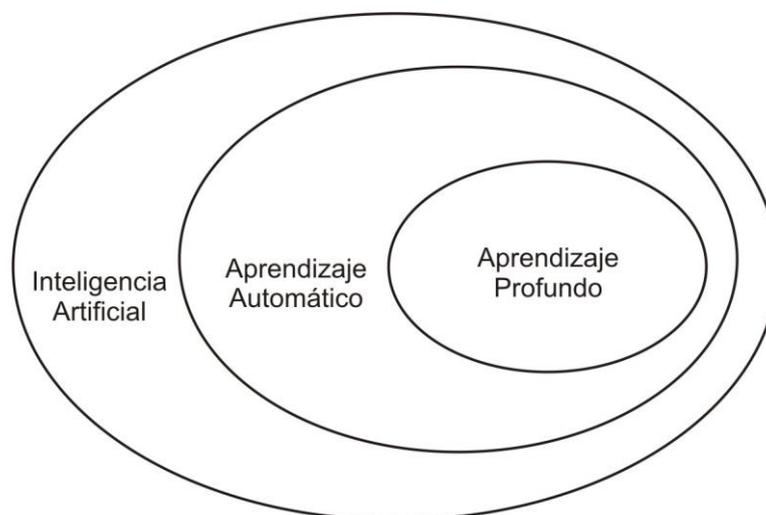
La técnica comúnmente utilizada para la aplicación de aprendizaje profundo son las redes neuronales convolucionales (Convolutional Neural Networks - CNN), las cuales son redes bio-inspiradas en la corteza visual animal y son una variante de los perceptrones multi capa. Este tipo especializado de red neuronal se usa para procesar datos que tiene una topología similar a una cuadrícula conocida. Su nombre indica que la red emplea una operación matemática llamada “convolución”, que es un tipo especializado de operación lineal, utilizada en sus capas. (Goodfellow, Bengio, & Courville, 2016)

Una red neuronal convolucional es un tipo de red neuronal artificial donde las neuronas se corresponden a campos receptivos, de una manera muy similar a las neuronas de la corteza visual primaria de un cerebro biológico, las cuales son muy efectivas en tareas de visión artificial, clasificación y segmentación de datos. En la entrada de una red convolucional se encuentra la fase de extracción de características, compuesta de neuronas convolucionales y de neuronas de reducción de muestreo. En la salida de la red se encuentra neuronas tipo perceptrón sencillas, para realizar la clasificación final sobre las características extraídas. (Jiuxiang, y otros, 2018)

Los modelos de diagnóstico basados en el aprendizaje profundo aprenden automáticamente características de los datos de monitoreo de entrada y simultáneamente reconocen la condición funcional de las máquinas de acuerdo con las características aprendidas. En su mayoría incluyen las capas de extracción de características y la capa de clasificación. (Chollet, 2018)

Teniendo en cuenta las definiciones anteriores se considera que el aprendizaje profundo es: *una área del aprendizaje automático que usa redes neuronales muy complejas, las cuales procesan grandes cantidades de datos mediante algoritmos eficientes que resuelven problemas de regresión o clasificación. Por lo tanto, el aprendizaje profundo es un recurso efectivo para construir modelos predictivos descubriendo características de manera automática. Esta técnica es muy usada con datos no estructurados, como: texto, imagen, audio o video.* (Goodfellow, Bengio, & Courville, 2016)

Considerando la conceptualización anterior, en la figura 6 se muestra mediante un diagrama de Venn, que el aprendizaje profundo es un tipo de aprendizaje automático que es utilizado en la ciencia de la computación de inteligencia artificial.



*Figura 6. Relación entre inteligencia artificial, aprendizaje automático y aprendizaje profundo. (Chollet, 2018). Esta gráfica sitúa de aprendizaje profundo dentro de los métodos de inteligencia artificial.*

## 2.5 Conceptualización de redes neuronales convolucionales

Las redes neuronales convolucionales, son un tipo especializado de red neuronal para procesar datos que tiene una topología similar a una cuadrícula conocida, que incluyen:

- Datos de series temporales considerados como una cuadrícula en una dimensión que toma muestras a intervalos de tiempo regulares y,
- Datos de imágenes, que pueden considerarse como una cuadrícula de píxeles de dos dimensiones. (Goodfellow, Bengio, & Courville, 2016)

En la ecuación (4), se muestra la definición matemática de convolución  $s(t)$ , en donde emplea dos funciones  $x(t)$  y  $w(a)$ , siendo la primera una señal muestreada en instantes de tiempo y la segunda una ponderación con una posición “a” de las muestras  $x(t)$ . Si aplicamos una operación promedio ponderada en cada momento, obtenemos una nueva función que proporciona una estimación suavizada del estado de  $x(t)$ .

$$s(t) = \int x(a)w(t-a)da \quad (4)$$

Esta operación se llama convolución. En la ecuación (5) la operación de convolución se denota con un asterisco:

$$s(t) = (x * w)(t) \quad (5)$$

En la terminología de red convolucional, el primer argumento la función “x” se denomina entrada (input), y el segundo argumento “w” como el núcleo (Kernel). El resultado se denomina en mapa de características.

Si el índice de tiempo “t” en la función  $x(t)$  puede tomar solo valores enteros, suponemos que  $x$  y  $w$  se definen solo en el entero  $t$ , se puede definir la convolución discreta en la ecuación (6):

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a) \quad (6)$$

En las aplicaciones de aprendizaje automático, la entrada “x” (input) suele ser una matriz multidimensional de datos y el núcleo “w” (kernel) suele ser una matriz multidimensional de

parámetros que se adapta mediante el algoritmo de aprendizaje. En la literatura se refieren a estas matrices multidimensionales como tensores.

Debido a que cada elemento de la entrada "x" (input) y el núcleo "w" (kernel) deben almacenarse por separado, se asume que estas funciones son cero en todas partes en el conjunto finito de puntos para los que se almacenan los valores. Esto significa que se puede implementar la suma infinita sobre un número finito de elementos de matriz.

En la figura 7 se muestra un ejemplo de convolución aplicado a un tensor de dos dimensiones. Se restringe la salida a solo posiciones donde el núcleo se encuentra completamente dentro de la imagen, llamada convolución "válida". Se dibujan cuadros con flechas para indicar cómo se forma el elemento superior izquierdo del tensor de salida aplicando el núcleo a la región superior izquierda correspondiente del tensor de entrada.

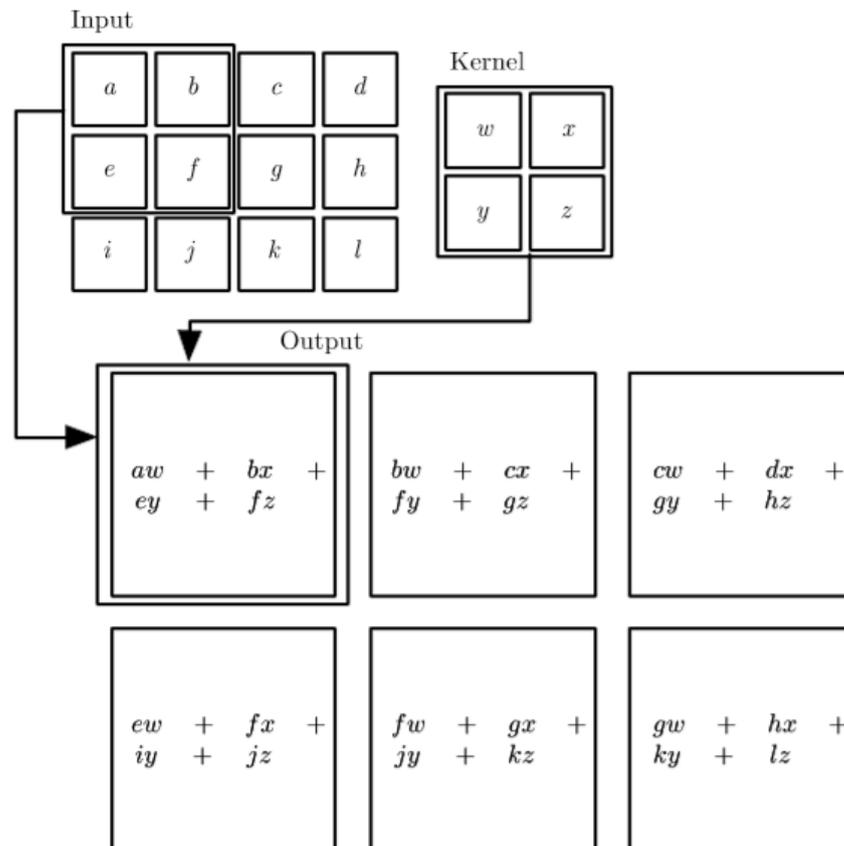


Figura 7. Ejemplo de convolución aplicado a un tensor de dos dimensiones. (Goodfellow, Bengio, & Courville, 2016). Visualización gráfica simplificada del proceso de convolución dentro una imagen.

Las redes neuronales convolucionales se componen de múltiples capas, las cuales identifican las características principales de imágenes. En cada una de ellas se implementan

filtros que producen una imagen convolucionada que posteriormente se ingresa a la siguiente capa. La estructura general de una red convolucional se muestra en la figura 8.

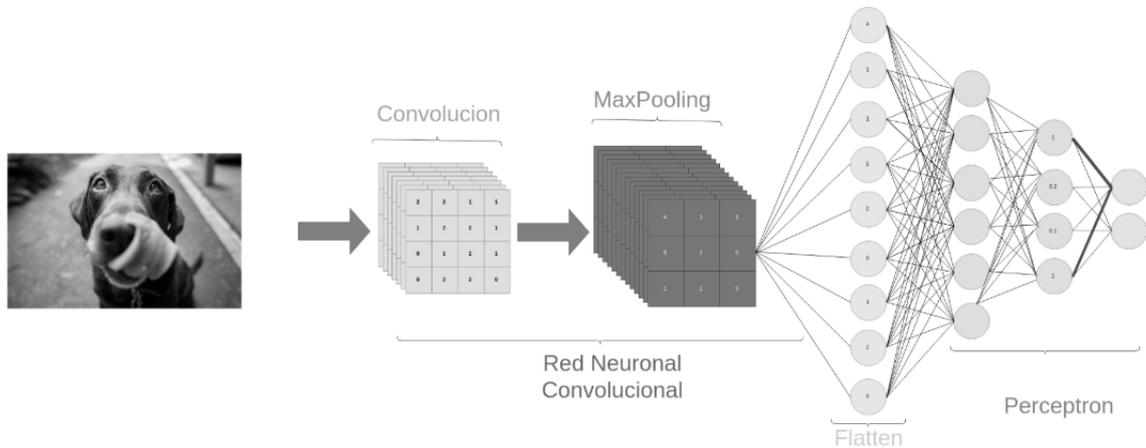


Figura 8. Modelo general de arquitectura de una red neuronal convolucional. (Crispi, 2019).

*Esta representación permite identificar el proceso y las partes que componen una red neuronal convolucional.*

**Capa convolucional:** recibe la imagen de entrada y se aplican filtros de convolución obteniendo el mapa de características, el cual funciona como un detector de propiedades de la imagen. Con este proceso se borra cierta información de la imagen y maximizar otro tipo de información que puede ser parte integral del resultado con el fin de reducir su tamaño para hacer el procesamiento más rápido.

**Capa de función rectificadora lineal uniforme (ReLU):** en esta capa se ingresan parámetro de no linealidad, la cual altera la linealidad de la imagen resultante de la convolucion con el fin de que el algoritmo pueda determinar sus límites.

**Capa de reducción o maxpooling:** aquí se realiza una representación de submuestreo, en donde se reduce el vector de características y los parámetros de la red neuronal convolucional. En este proceso se identifican las propiedades más importantes de la imagen obteniendo sus valores más altos.

**Capa de normalización o Flattering:** es el proceso de disponer el vector de características en forma de columnas para poder pasar los datos de la imagen a la capa de clasificación.

**Capa de clasificación:** En esta etapa se clasifican las características de la imagen extraídas en los pasos anteriores. Esta capa se compone de una red neurona tipo perceptron multicapa

en donde ejecuta el proceso de “forward propagation” y “back propagation” para la clasificación aplicando la función softmax.

## 2.6 Framework de Aprendizaje Profundo

Los framework de aprendizaje profundo son paquetes de software de programación diseñados para el desarrollo, implementación y entrenamiento de redes neuronales o de algoritmos de aprendizaje automático en general. Las principales ventajas de estas librerías de programación son:

- Simplifica el desarrollo de grafos de computación de gran tamaño.
- Calcula de manera automática los gradientes en el entrenamiento de las redes neuronales.
- Facilita la ejecución y entrenamiento en la unidad de procesamiento gráfico (GPU) y entornos distribuidos.
- Optimiza el entrenamiento y ejecución de los algoritmos.

A continuación se describen brevemente los framework más usados en la implementación de redes neuronales convolucionales.

**TensorFlow:** es un framework open-source para computación numérica que utiliza grafos de computación en donde los datos, en forma de tensores fluyen entre distintas operaciones. Su principal aplicación es en las áreas de aprendizaje automático y aprendizaje profundo. Fue desarrollado por Google y es utilizado para investigación y sistemas en producción. (Dean & Monga, 2019)

**Theano:** es una librería en Python para computación numérica. Fue creado en 2007 por Yoshua Bengio y es uno de los primeros frameworks que empezaron a utilizarse en el mundo del aprendizaje profundo para optimizar los entrenamientos. Incluye soporte para utilizar GPU y es similar a TensorFlow en cuanto a que las operaciones se definen en forma de un grafo que se ejecuta posteriormente. Su desarrollo fue oficialmente interrumpido a finales de 2017. (Theano, 2017)

**PyTorch:** es uno de los frameworks más utilizados en la actualidad. Proviene de Torch, otros de los frameworks “clásicos” de aprendizaje profundo como Theano. Esta desarrollado

por Facebook. Utiliza gráficos de computación dinámica al igual que TensorFlow, el cual es calculado a la vez que el código se ejecuta. (PyTorch, 2020)

**Caffe2:** Está escrito en C++ y su énfasis está en los sistemas en producción con redes neuronales. A diferencia de gran parte de los otros frameworks, no es necesario escribir código para definir modelos. Fue desarrollado por Facebook y esta evolución de Caffe y funciona similar a TensorFlow, mediante grafos estáticos de computación y una interfaz en Python sobre un core escrito en C++. (Caffe2, 2020)

**CNTK:** Microsoft Cognitive Toolkit (CNTK) es un kit de herramientas de código abierto para el aprendizaje profundo distribuido de grado comercial. Describe las redes neuronales como una serie de pasos computacionales a través de un gráfico dirigido. CNTK permite al usuario realizar y combinar fácilmente tipos de modelos populares, como las redes neuronales profundas de retroalimentación, las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN / LSTM). CNTK implementa el aprendizaje de descenso de gradiente estocástico (SGD, error de retropropagación) con diferenciación y paralelización automáticas en múltiples GPU y servidores. (The Microsoft Cognitive Toolkit, 2017)

**MXNET:** es un marco de inferencia y formación técnica escalable y ágil con una API concisa y fácil de usar para aprendizaje automático. MXNet incluye la interfaz de Gluon que permite a los desarrolladores con cualquier nivel de experiencia comenzar a usar el aprendizaje profundo en la nube, en dispositivos de borde y en aplicaciones para dispositivos móviles. En tan solo unas líneas de código de Gluon, es posible crear regresión lineal, redes convolucionales y LSTM recurrentes para la detección de objetos, el reconocimiento de voz, recomendaciones y personalizaciones. Desarrollada por Amazon. (Amazon, 2020)

**Keras:** es una librería de alto nivel. Tiene una interfaz modular en Python para el desarrollo de redes neuronales, facilitando la tarea de programadores ya que no necesitan definir arquitectura de bajo nivel. Funciona sobre TensorFlow, aunque también se puede usar en otros frameworks como Theano y CNTK. (Keras, 2020)

## **3. OBJETIVOS CONCRETOS Y METODOLOGÍA DE TRABAJO**

### **3.1. Objetivo general**

Diseñar y construir un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando una técnica de aprendizaje profundo basada en una red neuronal convolucional.

### **3.2. Objetivos específicos**

3.2.1 Seleccionar y organizar los datos experimentales a utilizar por el software de detección y diagnóstico inteligente de fallas de rodamientos.

3.2.2 Extracción de los atributos de condición de los datos en el dominio del tiempo y del tiempo-frecuencia.

3.2.3 Seleccionar las características de los datos y reducir sus atributos mediante el enfoque de aprendizaje no supervisado.

3.2.4. Construir el algoritmo de detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional y análisis de severidad de daño.

3.3.5 Validar los resultados del algoritmo para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional.

3.2.6 Diseñar y desarrollar la interfaz gráfica de usuario del software para la detección y diagnóstico inteligente de fallas en rodamientos basado en el algoritmo de aprendizaje profundo.

### 3.3. Metodología del trabajo

El proceso metodológico para la realización de trabajo propuesto se muestra en la figura 9.

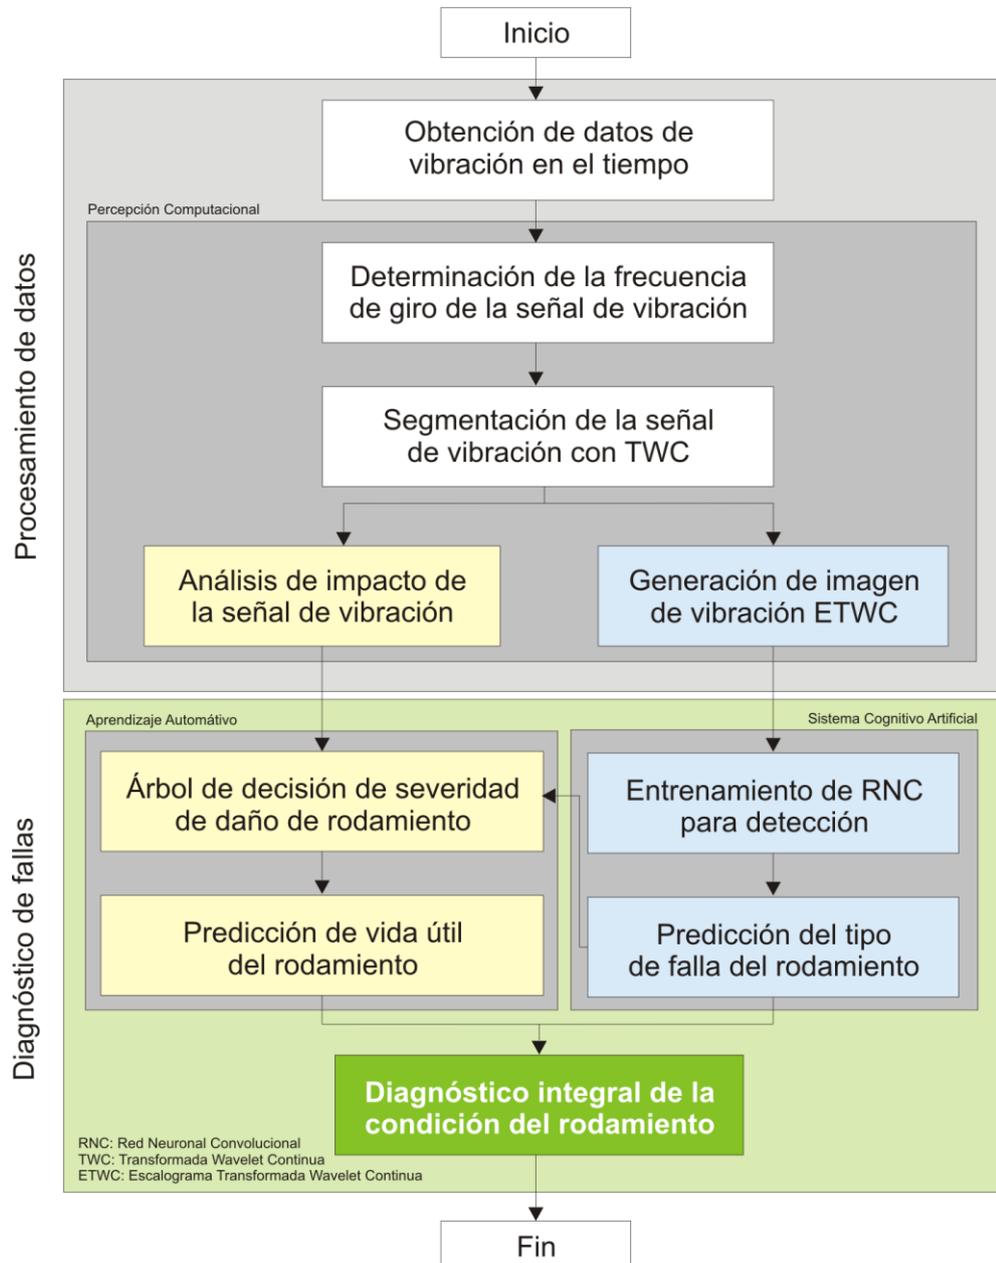


Figura 9. Flujograma de la metodología del trabajo propuesto. Esta representación permite identificar el desarrollo metodológico del sistema desarrollado y resaltar el innovador aporte de solución planteada en el campo de investigación de la inteligencia artificial.

### 3.3.1. Obtención de datos en vibración en el tiempo

Los datos utilizados en el desarrollo del presente trabajo fueron elegidos de (Huang & Baddour, 2018), en donde fueron recopilados 18 millones de datos de vibración de rodamientos con diferentes condiciones de falla y velocidad variable en el tiempo. Las condiciones de falla del rodamiento incluyen saludable, defectuoso con daño en pista interna, daño en pista externa y daños combinados. La gran cantidad de datos recopilados aportan suficiente información para el diagnóstico de fallas de rodamientos. En la tabla 2 se muestra la especificación de los datos utilizados.

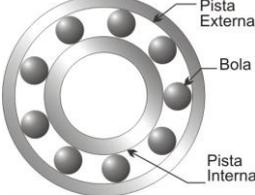
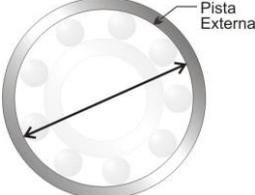
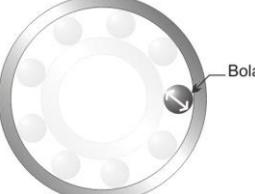
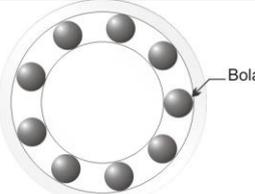
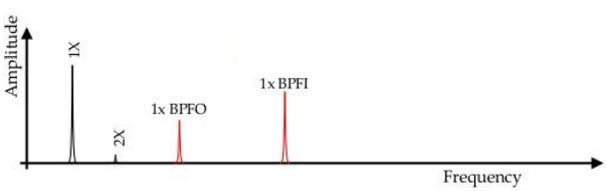
<b>Área temática:</b>	Ingeniería mecánica
<b>Especificación del área temática:</b>	Vibración, monitoreo de condición de máquina.
<b>Tipo de dato:</b>	Archivos .mat
<b>Como se adquirieron los datos:</b>	Se utilizó un acelerómetro para recopilar los datos de vibración y un encoder incremental para recopilar los datos de velocidad de rotación.
<b>Formato de los datos:</b>	Cruda
<b>Factores experimentales:</b>	Dos configuraciones experimentales: condición de salud del rodamiento y condición de velocidad variable.
<b>Características experimentales:</b>	Tanto la condición de salud del rodamiento como la condición de velocidad variable cambiarán las características de frecuencia de los datos de vibración del rodamiento.
<b>Ubicación de origen de los datos:</b>	Ottawa, Canadá
<b>Accesibilidad de datos:</b>	Mendeley Data, <a href="http://dx.doi.org/10.17632/v43hmbwxpm.1">http://dx.doi.org/10.17632/v43hmbwxpm.1</a>

Tabla 2. Tabla de especificación de datos de rodamiento. (Huang & Baddour, 2018)

Valor de los datos:

- Los datos fueron recopilados de rodamientos que funcionan en condiciones de velocidad de rotación variable en el tiempo. Este conjunto de datos difiere de los conjuntos de datos existentes en la literatura que se han recopilado bajo la condición de velocidad constante.
- Los datos recopilados se pueden utilizar para analizar las características de frecuencia de rodamientos de diferentes condiciones de salud en condiciones de velocidad variable en el tiempo.
- Los datos también se pueden aplicar para evaluar la efectividad de cualquier método desarrollado recientemente para soportar diagnóstico de fallas o monitoreo de condiciones bajo condiciones de velocidad variable en el tiempo.

*Diseño del conjunto de datos:* se utilizaron dos canales para la recolección de los datos, uno para los datos de vibración y otro para los datos de velocidad. Las señales fueron muestreadas a 200.000 Hz durante 10 segundos. Se construyeron 36 conjuntos de datos, para cada uno de ellos, hay dos configuraciones experimentales: condición de salud del rodamiento y condición de velocidad variable. En la tabla 3 se muestra los parámetros del rodamiento usados en la recolección de los datos:

Tipo de rodamiento	ER16K	
Diámetro de pista	38.52 mm	
Diámetro de bolas	7.94 mm	
Número de bolas	9	
Frecuencia de paso de las bolas por defecto en pista interna	5.43 fr	
Frecuencia de paso de las bolas por defecto en pista externa	3.57 fr	
Carga dinámica de carga (C)	14.0119 kN	

*Tabla 3. Parámetros de los rodamientos usados en la recolección de los datos. (Huang & Baddour, 2018)*

Los datos de vibración fueron estandarizados en dataframes, en donde se construyeron 3 tablas en una base de datos y cada una de ellas contiene 6 columnas con la información de vibración y velocidad.

### 3.3.2. Determinación de la frecuencia de corte y segmentación de señal de vibración

Las frecuencias características de falla de los rodamientos están relacionadas con la velocidad de rotación. Para las señales de vibración seleccionadas para el presente trabajo de investigación se cuenta una frecuencia de muestreo  $f$  (hz), la velocidad de rotación ( $rpm$ ) de inicio y fin, tiempo de total de señal muestreada. La determinación de la frecuencia de corte y segmentación de la señal toma en cuenta los siguientes pasos:

- a. Determinación del periodo de muestreo  $\Delta t$  en la ecuación (7):

$$\Delta t = \frac{1}{\text{frecuencia de muestreo } f \text{ (hz)}} = \frac{1}{200.000} = 500 \text{ milisegundos} \quad (7)$$

- b. Calculo de cantidad de datos "d" de las señal muestreada  $t = 10$  segundos en la ecuación (8):

$$d = \frac{t}{\Delta t} = \frac{10}{0.000005} = 2'000.000 \quad (8)$$

- c. Determinación de la frecuencia central  $f_c$  requerida para una determinada escala "a" de la señal de Transformada Wavelet Continua en la ecuación (9):

$$f_c = \frac{a}{2} \quad (9)$$

- d. Calculo de la frecuencia de rotación  $f_r$  se determina en la ecuación (10):

$$f_r = \frac{\text{velocidad de rotación (rpm)}}{60} \quad (10)$$

- e. La frecuencia de corte  $f_w$  está dada por la multiplicación de la frecuencia de corte  $f_c$  y la frecuencia de rotación  $f_r$  en la ecuación (11):

$$f_w = f_c * f_r \quad (12)$$

- f. Con la frecuencia de corte se calcula el tiempo de un ciclo de rotación  $t_r$  del rodamiento según la ecuación (12):

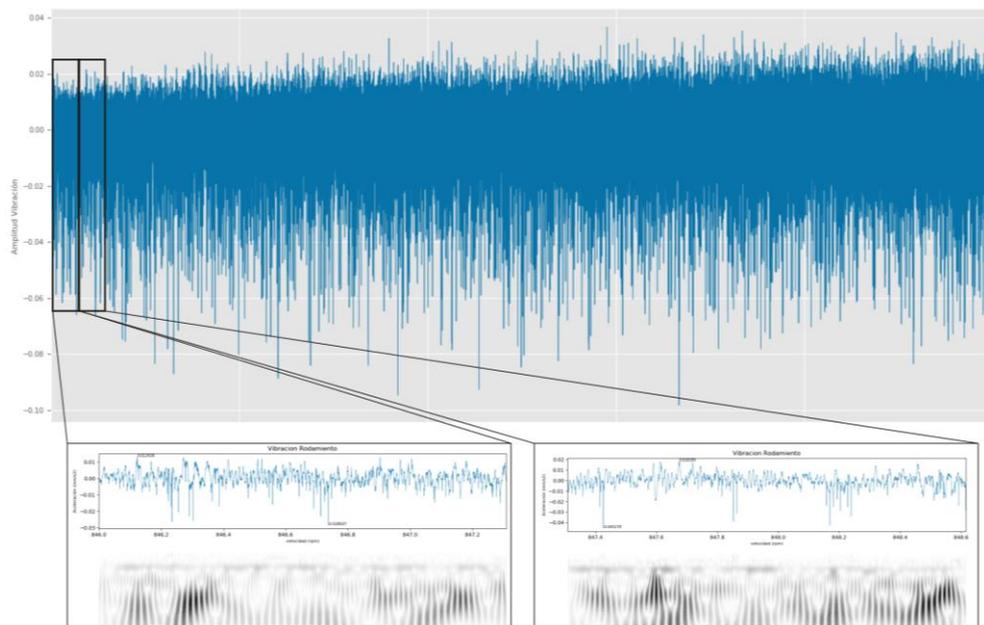
$$t_r = \frac{1}{f_w} \quad (12)$$

- g. Finalmente, se determina la cantidad de datos  $d_r$  contenido un ciclo de rotación  $t_r$  del rodamiento, relacionándolo con el periodo de muestreo  $\Delta t$  en la ecuación (13):

$$d_r = \frac{t_r}{\Delta t} \quad (13)$$

Las frecuencias características de falla del rodamiento son mayores que la frecuencia de rotación, por lo tanto, la segmentación de la señal a una determinada escala es suficiente para capturar las características de falla del rodamiento y su posterior diagnóstico.

El segmento recortado del Escalograma de la Transformada Wavelet Continua (ETWC) contiene todas las frecuencias características necesarias para el análisis de falla de los rodamientos. Estos segmentos se determinan a diferentes velocidades de rotación, los cuales tienen mismo rango de tiempo, con el fin de identificar las características de falla para un mismo daño, las cuales aparecen en una posición similar en el Escalograma de la Transformada Wavelet Continua. Por lo tanto, la clasificación de la Red Neuronal Convolutiva podrá tener un resultado preciso. En la figura 10 se muestra la representación de la señal de vibración completa y su segmentación.



*Figura 10. Señal de vibración completa y su segmentación. Representación gráfica de extracción de características de la señal de vibración cruda*

### 3.3.3. Predicción del tipo de falla del rodamiento con una red neuronal convolucional profunda

La extracción de características y la clasificación son las dos únicas fases en sistemas de con algoritmos de aprendizaje profundo. Estos métodos no requieren etapas adicionales para transformación, extracción de características y postprocesamiento. La extracción de características y la fase de clasificación para la detección de falla de rodamiento se combinan en una sola etapa de aprendizaje en la Red Neuronal Convolucional, la cual trabaja directamente sobre los datos sin procesar, para detectar las anomalías. Los datos de vibración en el dominio del tiempo mapeados en el Escalograma de la Transformada Wavelet Continua se introducen directamente en el Red Neuronal Convolucional.

La red neuronal convolucional está compuesta por varias capas convolucionales, las cuales cada una de ellas está compuesta por varios kernels, que generan a la salida el mapa de características al realizar la convolución con la imagen de entrada. Estos mapas pasan a una etapa de sub muestreo que generalmente usa la técnica de max-pooling, que consiste en tomar pequeños grupos de valores provenientes de los mapas de características y realiza un promediado de dichos valores para lograr reducir los parámetros, dando como resultado una agrupación de atributos. Posteriormente, pasa a la capa de normalización o Flattering en donde se disponen el vector de características en forma de columnas para poder pasar los datos de la imagen a la capa de clasificación. Finalmente, se clasifican las características de la imagen extraídas en los pasos anteriores. Esta capa se compone de una red neurona tipo perceptron multicapa en donde ejecuta el proceso de “forward propagation” y “back propagation” para la clasificación aplicando la función softmax.

Al unir toda la secuencia de procesos descritas anteriormente, se forma lo que se conoce como la arquitectura de una red convolucional, la misma que se puede observar en la figura 11.

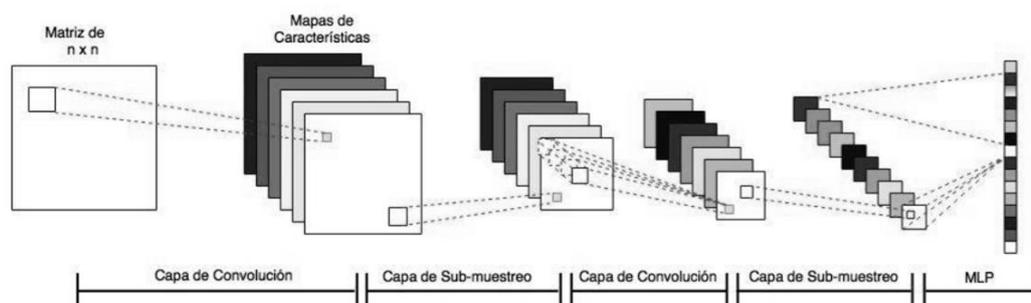


Figura 11. Arquitectura de una red neuronal convolucional. (Sánchez Loja, 2017)

### 3.3.4. Predicción de vida útil del rodamiento

#### Análisis de impacto señal de vibración

En esta etapa se identifica el pico más alto en amplitud positiva de cada señal de vibración, con el fin de analizar el impacto que tiene los elementos internos del rodamiento según su estado funcional. En este ejercicio se identifica el nivel de vibración que presenta cada rodamiento con el objetivo de generar las reglas a utilizar en el árbol de decisión. En la siguiente tabla 4 se muestran los valores máximos de vibración que presenta cada señal analizada.

	Segmento	Valor Máximo	Velocidad (rpm)	Cantidad de datos	rango de velocidad (rpm)	Total segmentos
Señal1 rodamiento sano	308	0,036605	1189,72	3301	846-1428	581
Señal 2 rodamiento sano	735	0,054033	1607,60	1725	846-1740	894
Señal1 rodamiento falla pista interna	844	1,026435	1.614,40	1569	750-1668	918
Señal 2 rodamiento falla pista interna	738	0,991577	1521,96	1928	780-1542	762
Señal 1 rodamiento falla pista externa	720	0,099414	1597,70	2017	888-1626	738
Señal 2 rodamiento falla pista externa	76	0,097112	870,40	4034	774-1380	606

Tabla 4. Valores máximos de vibración que presenta cada señal analizada.

Se puede identificar que la señal de vibración de falla en pista interna, presenta el nivel más alto de vibración.

#### Cuantificación de vida útil de rodamiento

Para el cálculo de vida nominal del rodamiento se toma como base la ecuación (14)

$$L_{10h} = \frac{10^6}{60 * n} \left( \frac{C}{P} \right)^p \quad (14)$$

El valor de la carga dinámica equivalente "P" se calcula partir de masa del eje, el cual ejerce una carga hipotética de 5,9 kN y se asume como factor axial el nivel de vibración " $V_a$ " que presenta cada rodamiento, el cual multiplica a dicha carga. Considerando que los valores típicos de factores axiales que ejercen fuerza en la carga dinámica equivalente, según tablas de fabricantes, son mayores a 1, se asigna un coeficiente multiplicador " $k$ " que amplifica el nivel de vibración " $V_a$ ", el cual varía según el tipo de falla presente en el rodamiento.

Tomando los parámetros del rodamiento del estudio y las consideraciones anteriores se reformula la ecuación de la vida útil del rodamiento, la cual depende del impacto de la vibración " $V_a$ ", coeficiente multiplicador " $k$ " y la velocidad " $n$ " a que es sometido, tal como se muestra en la ecuación (15):

$$L_{10h} = \frac{10^6}{60 * n} \left( \frac{14.0119}{5.9 * V_a * k} \right)^3 \quad (15)$$

### Árbol de decisión de severidad del daño

Para asignar el valor del coeficiente multiplicador " $k$ " del impacto de vibración, se plantea un árbol de decisión sencillo, teniendo en cuenta el tipo de estado funcional del rodamiento "Sano", "Falla en Pista Interna" o "Falla en Pista Externa" predicho por la red neuronal convolucional y utilizando una reglas de decisión con base a este. Por lo tanto si la condición del rodamiento es sano se asigna un valor de  $k = 40$ , si la condición del rodamiento es falla en pista interna se asigna un valor de  $k = 10$  y si la condición del rodamiento es falla en pista externa se asigna un valor de  $k = 50$ . Estos valores fueron determinados de acuerdo al análisis estadístico de los niveles de vibración de cada señal.

El árbol de decisión se obtiene por medio la representación en un espacio unidimensional en donde se recibe como entrada el tipo de falla detectado. El algoritmo elige primero para evaluación la variable "rodamiento sano" y a continuación, los ejemplos de entrenamiento se dividen en dos grupos más para evaluar el tipo de fallo. El algoritmo continúa dividiendo los nodos con la elección según la variable de entrada en cada iteración hasta que se alcance el criterio de parada establecido como: el árbol ha alcanzado un tamaño predefinido. En cada iteración el algoritmo elige aquella variable que mejor predice la variable objeto.

En la figura 12 se muestra el árbol de decisión de para asignación de valores de  $k$ .

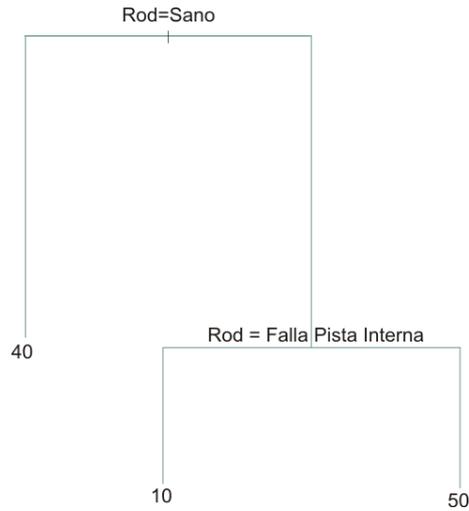


Figura 12. Árbol de decisión para asignación de valores de  $k$ . Representación gráfica del árbol de decisión en donde se valida la su utilidad para tareas simples de clasificación.

### 3.3.5. Diagnóstico Integral de la condición del rodamiento

El diagnóstico integral de la condición del rodamiento se determina mediante la unión de la predicción de la vida útil del rodamiento con la predicción del tipo de falla del rodamiento por medio de la red neuronal convolucional, de esta manera se tiene el estado funcional completo del rodamiento, el cual es publicado en la interfaz gráfica diseñada para este fin.

## 4. DESARROLLO ESPECÍFICO DE LA CONTRIBUCIÓN

En el presente capítulo se muestra la identificación de requisitos y la descripción del diseño, construcción y evaluación del software desarrollado para la detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo.

Para la construcción del sistema desarrollado se consideraron las fases o hitos que muestra el plan de trabajo descrito en la tabla 5.

Actividades	Mes 1				Mes 2				Mes 3				Mes 4			
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16
Entendimiento y definición del problema	■															
Alternativas de solución		■														
Propuesta de solución			■													
Adquisición de datos				■												
Tratamiento y almacenamiento de datos					■											
Segmentación de la señal de vibración						■										
Generación de imágenes de la señal de vibración							■									
Predicción del tipo de fallas del rodamiento								■								
Predicción de la vida útil de rodamiento									■							
Diagnóstico integral de la condición del rodamiento										■						
Construcción de interfaz gráfica											■					
Validación de resultados												■				

*Tabla 5. Plan de trabajo para el desarrollo del software para la detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo*

El entendimiento del problema surge de la necesidad de solucionar una situación real de la industria, en donde como profesional de confiabilidad he estado involucrado en comités de investigación de diferentes daños de equipo rotativo a causa de deterioros de rodamientos. La exploración de las diferentes alternativas de solución abre la posibilidad de la utilización de métodos de inteligencia artificial basada en aprendizaje profundo para el análisis de señales de muy alta frecuencia de muestreo con variabilidad en el tiempo para la detección y diagnóstico de fallos de manera automática. En este escenario se encuentra en un estudio de investigación una base de datos de señales de vibración de rodamientos con velocidad variable que describe un comportamiento real y diferentes condiciones funcionales que permitió la caracterización de fallas según su forma de onda en el dominio del tiempo.

A partir de estas consideraciones se inicia la presente investigación y desarrollo de solución de software, el cual involucró la utilización de métodos inteligentes descritos en las áreas de percepción computacional, aprendizaje profundo y sistemas cognitivos artificiales para la predicción de tipo de daño y severidad para un rodamiento.

## 4.1 Identificación de requisitos

Como parte fundamental de la ejecución del presente trabajo se contó con datos experimentales de calidad, los cuales fueron estandarizados y analizados para dar respuesta al problema de la investigación. En el almacenamiento de la información se utilizó la base de datos de SQLite como parte de la biblioteca estándar de Python. Su selección fue guiada por facilidad de implementación, nula configuración en servidores, perfil de usuario y permiso de acceso, lo que proporcionó flexibilidad en la creación del prototipo.

Para desarrollar el presente trabajo de investigación se utilizó el lenguaje de programación Python, el cual es un lenguaje de programación interpretado, multiplataforma y de alto nivel. Se ha elegido este lenguaje por ser uso libre, el más utilizado a lo largo de la asignatura del máster, además de contar con librerías de gran potencia de desarrollo y sobre todo por la compatibilidad con sistemas industriales.

Como editor de texto fue seleccionado Sublime Text, el cual posee una visualización de código por medio de colores que ayuda a la identificación de sentencias, funciones y errores de manera rápida e intuitiva. Este editor permite ejecutar el código directamente sobre él y posee una ventana para visualización de progreso y mensajes de alerta y finalización de la ejecución.

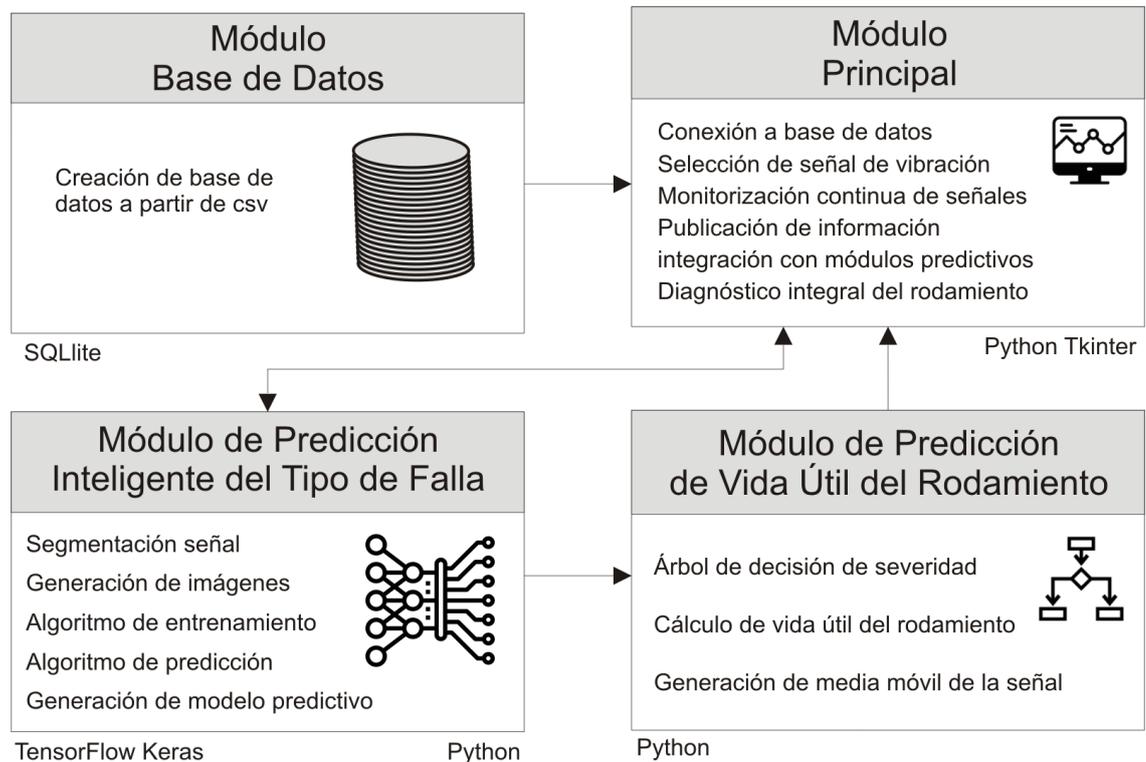
Para el análisis, visualización y procesamientos de los datos se desarrolló un software utilizando el paquete de interfaz gráfica de usuario (GUI) Python Tkinter, en donde mediante sus librerías fueron construidas de manera modular las funcionalidades necesarias para dar respuesta al problema planteado.

Para el desarrollo del modelo de entrenamiento y predicción de la red neuronal convolucional se utilizó la librería del alto nivel Keras sobre TensorFlow, la cual tiene una interfaz modular en Python para el desarrollo de redes neuronales, facilitando la tarea de programación ya que no necesitan definir arquitectura de bajo nivel.

## 4.2 Descripción del sistema desarrollado

El sistema desarrollado está compuesto de varios módulos programados en Python, los cuales interactúan entre sí para el análisis de la señal de vibración y el posterior diagnóstico

integral de la condición del rodamiento. La arquitectura de software desarrollado se muestra en la figura 13.



*Figura 13. Arquitectura del software de detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo. Visualización de los procesos construidos en sistema desarrollado.*

A continuación se describen cada uno de los módulos que integran el sistema desarrollado:

#### 4.2.1. Módulo de base de datos

En este módulo se genera la base de datos de las señales de vibración. El proceso inicia consolidando las señales de vibración en archivos de texto “.csv”, desde los archivos originales de Matlab. Posteriormente, se crea la base de datos a partir de un código desarrollado en Python y la librería de “sqlite3”. La información contenida en esta base de datos y sus tablas se puede visualizar en aplicación DB Browser (SQLite). Con este almacenamiento se dispone de los datos para ser analizados en los módulos posteriores. En la figura 14 se muestra el proceso de creación de base de datos anteriormente descrito.

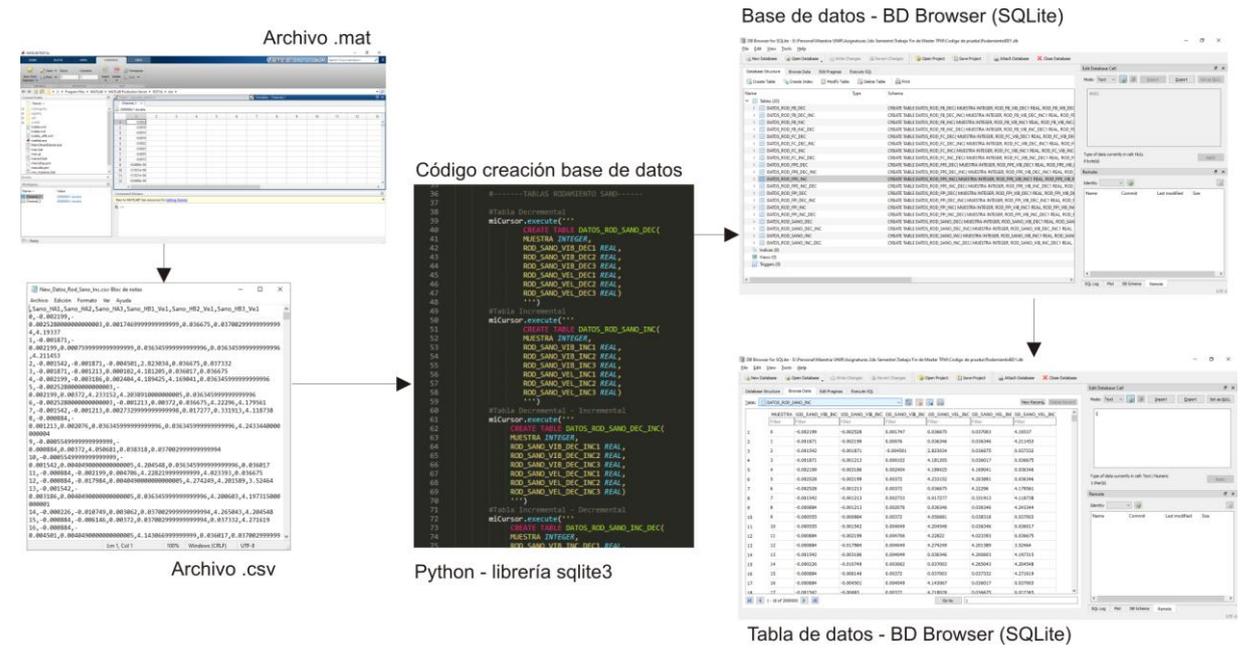


Figura 14. Proceso de creación de base de datos. Representación de creación de base de datos con archivos reales para el sistema desarrollado. Los paneles de las figuras muestran el flujo de creación de archivos que integran la base de datos. Los datos de las imágenes son representativos.

El nombre de la base de datos creada es “RodamientoBD1.db” y contiene las tablas descritas en la tabla 6.

Nombre	Descripción
DATOS_ROD_SANO_INC	<p>Señales de vibración de rodamiento sano. Contiene 7 columnas; la primera es el indicador de la muestra, las siguientes 3 corresponden a 3 señales de vibración con diferentes velocidades de rotación del rodamiento y las siguientes 3 columnas corresponden a la velocidad de cada una de las señales de vibración:</p> <p>MUESTRA                      ROD_SANO_VIB_INC1                      ROD_SANO_VIB_INC2                      ROD_SANO_VIB_INC3                      ROD_SANO_VEL_INC1</p>

	ROD_SANO_VEL_INC1 ROD_SANO_VEL_INC1
DATOS_ROD_FPI_INC	<p>Señales de vibración de rodamiento con falla en pista interna. Contiene 7 columnas; la primera es el indicador de la muestra, las siguientes 3 corresponden a 3 señales de vibración con diferentes velocidades de rotación del rodamiento y las siguientes 3 columnas corresponden a la velocidad de cada una de las señales de vibración:</p> <p>MUESTRA          ROD_FPI_VIB_INC1          ROD_FPI_VIB_INC2          ROD_FPI_VIB_INC3          ROD_FPI_VEL_INC1          ROD_FPI_VEL_INC1          ROD_FPI_VEL_INC1</p>
DATOS_ROD_FPE_INC	<p>Señales de vibración de rodamiento con falla en pista externa. Contiene 7 columnas; la primera es el indicador de la muestra, las siguientes 3 corresponden a 3 señales de vibración con diferentes velocidades de rotación del rodamiento y las siguientes 3 columnas corresponden a la velocidad de cada una de las señales de vibración:</p> <p>MUESTRA          ROD_FPE_VIB_INC1          ROD_FPE_VIB_INC2          ROD_FPE_VIB_INC3          ROD_FPE_VEL_INC1          ROD_FPE_VEL_INC1          ROD_FPE_VEL_INC1</p>

*Tabla 6. Estructura de base de datos de señales de vibración de rodamiento*

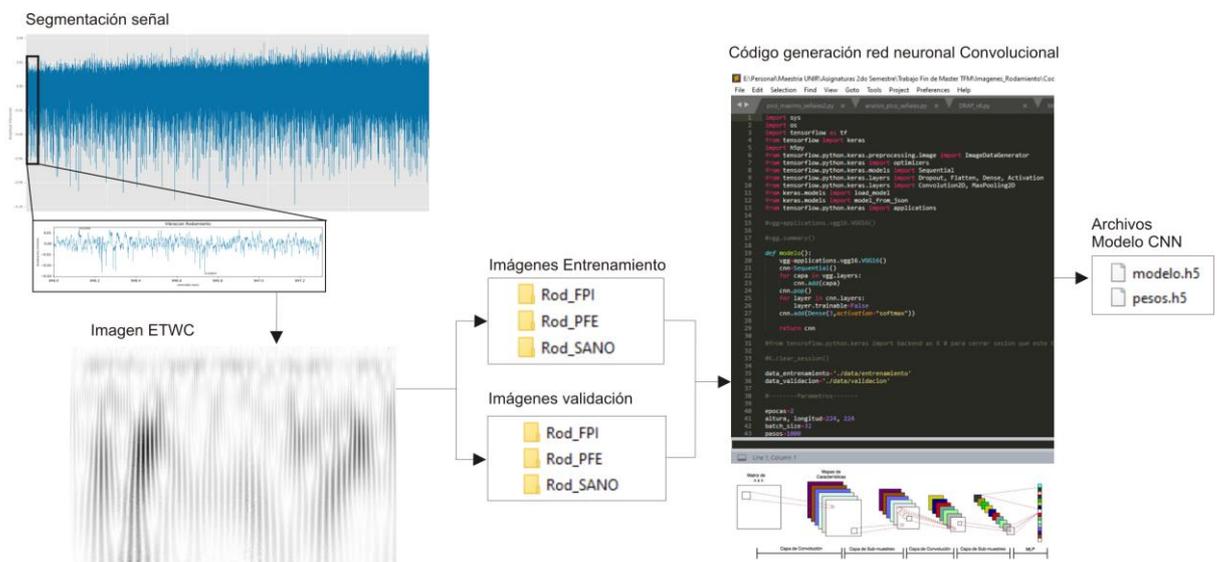
#### **4.2.2. Módulo de predicción inteligente de tipo de falla**

En este módulo convergen los procesos de tratamiento de datos para segmentación de la señal de vibración, generación de imágenes, creación del modelo, entrenamiento y

validación de la red neuronal convolucional. Posteriormente, se ejecuta el algoritmo predictivo y clasificación inteligente para la determinación del estado funcional del rodamiento.

### Tratamiento de datos y creación del modelo de predictivo

Luego de la creación de la base de datos, se inician la exploración de la información mediante la identificación de la frecuencia de rotación para capturar las frecuencias características de falla del rodamiento. Posteriormente, se recorta la señal y se genera la imagen del Escalograma de la Transformada Wavelet Continua a diferentes velocidades de rotación. Estas imágenes son agrupadas en conjuntos de entrenamiento y validación para cada tipo de condición funcional (Sano y Falla). El código de generación de la red neuronal convolucional toma las imágenes agrupadas para entrenar y validar el modelo predictivo. Como resultado de este proceso se crean dos archivos: uno es el modelo de la red neuronal convolucional y el otro corresponde a los pesos de cada capa de la misma. En la figura 15 se muestra el proceso anteriormente descrito.



*Figura 15. Proceso de tratamiento de datos y creación del modelo predictivo basado en red neuronal convolucional. Visualización de creación del modelo predictivo inteligente con archivos reales. Los paneles de las figuras muestran el flujo de creación de archivos que generan los archivos del modelo predictivo. Los datos de las imágenes son representativos.*

**Calculo de frecuencia central de las señales de vibración:** para el análisis de la frecuencia de rotación y la frecuencia central de las señales de vibración se consideraron las ecuaciones descritas en el capítulo 3.3.2 y la información de velocidad de inicio y fin de la cada señal. Los datos para cada señal se resumen en la tabla 7.

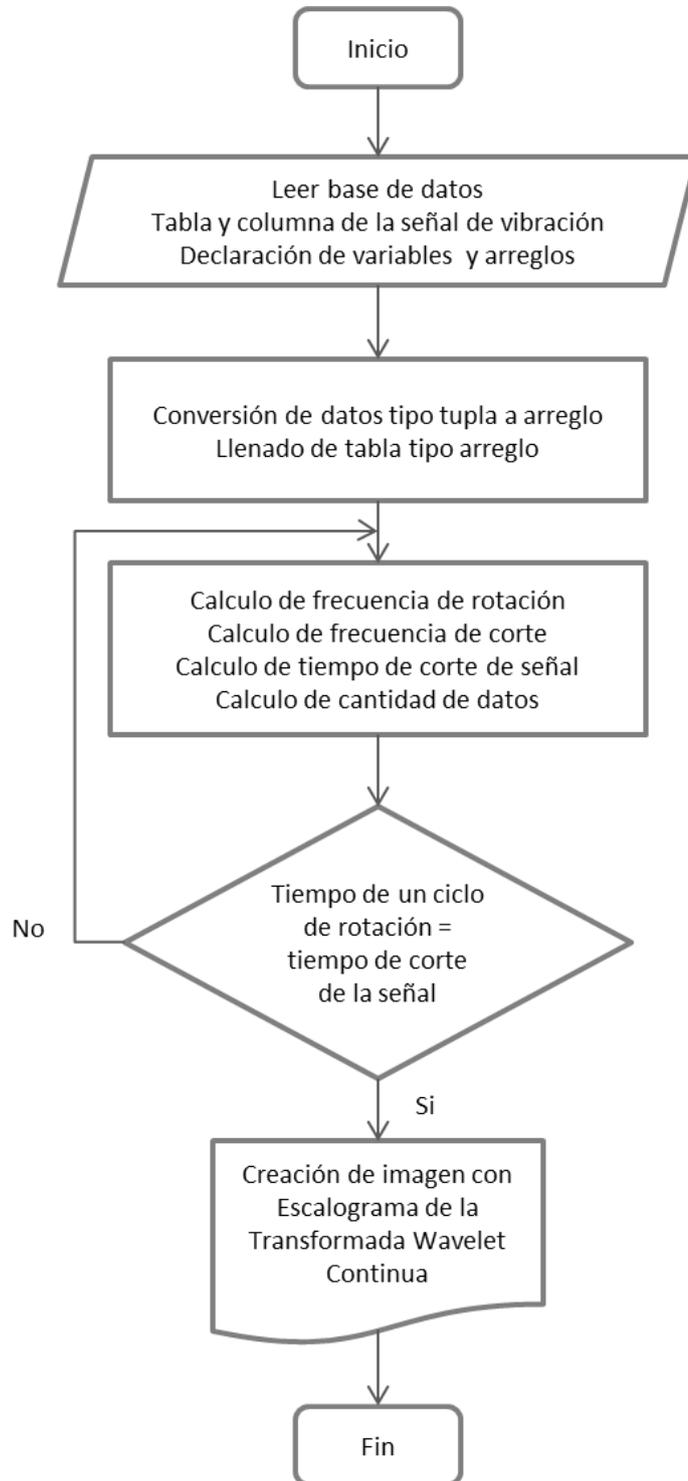
	frecuencia de muestreo (hz)	Tiempo de muestreo (seg)	Cantidad de datos total de cada señal	Velocidad inicio y fin de (rpm)	Total segmentos	Frecuencia central
Señal1 rodamiento sano	200.000	0.000005	2.000.000	846-1428	581	3.15
Señal 2 rodamiento sano	200.000	0.000005	2.000.000	846-1740	894	4.4
Señal1 rodamiento falla pista interna	200.000	0.000005	2.000.000	750-1668	918	4.8
Señal 2 rodamiento falla pista interna	200.000	0.000005	2.000.000	780-1542	762	4.1
Señal 1 rodamiento falla pista externa	200.000	0.000005	2.000.000	888-1626	738	3.7
Señal 2 rodamiento falla pista externa	200.000	0.000005	2.000.000	774-1380	606	3.5

*Tabla 7. Resumen de datos de la señales de vibración para segmentación*

**Segmentación de la señal de vibración y creación de las imágenes con el Escalograma de la Transformada Wavelet Continua (ETWC):** El algoritmo de creación de inicia con la conexión a la base de datos, en donde se busca la tabla y columna correspondiente a la señal a graficar, luego se declaran las variables y arreglos, se convierte el tipo de tabla tupla a tipo arreglo con el fin de acceder al dato crudo. Con la disponibilidad del dato se procede a la realizar los cálculos de frecuencia de rotación, frecuencia y tiempo de corte de la señal y cantidad de datos de la señal segmentada. En la figura 16 se muestra el flujograma del algoritmo desarrollado.

**Creación de grupos de imágenes para entrenamiento y validación:** A partir de cada imagen creada en el paso anterior, las cuales son agrupadas en conjuntos de entrenamiento y validación, con el fin de tener referencia de características como datos históricos observados para el entrenamiento del algoritmo inteligente y adquirir capacidades de predicción para situaciones futuras. Dichos conjuntos se utilizan para la construcción del modelo de aprendizaje profundo y ajustar las métricas de error mediante el conjunto de validación.

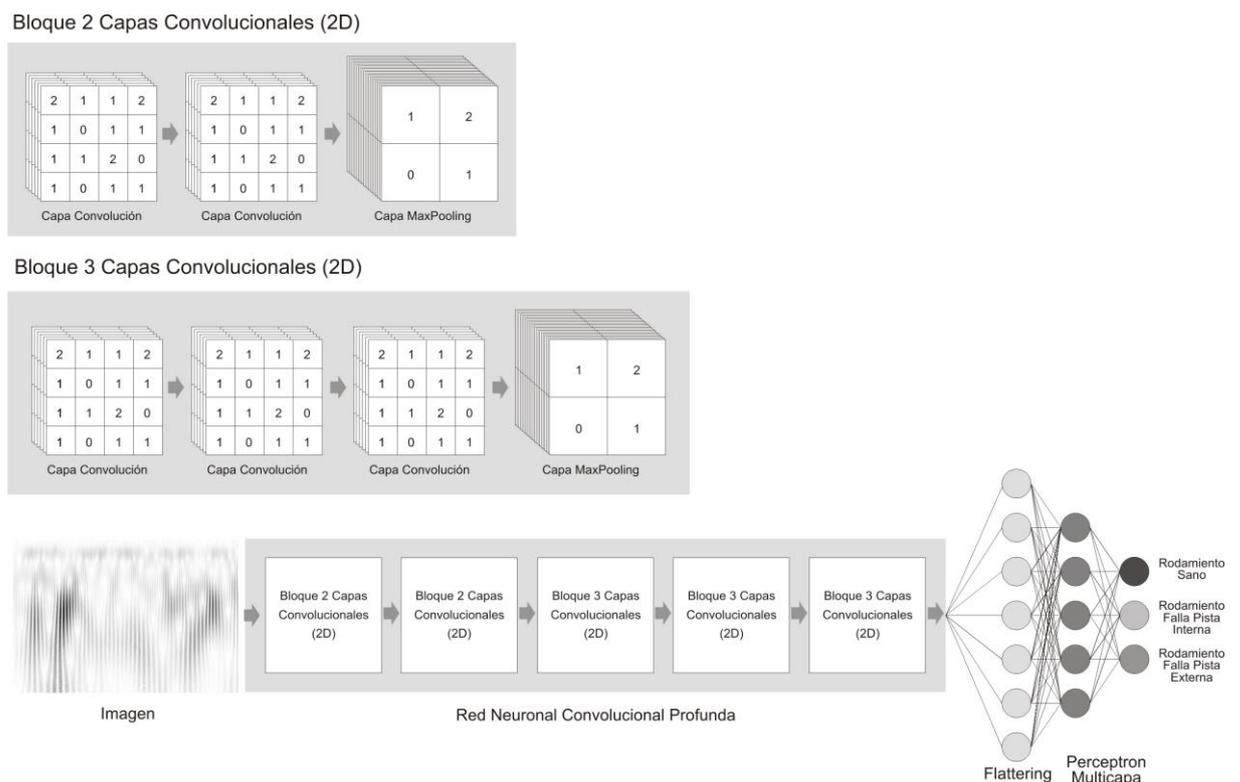
Se utilizó el 75% de las imágenes para crear el conjunto de entrenamiento y un 25 % de las imágenes para generar conjunto de validación. Para asegurarse que no existen diferencias sistemáticas entre los dos grupos fue necesario obtener las imágenes de forma aleatoria.



*Figura 16. Flujograma del algoritmo de segmentación de la señal de vibración y creación de las imágenes con el Escalograma de la Transformada Wavelet Continua. Descripción del proceso constructivo del código para segmentación de señales y creación de imágenes.*

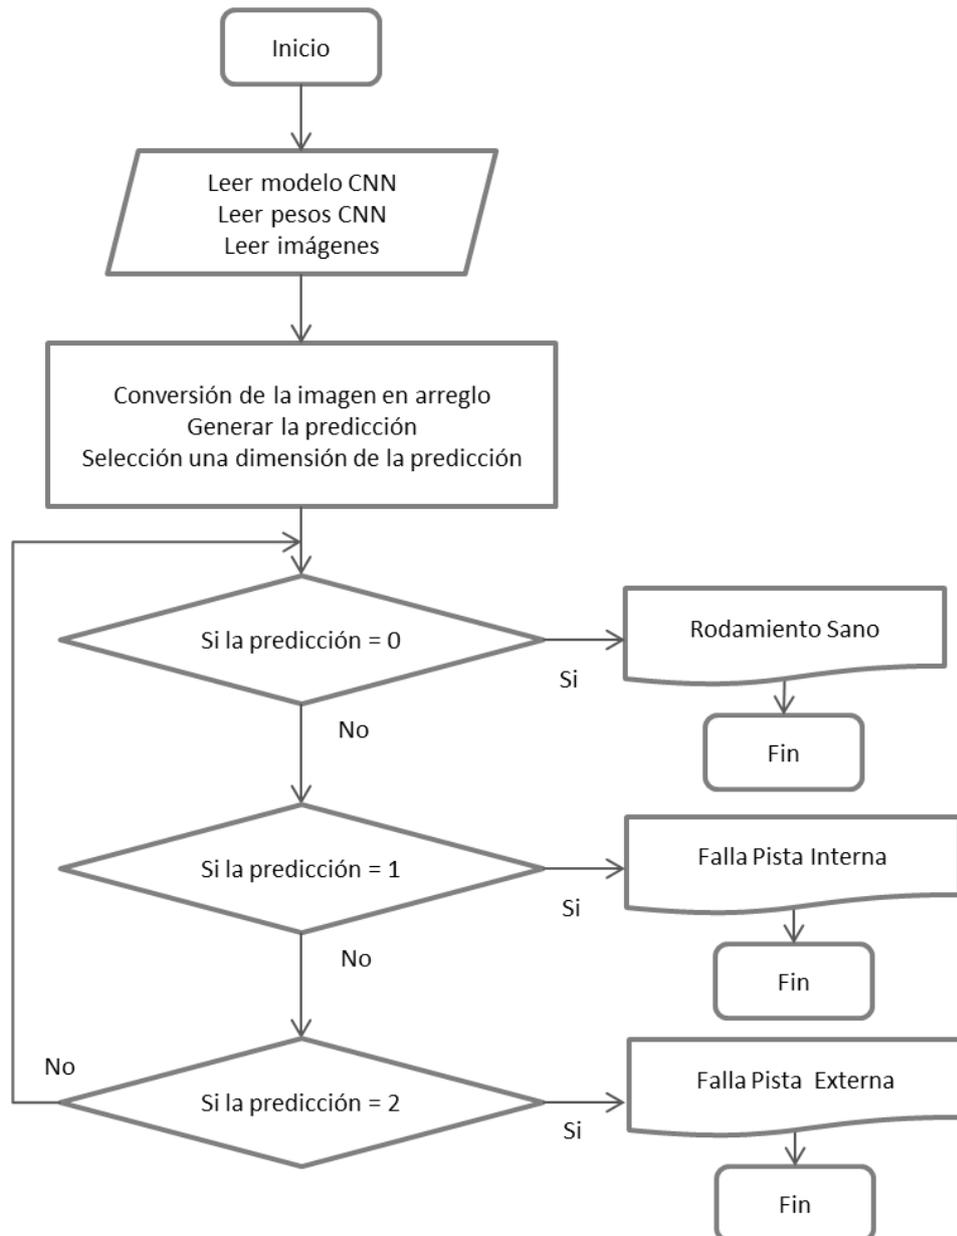
**Creación del modelo predictivo basado en red neuronal convolucional:** Para la construcción de la red neuronal convolucional, en el presente trabajo de fin de master se aplica el concepto de transferencia de aprendizaje o “Transfer Learning”, adaptando el modelo de aprendizaje profundo VGG16 de keras para realizar la predicción. Con este concepto se usa este modelo con capas pre-entrenadas, las cuales pueden reconocer bordes y sombras y se agregan tres capas densas para la activación y clasificación de las imágenes, las cuales reconocen patrones y estructuras complejas.

La arquitectura de la red neuronal convolucional VGG16 posee 5 bloques de capas convolucionales y maxpooling: Los primeros dos bloques tienen dos capas convolucionales y los tres siguientes bloques tienen tres capas convolucionales. Al final tiene tres capas densas para la activación, flattening y la capa de clasificación softmax basada en el perceptron multicapa. En la figura 17 se muestra la arquitectura de la red neuronal convolucional propuesta.



*Figura 17. Arquitectura de la red neuronal convolucional para la detección del estado funcional de rodamientos. Representación gráfica de las principales partes que componen la red convolucional profunda generada para la predicción inteligente de condición del rodamiento. Los paneles de las figuras muestran el flujo de creación de la predicción de la red neuronal convolucional. Los datos de las imágenes son representativos.*

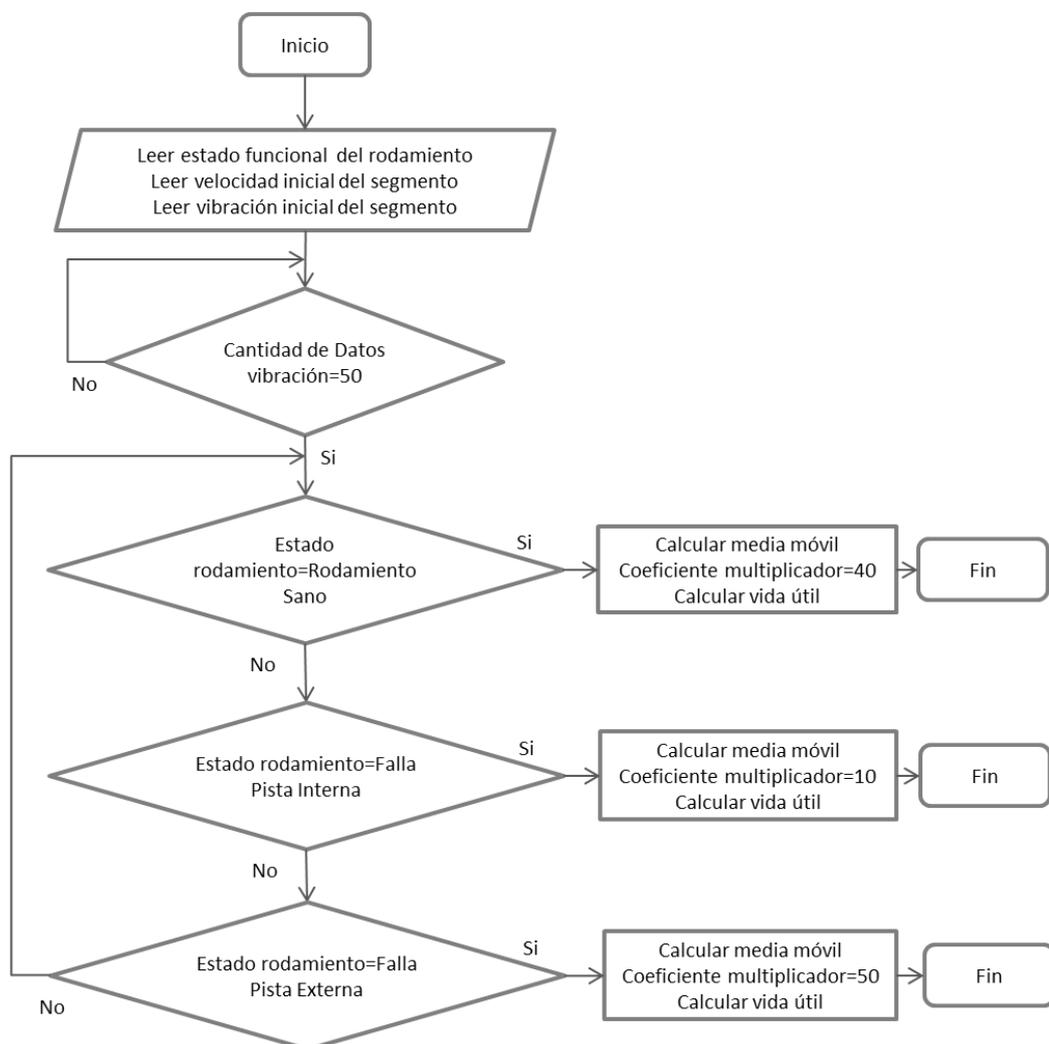
**Ejecución del modelo predictivo:** El algoritmo de ejecución del modelo de predicción de la red neuronal convolucional inicia con la lectura del modelo, los pesos y las imágenes. Posteriormente, se convierte la imagen en arreglo con el fin de ser analizada por el modelo, el cual se ejecuta para generar la predicción. La respuesta se restringe a un arreglo de una dimensión con el fin de obtener el vector del tamaño de las clases evaluadas: Rodamiento Sano, Falla en pista interna, Falla en pista externa. En la figura 18 se muestra el flujograma del código de ejecución del modelo predictivo.



*Figura 18. Flujograma del código de ejecución del modelo predictivo basado en una red neuronal convolucional profunda. Descripción del proceso constructivo del algoritmo para predecir el estado funcional del rodamiento.*

### 4.2.3. Módulo de predicción de vida útil del rodamiento

Este módulo calcula la vida útil remanente del rodamiento, considerando lo descrito en el capítulo 3.3.4 de este documento. El algoritmo de predicción inicia con la lectura del estado funcional, la velocidad y vibración del rodamiento. Posteriormente, se cargan 50 datos de vibración con el fin de calcular su media móvil. Se valida el estado funcional del rodamiento con el fin de asignar el coeficiente multiplicador de la fórmula de cálculo de vida remanente, esta asignación se realiza mediante una árbol de decisión que evalúa el estado funcional del rodamiento: sano, falla en pista interna y falla en pista externa. En la figura 19 se muestra el flujograma del código desarrollado para la predicción de la vida útil del rodamiento.



*Figura 19. Flujograma del código desarrollado para la predicción de la vida útil del rodamiento. Descripción del proceso constructivo del algoritmo utilizado para determina la severidad de daño del rodamiento.*

En la figura 20 muestra el árbol de decisión para asignar el coeficiente multiplicador para determinar la severidad de daño. El algoritmo elige primero para evaluación la variable “rodamiento sano” y a continuación, los ejemplos de entrenamiento se dividen en dos grupos más para evaluar el tipo de fallo.

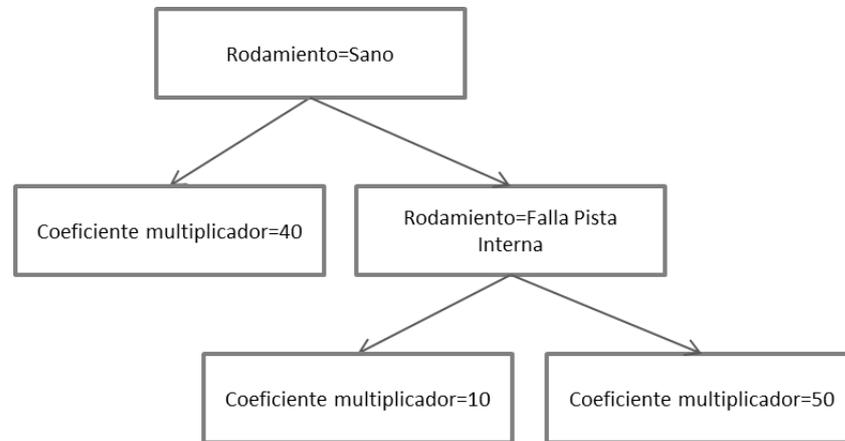
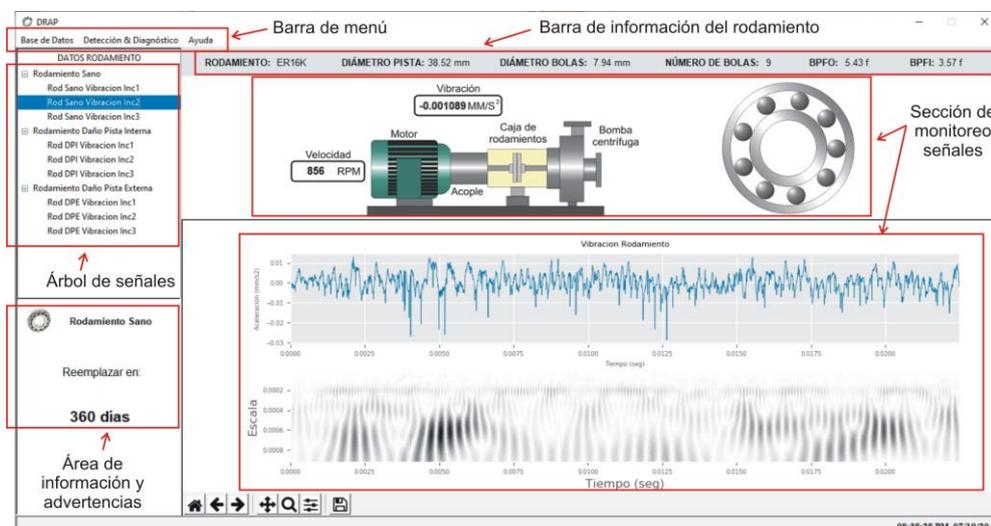


Figura 20. Árbol de decisión para asignar el coeficiente multiplicador para determinar la severidad de daño.

### 4.2.4 Módulo Principal

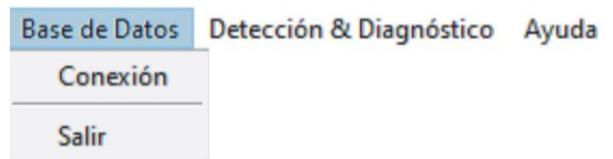
Este módulo integra los módulos predictivos, permite la conexión de la base de datos, la selección de la señal de vibración, monitoriza continuamente las señales y publica información sobre la detección y diagnóstico de la condición integral del rodamiento. Su desarrollo, al igual que los demás, fue realizado en Python y la interfaz gráfica fue construida en Tkinter. En la figura 21 se muestran las partes que compone el sistema desarrollado.



*Figura 21. Interfaz gráfica del software de detección y diagnóstico de fallas en rodamientos con velocidad variables aplicando aprendizaje profundo. Permite evidenciar la materialización del cada uno de los algoritmos predictivos desarrollados. Los paneles de las figuras muestran las partes que integran la interfaz gráfica. Los datos de las imágenes son representativos.*

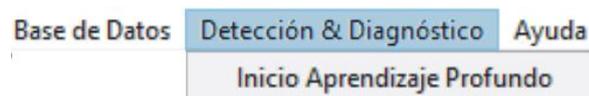
**Barra de menú:** en esta sección se encuentran las pestañas de base de datos, detección & diagnóstico y Ayuda.

En la pestaña de Base de Datos se haya la opción de conexión y salir de la aplicación, tal como se muestra en la figura 22.



*Figura 22. Barra menú base de datos*

En la pestaña de Detección y Diagnóstico se encuentra la opción de inicio del módulo predictivo del estado funcional de rodamiento con Aprendizaje Profundo, tal como se muestra en la figura 23.



*Figura 23. Barra Menú Detección & Diagnóstico.*

En la pestaña de Ayuda se incluye la opción de "Acerca de", en donde se verifica la versión del software y todos los derechos de autor, tal como se muestra en la figura 24.



*Figura 24. Barra Menú Ayuda.*

**Barra de información del rodamiento:** en esta área se muestra la información técnica del rodamiento utilizado en la investigación. En la figura 25 se muestra el detalle de esta área.

RODAMIENTO: ER16K	DIÁMETRO PISTA: 38.52 mm	DIÁMETRO BOLAS: 7.94 mm	NÚMERO DE BOLAS: 9	BPFO: 5.43 f	BPFI: 3.57 f
-------------------	--------------------------	-------------------------	--------------------	--------------	--------------

Figura 25. Barra de información del rodamiento

**Árbol de señales:** en esta área se disponen las señales de vibración según el estado funcional del rodamiento, las cuales pueden ser seleccionadas para análisis y evaluación. En la figura 26 se muestra en detalle esta área.

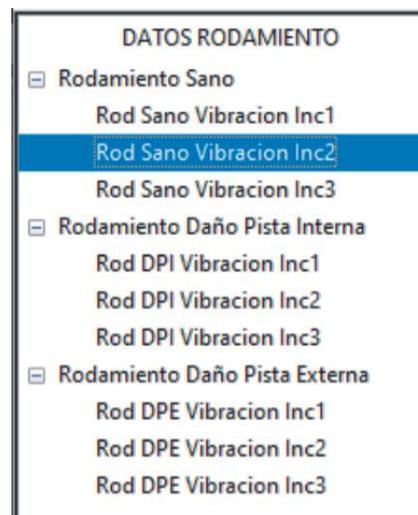
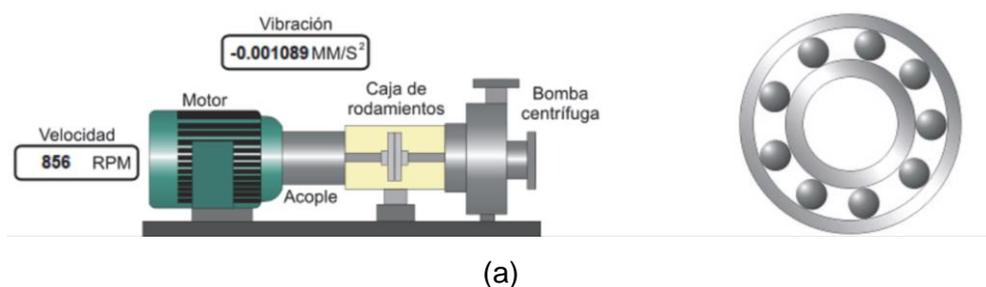


Figura 26. Área de árbol de señales de vibración.

**Sección de monitoreo de señales:** esta área se divide en el monitoreo de los valores de vibración y velocidad; en la parte inferior se visualiza la señal cruda de vibración y su respectivo escalograma de la transformada wavelet continua. En la figura 27a, 27b y 27c se muestra la representación del equipo rotativo, el rodamiento y los valores en tiempo real. En la figura 28 se muestra la señal de vibración.



(a)

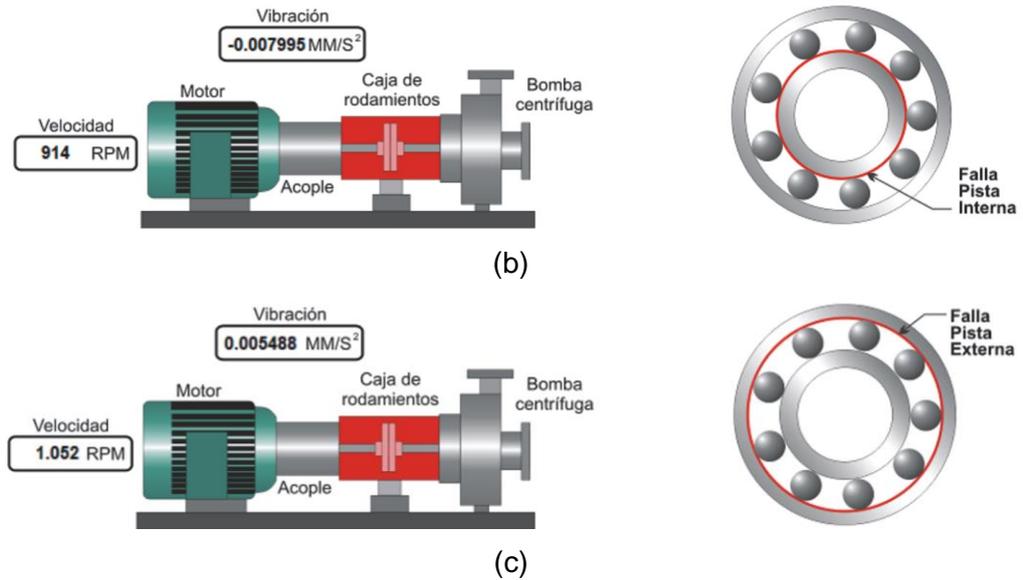


Figura 27. Área de representación de equipo rotativo y monitoreo continuo de datos de vibración y velocidad (a) Rodamiento Sano (b) Falla en Pista Interna (c) Falla en Pista Externa

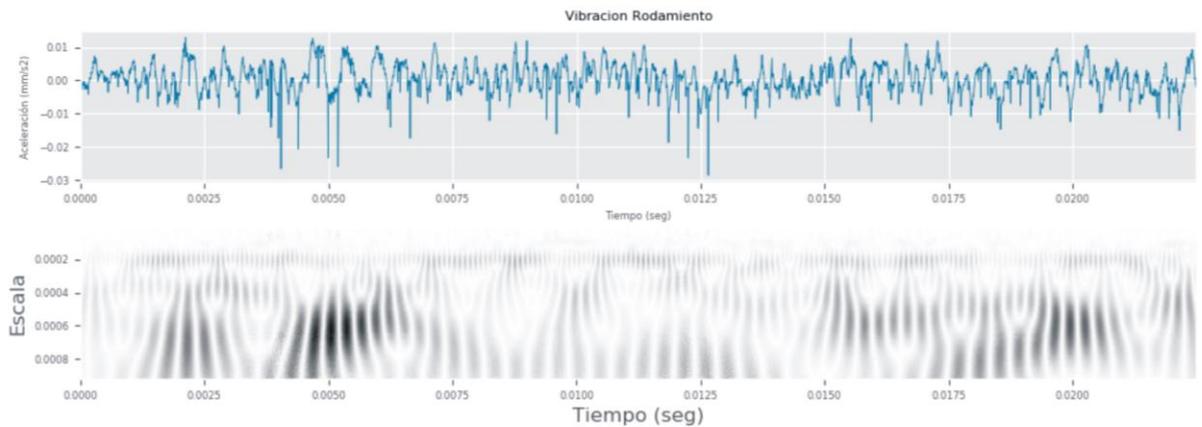


Figura 28. Monitoreo de la señal de vibración e imagen del Escalograma de la Transformada Wavelet Continua.

**Área de información y advertencias:** en esta sección se publica el estado funcional del rodamiento y la severidad de daño. En la figura 29 se muestra el despliegue de esta información.

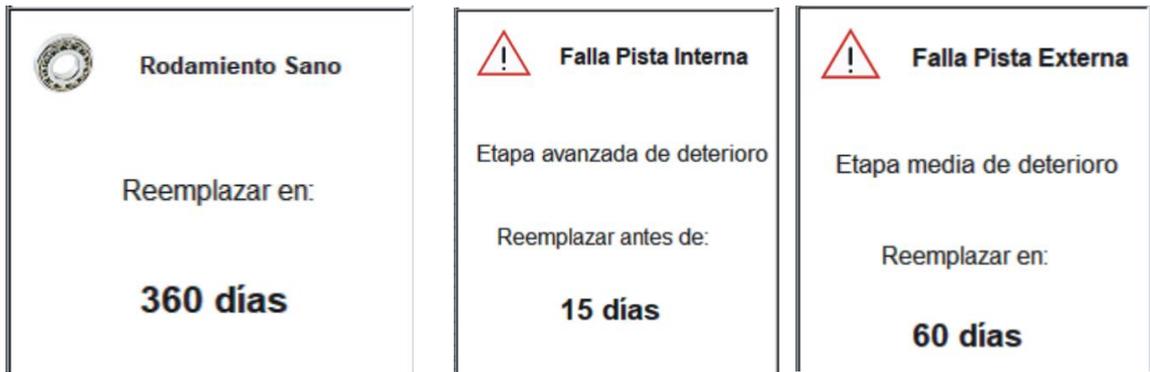


Figura 29. Área de publicación del estado funcional del rodamiento y predicción de vida útil remanente.

### 4.3 Evaluación

Para la evaluación del desempeño del sistema desarrollado se realizan pruebas con tres señales de vibración que contienen las condiciones, las cuales son: rodamiento sano, falla en pista en interna y falla en pista externa. Las características de la señal se muestran en la tabla 8.

	Tiempo total de la señal (Seg)	Velocidad inicial de la señal (rpm)	Velocidad final de la señal (rpm)
Rodamiento Sano	10	912	1602
Rodamiento con Falla en Pista Interna	10	810	1710
Rodamiento con Falla en Pista Externa	10	798	1578

Tabla 8. Características de las señales utilizadas para la evaluación del sistema desarrollado

En la evaluación se realizaron 20 pruebas para cada señal, lo cual se completaron 60 en total. En el desempeño del sistema desarrollado se logró una exactitud del 96,67%, debido a que se obtuvieron 58 diagnósticos de la condición acertados y 2 incorrectos. En todas las pruebas se obtuvieron predicciones de severidad del daño.

Se observa que los dos errores fueron visibles en la señal de falla en pista externa, lo cual abre la posibilidad de realizar un ajuste en los parámetros de entrenamiento del modelo de la red neuronal convolucional profunda con el fin de alcanzar mejoras en la exactitud de la

predicción. En la figura 30 se muestran las estadísticas de las pruebas realizadas con el sistema desarrollado

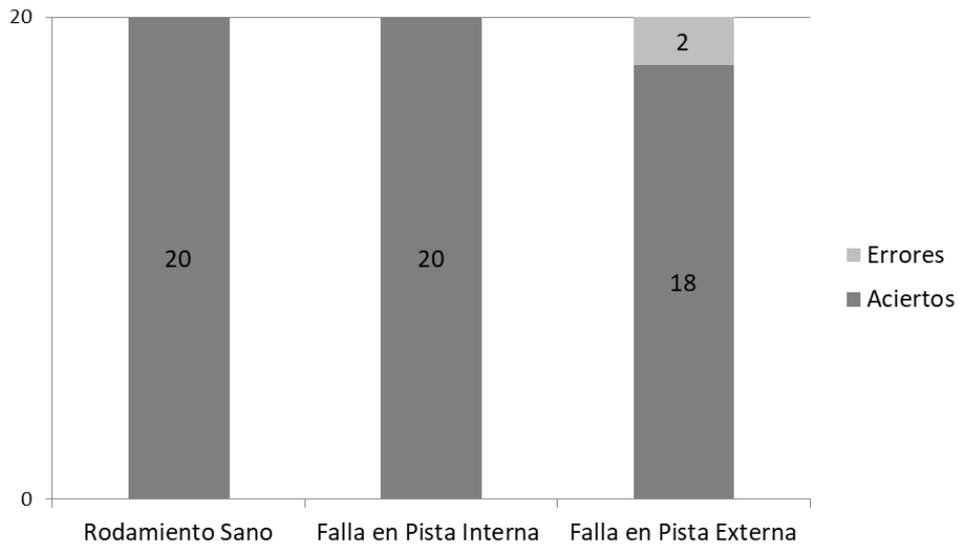


Figura 30. Estadísticas de pruebas realizadas con el sistema desarrollado para detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo.

En las figuras 31, 32 y 33 se muestran los pantallazos del sistema desarrollado con diagnóstico integral de las condiciones sano, falla en pista interna y falla en pista externa del rodamiento.

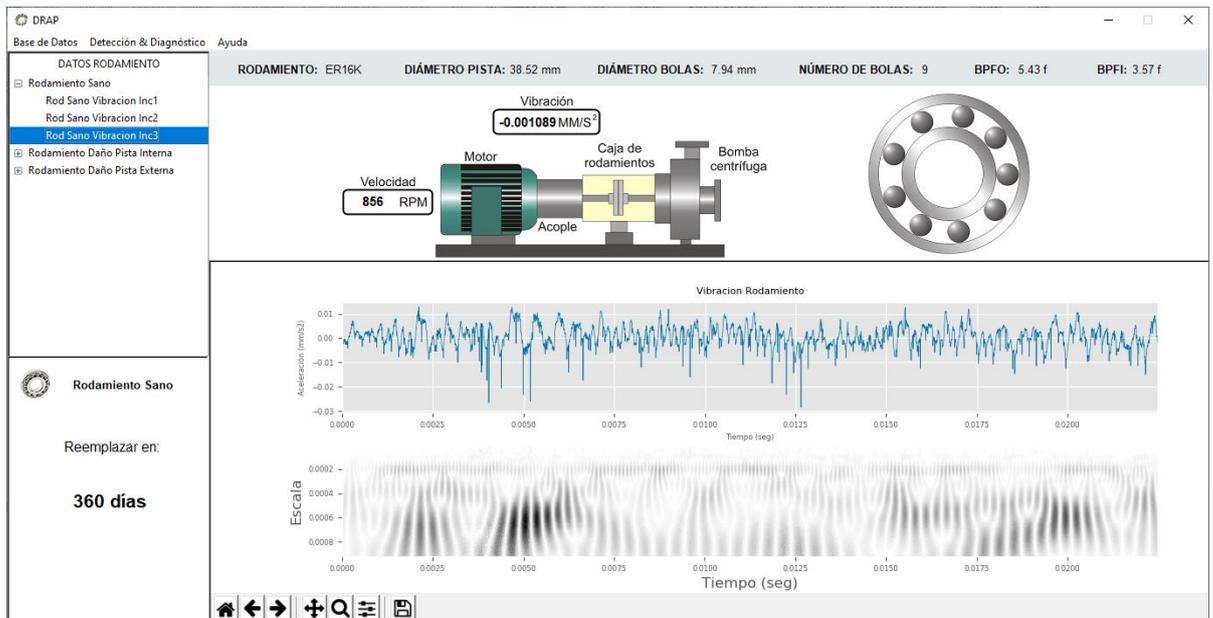


Figura 31. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Sano del rodamiento.

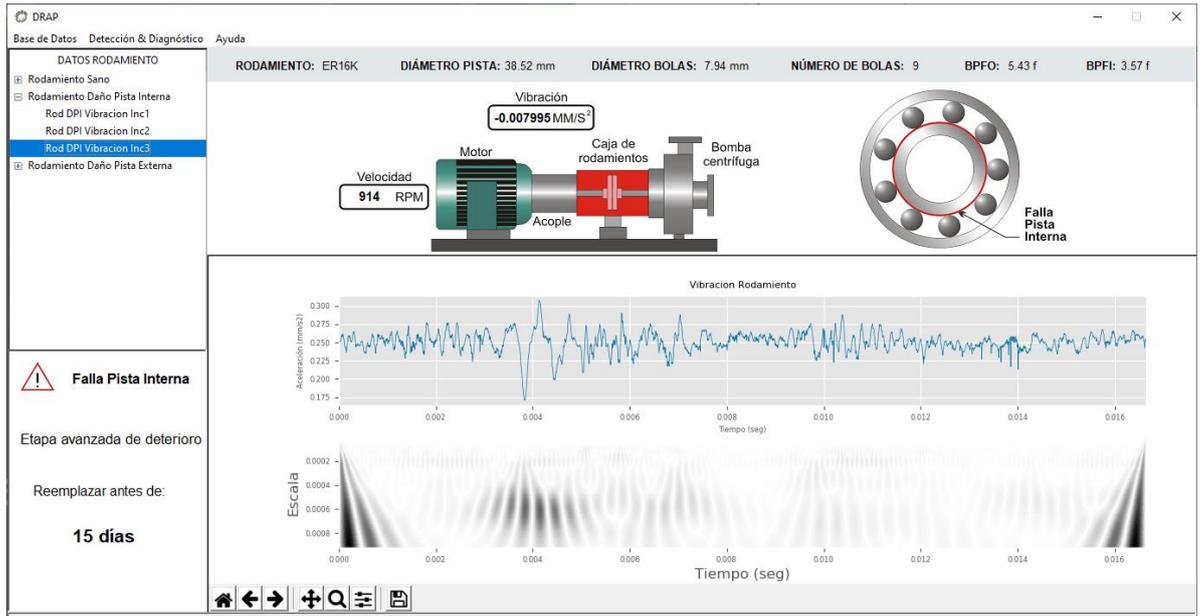


Figura 32. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Falla en Pista Interna del rodamiento.

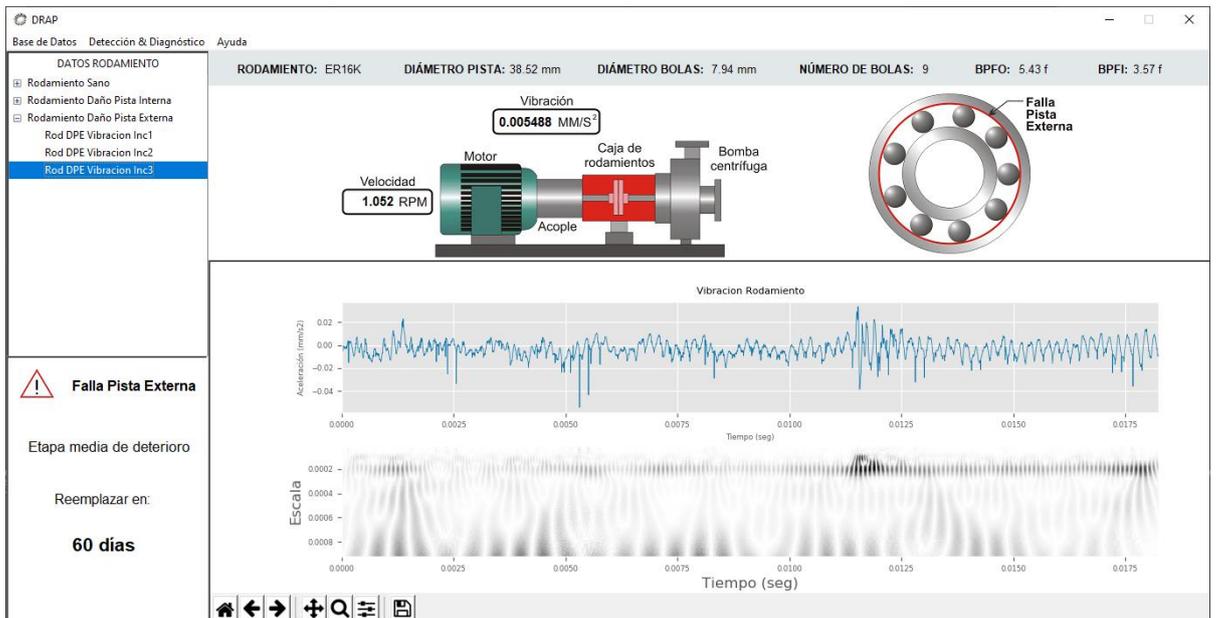


Figura 33. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Falla en Pista Externa del rodamiento

## 5. CONCLUSIONES Y TRABAJO FUTURO

En esta sección se hace un análisis del trabajo realizado, y se presentan las conclusiones de los resultados. Posteriormente se realiza un análisis de mejoras en el sistema aplicables en líneas de trabajo futuro.

### 5.1. Conclusiones

El problema planteado en este trabajo de fin de master aborda la necesidad de desarrollar un sistema que apoye a la toma de decisiones del personal técnico y operativo involucrado en procesos industriales que utilizan equipos rotativos. La solución planteada cumple con los objetivos propuestos diseñando y construyendo un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando una técnica de aprendizaje profundo basada una red neuronal convolucional.

En esta propuesta innovadora se combinaron métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación, simulando condiciones de operación real añadiendo una mayor complejidad en la caracterización y clasificación de las averías.

Los datos experimentales fueron seleccionados y organizados para la construcción del software de detección y diagnóstico inteligente de fallas de rodamientos y validación de resultados.

La extracción de los atributos de condición de los datos en el dominio del tiempo y del tiempo-frecuencia fueron determinados mediante la segmentación de la señal según la frecuencia de rotación y utilizando el método de la Transformada Wavelet Continua.

Las características de los datos y la reducción de sus atributos fueron estandarizados mediante la generación de imágenes con el método del Escalograma de la Transformada Wavelet Continua, lo cual permitió el análisis de las señales de vibración del rodamiento con un enfoque de aprendizaje no supervisado.

Se construyó un algoritmo para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional y análisis de severidad de daño.

Se diseñó y desarrolló una interfaz gráfica de usuario del software para la detección y diagnóstico inteligente de fallas en rodamientos basado en el algoritmo de aprendizaje profundo, el cual permite una conexión con la base de datos, monitorización continua de la velocidad de rotación y el nivel de vibración del rodamiento, visualización de la información de estado funcional con sus respectivas alarmas sobre tipo de falla y la vida útil, considerado este como un diagnóstico integral de la condición del rodamiento.

Los resultados obtenidos de la validación del algoritmo para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional fueron satisfactorios, detectando los diferentes estados funcionales de rodamiento sano, en falla en pista interna y falla en pista externa con sus respectivo cálculo de vida útil.

Se logra establecer que los rodamientos en falla presenta una disminución considerable de su vida útil con respecto al rodamiento sano; evolucionando su deterioro la condición incremental de la velocidad.

De igual manera la red neuronal convolucional logra identificar las fallas con una exactitud del 96,67%, al clasificar las imágenes de la señal de vibración según condición funcional a diferentes velocidades de rotación. Esto denota la gran aplicabilidad de este método de inteligencia artificial en problemas industriales condiciones reales de operación.

## **5.2. Líneas de trabajo futuro**

La aplicación de técnicas de sistemas cognitivos artificiales es relevante para solucionar este tipo de problemas debido a la alta capacidad de identificación de características y clasificación que poseen, además abre la puerta para el uso de teorías de transferencia de aprendizaje en donde se extrapolan las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

Este desarrollo puede evolucionar hacia la identificación de fallas de acuerdo a condiciones operativas, de almacenamiento o mantenimiento encontrando la causa raíz como deficiente lubricación o exceso de carga del rodamiento.

## 6. BIBLIOGRAFÍA

- Ahmed, H. A., Dennis Wong, M. L., & Nandi, A. K. (2016). Effects of Neural Network Parameters on Classification of Bearing Faults. *IEEE Industrial Electronics Society*.
- Amazon. (2020). AWS. Obtenido de <https://aws.amazon.com/es/mxnet/>
- Appana, D. K., Prosvirin, A., & Kim, J.-M. (2018). Reliable fault diagnosis of bearings with varying rotational speeds using envelope spectrum and convolution neural networks. *Soft Computing*.
- Arias Cijanes, C. A., Aranguren Zambrano, S., & Tarantino Alvarado, R. (2012). Diseño de una Estrategia de Control Tolerante a Fallos Basado en Conocimiento aplicado a un Lazo de Control de Nivel Industrial. *Revista Colombiana de Tecnologías de Avanzada*, 128-135.
- Bellman, R. (1978). *An Introduction to Artificial Intelligence: Can Computers Think?* Michigan: Boy & Fraser, Univerdad de Michigan.
- Caffe2. (2020). Obtenido de <https://caffe2.ai/>
- Calvo Rolle, J. L., Ferreiro García, R., & Alonso Alvarez, A. (2008). Sistema basado en conocimiento para el análisis de vibraciones en mantenimiento predictivo. *DYNA Ingeniería e Industria*, 484-492.
- Charniak, E., & McDermonntt, D. (1985). *Introduction to Artificial Intelligence*. Addison Wesley.
- Chen, Z., & Li, W. (2017). Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder Diagnosis Using Sparse Autoencoder. *IEEE*, 1693-1702.
- Chollet, F. (2018). *Deep Learning whit python*. New York: Manning Publication Co.
- Cortes, C., & Vapnik, V. (1995). Suport-Vector Network. *Kluver Academic Publishers, Boston*, 273-297.
- Cover, T. M., & Hart, P. E. (1967). Nearest Neightbor Pattern Classification. *IEEE Transaction on Information Theory*, 21-27.

- Crespo Marquez, A., Moreu de León, P., & Sánchez Herguedas, A. (2004). *Ingeniería de Mantenimiento. Técnicas y métodos de aplicación a fase operativa de los equipos*. Madrid, España: AENOR.
- Crispi, J. (14 de 6 de 2019). *Introducción al deep learning parte 2: Redes Neuronales Convolucionales*. Obtenido de <https://medium.com/@jcrispis56/introducci%C3%B3n-al-deep-learning-parte-2-redes-neuronales-convolucionales-f743266d22a0>
- Dai, W., Yang, Q., Xue, G.-R., & Yu, Y. (2007). Boosting for Transfer Learning. *ICML*, 193-200.
- Dean, J., & Monga, R. (1 de 10 de 2019). *TensorFlow*. Obtenido de <https://www.tensorflow.org/>
- Duan, L., Xie, M., Wang, J., & Bai, T. (2018). Deep learning enabled intelligent fault diagnosis: Overview and applications. *Journal of Intelligent & Fuzzy System*.
- EM Efficient Manufacturing. (2015). *Web Magazine of Industr.com*. Obtenido de <https://www.industr.com/en/the-true-cost-of-bearing-lubrication-695499>
- Eren, L., Ince, T., & Kiranyaz, S. (2018). A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN Classifier. *Journal of Signal Processing Systems*.
- Fuan, W., Hongkai, J., Haidong, S., Wenjing, D., & Shuaipeng, W. (2017). An adaptive deep convolutional neural network for rolling bearing fault diagnosis. *IOPScience*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Guo, L., Lei, Y., Xing, S., Yan, T., & Li, N. (2018). Deep Convolutional Transfer Learning Network: A New Method for Intelligent Fault Diagnosis of Machines with Unlabeled Data. *IEEE*.
- Guo, S., Yang, T., Gao, W., & Zhang, C. (2018). A Novel Fault Diagnosis Method for Rotating Machinery Based on a Convolutional Neural Network. *Sensor MDPI*.
- Haidong, S., Hongkai, J., Ke, Z., Dongdong, W., & Xingqiu, L. (2018). A novel tracking deep wavelet auto-encoder method for intelligent fault diagnosis of electric locomotive bearings. *Elsevier*, 193-209.

- Haidong, S., Hongkai, J., Xingqiu, L., & Shuaipeng, W. (2017). Intelligent Fault Diagnosis of Rolling Bearing Using Deep Wavelet Auto-encoder with Extreme Learning Machine . *Knowledge-Based Systems* .
- Haugeland, J. (1985). *Artificial intelligence: The very idea*. Georgia: Athens, University of Georgia.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Xplore CVPR*.
- Huang, H., & Baddour, N. (2018). Bearing vibration data collected under time-varying rotational speed conditions. *Elsevier*, 1745-1749.
- IBT Industrial Solution. (3 de Julio de 2018). *PrimeMOVER Industry News*. Obtenido de <https://www.ibtinc.com/causes-of-bearing-failure/>
- Jiuxiang, G., Zhenhua, W., Jason, K., Lianyang, M., Amir, S., Bing, S., . . . Tsuhan, C. (2018). Recent advance in convolution neural networks. *Elsevier Pattern Recognition*, 354-377.
- Keras. (2020). Obtenido de <https://keras.io/>
- Koller, D., & Friedman, N. (2010). *Probabilistic Graphical Models*. London: Mit press.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, 84-90.
- Kurzweil, R. (1992). *The Age of Intelligent Machines*. The MIT Press.
- Lei, Y., He, Z., Yanyang, Z., & Qiao, H. (2007). Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs. *Elsevier*, 2280-2294.
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., & Nandi, A. K. (2019). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Elsevier*, 138.
- Li, J., Li, X., He, D., & Qu, Y. (2019). A Novel Method for Early Gear Pitting Fault Diagnosis Using Stacked SAE and GBRBM. *mdpi*.
- Li, S., Liu, G., Tang, X., Lu, J., & Hu, J. (2017). An Ensemble Deep Convolutional Neural Network Model with Improved D-S Evidence Fusion for Bearing Fault Diagnosis. *Sensor MDPI*.

- Liao, S.-H. (2005). Expert system methodologies and applications—a decade review from 1995 to 2004. *Elsevier*, 93-103.
- Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Elsevier*, 33-47.
- Long, M., Wang, J., Cao, Y., Sun, J., & Yu, P. S. (2016). Deep Learning of Transferable Representation for Scalable Domain Adaptation. *IEEE*, 2027-2040.
- Long, M., Zhu, H., Wang, J., & Jordan, M. I. (2017). Deep transfer learning with joint adaptation networks. *Proceedings of the 34 th International Conference on Machine*.
- López Cataldo, D. A. (2016). *Diagnóstico de fallas de Rodamientos de Equipos de Rotación Utilizando Redes Neuronales Artificiales*. Valparaíso, Chile: Pontificia Universidad Católica de Valparaíso.
- Lu, C., Wang, Z., & Zhou, B. (2017). Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification. *Elsevier*, 139-151.
- Nilsson, N. J. (1998). *Artificial Intelligence: A New Synthesis*. Morgan Kaufmann.
- NSK. (s.f.). *Bearing Doctor* NSK. Obtenido de <https://www.nsk.com/common/data/ctrpPdf/e7005c.pdf>
- NSK Literature. (2010). Obtenido de Rodamiento de bolas de ranura profunda: <http://www.nsk-literature.com/es/deep-groove-ball-bearings/>
- Pan, S. J., Tsang, I. W., Kwok, J. T., & Yang, Q. (2011). Domain Adaptation via Transfer Component Analysis. *IEEE*, 199-210.
- Poole, D., Mackworth, A., & Goebel, R. (1998). *Computational Intelligence*. New York: Oxford University Press.
- PyTorch. (2020). Obtenido de <https://pytorch.org/>
- Ramirez, A. J. (2005). *Técnicas de diagnósticos de daños incipientes en rodamientos*. Punta Arenas, Chile: Universidad de Magallanes.
- Redman, T. C. (2 de 4 de 2018). *If Your Data Is Bad, Your Machine Learning Tools Are Useless*. Obtenido de Harvard Business Review: <https://hbr.org/2018/04/if-your-data-is-bad-your-machine-learning-tools-are-useless>

- Rich, E., & Knight, K. (1991). *Artificial Intelligence*. McGraw Hill Higher Education.
- Russell, S. J., & Norvig, P. (2008). *Inteligencia Artificial Un Enfoque Moderno*. Madrid, España: Pearson Educación S.A.
- Sánchez Loja, R. V. (2017). *Diagnóstico de fallos en cajas de engranajes mediante la aplicación de diferentes técnicas de inteligencia artificial*. Madrid, España: UNED Escuela de Doctorado.
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Elsevier*, 85-117.
- Shen, F., Chen, C., Yan, R., & Gao, R. X. (2015). Bearing Fault Diagnosis Based on SVD Feature Extraction and Transfer Learning Classification. *PHM*.
- SKF, U. I. (2015). *EM Efficient manufacturing*. Obtenido de <https://www.industr.com/en/the-true-cost-of-bearing-lubrication-695499>
- The Microsoft Cognitive Toolkit*. (22 de 01 de 2017). Obtenido de <https://docs.microsoft.com/en-us/cognitive-toolkit/>
- Theano*. (2017). Obtenido de <http://deeplearning.net/software/theano/>
- Villalonga Jalen, A., Castaño Romero, F., Matia, F., Beruvides López, G., & Haber, R. (2019). Monitorización del estado de rodamiento basada en técnicas de aprendizaje automático. *XL Jornadas de Automática*, 234-241.
- Wang, S., Xiang, J., Zhong, Y., & Zhou, Y. (2017). Convolutional neural network-based hidden Markov models for rolling element bearing fault identification. *Elsevier*, 1-12.
- Wen, L., Li, X., Gao, L., & Zhang, Y. (2017). A New Convolutional Neural Network Based Data-Driven Fault Diagnosis Method . *IEEE*.
- Widodo, A., & Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Sciencedirect*, 2560-2574.
- Winston, P. H. (1992). *Artificial Intelligence*. Pearson.
- Yang, B.-S., Lim, D.-S., & Chiow Tan, A. C. (2005). VIBEX: an expert system for vibration fault diagnosis of rotating machinery using decision tree and decision table. *Elsevier*, 735-742.
- Yang, T., Pen, H., Wang, Z., & Chang, C. (2016). Feature Knowledge Based Fault Detection of Induction Motors Through the Analysis of Stator Current Data. *IEEE*, 549-558.

- YanPing, Z., ShuHong, H., JingHong, H., Tao, S., & Wei, L. (2005). Continuous wavelet grey moment approach for vibration analysis of rotating machinery. *Elsevier*, 1202-1220.
- Yin, S., Li, X., Gao, H., & Kaynak, O. (2015). Data-Based Techniques Focused on Modern Industry: An Overview. *IEEE*, 657-667.
- Zhang, S., Zhang, S., Wang, B., & Habetler, T. G. (2019). Machine Learning and Deep Learning Algorithms for Bearing Fault Diagnostics: A Comprehensive Review. *IEEE-IAS*, 29857-29881.

## **7. ANEXO**

### **7.1 Anexo 1 Artículo Científico**

# Detección y Diagnóstico de Fallas en Rodamientos con Velocidad Variable Aplicando Aprendizaje Profundo



César Augusto Arias Cijanes

Universidad Internacional de la Rioja, Logroño (España)

Julio 23 de 2020

## RESUMEN

El presente trabajo tiene como propósito desarrollar un software para la detección y diagnóstico de fallas en rodamientos, aplicando Aprendizaje Profundo basado en una Red Neuronal Convolutiva sobre un Escalograma de Transformada Wavelet Continua de señales de vibración y Árbol de Decisión, el cual sirve de soporte al personal técnico para la toma de decisiones oportunas en escenarios operativos. Se resalta la combinación de métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación. Los resultados de la evaluación y predicción del modelo fueron satisfactorios cumpliendo con los objetivos planteados. Se evidencia la aplicación de técnicas de sistemas cognitivos artificiales para solucionar este tipo de problemas abriendo la puerta para el uso de teorías de transferencia de aprendizaje, extrapolando las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

## PALABRAS CLAVE

Aprendizaje Profundo, Aprendizaje Automático, Diagnóstico, Fallas, Red Neuronal Convolutiva, Transferencia de Aprendizaje

## I. INTRODUCCIÓN

Anticiparnos a la materialización de fallas en una máquina rotativa es de vital importancia para garantizar una operación confiable y segura de una instalación industrial. Detectar oportunamente potenciales anomalías en un equipo, minimiza el riesgo de pérdidas de lucro cesante, costos de reparación y afectación de seguridad de procesos como consecuencia de una falla. Estudios recientes cuantifican la afectación de daños de rodamientos entre USD \$25,000 y USD \$50,000 dólares por hora, en pérdida de productividad, costos de reparación y tiempo de inactividad. [17]

La mayoría de métodos de detección y diagnóstico de fallas de rodamientos fundamentan sus modelos a una determinada velocidad de rotación y no tienen la capacidad de cuantificar el daño en tiempo real, sin embargo en la realidad los equipos rotativos trabajan a velocidad variable. En este escenario operativo, la precisión de estos métodos de detección es baja y se necesitan ajustes complejos de sus parámetros.

Para dar respuesta a este problema, el presente trabajo de fin de master se desarrolla un software para la detección y diagnóstico de fallas en rodamientos de equipos

rotativos, aplicando Aprendizaje Profundo basado en una Red Neuronal Convolutiva sobre un Escalograma de Transformada Wavelet Continua y Árbol de Decisión, el cual sirve de soporte al personal técnico para la toma de decisiones oportunas en escenarios operativos. En esta propuesta innovadora se resalta la combinación de métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación, simulando condiciones de operación real añadiendo una mayor complejidad en la caracterización y clasificación de las averías. Los resultados de la evaluación y predicción del modelo fueron satisfactorios cumpliendo con los objetivos planteados.

## II. ESTADO DEL ARTE

El presente trabajo de fin de máster fundamenta su desarrollo en las técnicas actuales para la detección y diagnóstico inteligente de fallas, específicamente las basadas en redes neuronales convolucionales, como aporte el área de aprendizaje profundo en escenarios de big data y en diferentes condiciones funcionales de equipo rotativo; abriendo la puerta para el uso de teorías de transferencia de aprendizaje en donde se extrapolan

las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

Las técnicas de detección y diagnóstico inteligente de fallas hacen parte de las teorías de aprendizaje automático. Estas técnicas han sido ampliamente aplicadas en escenarios industriales, como herramientas analíticas que ayudan a mejorar las condiciones funcionales de los equipos rotativos, reconociendo de forma automática su estado operativo. Dichas técnicas han sido el objetivo de múltiples propuestas investigativas en las últimas tres décadas. [20]

En el pasado, las teorías tradicionales de aprendizaje automático aplicado al diagnóstico de condición de maquinaria, contribuyeron de forma significativa en la reducción de la intervención humana en esta tarea, trayendo la era de la inteligencia artificial. Las técnicas utilizadas en esta época fueron:

- Máquinas de Soporte Vectorial [5], [33]
- Redes Neuronales Artificiales. [29]
- Sistemas Expertos. [3], [35], [23].
- Árboles de decisión. [34]
- Modelo gráfico probabilístico. [18]
- Clasificadores Naive Bayes k-Nearest neighbour [24], [6].

En los últimos 10 años, las teorías de aprendizaje profundo han reforzado la asistencia artificial, lo que motiva la construcción de soluciones tecnológicas que involucren la relación entre grandes volúmenes de datos de monitoreo y la condición de los equipos. Las técnicas actualmente usadas en el diagnóstico inteligente de fallas son:

- Redes Neuronales Convolucionales [8].
- Red Neuronal Convolutiva AlexNet. [19]
- Red Neuronal Convolutiva Res Net [15]
- Red Neuronal Profunda Basada en Autoencoder [13]
- Red Neuronal Profunda Basada en Autoencoder Apilada [21]
- Red Neuronal Profunda de Creencia [4]
- Red Neuronal Profunda Generativa Adversaria [12]

En el futuro, las teorías de transferencia de aprendizaje propone utilizar el conocimiento de una o múltiples tareas del diagnóstico probadas en escenarios experimentales hacia escenarios productivos reales, superando de forma prospectiva las limitaciones de las aplicaciones investigativas. Las técnicas propuestas a utilizar son:

- Red Neuronal Profunda Generativa Adversaria Basada en Transferencia de Aprendizaje.[11]
- Transferencia de Aprendizaje Basado en clasificadores “Boosting”. [8]
- Transferencia de Aprendizaje Basado en Instancia [30]
- Transferencia de Aprendizaje Basado en Autoencoder de Eliminación de Ruido [25]
- Transferencia de Análisis de Componentes [28]
- Adaptación de Distribución Conjunta [26]
- Transferencia de Aprendizaje Profundo [25]

En la figura 1 se muestra la línea del tiempo de investigaciones sobre el diagnóstico inteligente de fallas utilizando machine learning. Se resaltan los trabajos de aprendizaje profundo.

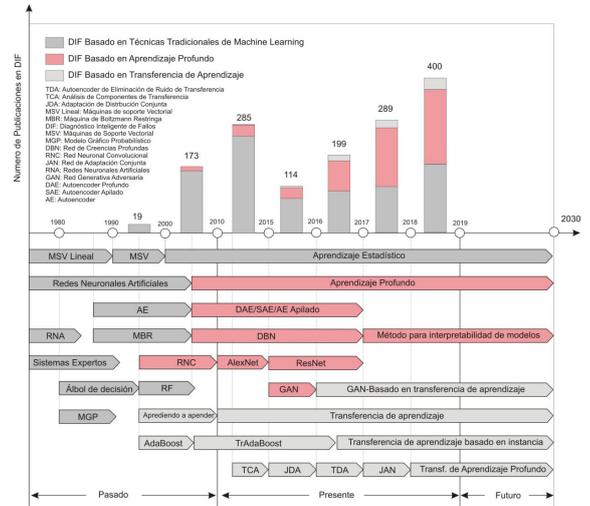


Figura 1. Historia de publicaciones para Diagnóstico Inteligente de Fallas utilizando técnicas de aprendizaje automático. [20]

A continuación se describen algunos trabajos científicos recientes aplicados al diagnóstico inteligente de fallas en equipos rotativos, utilizando métodos de aprendizaje profundo.

La oportunidad y precisión en la detección y el diagnóstico de fallas en sistemas industriales es importante para su desempeño confiable y seguro. En esta investigación, se estudia el rendimiento de un novedoso sistema de diagnóstico de fallas de rodamientos en tiempo real, el cual utiliza un clasificador de red neuronal convolutiva adaptativo compacto de una dimensión 1D. [9]

El diagnóstico de fallas es fundamental en sistemas industriales, ya que las detecciones tempranas sobre algún problema pueden ahorrar tiempo y costo. El aprendizaje profundo proporciona una forma efectiva de extraer automáticamente las características de los datos sin procesarlos; para ello se utilizan las redes neuronales convolucionales. En esta investigación, se propone una nueva red neuronal convolutiva basada en LeNet-5 para el diagnóstico de fallas, a través de un método que convierte señales en imágenes de 2 dimensiones (2D), el cual se prueba sobre tres conjuntos de datos de: cojinetes de motor, bomba centrífuga y bomba hidráulica de pistones axiales, alcanzando una precisión de predicción de 99.79%, 99.481% y 100% respectivamente. [32]

El diagnóstico de fallas es básico para garantizar la seguridad y el funcionamiento confiable de los equipos rotativos. En este estudio, se propone un nuevo método de diagnóstico que involucra el uso de una red neuronal convolutiva (CNN) para clasificar directamente del Escalograma de Transformada Wavelet Continuo (CWTS), que es una transformación de dominio frecuencia-tiempo de la señal original y contiene la mayor parte de la información de las señales de vibración. [12]

La red de creencias profundas (DBN) como un método de aprendizaje profundo utilizado para el diagnóstico de fallas. Este trabajo propone la unión de las técnicas de codificador automático apilado (SAE) y la máquina de Boltzmann restringida por Gauss-Binary (GBRBM) para el diagnóstico temprano de fallas en engranajes con señales de vibración sin procesar como entradas directas. [21]

Las condiciones de trabajo de los rodamientos suelen ser muy complejas, lo que hace difícil diagnosticar sus fallas. En este artículo, se estudia un novedoso método llamado red neuronal convolucional profundo adaptativo. Se propone la integración de una red neuronal convolucional unido con los métodos de optimización de partículas de enjambre y t-distribuida estocástica vecina embebida (t-SNE) para diagnosticar fallas de los rodamientos. Los resultados demuestran que es más efectivo y robusto que otros métodos inteligentes.[10]

El monitoreo inteligente de la condición funcional de los equipos rotativos y el diagnóstico de fallas son cada vez más importantes para la industria. En este artículo, se desarrolla un novedoso algoritmo para el diagnóstico de fallas de rodamientos basado en redes neuronales convolucionales profundas en conjunto con una teoría mejorada Dempster-Shafe. Las redes neuronales convolucionales toman como entrada los mapas de raíz media cuadrática (RMS) de las señales de vibración en el dominio de la frecuencia. La teoría D-S se implementa a través de la matriz de distancia de las evidencias y el índice modificado de Gini. El resultado muestra un mejor rendimiento de diagnóstico de fallas que los métodos existentes de aprendizaje automático.[22]

La mayoría de métodos de aprendizaje profundo para el diagnóstico de fallas de maquinaria rotativa tienen un buen rendimiento al procesar datos de rodamientos a una determinada velocidad de rotación. Sin embargo, la mayoría de los equipos rotativos en la realidad industrial tiene una velocidad de trabajo variable. Al procesar los datos del rodamiento con velocidad de rotación variable, los métodos existentes tienen una precisión baja o necesitan ajustes de parámetros complejos. Para resolver este problema, en este trabajo propone un método de diagnóstico de fallas basado en un Escalograma de Transformada Wavelet Continuo (CWTS) y la red neuronal convolucional de agrupación piramidal espacial de Pitágoras (PSPP-CNN). Según los resultados del experimento, este método tiene una precisión de diagnóstico más alta con velocidad de rotación variable con respecto a otros métodos. [12]

El aprendizaje no supervisado de características de datos de vibración es un gran desafío para el diagnóstico inteligente de fallas de los rodamientos. Este artículo, propone un método llamado Codificador Automático Wavelet Profundo (DWAE) con aprendizaje automático extremo (ELM) para el diagnóstico inteligente de fallas de los rodamientos. Los resultados confirman que el método propuesto es superior a los tradicionales y al estándar de aprendizaje profundo.[14]

Determinar las características óptimas bajo variaciones de velocidad de los rodamientos es una tarea difícil. Para abordar este problema, el artículo propone un diagnóstico de falla de rodamiento basado en análisis de emisión

acústica (AE) bajo fluctuaciones invariantes de las velocidades de rotación utilizando espectros envolventes (ES) y una red neuronal convolucional (CNN) para extraer automáticamente características de alta calidad y clasificar los defectos. Los resultados experimentales muestran que el método propuesto es efectivo en la detección de fallas en los rodamientos, proporciona una precisión de clasificación promedio de aproximadamente 86% bajo RPM variable.[2]

Un sistema electromecánico, los rodamientos son los componentes con mayor susceptibilidad a fallas debido a las condiciones de trabajo con altas velocidades y carga. En esta investigación, desarrolla un método de aprendizaje profundo basado en una red neuronal convolucional (CNN) y la teoría de la computación cognitiva para el diagnóstico de fallas. [27]

La detección automática y clasificación de fallas en los rodamientos es un tema importante para el monitoreo de los equipos rotativos. Este artículo, propone un método de clasificación de fallas basado en una red neuronal profunda con 3 capas ocultas y una arquitectura de codificación automática apilada. Aquí se estudia el rendimiento de la clasificación utilizando la red neuronal profunda y la propagación hacia atrás y los efectos sobre la precisión de la clasificación de la red neuronal profunda variando algunos parámetros. [11]

Las señales de vibración que generan los rodamientos en falla, generalmente presentan características no lineales y no estacionarias causadas por su entorno de trabajo. Es difícil desarrollar un método robusto para detectar fallas en rodamientos, basado en técnicas de procesamiento de señales. En este documento, se presentan un modelo de Markov oculto unido con una red neuronal convolucional (CNN –HMM) para clasificar múltiples fallas en un sistema mecánico. Los resultados de la clasificación confirman un rendimiento superior del modelo comparando con otros basados en: red neuronal convolucional puro, máquina de soporte vectorial (SVM) y una red neuronal de propagación inversa (BP). Se muestra una precisión promedio de clasificación de 98.125% y 98% para dos series de datos con reducciones aceptables de tasa de error. [31]

### III. OBJETIVOS Y METODOLOGÍA

**Objetivo general:** Diseñar y construir un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando una técnica de aprendizaje profundo basada una red neuronal convolucional.

**Objetivos específicos:**

- Seleccionar y organizar los datos experimentales a utilizar por el software de detección y diagnóstico inteligente de fallas de rodamientos.
- Extracción de los atributos de condición de los datos en el dominio del tiempo y del tiempo-frecuencia.
- Seleccionar las características de los datos y reducir sus atributos mediante el enfoque de aprendizaje no supervisado.
- Construir el algoritmo de detección y diagnóstico de fallas en rodamientos de equipos rotativos

industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional y análisis de severidad de daño.

- Validar los resultados del algoritmo para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional.
- Diseñar y desarrollar la interfaz gráfica de usuario del software para la detección y diagnóstico inteligente de fallas en rodamientos basado en el algoritmo de aprendizaje profundo.

**Metodología:**

El proceso metodológico para la realización de trabajo propuesto se muestra en la figura 2.

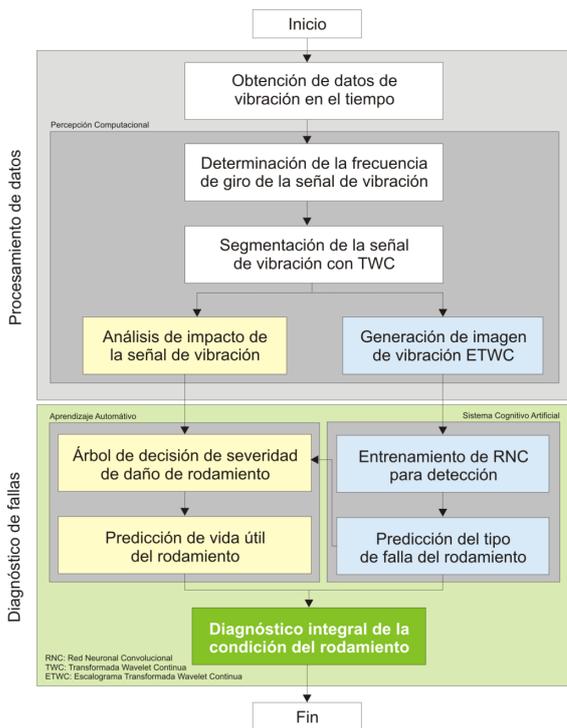


Figura 2. Flujograma de la metodología del trabajo propuesto.

**Obtención de datos en vibración en el tiempo:** Los datos utilizados en el desarrollo del presente trabajo fueron elegidos de [16], en donde fueron recopilados 18 millones de datos de vibración de rodamientos con diferentes condiciones de falla y velocidad variable en el tiempo. Las condiciones de falla del rodamiento incluyen saludable, defectuoso con daño en pista interna y daño en pista externa. Las señales fueron muestreadas a 200.000 Hz durante 10 segundos. Los datos de vibración fueron estandarizados en dataframes, en donde se construyeron 3 tablas en una base de datos y cada una de ellas contiene 6 columnas con la información de vibración y velocidad.

**Determinación de la frecuencia de corte y segmentación de señal de vibración:** Las frecuencias características de falla de los rodamientos están relacionadas con la velocidad de rotación. Para las señales de vibración seleccionadas para el presente trabajo de investigación se cuenta una frecuencia de

muestreo  $f(hz)$ , la velocidad de rotación ( $rpm$ ) de inicio y fin, tiempo de total de señal muestreada.

La determinación de la frecuencia de corte y segmentación de la señal toma en cuenta los siguientes pasos:

- h. Determinación del periodo de muestreo  $\Delta t$  en la ecuación (1):

$$\Delta t = \frac{1}{frecuencia\ de\ muestreo\ f(hz)} \quad (1)$$

- i. Cálculo de cantidad de datos "d" de la señal muestreada  $t = 10$  segundos en la ecuación (2):

$$d = \frac{t}{\Delta t} \quad (2)$$

- j. Determinación de la frecuencia central  $f_c$  requerida para una determinada escala "a" de la señal de Transformada Wavelet Continua en la ecuación (3):

$$f_c = \frac{a}{2} \quad (3)$$

- k. Cálculo de la frecuencia de rotación  $f_r$  se determina en la ecuación (4):

$$f_r = \frac{velocidad\ de\ rotación\ (rpm)}{60} \quad (4)$$

- l. La frecuencia de corte  $f_w$  está dada por la multiplicación de la frecuencia de corte  $f_c$  y la frecuencia de rotación  $f_r$  en la ecuación (5):

$$f_w = f_c * f_r \quad (5)$$

- m. Con la frecuencia de corte se calcula el tiempo de un ciclo de rotación  $t_r$  del rodamiento según la ecuación (6):

$$t_r = \frac{1}{f_w} \quad (6)$$

- n. Finalmente, se determina la cantidad de datos  $d_r$  contenido un ciclo de rotación  $t_r$  del rodamiento, relacionándolo con el periodo de muestreo  $\Delta t$  en la ecuación (7):

$$d_r = \frac{t_r}{\Delta t} \quad (7)$$

La Transformada Wavelet Continua (TWC) descompone la señal en el dominio de frecuencia-tiempo mediante el uso de una familia de funciones wavelet para obtener valores característicos. Luego, al analizar los coeficientes continuos de wavelets o usar el algoritmo de clasificación, se obtiene información las características que identifican una determinada condición de la señal.

Las ecuaciones (8) y (9) describe la teoría de la Transformada Wavelet Continua:

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R} \quad a \neq 0 \quad (8)$$

$$C_a(k) = \int x(t) \bar{\psi}_{a,b}(t) dt \quad (9)$$

Donde  $\psi_{a,b}$  es una función wavelet cuya forma y desplazamiento están determinados por el parámetro de escala “a” y el parámetro de posición “b”.  $C_a(k)$  es el coeficiente wavelet de  $x(t)$  en la evaluación de la escala “a”;  $k$  es el tiempo y  $\bar{\psi}_{a,b}(t)$  es el completo conjugado de función wavelet.

Las funciones de Transformada Wavelet Continua más comunes son: Sombrero Mexicano, Morlet y Gaussiano. Para el presente trabajo se escoge la wavelet Morlet debido a que tiene la relación de entropía de energía Shannon más alta que las demás familias wavelet, el cual mide el desempeño de las mismas.

A continuación en las figuras 3a, 3b y 3c se muestran las formas de onda de estas señales.

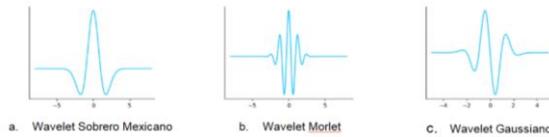


Figura 3. Formas de onda de wavelet madre Sombrero Mexicano, Morlet y Gaussiano.

El Escalograma es el valor absoluto de la Transformada Wavelet Continua (CWT) de una señal, trazada en función del tiempo y la frecuencia. El escalograma es útil para analizar señales con características que ocurren a diferentes escalas y cuando se requiere la localización del tiempo de eventos de corta duración y alta frecuencia como también de eventos de baja frecuencia y mayor duración.

El segmento recortado del Escalograma de la Transformada Wavelet Continua (ETWC) contiene todas las frecuencias características necesarias para el análisis de falla de los rodamientos. Estos segmentos se determinan a diferentes velocidades de rotación, los cuales tienen mismo rango de tiempo, con el fin de identificar las características de falla para un mismo daño, las cuales aparecen en una posición similar en el Escalograma de la Transformada Wavelet Continua. Por lo tanto, la clasificación de la Red Neuronal Convolutiva podrá tener un resultado preciso.

En la figura 4 se muestra la representación de la señal de vibración completa y su segmentación.

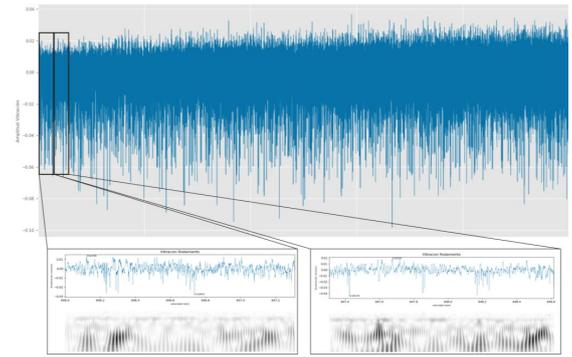


Figura 4. Señal de vibración completa y su segmentación.

**Predicción del tipo de falla del rodamiento con una red neuronal convolutiva profunda:** La extracción de características y la fase de clasificación para la detección de falla de rodamiento se combinan en una sola etapa de aprendizaje en la Red Neuronal Convolutiva, la cual trabaja directamente sobre los datos sin procesar, para detectar las anomalías. Los datos de vibración en el dominio del tiempo mapeados en el Escalograma de la Transformada Wavelet Continua se introducen directamente en el Red Neuronal Convolutiva.

Para la construcción de la red neuronal convolutiva, en el presente trabajo de fin de master se aplica el concepto de transferencia de aprendizaje o “Transfer Learning”, adaptando el modelo de aprendizaje profundo VGG16 de keras para realizar la predicción. Con este concepto se usa este modelo con capas pre-entrenadas, las cuales pueden reconocer bordes y sombras y se agregan tres capas densas para la activación y clasificación de las imágenes, las cuales reconocen patrones y estructuras complejas.

La arquitectura de la red neuronal convolutiva VGG16 posee 5 bloques de capas convolutivas y maxpooling: Los primeros dos bloques tienen dos capas convolutivas y los tres siguientes bloques tienen tres capas convolutivas. Al final tiene tres capas densas para la activación, flatterring y la capa de clasificación softmax basada en el perceptron multicapa. En la figura 5 se muestra la arquitectura de la red neuronal convolutiva propuesta.

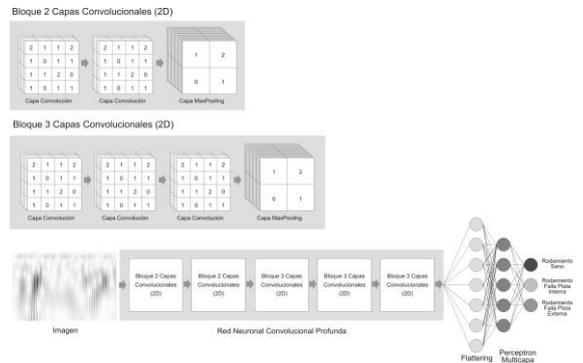


Figura 5. Arquitectura de la red neuronal convolutiva para la detección del estado funcional de rodamientos.

**Análisis de impacto señal de vibración:** En esta etapa se identifica el pico más alto en amplitud positiva de cada señal de vibración, con el fin de analizar el impacto que tiene los elementos internos del rodamiento según su estado funcional. En este ejercicio se identifica el nivel de vibración que presenta cada rodamiento con el objetivo de generar las reglas a utilizar en el árbol de decisión.

**Cuantificación de la vida útil del rodamiento:** Para este cálculo se toma como base la ecuación (10)

$$L_{10h} = \frac{10^6}{60 * n} \left( \frac{C}{P} \right)^p \quad (10)$$

El valor de la carga dinámica equivalente "P" se calcula partir de masa del eje, el cual ejerce una carga hipotética de 5,9 kN y se asume como factor axial el nivel de vibración "V<sub>a</sub>" que presenta cada rodamiento, el cual multiplica a dicha carga.

Considerando que los valores típicos de factores axiales que ejercen fuerza en la carga dinámica equivalente, según tablas de fabricantes, son mayores a 1, se asigna un coeficiente multiplicador "k" que amplifica el nivel de vibración "V<sub>a</sub>", el cual varía según el tipo de falla presente en el rodamiento.

Tomando los parámetros del rodamiento del estudio y las consideraciones anteriores se reformula la ecuación de la vida útil del rodamiento, la cual depende del impacto de la vibración "V<sub>a</sub>", coeficiente multiplicador "k" y la velocidad "n" a que es sometido, tal como se muestra en la ecuación (11):

$$L_{10h} = \frac{10^6}{60 * n} \left( \frac{14.0119}{5.9 * V_a * k} \right)^3 \quad (11)$$

**Árbol de decisión de severidad del daño:** Para asignar el valor del coeficiente multiplicador "k" del impacto de vibración, se plantea un árbol de decisión sencillo, teniendo en cuenta el tipo de estado funcional del rodamiento "Sano", "Falla en Pista Interna" o "Falla en Pista Externa" predicho por la red neuronal convolucional y utilizando una reglas de decisión con base a este. Por lo tanto si la condición del rodamiento es sano se asigna un valor de k = 40, si la condición del rodamiento es falla en pista interna se asigna un valor de k = 10 y si la condición del rodamiento es falla en pista externa se asigna un valor de k = 50. Estos valores fueron determinados de acuerdo al análisis estadístico de los niveles de vibración de cada señal.

El árbol de decisión se obtiene por medio de la representación en un espacio unidimensional en donde se recibe como entrada el tipo de falla detectado. El algoritmo elige primero para evaluación la variable "rodamiento sano" y a continuación, los ejemplos de entrenamiento se dividen en dos grupos más para evaluar el tipo de fallo. El algoritmo continúa dividiendo los nodos con la elección según la variable de entrada en cada iteración hasta que se alcance el criterio de parada establecido como: el árbol ha alcanzado un tamaño predefinido. En cada iteración el algoritmo elige aquella variable que mejor predice la variable objeto. En la figura 6 se muestra el árbol de decisión de para asignación de valores de k.

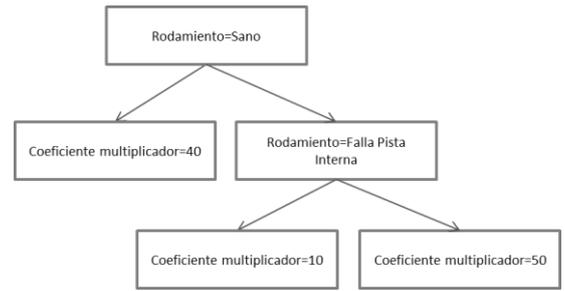


Figura 6. Árbol de decisión para asignar el coeficiente multiplicador para determinar la severidad de daño.

**Diagnóstico Integral de la condición del rodamiento:** Se determina mediante la unión de la predicción de la vida útil del rodamiento con la predicción del tipo de falla del rodamiento por medio de la red neuronal convolucional, de esta manera se tiene el estado funcional completo del rodamiento, el cual es publicado en la interfaz gráfica diseñada para este fin.

Este módulo integra los módulos predictivos, permite la conexión de la base de datos, la selección de la señal de vibración, monitoriza continuamente las señales y publica información sobre la detección y diagnóstico de la condición integral del rodamiento. Su desarrollo, al igual que los demás, fue realizado en Python y la interfaz gráfica fue construida en Tkinter.

En la figura 7 se muestran las partes que compone el sistema desarrollado, las cuales son:

- **Barra de menú:** en esta sección se encuentran las pestañas de base de datos, detección & diagnóstico y Ayuda.
- **Barra de información del rodamiento:** en esta área se muestra la información técnica del rodamiento utilizado en la investigación.
- **Árbol de señales:** en esta área se disponen las señales de vibración según el estado funcional del rodamiento, las cuales pueden ser seleccionadas para análisis y evaluación.
- **Sección de monitoreo de señales:** esta área se divide en el monitoreo de los valores de vibración y velocidad; en la parte inferior se visualiza la señal cruda de vibración y su respectivo Escalograma de la Transformada Wavelet Continua.
- **Área de información y advertencias:** en esta sección se publica el estado funcional del rodamiento y la severidad de daño.

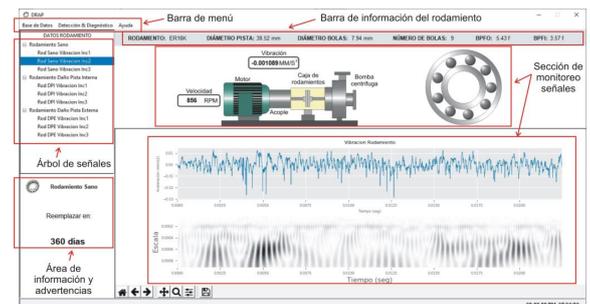


Figura 7. Interfaz gráfica del software de detección y diagnóstico de fallas en rodamientos con velocidad variables aplicando aprendizaje profundo.

IV. CONTRIBUCIÓN

El sistema desarrollado constituye una propuesta innovadora, en donde se combinaron métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación, simulando condiciones de operación real añadiendo una mayor complejidad en la caracterización y clasificación de las averías.

El sistema desarrollado está compuesto de varios módulos programados en Python, los cuales interactúan entre sí para el análisis de la señal de vibración y el posterior diagnóstico integral de la condición del rodamiento. La arquitectura de software desarrollado se muestra en la figura 8.

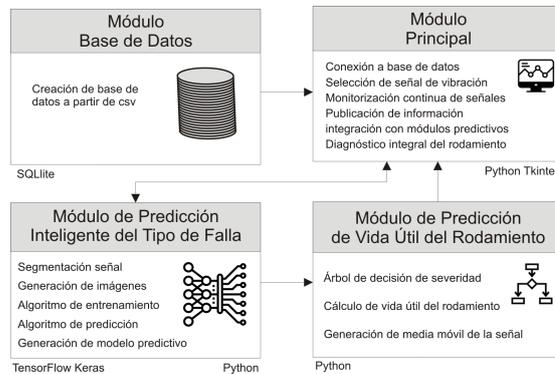


Figura 8. Arquitectura del software de detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo.

Tener un diagnóstico integral de la condición del rodamiento que prediga la vida útil del rodamiento proporciona una funcionalidad muy importante para toma de decisiones por parte del personal técnico, debido a que permite tener un reemplazo de esta parte de forma programada sin afectar la productividad del equipo ni incurrir en costos adicionales de mantenimiento.

Con la aplicación de técnicas de sistemas cognitivos artificiales para solucionar este tipo de problemas se abre la puerta para el uso de teorías de transferencia de aprendizaje, extrapolando las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

V. EVALUACIÓN Y RESULTADOS

Para la evaluación del desempeño del sistema desarrollado se realizan pruebas con tres señales de vibración que contienen las condiciones, las cuales son: rodamiento sano, falla en pista en interna y falla en pista externa. Las características de la señal se muestran en la tabla 1.

	Tiempo total de la señal (Seg)	Velocidad inicial de la señal (rpm)	Velocidad final de la señal (rpm)
Rodamiento Sano	10	912	1602
Rodamiento con Falla en Pista Interna	10	810	1710
Rodamiento con Falla en Pista Externa	10	798	1578

Tabla 1. Características de las señales utilizadas para la evaluación del sistema desarrollado

En la evaluación se realizaron 20 pruebas para cada señal, lo cual se completaron 60 en total. En el desempeño del sistema desarrollado se logró una exactitud del 96,67%, debido a que se obtuvieron 58 diagnósticos de la condición acertados y 2 incorrectos. En todas las pruebas se obtuvieron predicciones de severidad del daño.

En la figura 9 se muestran las estadísticas de las pruebas realizadas con el sistema desarrollado

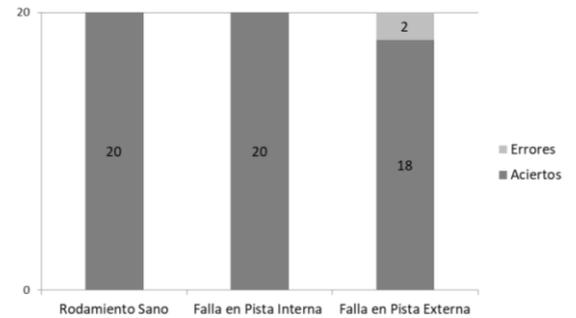


Figura 9. Estadísticas de pruebas realizadas con el sistema desarrollado para detección y diagnóstico de fallas en rodamientos con velocidad variable aplicando aprendizaje profundo.

Se observa que los dos errores fueron visibles en la señal de falla en pista externa, lo cual abre la posibilidad de realizar un ajuste en los parámetros de entrenamiento del modelo de la red neuronal convolucional profunda con el fin de alcanzar mejoras en la exactitud de la predicción.

En las figuras 10, 11 y 12 se muestran los pantallazos del sistema desarrollado con diagnóstico integral de las condiciones sano, falla en pista interna y falla en pista externa del rodamiento.

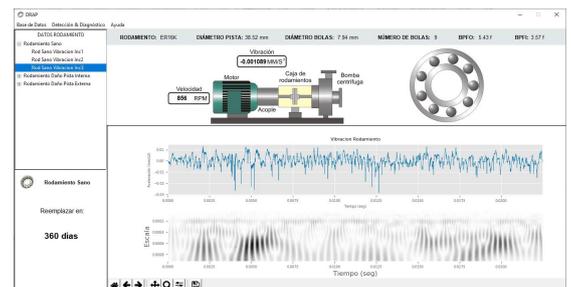


Figura 10. Pantallazo del sistema desarrollado con

diagnóstico integral de la condición Sano del rodamiento.

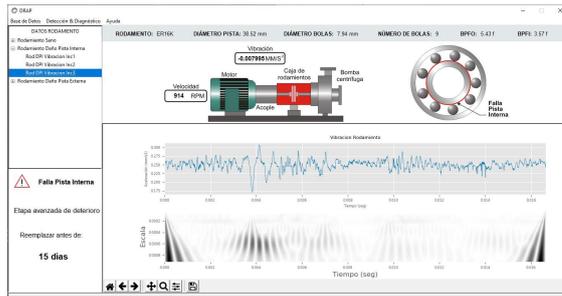


Figura 11. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Falla en Pista Interna del rodamiento.



Figura 12. Pantallazo del sistema desarrollado con diagnóstico integral de la condición Falla en Pista Externa del rodamiento.

## VI. DISCUSIÓN

Se plantea un ajuste en los parámetros de entrenamiento del modelo de la red neuronal convolucional profunda con el fin de alcanzar mejoras en la exactitud de la predicción.

## VII. CONCLUSIONES

El problema planteado en este trabajo de fin de master aborda la necesidad de desarrollar un sistema que apoye a la toma de decisiones del personal técnico y operativo involucrado en procesos industriales que utilizan equipos rotativos. La solución planteada cumple con los objetivos propuestos diseñando y construyendo un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando una técnica de aprendizaje profundo basada una red neuronal convolucional.

En esta propuesta innovadora se combinaron métodos de percepción computacional, sistemas cognitivos artificiales y aprendizaje automático para detectar fallas y severidad de daño de un rodamiento, bajo diferentes escenarios de velocidad de rotación, simulando condiciones de operación real añadiendo una mayor complejidad en la caracterización y clasificación de las averías.

Los datos experimentales fueron seleccionados y organizados para la construcción del software de detección y diagnóstico inteligente de fallas de rodamientos y validación de resultados.

La extracción de los atributos de condición de los datos en el dominio del tiempo y del tiempo-frecuencia fueron determinados mediante la segmentación de la señal según la frecuencia de rotación y utilizando el método de la Transformada Wavelet Continua.

Las características de los datos y la reducción de sus atributos fueron estandarizados mediante la generación de imágenes con el método del Escalograma de la Transformada Wavelet Continua, lo cual permitió el análisis de las señales de vibración del rodamiento con un enfoque de aprendizaje no supervisado.

Se construyó un algoritmo para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional y análisis de severidad de daño.

Se diseñó y desarrolló una interfaz gráfica de usuario del software para la detección y diagnóstico inteligente de fallas en rodamientos basado en el algoritmo de aprendizaje profundo, el cual permite una conexión con la base de datos, monitorización continua de la velocidad de rotación y el nivel de vibración del rodamiento, visualización de la información de estado funcional con sus respectivas alarmas sobre tipo de falla y la vida útil, considerado este como un diagnóstico integral de la condición del rodamiento.

Los resultados obtenidos de la validación del algoritmo para la detección y diagnóstico de fallas en rodamientos de equipos rotativos industriales aplicando la técnica de aprendizaje profundo basado en una red neuronal convolucional fueron satisfactorios, detectando los diferentes estados funcionales de rodamiento sano, en falla en pista interna y falla en pista externa con sus respectivo cálculo de vida útil.

Se logra establecer que los rodamientos en falla presenta una disminución considerable de su vida útil con respecto al rodamiento sano; evolucionando su deterioro la condición incremental de la velocidad.

La red neuronal convolucional logra identificar las fallas con una exactitud del 96,67%, al clasificar las imágenes de la señal de vibración según condición funcional a diferentes velocidades de rotación. Esto denota la gran aplicabilidad de este método de inteligencia artificial en problemas industriales condiciones reales de operación.

La aplicación de técnicas de sistemas cognitivos artificiales es relevante para solucionar este tipo de problemas debido a la alta capacidad de identificación de características y clasificación que poseen, además abre la puerta para el uso de teorías de transferencia de aprendizaje en donde se extrapolan las soluciones propuestas con datos experimentales a problemas similares presentes en escenario industriales.

Este desarrollo puede evolucionar hacia la identificación de fallas de acuerdo a condiciones operativas, de almacenamiento o mantenimiento encontrando la causa raíz como deficiente lubricación o exceso de carga del rodamiento.

## REFERENCIAS

- [1]
- [2] Ahmed, H. A., Dennis Wong, M. L., & Nandi, A. K. (2016). Effects of Neural Network Parameters on Classification of Bearing Faults. *IEEE Industrial Electronics Society*.
- [3] Appana, D. K., Prosvirin, A., & Kim, J.-M. (2018). Reliable fault diagnosis of bearings with varying rotational speeds using envelope spectrum and convolution neural networks. *Soft Computing*.
- [4] Arias Cijanes, C. A., Aranguren Zambrano, S., & Tarantino Alvarado, R. (2012). Diseño de una Estrategia de Control Tolerante a Fallos Basado en Conocimiento aplicado a un Lazo de Control de Nivel Industrial. *Revista Colombiana de Tecnologías de Avanzada*, 128-135.
- [5] Chen, Z., & Li, W. (2017). Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder Diagnosis Using Sparse Autoencoder. *IEEE*, 1693-1702.
- [6] Cortes, C., & Vapnik, V. (1995). *Support-Vector Network*. Kluwer Academic Publishers, Boston, 273-297.
- [7] Cover, T. M., & Hart, P. E. (1967). Nearest Neighbor Pattern Classification. *IEEE Transaction on Information Theory*, 21-27.
- [8] Dai, W., Yang, Q., Xue, G.-R., & Yu, Y. (2007). Boosting for Transfer Learning. *ICML*, 193-200.
- [9] Duan, L., Xie, M., Wang, J., & Bai, T. (2018). Deep learning enabled intelligent fault diagnosis: Overview and applications. *Journal of Intelligent & Fuzzy System*.
- [10] Eren, L., Ince, T., & Kiranyaz, S. (2018). A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN Classifier. *Journal of Signal Processing Systems*.
- [11] Fuan, W., Hongkai, J., Haidong, S., Wenjing, D., & Shuaipeng, W. (2017). An adaptive deep convolutional neural network for rolling bearing fault diagnosis. *IOPScience*.
- [12] Guo, L., Lei, Y., Xing, S., Yan, T., & Li, N. (2018). Deep Convolutional Transfer Learning Network: A New Method for Intelligent Fault Diagnosis of Machines with Unlabeled Data. *IEEE*.
- [13] Guo, S., Yang, T., Gao, W., & Zhang, C. (2018). A Novel Fault Diagnosis Method for Rotating Machinery Based on a Convolutional Neural Network. *Sensor MDPI*.
- [14] Haidong, S., Hongkai, J., Ke, Z., Dongdong, W., & Xingqiu, L. (2018). A novel tracking deep wavelet auto-encoder method for intelligent fault diagnosis of electric locomotive bearings. *Elsevier*, 193-209.
- [15] Haidong, S., Hongkai, J., Xingqiu, L., & Shuaipeng, W. (2017). Intelligent Fault Diagnosis of Rolling Bearing Using Deep Wavelet Auto-encoder with Extreme Learning Machine. *Knowledge-Based Systems*.
- [16] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Xplore CVPR*.
- [17] Huang, H., & Baddour, N. (2018). Bearing vibration data collected under time-varying rotational speed conditions. *Elsevier*, 1745-1749.
- [18] IBT Industrial Solution. (3 de Julio de 2018). PrimeMOVER Industry News. Obtenido de <https://www.ibtinc.com/causes-of-bearing-failure/>
- [19] Koller, D., & Friedman, N. (2010). *Probabilistic Graphical Models*. London: Mit press.
- [20] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). *ImageNet Classification with Deep Convolutional Neural Networks*. *Communications of the ACM*, 84-90.
- [21] Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., & Nandi, A. K. (2019). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Elsevier*, 138.
- [22] Li, J., Li, X., He, D., & Qu, Y. (2019). A Novel Method for Early Gear Pitting Fault Diagnosis Using Stacked SAE and GBRBM. *mdpi*.
- [23] Li, S., Liu, G., Tang, X., Lu, J., & Hu, J. (2017). An Ensemble Deep Convolutional Neural Network Model with Improved D-S Evidence Fusion for Bearing Fault Diagnosis. *Sensor MDPI*.
- [24] Liao, S.-H. (2005). Expert system methodologies and applications—a decade review from 1995 to 2004. *Elsevier*, 93-103.
- [25] Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Elsevier*, 33-47.
- [26] Long, M., Wang, J., Cao, Y., Sun, J., & Yu, P. S. (2016). Deep Learning of Transferable Representation for Scalable Domain Adaptation. *IEEE*, 2027-2040.
- [27] Long, M., Zhu, H., Wang, J., & Jordan, M. I. (2017). Deep transfer learning with joint adaptation networks. *Proceedings of the 34 th International Conference on Machine*.
- [28] Pan, S. J., Tsang, I. W., Kwok, J. T., & Yang, Q. (2011). Domain Adaptation via Transfer Component Analysis. *IEEE*, 199-210.
- [29] Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Elsevier*, 85-117.
- [30] Shen, F., Chen, C., Yan, R., & Gao, R. X. (2015). Bearing Fault Diagnosis Based on SVD Feature Extraction and Transfer Learning Classification. *PHM*.
- [31] Wang, S., Xiang, J., Zhong, Y., & Zhou, Y. (2017). Convolutional neural network-based hidden Markov models for rolling element bearing fault identification. *Elservier*, 1-12.
- [32] Wen, L., Li, X., Gao, L., & Zhang, Y. (2017). A New Convolutional Neural Network Based Data-Driven Fault Diagnosis Method. *IEEE*.
- [33] Widodo, A., & Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Sciencedirect*, 2560-2574.
- [34] Yang, B.-S., Lim, D.-S., & Chiow Tan, A. C. (2005). VIBEX: an expert system for vibration fault diagnosis of rotating machinery using decision tree and decision table. *Elsevier*, 735-742.
- [35] Yang, T., Pen, H., Wang, Z., & Chang, C. (2016). Feature Knowledge Based Fault Detection of Induction Motors Through the Analysis of Stator Current Data. *IEEE*, 549-558.