

“Desarrollo de un Sistema de Diagnóstico de Fallas en Motores de Inducción Orientado a Sistemas de Supervisión Industrial, Utilizando Algoritmos de Inteligencia Artificial”

Juan Francisco Torres Pérez

2026

Requisito parcial para obtener el título de:
Ingeniero Civil Electricista

Profesor Guía:
Dr. Johnny Wladimir Rengifo Santana

Comisión:
Dr. Antonio Alejandro Sánchez Squella
Dr. Eduardo Andrés Salamanca Henríquez

Santiago, 2026.



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título Tesis de Postgrado

Título del trabajo: “Desarrollo de un Sistema de Diagnóstico de Fallas en Motores de Inducción Orientado a Sistemas de Supervisión Industrial, Utilizando Algoritmos de Inteligencia Artificial”.

Nombre del candidato(a): Juan Francisco Torres Pérez

Carrera / Grado: Ingeniería Civil Eléctrica / Ingeniero Civil Electricista

Campus: Santiago, San Joaquín.

Departamento: Departamento de Ingeniería Eléctrica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Johnny Wladimir Rengifo Santana, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

6 meses 12 meses 2 años 3 años 5 años 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 29/05/2026


Firma: _____

Estudiante o Candidato(a):

Fecha: 29/05/2026

Firma: _____

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



“Desarrollo de un Sistema de Diagnóstico
de Fallas en Motores de Inducción
Orientado a Sistemas de Supervisión
Industrial, Utilizando Algoritmos de
Inteligencia Artificial”

Juan Francisco Torres Pérez

2026

*“No llores más, dame la mano contame tu suerte. De esta manera quizá no sea la
muerte la que nos logre apagar el dolor.”*
— *Gustavo Napoli*

Agradecimientos

Sobre hombros de gigantes...

Con la libertad que me otorga esta página, en contraste con la formalidad y rigor técnico del presente documento, quisiera manifestar mi gratitud hacia aquellos faros que tuve la fortuna de tener a lo largo de mi odisea por esta institución.

Con inmenso aprecio y admiración, comienzo por mi madre, la cual me enseñó desde la infancia el luchar por la seguridad y felicidad de las personas que uno ama, el cómo enfrentar la adversidad y siempre buscar una mejor versión de sí mismo. En este sentido, quiero darle las gracias a toda mi familia, ya que la búsqueda de su bienestar ha sido siempre uno de mis principales objetivos. Espero algún día llegar a retribuir todo el apoyo, comprensión y amor que me han dado desde el día que nací.

Quiero darle las gracias a mi amor, Damaris, por ser la persona por la cual todo este camino tiene sentido. Por darme la fuerza necesaria para levantarme luego de cada caída, ser aquello por lo que vale la pena mi lucha. Nuestro pasado, presente y futuro han sido los pensamientos con los cuales he sobrellevado las mayores adversidades y, por lo mismo, mis esfuerzos en la vida siempre van a estar orientados hacia su felicidad.

A aquellas personas que acompañaron mi camino en los momentos académicamente más duros, agradezco a todos los amigos que formé en esta institución. Gracias Eduardo, Diego, Alexis, Carlos, Zarko, Pablo, Cristian, Romanet, Víctor, Paula, Bastián P., Felipe, Bastián C. y Valentina. Todos guardan un espacio en mi corazón, estuvieron conmigo desde aquel niño ingenuo que entró con muchos sueños a esta carrera, hasta el hombre que he forjado en el presente. Siempre tendrán en mí a un amigo con el cual puedan contar. En conjunto con todo lo anterior, quiero mencionar especialmente a mi amigo Luis, junto al cual transité codo con codo gran parte de este camino. En mi memoria quedarán aquellas tardes enteras conversando, aquellas miradas cómplices cada vez que se asignaba un trabajo en parejas, las manos negras de tanto borrar pizarras y la idea constantemente reafirmada de presenciar los albores de un magno profesional.

Dentro de mi senda académica, la frase que da comienzo a este manifiesto emotivo no podría ser mejor aplicada que sobre mis principales guías dentro de este recorrido. En primer lugar, a mi profesor Pablo Jimenez, el cual no solo me inculcó en mí la curiosidad entusiasta sobre los fenómenos electromagnéticos, sino que con esto pavimentó el camino que me llevó a ser lo que soy hoy en día. En esta última etapa es que destaco al profesor Johnny Rengifo, el cual fue uno de mis más grandes apoyos dentro de este tramo. En mí siempre habrá un profundo agradecimiento hacia toda la paciencia, dedicación y ánimos que me otorgó. Cada vez que puse un pie fuera de su oficina me encontré en un mejor estado del cual entré.

Finalizo agradeciendo a dios, por ser la esperanza, la estrella de mi camino. Por darme la fuerza para cumplir mi voluntad.

Índice de contenidos

| | |
|---|------------|
| Índice de contenidos | I |
| Índice de figuras | III |
| Índice de tablas | V |
| Resumen | 1 |
| 1. Introducción | 3 |
| 2. Modos de falla en motores de inducción | 9 |
| 2.1. Antecedentes y selección de modos a analizar | 9 |
| 2.2. Daño en sistema de rodamientos | 11 |
| 2.3. Cortocircuito en devanados del estator | 14 |
| 2.4. Influencia cruzada de fallas en variables operativas | 17 |
| 3. Herramientas de tratamiento de datos | 20 |
| 3.1. Estrategias de aumento de datos | 21 |
| 3.2. Vector de Clarke de corriente eléctrica | 23 |
| 3.3. Análisis tiempo-frecuencia | 24 |
| 3.3.1. Transformada de Stockwell | 25 |
| 3.4. Conversión tensorial de espectrogramas | 27 |
| 4. Algoritmos de inteligencia artificial | 29 |
| 4.1. Antecedentes | 29 |
| 4.2. Arquitecturas de aprendizaje profundo | 30 |
| 4.2.1. Redes neuronales totalmente conectadas y funciones de activación | 30 |
| 4.2.2. Redes neuronales convolucionales | 33 |
| 4.2.3. Redes neuronales recurrentes | 35 |
| 4.3. Algoritmo de optimización de hiperparámetros | 38 |
| 4.4. Indicadores de desempeño en algoritmos de clasificación | 39 |
| 4.4.1. Matriz de confusión | 39 |
| 4.4.2. Indicadores de desempeño | 40 |
| 5. Bases de datos | 43 |
| 5.1. Base de datos de la Universidad Técnica Federico Santa María | 44 |
| 5.1.1. Montaje experimental | 44 |
| 5.1.2. Instrumentación y adquisición de mediciones | 46 |
| 5.1.3. Tipos de fallas inducidas | 46 |

| | |
|---|-----------|
| 5.1.3.a. Falla en elemento rodante | 46 |
| 5.1.3.b. Falla por cortocircuito entre espiras | 48 |
| 5.1.4. Condiciones de operación analizadas | 49 |
| 5.1.4.a. Grados de carga | 50 |
| 5.1.4.b. Tipo de alimentación del motor | 50 |
| 5.1.4.c. Severidad de fallas inducidas | 51 |
| 5.2. Base de datos de la <i>Case Western Reserve University</i> | 52 |
| 5.2.1. Montaje experimental | 52 |
| 5.2.2. Adquisición de mediciones | 53 |
| 5.2.3. Tipos de fallas inducidas | 54 |
| 5.2.4. Condiciones de operación analizadas | 55 |
| 5.3. Base de datos de la <i>Korean Advanced Institute of Science & Technology</i> | 56 |
| 5.3.1. Montaje experimental | 56 |
| 5.3.2. Adquisición de mediciones | 57 |
| 5.3.3. Tipos de fallas inducidas | 57 |
| 5.3.4. Condiciones de operación analizadas | 59 |
| 6. Metodología | 60 |
| 6.1. Esquema general del sistema de diagnóstico | 60 |
| 6.2. Tratamiento de datos | 62 |
| 6.2.1. Aplicación de estrategia de aumento de datos | 62 |
| 6.2.2. Procedimiento de generación de espectrogramas | 63 |
| 6.2.3. Creación de base de datos para el entrenamiento y validación del modelo | 65 |
| 6.3. Arquitectura del modelo desarrollado | 66 |
| 6.3.1. Módulo convolucional | 66 |
| 6.3.2. Módulo LSTM | 69 |
| 6.3.3. Módulo FC | 70 |
| 6.4. Procesos de entrenamiento y validación | 71 |
| 7. Resultados y análisis | 74 |
| 8. Conclusiones | 80 |

Índice de figuras

| | | |
|------|--|----|
| 2.1. | Diagramas representativos de la (a) estructura general de un rodamiento de bolas, junto con la (b) distribución geométrica de sus componentes. Adaptado de [21] y [22] respectivamente. | 12 |
| 2.2. | Ejemplos de consecuencias de mecanismos de degradación en elementos de un sistema de rodamientos [24]. Entre ellos, (a) escamado en pista interna y (b) fractura por fatiga mecánica en jaula. | 12 |
| 2.3. | Ejemplo de aumento progresivo del escamado en una pista de un rodamiento. El nivel de deterioro aumenta de izquierda a derecha [24]. | 13 |
| 2.4. | Ilustración del fenómeno vibratorio provocado por una grieta en la pista externa de un sistema de rodamientos. Adaptado de [25]. | 13 |
| 2.5. | Proceso de devanado de un motor eléctrico. Se distingue el (a) núcleo y los (b) devanados insertos en sus ranuras dentro del estator [29]. | 15 |
| 2.6. | Diagrama representativo de los tipos de aislamientos en una bobina con perspectiva en un corte de su sección transversal. Adaptado de [30]. | 15 |
| 2.7. | Fallas por cortocircuito entre espiras de (a) menor [31] y (b) mayor severidad [19]. En este último caso, derivando a un cortocircuito fase-tierra. Notar que las bobinas superiores fueron removidas para exponer la falla en las inferiores. | 16 |
| 3.1. | Representación estructural de la aplicación de la transformada RGB sobre una imagen de entrada. | 28 |
| 4.1. | Diagrama de una red neuronal totalmente conectada con una capa oculta. | 32 |
| 4.2. | Esquema secuencial de la operación de convolución entre una matriz de 4x4 (entrada) y un kernel de 2x2, creando una matriz de salida de 3x3. Adaptado de [48]. | 34 |
| 4.3. | Esquema operativo de una red LSTM en un instante t . Adaptado de [13]. | 38 |
| 4.4. | Matriz de confusión ilustrativa. | 40 |
| 5.1. | Montaje implementado para la recolección de datos experimentales (UTFSM). | 44 |
| 5.2. | Acople flexible Rexnord Omega modelo ES10-R utilizado en el banco de pruebas para la conexión motor-generador. | 45 |
| 5.3. | (a) Rodamiento Craft 1207 EF-J31, junto con su (b) esquema geométrico de referencia. | 47 |
| 5.4. | Rodamientos Craft 1207 EF-J31 sometidos a una perforación de un elemento rodante de (a) 0,3mm y (b) de 0,5mm. | 48 |

| | | |
|------|--|----|
| 5.5. | (a) Esquema de conexión del devanado de estator de la fase U con <i>taps</i> accesibles para la inducción controlada de fallas de cortocircuito entre espiras (esquema similar para las otras fases, junto con una vista (b) superior y (c) lateral de la aplicación de esta modificación constructiva en el MI ensayado). | 49 |
| 5.6. | Montaje implementado para la recolección de datos experimentales (CW-RU). Adaptado de [55]. | 52 |
| 5.7. | (a) Rodamiento SKF 6205 2RSJEM (imagen ilustrativa mostrada en la página web del fabricante [56]), junto con su (b) esquema geométrico de referencia. | 54 |
| 5.8. | Montaje implementado para la recolección de datos experimentales (KAIST). Adaptado de [57]. | 56 |
| 5.9. | (a) Rodamiento NSK 6205 DDU (imagen ilustrativa mostrada en la página web del fabricante [58]), junto con su (b) esquema geométrico de referencia. | 58 |
| 6.1. | Diagrama completo del sistema de diagnóstico desarrollado. | 61 |
| 6.2. | Ejemplares resultantes del proceso de creación de espectrogramas. Se muestra una representación de (a) módulo de corrientes de Clarke en el tiempo y (b) vibración en el sistema de rodamientos. | 65 |
| 6.3. | Diagrama de la transformación tensorial de los espectrogramas de módulos del vector de Clarke en el tiempo y vibraciones a la entrada del módulo convolucional. Los datos incluidos en el tensor son meramente referenciales. | 67 |
| 6.4. | Diagrama del flujo de información a través del módulo LSTM. | 70 |
| 7.1. | Resultados del modelo dual ante entrada de vibración en el rodamiento y corriente de fase a . Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas. | 75 |
| 7.2. | Resultados del modelo dual ante entrada de vibración en el rodamiento y módulo del vector de Clarke. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas. | 76 |
| 7.3. | Resultados del modelo entrenado en base a registros de la CWRU. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas. | 78 |
| 7.4. | Resultados del modelo entrenado en base a registros de la CWRU. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas. | 79 |

Índice de tablas

| | | |
|-------|--|----|
| 2.1. | Comparación de la distribución porcentual de fallas en MI según estudios de IEEE-IAS y EPRI. | 10 |
| 2.2. | Categorización de modos de falla en motores de inducción. | 10 |
| 3.1. | Combinaciones de valores de los tres canales RGB que dan como resultado colores básicos. | 28 |
| 5.1. | Datos de placa del motor y generador ensayados. | 45 |
| 5.2. | Parámetros geométricos característicos del rodamiento Craft 1207 EF-J31. | 47 |
| 5.3. | Grados de severidad de falla por cortocircuito entre espiras para cada tipo de conexión entre el borne principal (número 1) y algún otro terminal. | 48 |
| 5.4. | Niveles de carga aplicados sobre el MI durante la creación de la base de datos. El grado de carga porcentual presentado en la última columna es relativo al par nominal del motor. | 50 |
| 5.5. | Distribución de muestras por clase dentro de la base de datos UTFSM. | 51 |
| 5.6. | Datos de placa del motor ensayado en la base de datos perteneciente a la CWRU. | 52 |
| 5.7. | Parámetros geométricos característicos del rodamiento SKF 6205 2RSJEM. | 55 |
| 5.8. | Distribución de muestras por clase dentro de la base de datos de la CWRU. | 56 |
| 5.9. | Datos de placa del motor ensayado en la base de datos perteneciente a la KAIST. | 57 |
| 5.10. | Parámetros geométricos característicos del rodamiento NSK 6205 DDU. | 58 |
| 5.11. | Distribución de muestras por clase dentro de la base de datos de la KAIST. | 59 |
| 6.1. | Distribución de muestras por clase dentro de la base de datos UTFSM luego de la implementación de EAD. | 63 |
| 6.2. | Distribución de muestras por clase dentro de la base de datos CWRU luego de la implementación de EAD. | 63 |
| 6.3. | Esquema de la estructura en capas del módulo convolucional implementado. | 68 |
| 7.1. | Hiperparámetros óptimos encontrados por el algoritmo de Optuna para la iteración inicial del modelo. | 74 |
| 7.2. | Hiperparámetros óptimos encontrados por el algoritmo de Optuna para el modelo luego de aplicar las EAD sobre la base de datos. | 76 |
| 7.3. | Desempeño del modelo evaluado ante diferentes características y señales de entrada. | 77 |

Resumen

En la industria moderna, la continuidad operativa depende en una importante medida de la confiabilidad de los motores eléctricos insertos en sus procesos productivos. Por consecuencia, las fallas imprevistas en estos equipos generan elevados costos operativos debido a paradas no programadas. Si bien, existen métodos de diagnóstico tradicionales empleados para evitar estos imprevistos, estos suelen requerir de conocimiento experto para la extracción y reconocimiento de patrones característicos de fallas, lo cual limita la escalabilidad de este análisis ante esquemas de supervisión con gran cantidad de información.

Para abordar esta problemática, en el presente trabajo de título se desarrolla un sistema de detección y diagnóstico de fallas automatizado basado en inteligencia artificial, empleando una arquitectura híbrida de aprendizaje profundo de tipo CNN-LSTM. El modelo propuesto procesa información gráfica relativa a representaciones tiempo-frecuencia generadas a partir de señales físicas (vibraciones y módulos de vector de Clarke en el tiempo), traduciéndolas en forma de mapas de calor relativos a su intensidad espectral en el tiempo. Por otra parte, el entrenamiento de este algoritmo se fundamenta principalmente en la base de datos experimental elaborada por la Universidad Técnica Federico Santa María (UTFSM), la cual contempla registros vibratorios y de corriente relativos a un motor de inducción trifásico sujeto a operación sana, fallas en elementos rodantes, cortocircuitos entre espiras y estados de falla mixta. A su vez, el modelo fue probado en base a bases de datos públicas externas a la antes comentada. En concreto, las pertenecientes a las instituciones *Case Western Reserve University* (CWRU) y *Korea Advanced Institute of Science & Technology* (KAIST), con el objetivo de evaluar la adaptabilidad del modelo ante distintos tipos de datos operativos

Los resultados obtenidos demuestran la viabilidad, eficacia y robustez del sistema propuesto. En su evaluación con la base de datos de la UTFSM, el modelo alcanzó un *f1-score* promedio del 95,07%, destacando su nula tasa de falsos positivos al evaluar condiciones saludables, un factor crítico para evitar falsas alarmas en la industria. Finalmente, la capacidad de generalización y adaptabilidad del algoritmo fue validada exitosamente frente a las bases de datos externas de la CWRU y KAIST, logrando métricas de precisión y *f1-score* del 100% en la clasificación de diversos tipos de daño en rodamientos, de acuerdo al componente afectado.

Nomenclatura y Abreviaciones

| | |
|-----------------|--|
| MI | : Motor de Inducción. |
| IEEE-IAS | : <i>IEEE Industry Applications Society</i> . |
| EPRI | : <i>Electric Power Research Institute</i> . |
| IA | : Inteligencia Artificial. |
| ML | : <i>Machine Learning</i> (Aprendizaje Automático). |
| DL | : <i>Deep Learning</i> (Aprendizaje Profundo). |
| CNN | : <i>Convolutional Neural Network</i> (Redes Neuronales Convolucionales). |
| RNN | : <i>Recurrent Neural Network</i> (Redes Neuronales Recurrentes). |
| LSTM | : <i>Long Short-Term Memory</i> (Memoria de Largo y Corto Plazo). |
| EAD | : Estrategia de Aumento de Datos. |
| AWGN | : <i>Additive White Gaussian Noise</i> (Ruido Blanco Gaussiano Aditivo). |
| MCSA | : <i>Motor Current Signature Analysis</i> (Análisis de Firma de Corriente de Motor). |
| ATF | : Análisis Tiempo-Frecuencia. |
| STFT | : <i>Short-Time Fourier Transform</i> (Transformada de Fourier de Tiempo Corto). |
| WT | : <i>Wavelet Transform</i> (Transformada de Wavelet). |
| ST | : <i>Stockwell Transform</i> (Transformada de Stockwell). |
| CWT | : <i>Continuous Wavelet Transform</i> (Transformada de Wavelet Continua). |
| RGB | : Formato de imagen <i>Red, Green and Blue</i> . |
| FC | : <i>Fully-Connected neural networks</i> (redes neuronales Totalmente Conectadas). |
| VP | : Verdaderos Positivos. |
| VN | : Verdaderos Negativos. |
| FP | : Falsos Positivos. |
| FN | : Falsos Negativos. |
| UTFSM | : Universidad Técnica Federico Santa María. |
| CWRU | : <i>Case Western Research University</i> . |
| KAIST | : <i>Korea Advanced Institute of Science & Technology</i> . |

Capítulo 1

Introducción

Dentro de los procesos productivos modernos, la continuidad y eficiencia operativa se han consolidado como factores determinantes para la competitividad industrial. En este contexto, el impacto económico que tienen los procesos de mantenimiento dentro de las plantas productivas cobra especial relevancia, dado que, por ejemplo, puede representar hasta un 60 % del total del costo de producción en la industria pesada [1]. El núcleo de los procesos productivos se encuentra en los sistemas electromecánicos, concretamente, en los Motores de Inducción (MI) de jaula de ardilla, ya que estos concentran más del 80 % del consumo energético dentro del marco industrial [2]. Por ende, cualquier ocurrencia de fallas imprevistas en este tipo de maquinaria no solo compromete la seguridad del personal y la integridad de los activos, sino que conlleva consecuencias financieras en todo el núcleo productivo. Según lo anterior se desprende que la industria demanda estrategias de mantenimiento eficientes que permitan asegurar su rentabilidad a través de la reducción de costos asociados al lucro cesante y a tiempos de inactividad no programados.

La operación misma de los MI en entornos industriales complejos, junto con la variabilidad en las condiciones de carga y alimentación, inexorablemente acelera en el desgaste de sus componentes internos. Este deterioro propicia la aparición de fallas, las cuales actúan como alteraciones en el comportamiento nominal del MI a través de la pérdida de la integridad de alguno de sus elementos. Dependiendo del grado de severidad, estas anomalías pueden inducir desbalances en la alimentación, modificar la naturaleza del par en el eje (reduciendo el par medio o induciendo pulsaciones de par), creando zonas de calor excesivo, entre otros. De esta forma, las fallas comprometen desde la eficiencia general del equipo hasta su continuidad operativa [3].

Los principales tipos de fallas diferenciadas que pueden afectar a un motor eléctrico son las siguientes [3]:

1. Fallas en el sistema de rodamientos o caja de cambios.
2. Apertura o cortocircuito en un devanado de estator.
3. Conexión irregular en los devanados de estator.
4. Excentricidad estática o dinámica en el entrehierro.
5. Eje deformado.

6. Barra rota de rotor o agrietamiento en sus anillos conectores.
7. Cortocircuito en el devanado de campo del rotor.

Sin embargo, desde un punto de vista holístico, estas se pueden categorizar de acuerdo al componente principal afectado del entorno electromecánico del MI, obteniendo las siguientes categorías:

- Fallas en el sistema de rodamientos.
- Fallas en el estator.
- Fallas en el rotor.

Respecto a la relevancia de estas categorías, estudios estadísticos realizados por las organizaciones IEEE *Industry Applications Society* (IEEE-IAS) [4]-[6] y *Electric Power Research Institute* (EPRI) [7] han permitido cuantificar sus respectivas probabilidades de ocurrencia. Esta evidencia señala que las fallas en rodamientos se posicionan consistentemente como la causa principal de los tiempos de inactividad, registrando tasas de incidencia del 44 % y 41 % según la IEEE-IAS y el EPRI, respectivamente. En segundo lugar, las fallas en el estator constituyen la siguiente categoría crítica, con una frecuencia de ocurrencia que se ubica entre el 26 % y el 36 %. Mientras que las fallas en el rotor (8-9 %) y de un conjunto de otros componentes (22-14 %) representan el resto del universo de muestras.

Ante esta problemática, fabricantes y propietarios de estos equipos han implementado soluciones basadas en protecciones relativas al sistema de alimentación eléctrica (como de sobrecorriente, sobretensión, etc) o en estrategias de mantenimiento correctivo, las cuales consisten en tratar el equipo una vez haya fallado. Sin embargo, la creciente complejidad de los entornos en los cuales estas máquinas están insertas aumenta la necesidad de realizar un diagnóstico de falla temprano, que permita mantener en equilibrio la confiabilidad y eficiencia operativa. Es así como nace la estrategia de mantenimiento predictivo, la cual se basa en el monitoreo de condiciones del activo, midiendo las variables físicas con el objetivo de determinar la necesidad real de realizar una intervención sobre el equipo, permitiendo así programar las actividades de mantenimiento solamente cuando son estrictamente necesarias, anticipándose a una avería. Como consecuencia, se logra una reducción sustancial en los costos globales de mantenimiento y pérdidas de producción, garantizando con ello una mayor confiabilidad operativa de los equipos [1, 3].

En el marco de este tipo de estrategias, se han desarrollado diversos esquemas de diagnóstico orientados en la detección de los síntomas físicos que las distintas fallas producen sobre las variables operativas medibles de un MI. Alteraciones como desequilibrios en las tensiones y corrientes de línea, el aumento de las pulsaciones de par, incremento de pérdidas que derivan en un calentamiento excesivo o una reducción de la eficiencia general, actúan como indicadores clave de una condición anómala. En consecuencia, el principio en el cual se fundamentan estos métodos radica en la detección de patrones relativos a la desviación de dichas variables con respecto a la operación en estado saludable. Entre las técnicas de detección más destacadas en la literatura, se encuentran las siguientes [2, 3]:

1. Modelos de inteligencia artificial basados en aprendizaje automático.

2. Monitoreo de vibraciones.
3. Análisis de firma de corriente del motor. [\[1\]](#)
4. Monitoreo del campo electromagnético utilizando bobinas exploratorias.
5. Análisis térmico.
6. Análisis químico.
7. Monitoreo de emisiones de radiofrecuencia.
8. Análisis de emisiones de ruido acústico.
9. Reconocimiento por rayos infrarrojos.

Si bien existe una amplia variedad de sensores capaces de realizar las mediciones necesarias para implementar cada uno de los métodos de diagnóstico antes enumerados, los esquemas de monitoreo de condición se han concentrado tradicionalmente en aquellos basados en registros vibratorios [\[1\]](#). Sin embargo, la implementación de los sensores mecánicos necesarios puede resultar invasivo y costoso, especialmente cuando hay maquinaria de grandes proporciones en una línea de producción. Como alternativa, surgen los métodos de monitoreo basados en la corriente eléctrica de estator, los cuales pueden proporcionar indicaciones de falla similares al análisis de vibraciones, pero con la ventaja significativa de no requerir acceso físico al motor. En consecuencia, el análisis de estas dos variables constituye la base predominante para distinguir entre condiciones operacionales de una máquina saludable y en condiciones de falla [\[8\]](#).

Tanto para el análisis de señales vibratorias como de corriente, el procesamiento de los datos se estructura en tres dominios principales: tiempo, frecuencia y tiempo-frecuencia. Cada uno de estos enfoques posee pros y contras específicos dependiendo de la naturaleza de la señal y el régimen de operación del motor, tal como se describe a continuación [\[9\]](#):

- **Dominio del tiempo:** Esta estrategia se basa en analizar la evolución temporal de las magnitudes de una señal o sus propiedades estadísticas, con el objetivo de identificar desviaciones respecto al comportamiento nominal. Su principal ventaja radica en la simplicidad computacional de su ejecución, lo que facilita su implementación en sistemas con recursos limitados. Sin embargo, su sensibilidad puede verse comprometida en entornos con mucho ruido o ante fallas incipientes de manifestación sutil.
- **Dominio de la frecuencia:** Este enfoque parte de la premisa de que las fallas inducen perturbaciones periódicas (como asimetrías en el entrehierro), las cuales modulan las señales medibles generando componentes espectrales anómalos. Es la técnica estándar para regímenes estacionarios, aunque enfrenta desafíos como la fuga espectral y la gran limitación de detección bajo condiciones de operación no estacionarias
- **Dominio tiempo-frecuencia:** A diferencia del enfoque puramente frecuencial, el cual asume que todo el espectro es constante a lo largo del periodo de simulación,

¹Traducción del inglés “*Motor Current Signature Analysis*”.

esta estrategia caracteriza la evolución del contenido espectral de una señal a lo largo del periodo de medición. Su funcionamiento se basa en aplicar ventanas de análisis acotadas que se desplazan a lo largo del dominio temporal. Esto permite localizar la energía de la señal simultáneamente en ambos dominios, revelando no solo qué componentes espectrales están presentes, sino cuándo se manifiestan y con qué intensidad. Si bien, este método ofrece una capacidad de análisis dinámico superior, su implementación conlleva una carga computacional considerablemente mayor con respecto a los dos enfoques anteriores.

Independientemente del dominio del análisis seleccionado, una parte fundamental del proceso de diagnóstico consiste en transformar la vasta cantidad de datos crudos en un conjunto reducido de indicadores específicos que concentran la información del estado de la máquina estudiada, filtrando así el ruido e información redundante en el camino. En la literatura, a estos indicadores se les denomina “características”². Existen diversos tipos de técnicas para extraerlos a partir de la información cruda de la señal (cual sea el dominio del análisis), las cuales incluyen desde el cálculo de parámetros estadísticos hasta métodos de normalización o de reducción de ruido³ [10]. Es importante señalar que, bajo métodos tradicionales, tanto la acción de extracción de características como su interpretación para diagnosticar el estado de un motor independientemente la técnica y el dominio del análisis realizado requiere de algún grado de conocimiento experto [8].

Como respuesta a la dependencia del juicio experto de los métodos clásicos, han ganado prominencia los enfoques basados en técnicas de Inteligencia Artificial (IA). En este contexto, un método de IA no busca modelar explícitamente los fenómenos físicos detrás de una falla en el motor, sino construir modelos matemáticos capaces de aprender patrones de degradación y correlaciones complejas a partir de un conjunto de información histórica relativa al activo analizado. En primera instancia, estos enfoques se han materializado a través de las técnicas de aprendizaje automático o *Machine Learning* (ML), donde las características previamente extraídas mediante técnicas de procesamiento de señales son utilizadas para entrenar algoritmos de clasificación de estados (tales como Máquinas de Vectores de Soporte, *Random Forest*, *K-Nearest Neighbors*, entre otros) [9].

Si bien los enfoques clásicos de ML han demostrado eficacia, su desempeño continúa dependiendo estructuralmente de la calidad de las características extraídas manualmente a partir de los datos crudos, conservando un grado de dependencia del experto que lleva a cabo estas actividades [11]. Este aspecto representa una limitación relevante en aplicaciones de esquemas de monitoreo en línea, particularmente en entornos industriales modernos impulsados por el “internet de las cosas”⁴, donde la adquisición continua de flujos masivos de datos hace impracticable la extracción de características manual [12].

Como respuesta ante estas restricciones, emergen las técnicas de Aprendizaje Profundo (DL, por sus siglas en inglés), siendo estas a su vez un subgrupo avanzado del ML. Estos modelos son caracterizados por su habilidad para procesar grandes volúmenes de información cruda, generando automáticamente representaciones jerárquicas de la información ante múltiples escalas y de múltiples niveles. Este proceso es llevado a cabo mediante el uso de redes neuronales de múltiples capas, las cuales aplican transformaciones no lineales sucesivas a la señal de entrada, aprendiendo dependencias complejas y patrones

²Traducción del inglés “*features*”.

³Conocidos en la literatura como “*denoising*”.

⁴Traducción del inglés “*internet of things*”.

ocultos en la dinámica del sistema que serían imperceptibles para modelos más superficiales. En consecuencia, el DL permite automatizar simultáneamente tanto la extracción de características complejas como su utilización para la clasificación del estado de un activo, superando así barreras de escalabilidad y eficiencia propias de los enfoques previos de ML [11, 12].

En el ámbito del monitoreo de condiciones orientado a máquinas eléctricas, diversos enfoques de DL han sido implementados. Entre estos, dos de las principales técnicas en cuestión han sido las redes neuronales convolucionales (CNN, por sus siglas en inglés) y las redes neuronales recurrentes (RNN, por sus siglas en inglés) [11]. En cuanto a las CNN, su funcionamiento se basa en la operación de convolución entre una entrada (comúnmente una representación bidimensional de una señal, como un espectrograma) y un filtro o *kernel*. Mediante este mecanismo, la red examina diferentes regiones de la imagen, extrayendo características locales mediante el desplazamiento del *kernel* a lo largo de esta. Como resultado, la CNN agrupa toda esta información espacial en una estructura de salida denominada como “mapa de características”, sintetizando en esta todos los patrones gráficos obtenidos a partir de la imagen analizada [13].

Por su parte, las RNN son una arquitectura diseñada para procesar información de forma secuencial a partir de un conjunto sucesivo de vectores de características en la entrada. Esto se lleva a cabo mediante conexiones de retroalimentación, las cuales generan una memoria interna que permite retener información de los estados anteriores al punto de análisis. De esta manera, la salida en cada paso secuencial depende tanto de la entrada actual como de la información guardada en memoria, permitiendo así el reconocimiento de patrones dinámicos a lo largo de la secuencia de entrada. Sin embargo, las RNN presentan un gran inconveniente a la hora de procesar secuencias extensas, sufriendo problemas de inestabilidad durante su proceso de aprendizaje (problema catalogado en la literatura como “explosión” y “desvanecimiento” de gradiente respectivamente), impidiendo capturar patrones de largo plazo de forma efectiva. En este contexto es que surgen un subconjunto de las RNN; las redes *Long Short-Term Memory* (LSTM), las cuales poseen la capacidad de almacenar memoria mediante mecanismos internos de selectividad de información, aprendiendo qué datos olvidar y cuales retener, lo cual garantiza la estabilidad del entrenamiento, preservando a su vez la capacidad de reconocer de patrones secuenciales de largo plazo [13].

Estableciendo una sinergia entre ambos tipos de estrategias de DL antes comentadas, investigación reciente ha convergido hacia el desarrollo de modelos híbridos de redes CNN y LSTM. Esta clase de arquitectura permite que el bloque convolucional extraiga sus propias características jerárquicas a partir de un conjunto de datos, las cuales posteriormente son procesadas secuencialmente por el bloque recurrente para capturar dependencias secuenciales. En la literatura, esta estrategia de diagnóstico reporta niveles de precisión que oscilan entre el 92,6 % y el 98,6 % resultante del proceso de pruebas ante sus respectivos conjuntos de datos relativos a distintos tipos de fallas en activos eléctricos [14]-[16]. Estos resultados evidencian el alto potencial de este modelo híbrido ante aplicaciones ligadas al monitoreo de activos.

En función de lo anterior, la presente memoria de titulación busca desarrollar un sistema de diagnóstico de fallas aplicando este tipo de arquitectura híbrida. Como distinción clave, se busca entrenar este modelo de DL mediante una base de datos novedosa como lo es la generada por la Universidad Técnica Federico Santa María. A diferencia de ba-

ses de datos públicas similares, esta cuenta con datos operativos de un MI sometido a escenarios de fallas combinadas en su sistema de rodamientos a la vez que en el devanado de su estator, además de contar con diversas regímenes de alimentación. En términos metodológicos, las señales provenientes de esta base de datos se transforman al dominio de tiempo-frecuencia, creando representaciones bidimensionales de cada muestra en forma de un espectrograma. Bajo este esquema, el módulo convolucional se encarga de extraer características complejas y patrones de energía visuales presentes en los espectrogramas, mientras que el módulo LSTM procesa dicha información para capturar las dependencias secuenciales en las características extraídas. Esta integración permite obtener una caracterización integral y robusta de los distintos modos de falla del equipo estudiado.

En coherencia con los antecedentes expuestos, el objetivo general de la presente memoria de título es el siguiente:

- Desarrollar un algoritmo de detección y diagnóstico de fallas en motores de inducción a través de la aplicación de un modelo de aprendizaje supervisado, entrenado en base a datos recopilados mediante sistemas de adquisición disponibles en el mercado.

En donde, para llevarlo a cabo, se plantean los siguientes objetivos específicos:

- Seleccionar principales causas de las fallas eléctricas y/o mecánicas en los motores de inducción trifásicos en base a los registros proporcionados por la empresa SHEN en complemento con información bibliográfica de alto valor académico.
- Crear una base de datos relativa al registro de señales indicadoras de la operación sana y bajo falla de motores de inducción, en concordancia con los modos de falla previamente seleccionados.
- Entrenar un algoritmo de inteligencia artificial basado en un modelo de aprendizaje supervisado para el reconocimiento y diagnóstico de fallas en motores de inducción, tomando como referencia la base de datos previamente establecida.
- Validar el sistema de diagnóstico desarrollado en base a una nueva base de datos distinta de la utilizada para el entrenamiento del algoritmo.

Capítulo 2

Modos de falla en motores de inducción

2.1. Antecedentes y selección de modos a analizar

Tanto el rendimiento como la confiabilidad operativa de un MI pueden verse comprometidos debido a múltiples factores. Para el desarrollo de algoritmos de diagnóstico efectivos, es fundamental identificarlos y comprender su incidencia sobre las variables del sistema analizado. En este contexto, un modo de falla se define como una alteración en el comportamiento funcional del motor, generando desviaciones medibles con respecto a su operación esperada. Estas alteraciones pueden manifestarse en forma de una reducción en el par medio, introducción de componentes espectrales anómalas en el par o la corriente eléctrica en estator, asimetrías en el flujo del entrehierro, formando áreas de sobrecalentamiento o reduciendo la eficiencia de la máquina debido al aumento de las pérdidas operativas [3].

En función de los síntomas antes descritos, es posible segmentar los modos de falla del MI de acuerdo al componente principal afectado, obteniendo las siguientes categorías:

- Fallas en el sistema de rodamientos.
- Fallas en el estator.
- Fallas en el rotor.

Con el propósito de estimar la prevalencia de fallas en estos componentes, diversas organizaciones han llevado a cabo estudios de confiabilidad en MIs. Entre estas, destacan las investigaciones realizadas por IEEE-IAS [4]-[6] y EPRI [7], las cuales consistieron en una serie de encuestas relativas a la operación de maquinaria en entornos industriales reales. Un resumen de los resultados de estos estudios se encuentra en la Tabla [2.1].

Tabla 2.1. Comparación de la distribución porcentual de fallas en MI según estudios de IEEE-IAS y EPRI.

| Categoría | IEEE-IAS [%] | EPRI [%] |
|-----------------------|--------------|----------|
| Fallas en rodamientos | 44 | 41 |
| Fallas en el estator | 26 | 36 |
| Fallas en el rotor | 8 | 9 |
| Otras fallas | 22 | 14 |

A partir de la segmentación realizada, la Tabla 2.2 muestra los principales modos de falla asociados a cada categoría. Esta recopilación se fundamenta en la revisión bibliográfica de trabajos variados dedicados al análisis de fallas en máquinas eléctricas [3, 17, 18, 19].

Tabla 2.2. Categorización de modos de falla en motores de inducción.

| Categoría | Modo de falla | Manifestación en variables operativas |
|--|---|---|
| Fallas en el sistema de rodamientos | Daño en pista externa. | Aumento en magnitud de componentes espectrales anómalos en vibraciones e incremento de emisiones acústicas. |
| | Daño en pista interna. | |
| | Daño en elementos rodantes. | |
| | Daño en jaula. | |
| Fallas en el estator | Cortocircuito entre espiras. | Aumento en magnitud de componentes espectrales anómalos e incremento de corriente de secuencia negativa. |
| | Cortocircuito entre fases. | Desbalance extremo entre corrientes de estator. |
| | Cortocircuito fase-tierra. | |
| | Fase abierta. | |
| | Descargas parciales. | Creación de pulsos de corriente de alta frecuencia e incremento de emisiones acústicas. |
| Sobrecalentamiento causado por filtración de refrigerante. | Creación de puntos calientes localizados. En casos extremos puede inducir cortocircuitos. | |
| Fallas en el rotor | Barra rota. | Aumento en magnitud de bandas laterales en torno a la fundamental y componentes espectrales anómalos en corriente de estator. |
| | Anillo extremo roto. | |
| | Excentricidad estática y dinámica. | Aumento en magnitud de componentes espectrales anómalos tanto en vibraciones como en corriente de estator. |
| | Rotor deformado. | |

Como se observa en la Tabla 2.1, pese a que existen variaciones considerables en las distribuciones porcentuales en los estudios citados, ambos comparten que las dos principales categorías de fallas en MI se encuentran relacionadas a su sistema de rodamientos y al estator, poseyendo en conjunto entre un 70 % y 77 % de las fallas registradas por las respectivas organizaciones. Asimismo, aunque de la literatura se desprende una amplia variedad de modos de falla para estas categorías (ver Tabla 2.2), el desarrollo de modelos de IA orientados a su detección requiere intrínsecamente de un conjunto de datos operati-

vos para cada condición anómala específica. En consecuencia, aunque la presente memoria de titulación reconoce la relevancia técnica que todos los modos descritos poseen para su respectiva categoría, su alcance se encuentra limitado con respecto a la disponibilidad de información experimental. En este contexto, la selección de los modos de falla a analizar se realiza en función de aquellos en los cuales se cuenta con datos operativos suficientes, buscando de esta forma un proceso de entrenamiento, evaluación y prueba robusto para el algoritmo propuesto.

En función de lo anteriormente expuesto, la base de datos experimental empleada en este trabajo es desarrollada por el Laboratorio de Investigación de Accionamientos Avanzados de la Universidad Técnica Federico Santa María (campus San Joaquín). Esta está constituida por datos de operación de un MI sujeto a fallas por cortocircuito en devanados de estator y por daño localizado en uno de los elementos rodantes de su sistema de rodamientos, ambas inducidas manualmente de forma controlada. Una mayor descripción de esta base de datos se encuentra en la Sección 5.1 del presente documento. En consecuencia, en las posteriores secciones se detallan los fundamentos físicos y las consecuencias operativas de estas fallas en la operación de un MI.

Es entonces que, según lo señalado anteriormente, el presente trabajo busca elaborar un algoritmo de diagnóstico centrado en los dos modos de falla presentes en dicha base de datos. Esta decisión, pese a responder a las restricciones intrínsecas ya expuestas, mantiene una alta pertinencia para los sistemas de supervisión industrial, dado que las condiciones de falla estudiadas corresponden a las de mayor prevalencia dentro de los estudios consultados. De este modo, se espera maximizar la utilidad del modelo desarrollado en el contexto de sistemas de supervisión industrial considerando las limitaciones intrínsecas de la base de datos empleada.

2.2. Daño en sistema de rodamientos

Los sistemas de rodamientos constituyen un componente mecánico esencial en la operación de las máquinas rotativas, ya que no solo permiten la libre rotación del eje, sino que lo soportan estructuralmente, manteniendo su alineación y absorbiendo cargas axiales y radiales que pueden serle aplicadas. En términos de sus características constructivas, los componentes principales que conforman a este sistema son la pista externa, pista interna, jaula de contención y elementos rodantes [20], tal cual se muestra en la Figura 2.1(a). Un mayor acercamiento a los parámetros geométricos se presenta en la Figura 2.1(b).




Figura 2.1. Diagramas representativos de la (a) estructura general de un rodamiento de bolas, junto con la (b) distribución geométrica de sus componentes. Adaptado de [21] y [22] respectivamente.

Dada la heterogeneidad de componentes que conforman al sistema de rodamientos, existen procesos de degradado por los cuales cada uno de estos elementos puede deteriorarse de forma independiente al resto. Estos procesos están impulsados por condiciones operativas adversas como la contaminación, corrosión, sobreesfuerzos mecánicos por sobrecarga, desalineamiento o lubricación inadecuada de los componentes [23]. Estos factores pueden inducir diversos tipos de daños en el sistema, tales como picaduras⁵, escamado⁶, grietas, fracturas, entre otros. Muestras reales de componentes de rodamientos deteriorados por estos fenómenos se pueden apreciar en las Figuras 2.2 y 2.2. Detectar estos daños durante sus fases iniciales de aparición resulta crítico para salvaguardar la salud del sistema de rodamientos, ya que los defectos incipientes pueden evolucionar con el tiempo hasta puntos de mayor criticidad, comprometiendo la estabilidad operativa del sistema de rodamientos [24]. Este fenómeno se ilustra en la Figura 2.3.



Figura 2.2. Ejemplos de consecuencias de mecanismos de degradación en elementos de un sistema de rodamientos [24]. Entre ellos, (a) escamado en pista interna y (b) fractura por fatiga mecánica en jaula.

⁵Traducción del inglés “pitting”.

⁶Traducción del inglés “spalling”.




Figura 2.3. Ejemplo de aumento progresivo del escamado en una pista de un rodamiento. El nivel de deterioro aumenta de izquierda a derecha [24].

Estas distintas formas de degradación generan asimetrías cinéticas localizadas durante el giro del eje (debido a la pérdida en la integridad estructural del sistema de rodamientos), creando fuerzas de amplitudes considerables durante un corto periodo de tiempo cada vez que un componente entra en contacto con una zona dañada. Estas fuerzas se manifiestan a modo de pulsos vibratorios transitorios, los cuales se ven rápidamente atenuados por el amortiguamiento que impone naturalmente el resto de componentes durante el giro de la máquina [25]. Un ejemplo de este fenómeno mecánico se puede apreciar en la Figura 2.4.

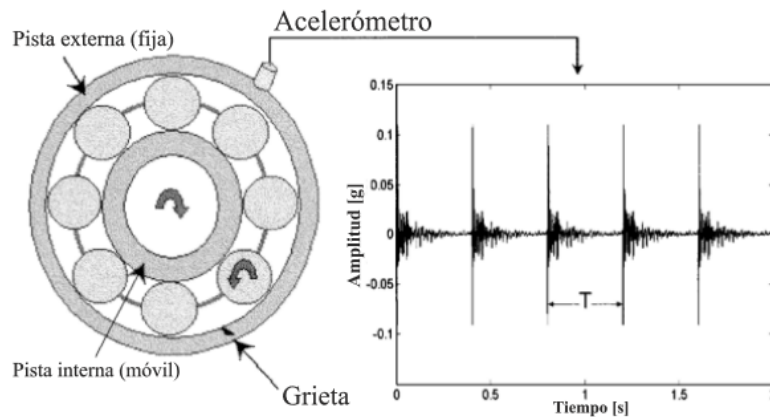


Figura 2.4. Ilustración del fenómeno vibratorio provocado por una grieta en la pista externa de un sistema de rodamientos. Adaptado de [25].

Cada elemento del sistema de rodamientos sujeto a falla genera vibraciones de frecuencias específicas, debido al contacto periódico con la zona afectada durante la rotación de la máquina. Estas “huellas frecuenciales” pueden ser obtenidas mediante relaciones matemáticas ligadas a las características cinéticas de la operación y a la geometría del sistema.

Las ecuaciones representativas de estos fenómenos se presentan a continuación. En ellas, f_m representa la velocidad del eje, n es la cantidad de elementos rodantes individuales, α es el ángulo de contacto del elemento rodante, d es el diámetro del elemento rodante mientras que D es el efectivo del rodamiento (véase Figura 2.1(b)) [20].

▪ **Pista externa e interna (respectivamente):**

$$f_{PE} = \frac{n \cdot f_m}{2} \cdot \left\{ 1 - \frac{d}{D} \cos(\alpha) \right\} \quad (2.1)$$

$$f_{PI} = \frac{nf_m}{2} \cdot \left\{ 1 + \frac{d}{D} \cos(\alpha) \right\} \quad (2.2)$$

- **Jaula:**

$$f_J = \frac{f_m}{2} \cdot \left\{ 1 - \frac{d}{D} \cos(\alpha) \right\} \quad (2.3)$$

- **Elementos rodantes:**

$$f_{ER} = \frac{Df_m}{2d} \cdot \left\{ 1 - \left(\frac{d}{D} \cos(\alpha) \right)^2 \right\} \quad (2.4)$$

Altos niveles de vibración causados por el deterioro de uno o más componentes dañados del sistema de rodamientos pueden comprometer toda una cadena de producción, en la cual el motor mismo está inserto. En este contexto, una parte fundamental de la labor de mantenimiento de las máquinas eléctricas consiste en estimar el estado del sistema de rodamientos mediante el monitoreo del incremento del nivel de vibraciones, buscando comparar valores actual con registros de referencia históricos. Si es que los resultados de este ejercicio muestran un ligero incremento en la intensidad de las vibraciones, se puede intuir la existencia de una falla incipiente, mientras que un aumento considerable en este apartado suele asociarse a un estado avanzado de degradación de la máquina [26, 27].

Con el objetivo de registrar estos fenómenos vibratorios, diversos tipos de instrumentos son empleados durante la operación de un motor. Entre estos se destacan los transductores de vibración, los cuales convierten las señales vibratorias de naturaleza cinética en señales proporcionales de naturaleza eléctrica. A su vez, estos instrumentos de medición pueden ser segmentados de acuerdo a la variable primaria registrada, según se muestra a continuación [20]:

- **Sondas de proximidad:** Estos dispositivos se basan en la medición de la distancia relativa entre la punta del sensor y una superficie determinada, siendo sensibles al cambio en los parámetros electromagnéticos dentro de la brecha de estos dos elementos.
- **Transductores de velocidad:** Típicamente basados en la respuesta a perturbaciones de una bobina suspendida sísmicamente dentro del campo magnético de un imán permanente, los transductores de velocidad registran una señal de tensión proporcional a la velocidad inherente al fenómeno vibratorio en la superficie en la cual son ubicadas.
- **Acelerómetros:** Esencialmente, son instrumentos que transforman una señal de aceleración en una señal eléctrica proporcional. Entre estos, los más empleados en aplicaciones ligadas al monitoreo de condiciones de máquinas rotatorias son los acelerómetros piezoeléctricos, los cuales generan una señal eléctrica como respuesta ante la deformación de sus materiales internos que se induce durante el movimiento vibratorio de la operación.

2.3. Cortocircuito en devanados del estator

Los MI deben su operación a la alimentación que ingresa a través de sus devanados del estator, los cuales son un sistema de bobinas de alambre conductor enrolladas simétricamente a través de las ranuras dispuestas para su sujeción dentro de la estructura del

estator, tal cual se aprecia en la Figura 2.5. La función de estos devanados es conducir la energía proveniente de las corrientes de alimentación para formar un campo magnético en el entrehierro tal de inducir el giro mecánico en el rotor, permitiendo la operación del motor [28].




Figura 2.5. *Proceso de devanado de un motor eléctrico. Se distingue el (a) núcleo y los (b) devanados insertos en sus ranuras dentro del estator [29].*

Además del material conductor, otro componente esencial del devanado de estator corresponde a su mecanismo de aislamiento, el cual está encargado de prevenir la ocurrencia de cortocircuitos entre los componentes en los que se encuentra en contacto. Existen tres tipos de mecanismos de aislamiento de acuerdo al tipo de falla que busquen prevenir; las ocurridas entre subconductores, entre espiras o entre material conductor y la carcasa misma del estator [19]. Un diagrama representativo de este tipo de aislamientos se presenta en la Figura 2.6.

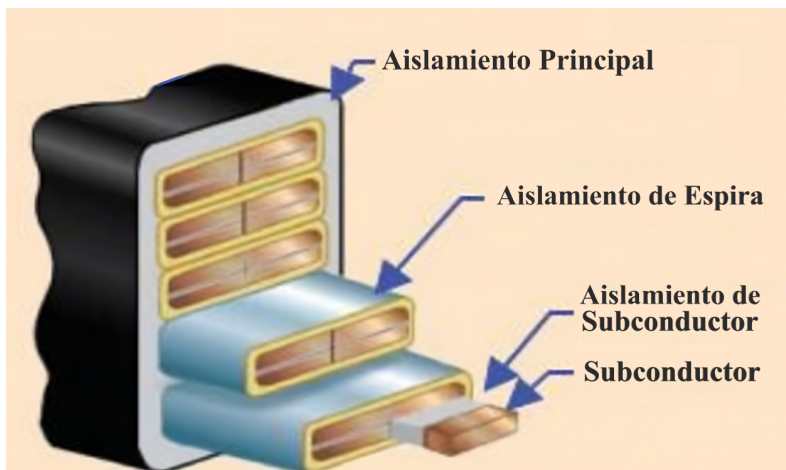


Figura 2.6. *Diagrama representativo de los tipos de aislamientos en una bobina con perspectiva en un corte de su sección transversal. Adaptado de [30].*

Comúnmente, el aislamiento de un devanado tiende a fallar debido a procesos graduales de deterioro en lugar de eventos catastróficos durante la operación de las máquinas. Estos fenómenos están ligados al sometimiento del aislamiento ante picos de tensión de gran magnitud durante un tiempo corto, aplicación de grandes esfuerzos mecánicos o sometimiento a altas temperaturas durante la operación. Estos fenómenos de desgaste progresivo se pueden surgir luego de haber descargas atmosféricas a la máquina, fallos en la fuente de alimentación del motor (que causen aumentos repentinos en la corriente de estator, ejerciendo fuerza mecánica sobre los devanados) o errores operativos relacionados al sistema de refrigeración del motor. Esta clase de fenómenos provocan que el aislamiento pierda cualidades mecánicas y/o eléctricas esperadas durante la operación normal de una máquina, hasta el punto de permitir el flujo de corriente entre componentes que originalmente se debían mantener aislados [19]. En la Figura 2.7 se muestran las consecuencias de un evento de falla catastrófica sobre su respectivo devanado de estator.




Figura 2.7. Fallas por cortocircuito entre espiras de (a) menor [31] y (b) mayor severidad [19]. En este último caso, derivando a un cortocircuito fase-tierra. Notar que las bobinas superiores fueron removidas para exponer la falla en las inferiores.

Cuando este mecanismo de falla actúa sobre las espiras de una bobina, además de crear un camino de conducción que (en efectos prácticos) genera una bobina con menor número de vueltas, crea una corriente circulante a través del tramo de conducción omitido por efectos del cortocircuito. Este tramo de conducción se acopla magnéticamente con el resto de la bobina, generando una fuerza magnetomotriz (FMM) en el entrehierro que se opone a la dirección de la del tramo principal [32]. Esta perturbación localizada presenta una forma de onda espacial de naturaleza rectangular o pulsante centrada específicamente en las ranuras que alojan la bobina afectada. Entonces, dado que el rotor gira a una velocidad asíncrona respecto a estos componentes espacialmente estacionarios, se produce una interacción dinámica que modula el flujo magnético, transformando estos armónicos espaciales en armónicos temporales observables. Es precisamente esta superposición de frecuencias la que induce componentes espectrales anómalos en las variables eléctricas del estator, cuya ubicación en el espectro de frecuencias obedece a la siguiente relación [33] [34]:

$$f_{CCe} = \left\{ k \pm n \cdot \left(\frac{1-s}{p} \right) \right\} \cdot f_s \quad (2.5)$$

En donde p representa los pares de polos del equipo afectado, s el deslizamiento operativo, f_s la frecuencia de suministro, mientras que k y n son índices armónicos, tal que $k =$

$\{1, 3, 5, \dots\}$ y $n = \{1, 2, 3, \dots\}$. A partir de esta expresión, considerando que el deslizamiento operativo se define de la siguiente manera:

$$s = \frac{f_s - pf_m}{f_s} \quad (2.6)$$

Es posible reemplazar (2.6) en (2.5), obteniendo una versión simplificada de la expresión de frecuencias características de la falla por cortocircuito en espiras, la cual se muestra en (2.7).

$$f_{CCe} = k \cdot f_s \pm n \cdot f_m \quad (2.7)$$

2.4. Influencia cruzada de fallas en variables operativas

Cabe explicitar que la influencia de los modos de falla descritos en las secciones 2.2 y 2.3 sobre las variables operativas del MI fue descrita dentro de sus dominios físicos predominantes: vibraciones para falla en rodamientos y corrientes de estator para la falla por cortocircuito en espiras. No obstante, debido al principio de operación de una máquina eléctrica, ambos fenómenos electromecánicos se encuentran inherentemente vinculados. Esta propiedad puede ser demostrada a partir de una falla en rodamientos (cualquiera esta sea), en la cual son inducidas oscilaciones anómalas en el par de carga de operación saludable (T_H), añadiendo un componente de rizado (ΔT_{carga}) cuya magnitud es significativamente menor a T_H , naturalmente. En consecuencia, el par de carga instantáneo es representado mediante la siguiente relación [35]:

$$T_{carga} = T_H + \Delta T_{carga} \quad (2.8)$$

En donde la perturbación se define como:

$$\Delta T_{carga} = A_F \cdot \cos(2\pi f_F t) \quad (2.9)$$

Luego, a partir del modelo dinámico de una máquina rotatoria (despreciando las pérdidas mecánicas), es posible relacionar el par de carga con el par electromagnético (T_{em}) obteniendo la relación descrita en 2.10. Para un régimen de operación cuasi-estacionario, es posible reescribir la anterior relación incorporando la teoría de pequeñas señales, lo cual permite relacionar las variaciones de velocidad con las perturbaciones del par electromagnético y de carga, según se muestra en (2.11).

$$J \cdot \frac{d\omega_r(t)}{dt} = T_{em} - T_{carga} = 0 \quad (2.10)$$

$$J \cdot \frac{d\Delta\omega_r(t)}{dt} = \Delta T_{em} - \Delta T_{carga} \quad (2.11)$$

Esta respuesta surge naturalmente debido a que el motor, para mantener el giro, busca compensar la variación mecánica impuesta por ΔT_{carga} . En consecuencia, el par electromagnético desarrolla un componente oscilatorio tal de restablecer el equilibrio operacional.

Por otra parte, al asumir condiciones de operación lineal dentro de la curva par-velocidad del motor, se puede establecer la relación (2.12) y, por tanto, expandir esta expresión para pequeñas señales, obteniendo (2.13).

$$T_{em} = \frac{3P}{2\pi f} \cdot \frac{V^2(1 - P\omega_r)}{R_2 \cdot 2\pi f} \quad (2.12)$$

$$\Delta T_{em} = -\frac{3P^2}{(2\pi f)^2} \cdot \frac{V^2}{R_2} \cdot \Delta\omega_r = -k\Delta\omega_r \quad (2.13)$$

Al incorporar (2.9) y (2.13) dentro del modelo dinámico descrito en (2.11), se pueden reordenar los elementos para obtener una relación entre velocidad de giro y par mediante la siguiente ecuación diferencial:

$$J \cdot \frac{\Delta\omega_r(t)}{dt} + k\Delta\omega_r(t) = -A_F \cdot \cos(2\pi f_F t) \quad (2.14)$$

La resolución de (2.14), permite determinar una expresión para las fluctuaciones de velocidad, según se muestra a continuación:

$$\Delta\omega_r(t) = -\frac{A_F}{\sqrt{k^2 + (2\pi f_F J)^2}} \cdot \cos\left(2\pi f_F t - \arctg\left(\frac{2\pi f_F J}{k}\right)\right) \quad (2.15)$$

Por consiguiente, al incorporar (2.15) en (2.13), se deducen las variaciones en el par electromagnético expresadas en (2.16).

$$\Delta T_{em}(t) = \frac{kA_F}{\sqrt{k^2 + (2\pi f_F J)^2}} \cdot \cos\left(2\pi f_F t - \arctg\left(\frac{2\pi f_F J}{k}\right)\right) \quad (2.16)$$

En términos de magnitud, es posible normalizar (2.16) en función de (2.10), obteniendo la siguiente relación:

$$\frac{|\Delta T_{em}(t)|}{T_{em}} = \beta \cdot \frac{|\Delta T_{carga}|}{T_{carga}} \quad (2.17)$$

Donde:

$$\beta = \frac{k}{\sqrt{k^2 + (2\pi f_F J)^2}} \quad (2.18)$$

Luego, en función de los supuestos iniciales, es posible asumir operación ante variaciones despreciables en la alimentación de la máquina. Esta condición implica que el flujo magnético en el entrehierro permanece constante a lo largo del presente escenario de pequeñas variaciones. En consecuencia, las oscilaciones de par electromagnético son reflejadas únicamente hacia la corriente de estator, creando modulaciones sobre la señal original definidas mediante la siguiente expresión [36]:

$$i_s(t) = \sqrt{2}I \cdot \cos(2\pi f_s t + \delta_T) + \Delta I \cdot \cos\left(2\pi f_F t - \arctg\left(2\pi f_F \cdot \frac{J}{k}\right)\right) \quad (2.19)$$

Siendo δ_T el desplazamiento angular relativo con respecto a las perturbaciones de par.

Bajo este modelo, surgen dos componentes superpuestas a la corriente de estado estacionario, las cuales comparten una magnitud de $\frac{1}{2}\Delta I$ y poseen frecuencias de $f_s + f_F$ y $f_s - f_F$. Estas componentes son representadas a partir de (2.20).

$$\Delta i_s(t) = \frac{\Delta I}{2} \cdot \cos\left(2\pi \cdot (f_s \pm f_F)t \mp \arctg\left(2\pi f_F \cdot \frac{J}{k}\right) + \delta_T\right) \quad (2.20)$$

De forma análoga al análisis del par, es posible normalizar (2.20) con respecto a la corriente I . Sin embargo, en este caso, se normaliza en base al componente puramente

activo de corriente ($\sqrt{2}I \cdot \cos(\phi)$), ya que esta es la que genera par electromagnético. Bajo esta premisa, es posible realizar la siguiente aproximación:

$$\frac{\Delta I}{\sqrt{2}I \cdot \cos(\phi)} = \frac{\Delta T_{em}}{T_{em}} = \beta \cdot \frac{\Delta T_{carga}}{T_H} \quad (2.21)$$

Por lo tanto, al despejar (2.21):

$$\Delta I = \beta \frac{\sqrt{2}I \cdot \cos(\phi)}{T_H} \cdot \Delta T_{carga} \quad (2.22)$$

Lo cual evidencia que, bajo las condiciones de operación anteriormente señaladas, las perturbaciones en par de carga inducidas por los fenómenos vibratorios producidos por una falla en rodamientos pueden verse manifestadas en magnitud sobre la corriente de estator.

Dentro del dominio de la frecuencia, y considerando lo presentado en (2.20), las perturbaciones en corriente inducidas por la falla en cuestión poseen un valor de frecuencia característico. Estas frecuencias de falla se definen de la siguiente forma:

$$f_{mod} = |f_s \pm n f_F| \quad (2.23)$$

Donde $n \in \mathbb{N}$ y f_F es la frecuencia característica de una falla en el sistema de rodamientos, sea esta cualquiera de las definidas en (2.1), (2.2), (2.3) o (2.4).

Capítulo 3

Herramientas de tratamiento de datos

El desempeño del sistema de diagnóstico propuesto en la presente memoria de titulación no depende exclusivamente de la robustez del modelo de IA incorporado, sino también de un proceso de tratamiento de datos eficaz, capaz de revelar características útiles para el diagnóstico en base a información latente dentro de las propias señales crudas. Esta clase de procedimiento es crítico, dado que las señales, en su estado original, presentan un alto nivel de ruido e información redundante que obstaculizan una interpretación directa por parte de un modelo de diagnóstico [10]. En consecuencia, una etapa de preprocesamiento sobre los datos resulta indispensable para mitigar la información irrelevante y acentuar los patrones espectrales característicos asociados al comportamiento del MI bajo operación saludable y condiciones de falla.

En este contexto, las herramientas de tratamiento de datos implementadas en este trabajo son las siguientes:

1. Aplicación de estrategias de aumento de datos.
2. Obtención del módulo del vector de Clarke de corrientes eléctricas.
3. Aplicación de transformada tiempo-frecuencia.
4. Conversión de información gráfica a formato tensorial.

Con respecto a la primera herramienta, es menester considerar que la robustez de los modelos de IA de clasificación basados en el aprendizaje profundo, como el planteado para el sistema de diagnóstico de la presente memoria de titulación (tratado con mayor profundidad en la Sección 6.3), depende del volumen de datos empleados para su proceso de entrenamiento [13]. Es por ello que, si es que se maneja una base de datos reducida, es posible mejorar el desempeño de un modelo de clasificación si es que se aplican Estrategias de Aumento de Datos (EAD). Esta clase de técnicas consisten en incrementar sintéticamente el número de muestras disponibles mediante la generación de copias ligeramente modificadas a partir de los datos originales. De este modo, la implementación de estas técnicas permite conseguir una mejor variabilidad estadística del conjunto de datos sin la necesidad de recolectar muestras adicionales, de esta forma mejorando la capacidad de

generalización del modelo y disminuyendo el riesgo de sobreajuste con respecto al conjunto de datos de entrenamiento original.

La segunda herramienta de preprocesado es de aplicación exclusiva sobre las señales de corriente trifásicas, siendo incoherente su aplicación sobre registros vibratorios. Esta consiste en la extracción del módulo del vector de Clarke mediante la transformada estacionaria homónima. Este procedimiento matemático permite proyectar las tres fases originales del MI hacia un marco de referencia bidimensional y ortogonal, donde la dinámica eléctrica queda descrita por sus componentes espacial real e imaginaria. A partir de la composición geométrica de estas señales, el módulo del vector resultante para cada instante temporal, sienta esta la variable en cuestión. La implementación de esta estrategia garantiza que la red neuronal sea entrenada con una mayor densidad de información representativa de las fallas estudiadas, sin comprometer de sobremanera el rendimiento computacional durante su proceso de aprendizaje.

En el caso de la tercera herramienta, esta consiste principalmente en la transformación de las señales crudas a espectrogramas, los cuales son representaciones gráficas bidimensionales (imágenes) que contienen un mapa de calor relativo a la densidad energética de cada componente del espectro de frecuencia a lo largo de la ventana de medición.

Por último, la cuarta herramienta aborda un requisito estructural del modelo de IA propuesto: que las imágenes de entrada (espectrogramas) posean una estructura de datos tensorial. Esta exigencia se satisface mediante la transformación gráfica RGB (siglas en inglés de los colores rojo, verde y azul). Este método descompone la imagen de entrada en tres matrices independientes (denominadas “canales”), donde cada una representa la intensidad de los componentes rojo, verde y azul que conforman cada píxel de la imagen [13], generando así una estructura de datos admisible por el modelo en cuestión.

En las siguientes secciones se profundiza en cada una de las herramientas que conforman el sistema de tratamiento de datos utilizado. Abarcando desde la primera modificación estructural de las señales físicas; la transformada tiempo-frecuencia, hasta la posterior adaptación tensorial de la información. De esta forma, estableciendo el nexo desde los datos crudos hasta la arquitectura de IA propuesta para el sistema de diagnóstico.

3.1. Estrategias de aumento de datos

Tradicionalmente, las EAD utilizadas en el contexto de redes neuronales convolucionales (arquitectura empleada en el modelo implementado en la presente memoria de título) se fundamentan en la aplicación de modificaciones gráficas y/o estructurales sobre las imágenes de entrada, tales como rotaciones, inversiones o alteraciones cromáticas [13]. Sin embargo, en el contexto de análisis de señales, la implementación directa de alguna de estas técnicas visuales resulta inviable, ya que violaría la lógica interna que poseen este tipo de datos: la estricta interdependencia secuencial derivada de su naturaleza temporal.

Para sortear esta limitación intrínseca de las técnicas tradicionales, autores como Vishwakarma et. al [37] han adoptado la estrategia de incorporación de Ruido Blanco Gaussiano Aditivo (AWGN, por sus siglas en inglés) para aumentar su batería de datos. Esta técnica busca simular la acción de perturbaciones ambientales estocásticas que afectan a una señal física, siendo de esta forma una EAD coherente con la estructura secuencial de los datos en cuestión. En su investigación, los autores demuestran que la integración de AWGN durante la fase de entrenamiento obliga al modelo convolucional a extraer carac-

terísticas subyacentes más robustas, logrando un desempeño superior en comparación con el entrenamiento basado exclusivamente en el conjunto de datos original (sin EAD).

Por otra parte, Zhang et. [38] implementan AWGN en el contexto de un modelo de clasificación de estados de un MI trifásico, empleando señales de vibración crudas. Si bien en su estudio esta técnica no fue empleada estrictamente como una EAD para expandir el conjunto de entrenamiento, los autores utilizaron señales contaminadas bajo diversos niveles de AWGN con el objetivo de simular condiciones de contaminación reales inherentes al contexto de producción industrial. Sus resultados evidencian el beneficio directo de exponer el modelo a estas perturbaciones: al someter la red neuronal a escenarios con una baja relación señal-ruido, el sistema de diagnóstico logra mantener precisiones superiores al 90 % para niveles de relación señal-ruido entre ± 4 [dB] sin requerir algún tipo de filtrado o preprocesamiento de eliminación de ruido. De esta forma, su investigación valida al AWGN como una herramienta que, lejos de degradar el valor que posee un conjunto de datos contaminados para la representación de los fenómenos físicos relativos a una falla, es útil para aumentar la robustez del modelo ante perturbaciones propias del entorno operativo.

En concordancia con ambas investigaciones, se espera que la implementación de la incorporación de AWGN como EAD durante el proceso de entrenamiento del modelo propuesto en esta memoria represente un doble beneficio: por un lado, incrementar el desempeño clasificatorio general y, por el otro, obligar al modelo a aprender características de falla que sean invariantes al ruido. Esta estrategia proyecta un aumento significativo en la robustez y la capacidad de generalización del sistema frente a los escenarios de operación reales y comúnmente ruidosos que enfrentan los MI.

Para materializar esta EAD, en términos técnicos, el procedimiento consiste en sumar matemáticamente el ruido gaussiano en cuestión sobre cada señal cruda de forma previa a la implementación de cualquier tipo de transformada espectral (como lo puede ser la elaboración de un espectrograma), siguiendo la siguiente relación:

$$x_r(t) = x(t) + r_g(t) \quad (3.1)$$

Donde $x(t)$ representa la señal física original, mientras que $x_r(t)$ es la señal con ruido añadido y $r_g(t)$ el ruido gaussiano en cuestión, el cual viene definido por la expresión (3.2).

$$r_g(t) \sim N(0, p_r \cdot \sigma_x) \quad (3.2)$$

Esta formulación establece que el AWGN se define con media cero (para no alterar el propio valor medio o *offset* de $x(t)$) y desviación estándar proporcional a la de la señal original σ_x ponderada por el parámetro p_r , el cual actúa como un coeficiente de severidad, permitiendo controlar la magnitud de la perturbación añadida.

Finalmente, de forma complementaria a la inyección de ruido, se implementa la EAD de ventaneo temporal de las muestras. En esta técnica consiste en fraccionar una señal de larga duración en dos o más segmentos homogéneos de menor longitud. De esta forma, es posible aumentar significativamente el volumen del conjunto de datos disponible sin alterar la coherencia física inherente a las señales operativas de un MI. La efectividad en la implementación de esta EAD se puede apreciar en el artículo de Zhang et. al [38] tratado anteriormente, donde la aplicación de esta técnica permitió que su modelo basado en una arquitectura convolucional extrajera características del conjunto de datos aumentado de forma tal de lograr un 100 % de precisión en la clasificación de fallas sobre los registros

analizados. Tomando este precedente empírico, la implementación del ventaneo temporal en el conjunto de datos del presente sistema de diagnóstico augura la generación de un conjunto de datos lo suficientemente representativo como para estimular la capacidad de aprendizaje del modelo, esperando con esto obtener un mejor desempeño en comparación a un escenario sin su aplicación.

3.2. Vector de Clarke de corriente eléctrica

En el ámbito del monitoreo de condiciones del MI, el procesamiento tradicional para las señales de corriente de estator suele centrarse en la técnica de Análisis de Firma de Corriente de Estator (MCSA, por sus siglas en inglés) [3]. Esta técnica se fundamenta en la evaluación individual de las señales dentro del dominio de la frecuencia, buscando indicadores del estado del activo a través del estudio de la presencia y evolución en el tiempo de componentes armónicos y/o modulaciones características de falla (como los presentados en (2.4) y (2.5) dentro de la Sección 2). Si bien, este enfoque unidimensional es ampliamente utilizado, analizar las fases de manera aislada presenta una limitación intrínseca: puede enmascarar dinámicas electromagnéticas acopladas que afectan al sistema trifásico en su conjunto, lo cual puede limitar la robustez de un modelo de IA basado en el procesamiento de estas señales.

Para superar esta restricción es menester transicionar hacia un análisis multivariable que trate al sistema del estator como una entidad unificada. Considerando que esta necesidad solucionarse incorporando simultáneamente las tres señales de corriente como entrada a un modelo de detección de fallas, dicha estrategia naturalmente aumentaría de forma drástica la dimensionalidad de los datos, implicando un costo computacional considerable tanto en la fase de entrenamiento como en la etapa de inferencia del modelo en comparación con el caso monovariable.

Con el objetivo de abordar esta compromiso entre eficiencia computacional y representatividad de los fenómenos físicos, una herramienta matemática idónea es la obtención del módulo del vector de Clarke en el tiempo, el cual se deriva a partir de la aplicación de la transformada homónima sobre las corrientes trifásicas de estator. Esta transformación lineal permite proyectar las tres magnitudes de fase originales (desplazadas en 120° entre sí) hacia un marco de referencia ortogonal bidimensional, definido por los ejes ortogonales α y β (componentes real e imaginario respectivamente).

Para llevar a cabo esta proyección espacial, a la vez de preservar la magnitud física original de las corrientes (evitando así incurrir en alguna alteración en la densidad de energía de la señal durante el preprocesamiento), se emplea la variante de la transformada invariante en amplitud. Matemáticamente, esta se define mediante la siguiente relación matricial [28]:

$$\begin{bmatrix} i_\alpha(t) \\ i_\beta(t) \\ i_0(t) \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} i_a(t) \\ i_b(t) \\ i_c(t) \end{bmatrix} \quad (3.3)$$

Cabe destacar que, para un sistema trifásico con neutro levantado, naturalmente se cumple la siguiente relación:

$$i_a(t) + i_b(t) + i_c(t) = 0 \quad (3.4)$$

En consecuencia, al desglosar el componente de secuencia cero de la relación (3.3), es posible aplicar (3.4) para deducir la siguiente propiedad fundamental de la Transformada

de Clarke en el contexto de diagnóstico:

$$i_0(t) = \frac{1}{3} (i_a(t) + i_b(t) + i_c(t)) = 0 \quad (3.5)$$

De esta forma, a partir de (3.5) se establece un sistema en donde la totalidad de la dinámica de las corrientes del estator queden contenidas y descritas por sus componentes ortogonales $i_\alpha(t)$ y $i_\beta(t)$, a partir de las cuales se conforma el vector de Clarke de corriente de estator ($i_s(t)$). En el contexto del diagnóstico de fallas, la característica de mayor interés analítico de esta variable se encuentra en la evolución de su módulo en el tiempo, siendo esta definida por la relación siguiente:

$$|i_s(t)| = \sqrt{i_\alpha(t)^2 + i_\beta(t)^2} \quad (3.6)$$

El aspecto clave de esta métrica radica en su interpretación física y geométrica, ya que en un MI operando bajo condiciones saludables y bajo alimentación balanceada, las señales $i_\alpha(t)$ y $i_\beta(t)$ son ondas sinusoidales puras, de igual amplitud y desfase simétrico de 90° . De este modo, al graficar el lugar geométrico de estas componentes en el plano bidimensional, la trayectoria resultante traza una circunferencia perfecta. En consecuencia, la variable $|i_s(t)|$ adquiere un valor estrictamente constante, equivalente al radio de dicha circunferencia [28].

Ante cualquier alteración de las condiciones ideales anteriormente planteadas (tales como una alimentación desbalanceada o falla por cortocircuito en espiras) la distribución espacial del campo magnético de la máquina se ve alterada, rompiendo su simetría. Este fenómeno electromagnético induce la aparición de componentes de secuencia negativa en las corrientes de de estator. En el plano $\alpha\beta$, la presencia de estos componentes distorsiona la trayectoria circular ideal del lugar geométrico, achatándola hasta convertirla en una elipse [39]. El efecto directo de esta deformación es que el radio del vector espacial deja de ser constante, lo cual implica que el módulo $|i_s(t)|$ comienza a exhibir oscilaciones superpuestas a su valor constante, las cuales poseen una frecuencia y amplitud directamente relacionadas a los componentes frecuenciales característicos de las fallas previamente analizadas.

Según lo anteriormente descrito, la extracción de la señal $|i_s(t)|$ constituye una estrategia eficaz para la reducción de dimensionalidad durante el proceso de tratamiento de datos de entrada al modelo de IA tratado en el presente documento. La principal ventaja de este enfoque radica en su capacidad para comprimir la dinámica simultánea de las tres fases del estator en una única variable temporal unidimensional, disminuyendo drásticamente el costo computacional del modelo sin sacrificar la riqueza de los registros de corriente. Por consecuencia, la determinación del módulo del vector de Clarke se establece como una herramienta fundamental en el proceso de tratamiento de datos ligados, naturalmente, de forma exclusiva a los registros de corriente eléctrica.

3.3. Análisis tiempo-frecuencia

El Análisis Tiempo-Frecuencia (ATF) es una herramienta que, a diferencia de los métodos restringidos a un único dominio, determina el contenido espectral de una señal considerando su evolución temporal a lo largo de una ventana de medición. De este modo, el ATF permite representar la densidad energética de una señal en forma de una superficie bidimensional con coordenadas representativas del tiempo y la frecuencia [40]. En consecuencia, a través del ATF, es posible crear el espectrograma de una señal.

Sin embargo, la aplicación de estas técnicas de ATF se encuentran intrínsecamente condicionadas por el principio de incertidumbre de Heisenberg. En el contexto del análisis de señales, este límite teórico establece la imposibilidad de determinar con precisión absoluta y simultánea la ubicación temporal y frecuencial de un evento dentro de la señal [40]. Esta restricción impone un compromiso entre resoluciones, tal que un aumento en la precisión en un dominio impone una degradación en el otro. Por ello, la elección de la técnica de ATF resulta crítica para resaltar eficazmente los patrones de falla y facilitar el aprendizaje del modelo de IA.

Entre las técnicas más consolidadas de ATF se encuentran la Transformada de Fourier de Tiempo Corto (STFT, por sus siglas en inglés) y la Transformada de Wavelet (WT, por sus siglas en inglés) [9]. La primera fundamenta su operación en la segmentación de una señal mediante una ventana temporal de ancho fijo que se desliza a lo largo del eje de tiempo, determinando la transformada de Fourier localmente dentro de cada segmento [41]. Este enfoque genera una representación uniforme del espectro, aunque impone una limitación intrínseca: el compromiso entre resolución temporal y frecuencial queda pre-determinado por el tamaño de ventana seleccionado, el cual permanece constante durante todo el análisis.

Por su parte, la WT opera mediante la descomposición de la señal a través de su convolución con versiones escaladas y trasladadas de una función base, denominada “*wavelet madre*”. Este mecanismo permite adaptar la resolución de análisis según la frecuencia. Además, el uso de *wavelets* de dominio complejo permite recuperar la fase instantánea de los componentes frecuenciales en la ventana de análisis. Sin embargo, esta ventaja conlleva un costo computacional significativamente mayor, dado que exige el cálculo de coeficientes sobre un dominio continuo de escalas para componentes reales e imaginarias, aumentando el costo de su implementación frente a otras técnicas.

En este escenario emerge la Transformada de Stockwell (ST), la cual integra ventajas de la STFT y la WT en una única herramienta de análisis. Esta transformada conserva una relación directa con la base operativa de Fourier, pero incorpora una ventana gaussiana adaptativa que se dilata a medida que se traslada a lo largo del espectro de frecuencia de la señal sobre la cual se aplica. Esta característica permite a la ST otorgar un mapa dinámico relativo al nivel energético de cada componente frecuencial dentro de la señal, empleando ventanas de análisis angostas en altas frecuencias (priorizando la resolución temporal) y ventanas amplias en bajas frecuencias (priorizando la resolución espectral) [42]. La base teórica con la cual opera esta transformada se detalla en la siguiente subsección.

3.3.1. Transformada de Stockwell

La transformada de Stockwell (ST) fue propuesta originalmente por Stockwell et. al en el 1996 con el objetivo de desarrollar un método de representación tiempo-frecuencia que ofreciera una resolución dinámica de una señal, pero sin perder la relación directa con su transformada de Fourier [42].

La derivación matemática de esta herramienta se fundamenta en una extensión de la Transformada de Wavelet Continua (CWT, por sus siglas en inglés), sobre la cual se aplica una (denominada por los autores) “corrección de fase”. A modo ilustrativo del desarrollo, se muestra la CWT de una señal $x(t)$, utilizando la *wavelet madre* w_m , obteniendo su

expresión matemática [42]:

$$W_x(\tau, a) \int_{-\infty}^{\infty} x(t) \cdot w_m(t - \tau, a) dt \quad (3.7)$$

En donde a es el factor de dilatación, la cual es la variable representativa del ancho de la *wavelet* madre w_m , controlando directamente la resolución misma de la transformada. En este contexto, Stockwell invoca la relación directa entre a y el inverso de la frecuencia de análisis f . Entonces, bajo esta premisa, es posible definir la siguiente *wavelet* madre:

$$w_m(t, f) = \frac{|f|}{\sqrt{2\pi}} \cdot e^{-\frac{t^2 f^2}{2}} \cdot e^{-i2ft} dt \quad (3.8)$$

A partir de esta base es que se constituye la ST aplicando un término de corrección de fase ($e^{i2\pi \cdot f\tau}$) sobre la estructura convencional de la CWT mostrada en (??) tal que, utilizando la *wavelet* madre (3.8), se defina la transformada en cuestión para la señal $x(t)$ mediante (3.9).

$$S_x(\tau, f) = e^{i2\pi \cdot f\tau} \cdot W_x(\tau, f) \quad (3.9)$$

Entonces, al desarrollar (3.9), se obtiene la expresión general de la ST en tiempo continuo:

$$S_x(\tau, f) = \int_{-\infty}^{\infty} x(\tau) \cdot \frac{|f|}{\sqrt{2\pi}} \cdot e^{-\frac{(t-\tau)^2 f^2}{2}} \cdot e^{j2\pi f\tau} d\tau \quad (3.10)$$

De esta forma, el componente $\frac{|f|}{\sqrt{2\pi}} \cdot e^{-\frac{(t-\tau)^2 f^2}{2}}$ actúa como la ventana gaussiana móvil característica de esta transformada. Este término, al depender de la frecuencia mediante el factor de dilatación a (equivalente al inverso de la frecuencia), permite ajustar dinámicamente la ventana gaussiana. Esta propiedad se basa en que, a medida que la frecuencia aumenta, el término f^2 comprime la ventana en el dominio temporal, incrementando la precisión para localizar eventos transitorios rápidos dentro de la señal. De manera inversa, cuando la frecuencia disminuye, la ventana se dilata, lo que sacrifica localización temporal para maximizar la resolución espectral.

Finalmente, se establece una propiedad fundamental: la integración de la ST a lo largo del tiempo equivale al espectro de Fourier global de la señal $x(t)$, denotado como $X(f)$. Esta característica implica que la ST representa una descomposición lineal del espectro de Fourier, relación que se formaliza mediante

$$X(f) = \int_{-\infty}^{\infty} S_x(\tau, f) d\tau \quad (3.11)$$

Naturalmente, de (3.11) se deriva la relación:

$$x(t) = \int_{-\infty}^{\infty} \left\{ \int_{-\infty}^{\infty} S_x(\tau, f) d\tau \right\} \cdot e^{i2\pi ft} df \quad (3.12)$$

De esta forma, al basarse en la transformada de Fourier, la implementación de la ST puede beneficiarse de la eficiencia de cómputo que caracteriza el cálculo de este tipo de herramientas (como la técnica de transformada rápida de Fourier) [42]. Esto reduce drásticamente la complejidad de cálculo, asegurando la viabilidad de su aplicación para grandes conjuntos de datos.

A modo de rigor técnico, Stockwell et. al advierten que (3.11) demuestra el hecho de que la ST viola el fundamento matemático de la CWT. Esta cualidad radica en el hecho de que (3.8), como “*wavelet*” madre, no posee media cero, por lo cual incumple una condición fundamental para su aplicación dentro de este tipo de transformada tiempo-frecuencia. En consecuencia, la ST no constituye una CWT formal, sino que emplea su estructura matemática de forma auxiliar para así poder deducir su definición formal [42].

Por otra parte, a partir de (3.10), se extrae una de las principales cualidades de la ST: la conservación de la fase absoluta de la señal. Esta característica se atribuye al componente complejo $e^{j2\pi f\tau}$, el cual fija a los componentes moduladores de la ST al eje del tiempo, estableciendo una referencia en fase absoluta al origen, mientras que se solo la ventana gaussiana se desplaza por el espectro.

Esta propiedad resulta sumamente relevante para la interpretación sincronizada de múltiples señales simultáneas, ya que garantiza que ningún componente del espectro de frecuencia se ve desplazado en el dominio del tiempo, permitiendo correlacionar eventos transitorios que se manifiestan coordinadamente en múltiples tipos de señales, sin errores de alineación.

Naturalmente, la combinación de estas propiedades convierte a la ST en una herramienta atractiva para el uso en el preprocesado de las señales de vibración y corriente asociadas a la operación de un MI en situación de falla, donde coexisten componentes estacionarias y transitorias. Por esta razón, la ST es la técnica seleccionada para implementar dentro del sistema de diagnóstico, ya que su capacidad para generar representaciones espectrales con resolución adaptativa y preservación explícita de la fase facilita la identificación de patrones multinivel por parte del modelo de IA implementado.

3.4. Conversión tensorial de espectrogramas

El modelo de IA desarrollado en este trabajo impone requisitos estrictos sobre la estructura de los datos de entrada, los cuales deben poseer un formato de arreglos numéricos estructurados (tensores). Dado que los espectrogramas generados a partir de las técnicas de ATF poseen una naturaleza gráfica bidimensional (imágenes), es necesario adaptar su formato para coincidir con el solicitado por el modelo.

Con el fin de satisfacer esta necesidad, se implementa un proceso de conversión de imágenes al formato de codificación RGB (del inglés “*Red, Green and Blue*”). Esta técnica consiste en descomponer el color específico de cada píxel de la imagen en tres componentes independientes (denominados “canales”), los cuales cuantifican la intensidad relativa de los colores rojo, verde y azul que conforman su tonalidad cromática específica. El valor numérico asignado a cada componente se encuentra dentro de un rango de 0 a 255, siendo la magnitud directamente proporcional a la intensidad del color correspondiente [13]. A modo ilustrativo, en la Tabla 3.1 se presentan algunos colores básicos junto con su codificación asociada en formato RGB.

Tabla 3.1. *Combinaciones de valores de los tres canales RGB que dan como resultado colores básicos.*

| Color del píxel | Valor R | Valor G | Valor B |
|-----------------|---------|---------|---------|
| Rojo puro | 255 | 0 | 0 |
| Verde puro | 0 | 255 | 0 |
| Azul puro | 0 | 0 | 255 |
| Blanco | 255 | 255 | 255 |
| Negro | 0 | 0 | 0 |

En términos estructurales, los tres canales que genera la transformación consisten en matrices independientes que almacenan los valores de intensidad cromática relativos a cada uno de los píxeles de la imagen original. La combinación de estas tres matrices origina un arreglo tridimensional (tensor) de dimensiones $3 \times L \times A$, donde L y A representan el largo y alto en píxeles de la imagen convertida [13]. Un esquema ilustrativo de este proceso de transformación se muestra en la Figura 3.1.

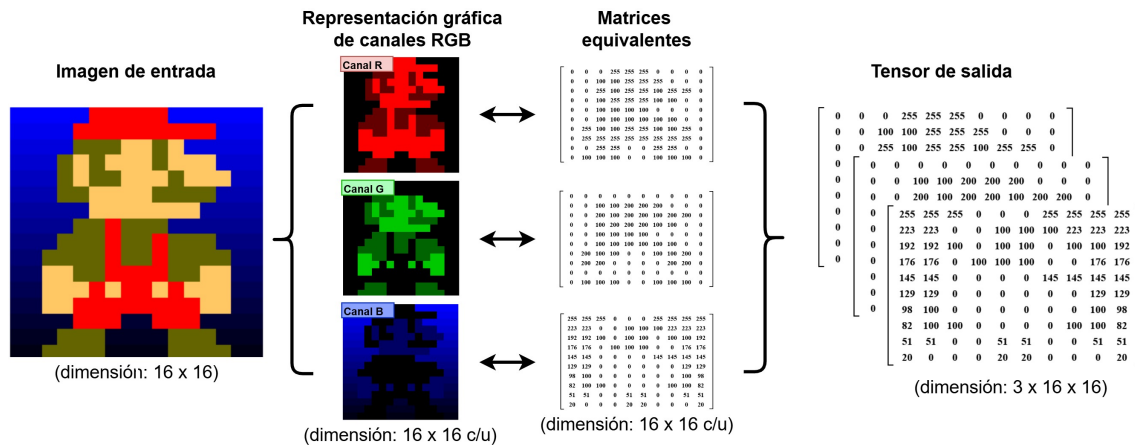


Figura 3.1. *Representación estructural de la aplicación de la transformada RGB sobre una imagen de entrada.*

Capítulo 4

Algoritmos de inteligencia artificial

4.1. Antecedentes

El diagnóstico de fallas en máquinas eléctricas consiste en la evaluación sistemática de la condición operativa del activo, con el objetivo de detectar desviaciones respecto a su comportamiento nominal. Ante la presencia de una anomalía, los esfuerzos de mantenimiento predictivo se orientan a identificar la localización y los componentes afectados mediante el análisis de patrones característicos asociados a la anomalía en cuestión. Bajo esta premisa, en la literatura se aborda la detección de fallas incipientes como un problema de clasificación de estados, fundamentado en el reconocimiento de patrones complejos dentro de los datos operativos del MI [43].

Debido a la naturaleza estocástica y a la alta variabilidad de las señales capturadas en entornos industriales, el proceso de diagnóstico de fallas rara vez se realiza sobre los datos crudos. Por el contrario, se requiere de una etapa de preprocesamiento orientada a acentuar los atributos relevantes para el diagnóstico, transformando la información original en representaciones de mayor jerarquía, conocidas como “características”. Es en este contexto donde los algoritmos de IA basados en DL han emergido como herramientas de gran eficacia, debido a su capacidad para extraer estas características y modelar autónomamente relaciones no lineales en ellas, las cuales pueden pasar inadvertidas por métodos de análisis convencionales. Esta cualidad permite automatizar la clasificación del estado de un MI sin la necesidad de programar reglas de decisión explícitas, facilitando el monitoreo de condiciones en ambientes industriales que concentren una amplia cantidad de activos.

No obstante, a pesar de los múltiples beneficios que ofrecen los modelos de DL para el monitoreo de condiciones, existe un desafío inherente relativo al cómo se procesa la información para generar una salida; es decir, en la forma en que el algoritmo toma decisiones a partir de las características extraídas. En la literatura, a este desafío se le conoce como “problema de la caja negra”⁷ [44, 45]. Este surge de la lógica operativa inherente a las arquitecturas de redes neuronales, en la cual la información fluye a través de una vasta red de parámetros interconectados mediante operaciones algebraicas y transformaciones no lineales hasta elaborar una predicción. En consecuencia, las relaciones entre los datos de entrada que la red aprende para deducir este diagnóstico son altamente abstractas, dificultando la comprensión de los criterios exactos que conducen a cada salida determinada

⁷Traducción del inglés “*black box problem*”.

(mayor detalle de este principio de operación disponible en la Sección [4.2.1](#)).

Esta opacidad algorítmica es un tema de estudio transversal en múltiples disciplinas tales como la legalidad [\[44\]](#), la medicina y, por supuesto, el monitoreo de condiciones de maquinaria industrial [\[45\]](#). En este último foco, la escasa interpretabilidad plantea naturalmente un reto respecto a la confianza depositada en este diagnóstico automatizado. Sin embargo, lejos de invalidar la utilidad de estas herramientas, este desafío subraya la necesidad de comprender a cabalidad los fundamentos algorítmicos que las rigen. Asimismo, evidencia que el DL no busca reemplazar el juicio experto dentro de las cadenas productivas, sino posicionarse como un sistema de soporte a la toma de decisiones, donde el especialista humano utiliza las predicciones del modelo para realizar la evaluación final y determinar las acciones de mantenimiento que correspondan con la condición del activo analizado.

En virtud de lo anterior, el presente capítulo profundiza en los fundamentos teóricos de los modelos seleccionados para el desarrollo del sistema de diagnóstico de fallas tratado en este documento. En primer lugar, se describen las RRNN Totalmente Conectadas (FC, por sus siglas en inglés) como la arquitectura básica del DL, para luego transicionar a modelos más sofisticados como las CNN y RNN. Finalmente, se detalla el algoritmo de optimización de hiperparámetros Optuna, siendo este una herramienta fundamental para la realización de búsquedas automatizadas de configuraciones paramétrico-estructurales para las RRNN. Por último, este capítulo concluye con la presentación de métricas de desempeño utilizadas para cuantificar el desempeño de los modelos de clasificación basados en DL.

4.2. Arquitecturas de aprendizaje profundo

4.2.1. Redes neuronales totalmente conectadas y funciones de activación

Las redes neuronales Totalmente Conectadas (o FC, por sus siglas en inglés) constituyen un algoritmo fundamental dentro del DL, ya que representan la estructura fundamental sobre la cual se desarrollan arquitecturas más complejas. El elemento primordial de este tipo de algoritmo es la neurona artificial, la cual representa un modelo matemático basado en el comportamiento de sus homólogas biológicas. En términos operativos, cada neurona recibe un conjunto limitado de entradas (x_i) que son ponderadas mediante parámetros ajustables denominados como “pesos” (w_i), los cuales determinan la importancia que tiene alguna entrada i con respecto al valor de la salida (h). Adicionalmente, en cada neurona se incorpora un valor de sesgo (b), el cual actúa como un ajuste en el valor resultante de la suma ponderada de todas las entradas. Esta interrelación paramétrica define el funcionamiento básico de las RRNN, representándose matemáticamente a partir de la siguiente expresión [\[13\]](#):

$$h'(x) = \sum_{i=1}^n w_i \cdot x_i + b \quad (4.1)$$

Notar que [\(4.1\)](#) establece una relación esencialmente lineal entre las variables del sistema. No obstante, la capacidad de las RRNN para modelar patrones no lineales en el conjunto de datos de entrada proviene de las denominadas “funciones de activación”. Estas funciones introducen transformadas no lineales que se aplican dentro de cada neurona, convirtiendo el cómputo algebraico simple en una salida capaz de representar jerarquías y dependencias no lineales. A partir de este proceso, es posible establecer patrones complejos

entre los datos de entrada a través de, por ejemplo, activaciones condicionales entre capas neuronales.

Entre las funciones de activación más utilizadas en la literatura, se encuentran las siguientes [13, 46]:

- **Sigmoide (σ):**

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4.2)$$

Esta función transforma cualquier valor real en un rango entre 0 y 1, lo cual permite dar una interpretación probabilística del resultado de una neurona. Esto es particularmente útil en problemas de clasificación binaria. Sin embargo, su costo computacional tiende a ser mayor que otras funciones de activación debido a la necesidad de cálculo de un valor exponencial.

- **ReLU:**

$$ReLU(x) = \max(x, 0) \quad (4.3)$$

Del inglés “*Rectified Linear Unit*”, esta es una función simple y eficiente, la cual asigna valor cero a cualquier entrada negativa y no altera su valor en caso contrario. Es ampliamente utilizada en arquitecturas de RRNN de DL debido a su bajo costo computacional y simplicidad. A pesar de acelerar la convergencia del entrenamiento, puede inducir el fenómeno de “*dying ReLU*”, en el cual ciertas neuronas resultan inactivas permanentemente al emitir siempre un valor de cero, dejando de contribuir al aprendizaje de la red.

- **Softmax:**

$$\text{softmax}(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad (4.4)$$

A diferencia de las anteriores, esta función se aplica generalmente en la capa de salida de modelos de clasificación multiclase. Su objetivo es normalizar el vector de valores reales resultante en una distribución de probabilidad, donde la suma de todas las salidas es igual a 1. Esto permite identificar la confianza del modelo hacia cada una de las clases posibles.

Entonces, a partir de la implementación de una función de activación cualquiera (FA) sobre la suma de pesos y sesgos representada en (4.1), se establece la relación final entre el conjunto de entradas x y la salida efectiva de la neurona y a través de la siguiente expresión:

$$h = FA\{h'(x)\} = FA \left\{ \sum_{i=1}^n w_i \cdot x_i + b \right\} \quad (4.5)$$

A partir de la definición mononeuronal de (4.5), se definen las redes FC como un sistema interconectado de capas de neuronas, cada una con sus propios pesos, sesgos y funciones de activación (según corresponda). Bajo esta premisa, la forma más básica de formar una FC consiste en organizar un conjunto de neuronas en tres capas: entrada, intermedia (denominadas “ocultas”) y de salida. A partir de esta estructura jerárquica es posible establecer relaciones de complejidad creciente a partir de la información de entrada [13]. En la Figura 4.1 se ilustra gráficamente la relación de conexión total entre las tres capas antes comentadas.

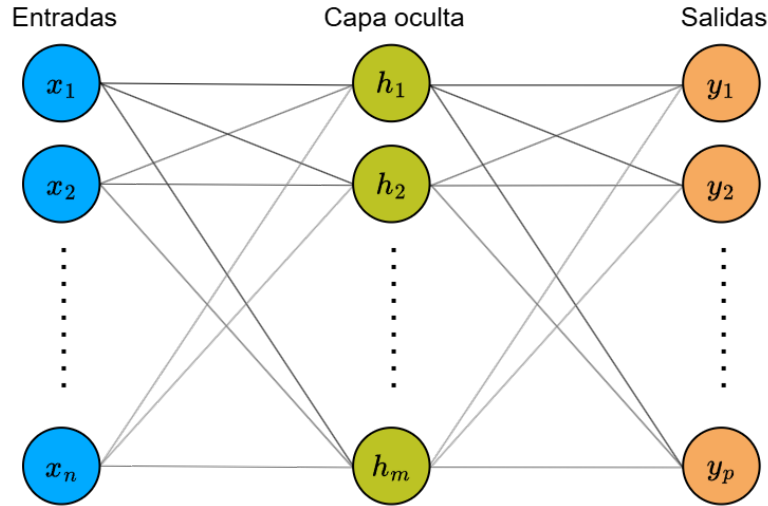


Figura 4.1. Diagrama de una red neuronal totalmente conectada con una capa oculta.

En presencia de una capa oculta, la relación entre una neurona de salida y_k (donde $k \in \{1, p\}$) y las n entradas se establece a través de cada neurona de la capa oculta h_j . Estas interacciones se describen a través de (4.6) y (4.7).

$$y_k = \sum_{j=1}^m w_{jk} \cdot h_j + b_k \quad (4.6)$$

$$h_j = FA \left\{ \sum_{i=1}^n w_{ij} \cdot x_i + b_j \right\} \quad (4.7)$$

Al sustituir (4.7) en (4.6), se obtiene la relación escalar final entre una neurona de salida y las entradas de la red FC.

$$y_k = \sum_{j=1}^m w_{jk} \cdot FA \left\{ \sum_{i=1}^n w_{ij} \cdot x_i + b_j \right\} + b_k \quad (4.8)$$

Generalizando esta expresión a todas las p salidas posibles, es posible agrupar todas las entradas, neuronas de la capa oculta y salidas de la red. De esta forma, formulando la relación matricial compacta de (4.8) a través de (4.9).

$$\mathbf{Y} = \mathbf{W}_{jk} \cdot \mathbf{H} + \mathbf{b}_k \quad (4.9)$$

Donde \mathbf{Y} , \mathbf{H} y \mathbf{X} representan un vector de p cantidad de salidas, m neuronas ocultas y n entradas respectivamente. A su vez, los vectores de sesgos \mathbf{b} y las matrices de pesos \mathbf{W} representan los parámetros respectivos de cada capa y unión entre capas de neuronas. Cabe destacar que este modelo algebraico puede ser extendido a cualquier número de capas ocultas, admitiendo una profundidad arbitraria en la arquitectura de una red FC.

Sea un modelo de clasificación fundamentado en la presente arquitectura de redes neuronales, es posible considerar al elemento y_k de mayor valor dentro de \mathbf{Y} como la predicción

final ante un vector de entradas \mathbf{X} . En este escenario, se evidencia que el proceso en el cual el modelo toma la decisión de su diagnóstico se basa en las interrelaciones matemáticas que existen entre sus parámetros entrenables. Esta dinámica operativa provoca que los criterios de clasificación sean altamente abstractos (especialmente ante un número elevado de neuronas). Es esta falta de transparencia estructural de donde emana el problema de la caja negra introducido en la Sección 4.1. Naturalmente, este desafío de interpretabilidad se extiende para arquitecturas de redes neuronales más sofisticadas, tales como las que se tratarán en las siguientes subsecciones.

4.2.2. Redes neuronales convolucionales

Las RRNN convolucionales (CNN, por sus siglas en inglés), originalmente propuestas en 1998 por LeCun [47], constituyen una de las arquitecturas más relevantes en el ámbito del DL. Su principal aspecto diferenciador radica en la capacidad de procesamiento de datos basados en estructuras espaciales, tales como imágenes o videos. Mediante este enfoque, las CNN son capaces de identificar patrones altamente abstractos en los datos de entrada, traduciendo esta información en forma de mapas de características. En un modelo de clasificación, estos mapas son posteriormente analizados por algún otro algoritmo de decisión que determina el estado o categoría general de la información procesada [48].

El nombre de este tipo de arquitecturas se debe a la operación matemática de convolución, la cual describe el cómo una función modifica o filtra a otra mediante un proceso de superposición ponderada. De forma teórica, en tiempo continuo, la convolución se realiza considerando una señal principal $f(t)$ y un *kernel* o filtro $g(t)$, estableciendo la siguiente relación:

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau) \cdot g(t - \tau) d\tau \quad (4.10)$$

Al representar (4.10) en un contexto de tiempo discreto (característico dentro del contexto de señales digitales), se obtiene la expresión:

$$(f * g)[n] = \sum_{m=-n/2}^{n/2} f[m] \cdot g[n - m] \quad (4.11)$$

Donde n representa la longitud de secuencia de análisis sobre la cual se realiza la operación.

Al aumentar la dimensionalidad estructural de los datos, la convolución es aplicada sobre una representación matricial $I \times J$ de la entrada (donde I y J representan la altura y ancho) y un *kernels* de dimensiones $N \times M$, en donde $I > N$ y $J > M$. Cada uno de los *kernels* se desplaza sistemáticamente por la entrada, sumando los resultados de la multiplicación entre elementos de ambas matrices [48]. De forma bidimensional y discreta, esta operación de convolución se expresa de la siguiente forma [13]:

$$(\mathbf{F} * \mathbf{G})[i, j] = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \mathbf{F}[i + n, j + m] \cdot G[n, m] \quad (4.12)$$

Donde $F[i, j]$ representa el valor del píxel de la matriz de entrada en la posición (i, j) , $G[m, n]$ corresponde al valor respectivo del *kernel* en la posición señalada. Una representación simplificada de (4.12) se aprecia en la Figura 4.2, en donde, por ejemplo, para el

“Paso 1” se realiza la operación:

$$Salida_{11} = (1 \cdot 0) + (0 \cdot 1) + (-1 \cdot -1) + (0 \cdot 2) = 1$$

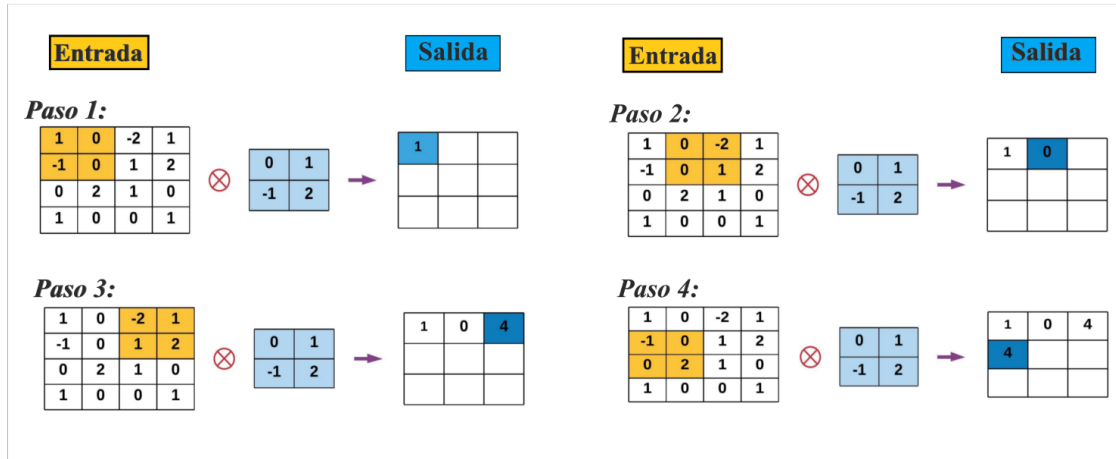


Figura 4.2. Esquema secuencial de la operación de convolución entre una matriz de 4×4 (entrada) y un kernel de 2×2 , creando una matriz de salida de 3×3 . Adaptado de [48].

La forma en la cual un *kernel* se desplaza sobre el largo y ancho de la matriz de análisis está determinada por los parámetros *stride* y *padding*. El primero de estos define el paso en píxeles que realiza el *kernel* entre cada iteración de cálculo, mientras que el segundo consiste en añadir filas y columnas de ceros alrededor de los bordes de la matriz original con el propósito de controlar el tamaño de la matriz de salida [48]. A modo de ejemplo, en la Figura 4.2 se aprecia una operación de convolución con *stride* de valor unitario y *padding* de cero.

En el contexto operativo de una CNN, se emplea la operación de convolución bidimensional descrita en (4.12) aplicando los parámetros entrenables de pesos y sesgos presentados en (4.9). El resultado de este proceso es la generación de tensores que, en términos de flujo de información en la red, representan los mapas de características extraídos a partir de la información de entrada. Este cambio estructural en la interpretación de (4.12) se refleja en la siguiente relación [13]:

$$\mathbf{H}_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \mathbf{W}_{i,j,n,m} \cdot \mathbf{X}_{i+n,j+m} + \mathbf{b}_{i,j} \quad (4.13)$$

En donde $\mathbf{H}_{i,j}$ representa el elemento del mapa de características en cuestión para la posición (i, j) . Por su parte, \mathbf{X} es la matriz de entrada, \mathbf{W} la matriz de pesos entrenables que conforman al *kernel* y, por último, $\mathbf{b}_{i,j}$ representa los sesgos asociados para la posición en cuestión. Cabe señalar que comúnmente los *kernels* conservan sus valores internos independientemente de la región de análisis de la matriz original (tal como se muestra en la Figura 4.2), lo cual permite aligerar la carga computacional al disminuir la cantidad de parámetros entrenables del modelo.

Una vez obtenida la matriz \mathbf{H} , se aplica una función de activación sobre de forma similar al procedimiento descrito en (4.5). Esta función se opera elemento por elemento sobre \mathbf{H} , permitiendo que la red tenga la capacidad de modelar relaciones no lineales a partir de sus datos de entrada sin afectar el proceso matemático de la operación convolucional.

Posteriormente, con el objetivo de mejorar la eficiencia computacional del modelo y de consolidar las características extraídas, se implementan capas de *pooling* luego de la aplicación de las funciones de activación. Estas capas realizan una reducción de dimensionalidad espacial sobre los mapas de características, preservando la información dominante en cada región localmente. Como resultado, el modelo adquiere cierta invariancia frente a pequeñas distorsiones en los datos de entrada. Pese a que existen múltiples tipos de estrategias en este apartado (tales como *pooling* de compuertas, *pooling* promedio o *minpooling*), la estrategia más utilizada con diferencia es la de *maxpooling*. Esta actúa reteniendo el valor máximo dentro de una región local de la matriz de entrada mediante el uso de una ventana de análisis de tamaño fijo [48]. Dicha ventana recorre la matriz de forma análoga al desplazamiento de un *kernel* en una capa convolucional, tal cual se describió anteriormente.

En resumen, el flujo de información sucesivo desde la capa convolucional, pasando por la función de activación hasta llegar a la capa de *pooling* constituye la estructura clásica de creación del mapa de características por parte de una CNN. De esta forma, es posible crear una arquitectura con múltiples apilamientos de estas capas, extrayendo características cada vez más refinadas dentro de mapas cada vez más pequeños (en términos dimensionales). Esta arquitectura jerárquica permite la captura de representaciones altamente abstractas a partir de los datos de entrada. Naturalmente, este procedimiento de extracción de características es escalable en términos dimensionales, siendo admisible desde el ejemplo bidimensional ya ilustrado, hasta un flujo de información n-dimensional mediante el uso de tensores. En este aspecto, por ejemplo, el sistema de conversión de imágenes por formato RGB descrito en la Sección 3.4 puede ser interpretado por una CNN mediante un análisis tensorial en tres dimensiones: largo, alto y número de canales (R, G y B).

4.2.3. Redes neuronales recurrentes

Las redes neuronales recurrentes, fundamentadas en los modelos de procesamiento distribuido desarrolladas por Rumelhari et. al en 1986 [49], corresponden a una arquitectura de DL diseñada específicamente para el procesado de información de naturaleza secuencial. Mientras que las CNN destacan por la extracción de características espaciales sobre muestras estáticas, las RNN tienen la capacidad de procesar dinámicas secuenciales (comúnmente relacionadas con series temporales). Esta cualidad les permite no solo evaluar una muestra de datos de forma aislada, sino comprender el contexto de su evolución en el tiempo.

En términos operativos, la principal diferencia entre una FC básica con respecto a la RNN radica en que esta última retiene información de eventos pasados durante su ejecución a través de conexiones dinámicas entre neuronas, las cuales establecen lazos de comunicación en los que se comparte información unilateralmente desde una neurona hacia otra de una capa siguiente, induciendo un comportamiento secuencial del flujo de datos que simulan la acción de pasos de tiempo adyacentes. De esta forma, se logra el

establecimiento de memoria interna denomina como “estado oculto” [13].

El funcionamiento técnico característico de una RNN se manifiesta al analizar la actualización de este estado oculto a lo largo de los pasos temporales. Este principio operativo es definido en base a (4.9) en donde, para un sistema de múltiples capas ocultas, la salida de una capa \mathbf{H} en el instante t no está determinada únicamente por sus parámetros entrenables y los datos de entrada. Por el contrario, su valor viene afectado de igual forma por el estado oculto del instante inmediatamente anterior. Esta dinámica se rige por la siguiente relación [13]:

$$\mathbf{H}_t = FA\{\mathbf{W}_{xh} \cdot \mathbf{X}_t + \mathbf{W}_{hh} \cdot \mathbf{H}_{t-1} + \mathbf{b}_h\} \quad (4.14)$$

Donde \mathbf{W}_{xh} representa la matriz de pesos asociada a la entrada en el instante t , \mathbf{W}_{hh} corresponde a su homólogo para el estado oculto del instante anterior ($t-1$) y \mathbf{b}_h el vector de sesgo respectivo para \mathbf{H}_t .

Considerando que el estado oculto representado en (4.14) es el último en la cadena secuencial, este consolida la información temporal completa acumulada por el sistema. En consecuencia, la capa de salida \mathbf{Y} se define mediante la siguiente expresión:

$$\mathbf{Y} = \mathbf{W}_{hq} \cdot \mathbf{H}_t + \mathbf{b}_q \quad (4.15)$$

Donde \mathbf{W}_{hq} y \mathbf{b}_q contienen los pesos y sesgos de esta última capa de salida en una RNN.

A pesar de la coherencia estructural que establecen las ecuaciones teóricas antes tratadas, la operación de una RNN tradicional presenta desafíos matemáticos significativos durante su fase de entrenamiento. Fundamentalmente, la optimización de los parámetros insertos en las matrices de pesos (\mathbf{W}) y vectores de sesgos (\mathbf{b}) se realiza típicamente mediante el algoritmo de retropropagación a través del tiempo, el cual calcula los gradientes del error entre el vector de predicciones de un modelo y los valores reales relativos a la etiqueta del dato predicho. Estos gradientes se propagan desde la salida hacia las capas traseras del modelo, ergo, desde el último instante temporal hasta el inicio de la secuencia [13].

Debido a la naturaleza recursiva que posee (4.14), la aplicación de la regla de la cadena utilizada para relacionar el estado oculto en un instante t con el estado inicial implica productos sucesivos de las matrices de peso \mathbf{W} entre cada una de las capas. Desde una perspectiva algebraica, si es que los valores propios de estas matrices son menores a la unidad, los gradientes experimentan un decaimiento exponencial a medida que se propagan desde t hacia atrás, el cual es un fenómeno conocido como “desvanecimiento de gradiente”. Naturalmente, para valores propios mayores a la unidad, ocurre el fenómeno inverso denominado “explosión de gradiente” [50].

Con el objetivo de mitigar la inestabilidad de los gradientes ante secuencias de gran extensión, Hochreiter y Schmidhuber propusieron en 1997 la arquitectura de redes recurrentes de Memoria a Corto y Largo Plazo (LSTM, por sus siglas en inglés) [50]. La operación de estas RRNN se fundamenta en la introducción de una estructura interna denominada “celda de memoria”, la cual sustituye a la recurrencia simple tradicional. La celda en cuestión permite regular internamente el flujo de información a través del tiempo mediante un mecanismo de compuertas, dotando al modelo de la capacidad de discriminar la información operativa histórica de acuerdo a su valor diagnóstico, pudiendo descartar información irrelevante bajo este criterio [13].

En términos arquitectónicos, el núcleo de la red LSTM se encuentra en el estado de celda \mathbf{C} , el cual, a diferencia del estado oculto (\mathbf{H}), este actúa como un canal que recorre la totalidad de la cadena secuencial con interacciones lineales menores. Esta configuración permite que la información persista a través de la secuencia completa sin alteraciones significativas, actuando como una memoria a largo plazo que mitiga eficazmente el desvanecimiento del gradiente.

El control sobre \mathbf{C} se ejerce mediante tres compuertas características: la compuerta de entrada, de olvido y de salida. Matemáticamente, las operaciones de estas compuertas son definidas mediante transformaciones afines seguidas de una función de activación sigmoide, la cual acota los valores de salida entre 0 y 1, emulando el comportamiento de una válvula que se abre y se cierra. Entonces, sea un instante presente t , la relación algebraica de cada una de las compuertas antes descritas se representa mediante las siguientes expresiones [13](#):

- **Compuerta de olvido:**

$$\mathbf{F}_t = \sigma\{\mathbf{W}_{xf} \cdot \mathbf{X}_t + \mathbf{W}_{hf} \cdot \mathbf{H}_{t-1} + \mathbf{b}_f\} \quad (4.16)$$

- **Compuerta de entrada**

$$\mathbf{I}_t = \sigma\{\mathbf{W}_{xi} \cdot \mathbf{X}_t + \mathbf{W}_{hi} \cdot \mathbf{H}_{t-1} + \mathbf{b}_i\} \quad (4.17)$$

- **Compuerta de salida**

$$\mathbf{O}_t = \sigma\{\mathbf{W}_{xo} \cdot \mathbf{X}_t + \mathbf{W}_{ho} \cdot \mathbf{H}_{t-1} + \mathbf{b}_o\} \quad (4.18)$$

Naturalmente, las expresiones [\(4.16\)](#), [\(4.17\)](#) y [\(4.18\)](#) muestran que cada compuerta posee sus propios parámetros entrenables contenidos sus respectivos \mathbf{W} y \mathbf{b} . En paralelo a estas operaciones, se calculan los valores de una “celda candidata” ($\tilde{\mathbf{C}}$), la cual tiene por objetivo actualizar el estado de celda \mathbf{C} luego de cada iteración secuencial. Esta operación se representa bajo la siguiente expresión:

$$\mathbf{C}_t = \mathbf{F}_t \odot \mathbf{C}_{t-1} + \mathbf{I}_t \odot \tilde{\mathbf{C}}_t \quad (4.19)$$

En esta relación, el producto de Hadamard (\odot) representa una multiplicación matricial elemento por elemento entre las matrices. En esta se muestra la esencia de una red LSTM: la compuerta \mathbf{F}_t dictamina qué proporción del contexto histórico se olvida, mientras que \mathbf{I}_t decide qué proporción de la nueva información candidata se integra a la memoria a largo plazo. Bajo esta premisa, si la salida del ciclo secuencial en el instante t dentro de la red LSTM se define como el propio estado oculto presente (\mathbf{H}_t), el cual se determina al filtrar el estado de celda \mathbf{C}_t mediante la compuerta de salida \mathbf{O}_t , es entonces posible establecer la siguiente relación:

$$\mathbf{H}_t = \mathbf{O}_t \odot \tanh\{\mathbf{C}_t\} \quad (4.20)$$

Definiéndose de esta forma al estado oculto \mathbf{H}_t como la salida de una LSTM para el instante t .

Un resumen esquematizado de todo el procedimiento anteriormente descrito, por el cual una celda LSTM obtiene su estado oculto y de celda en un instante t a partir de una entrada presente y sus estados pasados se presenta en la Figura [4.3](#).

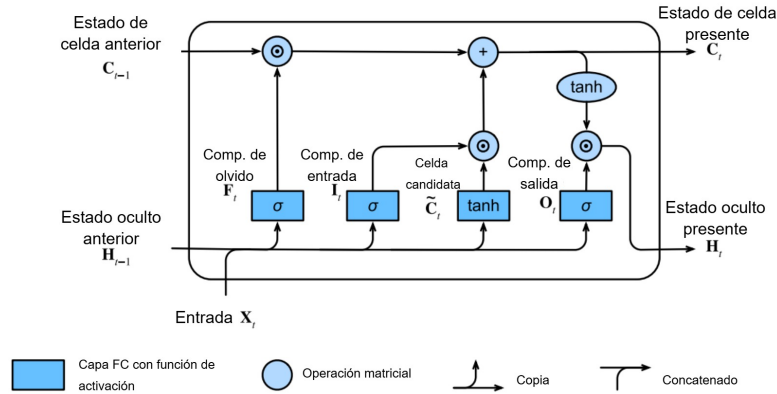


Figura 4.3. Esquema operativo de una red LSTM en un instante t . Adaptado de [13].

Gracias a la capacidad de propagar la información a través del tiempo mediante las matrices de pesos que relacionan un estado oculto con sus contiguos, las RNN resultan fundamentales para capturar patrones evolutivos insertos en señales dinámicas. Sin embargo, las versiones de mayor simpleza presentan limitaciones críticas ante secuencias de gran extensión debido a la inestabilidad de los gradientes. Por consecuencia, se opta por la implementación de un modelo LSTM, el cual se sobrepone a dichas restricciones mediante su mecanismo de compuertas. Además, debido a su principio de operación, se espera que estas sean capaces de ignorar ruidos transitorios irrelevantes y preservar únicamente los patrones de degradación a largo plazo dentro de las señales físicas de un MI. Otorgando al modelo la facultad de discriminar eventos repetitivos dentro de una muestra del ruido aleatorio del ambiente. Esta sinergia consolida un modelado espacio-temporal robusto a partir del conjunto de entrenamiento, cualidad esencial para establecer diagnósticos precisos ante condiciones anómalas variadas, tal como se propone en la presente memoria de titulación.

4.3. Algoritmo de optimización de hiperparámetros

En el ámbito del ML, los hiperparámetros representan las características primordiales que definen la estructura, el comportamiento general y el desempeño de un modelo. A diferencia de los parámetros convencionales como los pesos y sesgos en las RRNN, cuyos valores se optimizan durante el entrenamiento, los hiperparámetros deben ser ajustados externamente de forma previa. Estos ajustes son realizados según la naturaleza y objetivos específicos de cada RRNN. En este sentido, una selección adecuada de los hiperparámetros es fundamental para garantizar una buena capacidad de generalización, optimizar el tiempo de convergencia y maximizar el desempeño global de un modelo [13].

Tradicionalmente, el proceso de asignación de hiperparámetros es realizado de forma empírica, en base a pruebas de tipo “ensayo y error”, lo cual puede derivar en procesos de búsqueda sesgados e ineficientes tanto en tiempo de convergencia como en consumo de capacidad computacional. Para abordar estas limitaciones, se implementan algoritmos de optimización, los cuales tienen por objetivo el identificar y probar metódicamente una configuración de hiperparámetros tal que minimice o maximice alguna métrica objetivo que se plantee de forma inicial (véase Sección 4.4). La evaluación de la función objetivo que se plantea para este menester requiere de la ejecución intensiva de procesos iterativos

de entrenamiento y validación de una red neuronal, estableciendo ciclos secuenciales del tipo:

1. Asignar hiperparámetros.
2. Entrenar el modelo.
3. Evaluar su desempeño.
4. Repetir.

Este bucle es ejecutado hasta que se alcance un número predefinido de iteraciones o hasta el punto en el cual se alcance un máximo o mínimo local (según corresponda) dentro de un espacio de búsqueda predefinido. En este respecto, dado que la carga computacional que exige un algoritmo de optimización de hiperparámetros es intensiva, resulta imperativo que esta alcance un valor óptimo requiriendo la menor cantidad de evaluaciones posibles [13].

En este contexto, uno de los algoritmos más empleados para la optimización proviene del *framework* basado en *Python*: Optuna. Esta herramienta posee una arquitectura versátil y de fácil configuración, facilitando una implementación eficiente de diversas estrategias de búsqueda. En este proceso, Optuna muestrea un espacio de configuración para proponer nuevos hiperparámetros candidatos para una prueba de desempeño. De forma simultánea, el algoritmo implementa una estrategia de poda, la cual se encarga de monitorear el resultado intermedio de cada iteración o trial, descartando prematuramente aquellas ejecuciones poco prometedoras, acelerando el proceso de exploración. Esta administración asegura que los recursos computacionales se enfoquen exclusivamente en las configuraciones con mayor potencial de éxito, agilizando la convergencia hacia configuraciones hiperparámetros óptimas [51].

4.4. Indicadores de desempeño en algoritmos de clasificación

La evaluación del rendimiento de un modelo de aprendizaje automático constituye una etapa esencial dentro de su desarrollo, ya que permite cuantificar su eficacia en relación al objetivo del aprendizaje propuesto, además de determinar su capacidad de generalización frente a datos externos al proceso de entrenamiento. En este contexto, la implementación de métricas de evaluación proporciona indicadores sobre el grado de acierto y la naturaleza de los errores cometidos por el modelo, permitiendo a través de ello realizar comparaciones objetivas entre diferentes arquitecturas o entre distintas versiones del mismo modelo.

En el ámbito de clasificadores multiclase (como el de este trabajo), el análisis del desempeño puede ser realizado tanto a nivel individual por clase como de manera global, donde este último se centra en el universo de respuestas obtenidas. Para ello, se emplean herramientas diversas herramientas de análisis, las cuales serán descritas dentro de las siguientes subsecciones.

4.4.1. Matriz de confusión

Esta herramienta consiste en una representación estructurada de la relación entre las predicciones realizadas por el modelo y las clases reales del conjunto de datos.

En términos estructurales, dado un conjunto de datos de prueba aplicados sobre un modelo, la matriz de confusión se organiza de forma tal que las filas representan las clases reales del conjunto de datos en cuestión, mientras que las columnas son las clases predichas por el modelo. De este modo, cada elemento de la matriz indica la cantidad de instancias clasificadas en una determinada categoría, lo que permite diferenciar entre aquellas correctamente asignadas y aquellas que fueron clasificadas erróneamente.

A modo de ejemplo, considérese un modelo de clasificación de tres clases evaluado sobre 100 muestras. Entre estas, 14 representan a la clase “A”, 20 a la clase “B” y 66 a la clase “C”. A partir de esta distribución, en la Figura 4.4 se presenta una matriz de confusión representativa del desempeño del modelo hipotético en base al conjunto de datos descrito.

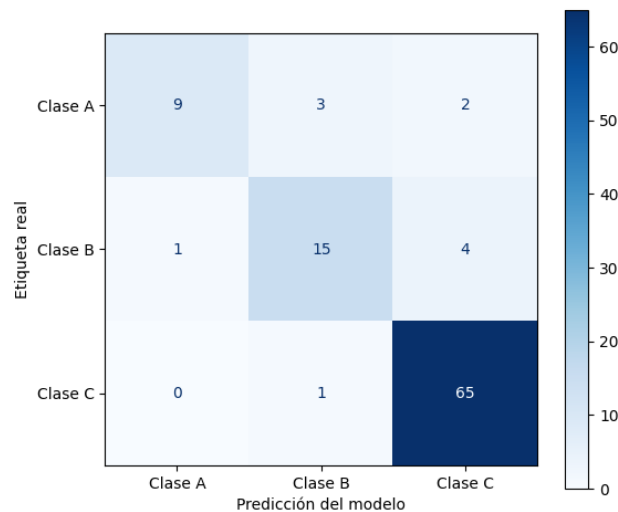


Figura 4.4. Matriz de confusión ilustrativa.

4.4.2. Indicadores de desempeño

La interpretación de los resultados presentes en una matriz de confusión requiere la utilización de indicadores cuantitativos que permitan evaluar con mayor profundidad el desempeño del modelo frente a cada una de las clases estudiadas. En este sentido, el análisis de estos indicadores otorga una mejor perspectiva sobre la capacidad del modelo para identificar correctamente los patrones en la información de entrada relacionados a cada una de las clases estudiadas, además de identificar posibles sesgos en las predicciones.

Tomando a modo de ejemplo la matriz de confusión presentada en la Figura 4.4, es posible introducir de forma ilustrativa los parámetros fundamentales para la realización del análisis de desempeño de un modelo de clasificación multiclase, siendo estos los siguientes:

- **Verdaderos positivos (VP):** Representan a las instancias en las cual el modelo predice correctamente la clase respectiva del dato de entrada. Dentro de una matriz de confusión, estos valores se ubican en la diagonal principal.
- **Falsos positivos (FP):** Son las instancias en las que el modelo clasifica erróneamente dentro de una clase determinada. En el caso del ejemplo, un falso positivo se presenta en el elemento de la segunda fila y primera columna de la matriz de

confusión, en la cual el modelo clasificó dicha muestra como perteneciente a la clase A, siendo que corresponde originalmente a la clase B.

- **Falsos negativos (FN):** Corresponden a las instancias que pertenecen realmente a una clase, pero que el modelo no logra identificar correctamente, por lo que predice una clase diferente. A modo de ejemplo, la clase B posee cinco FN, correspondientes a la suma de los elementos primero y tercero de la segunda fila, en los cuales el modelo predijo pertenencia a las clases A y C respectivamente.
- **Verdaderos negativos (VN):** Representan las instancias que no pertenecen a una clase específica y que, a su vez, el modelo predice correctamente esta no-pertenencia. Dicho de otra forma, son los casos en los que el modelo logra identificar que una muestra no corresponde a una determinada clase. Volviendo al ejemplo, en el caso de la clase B, sus verdaderos negativos serán 76, los cuales representan la cantidad total de muestras sin considerar las predicciones respectivas del modelo ni el subconjunto de entradas que efectivamente corresponden a la clase B.

A partir de estos parámetros esenciales, es posible derivar un conjunto de indicadores de mayor complejidad, las cuales ofrecen una visión más detallada sobre el rendimiento del modelo. Estas métricas son presentadas a continuación:

1. **Precisión:** Este indicador corresponde a uno de los más utilizadas a la hora de evaluar y comparar el desempeño de modelos de clasificación de estados aplicados en el diagnóstico de máquinas eléctricas [9, 10]. Representa la proporción de predicciones correctas sobre el total de predicciones realizadas, siendo esta relación representada mediante la siguiente expresión:

$$Pr = \frac{VP}{VP + FP} \quad (4.21)$$

Si bien, esta métrica ofrece una visión general del rendimiento del modelo, su interpretación es sesgada en escenarios en donde las clases de los datos se encuentran altamente desbalanceadas, ya que una alta precisión no implica necesariamente un buen desempeño en todas las clases analizadas.

2. **Sensibilidad:** Esta métrica mide la capacidad que posee el modelo para reconocer todas los elementos correspondientes a una clase. Esta relación se expresa de la siguiente forma:

$$Se = \frac{VP}{VP + FN} \quad (4.22)$$

Un valor alto de sensibilidad implica que el modelo posee una baja tasa de omisión, detectando gran parte de los casos pertenecientes a la clase de análisis. Por ende, esta métrica es especialmente relevante en contextos donde es más costoso no detectar una clase que verse sometido a mayor cantidad de falsos positivos.

3. **F1-score:** Corresponde al promedio armónico entre ambas métricas anteriores, proporcionando un indicador balanceado que considera tanto la capacidad del modelo para realizar predicciones acertadas, como la de reconocer todas las instancias de una clase dentro de un conjunto de datos. De esta forma, esta se expresa mediante la siguiente expresión:

$$F1 = 2 \cdot \frac{Pr \cdot Se}{Pr + Se} \quad (4.23)$$

Esta métrica resulta particularmente útil en problemas con clases desbalanceadas, ya que penaliza simultáneamente los errores por omisión y por detección de falsos positivos.

En el contexto de modelos de clasificación multiclase, el análisis de estas métricas de desempeño tanto a nivel global como individual (por clase) resulta esencial para realizar una evaluación completa del modelo. Mientras los indicadores globales ofrecen una visión general del rendimiento medio, las métricas específicas por clase permiten identificar posibles sesgos que el modelo pueda tener sobre determinadas categorías.

En términos ilustrativos, es de interés volver a analizar el ejemplo de la Figura 4.4, donde la clase C exhibe dos fenómenos particularmente relevantes: una cantidad considerable de FP y una distribución de FN proporcionalmente baja en relación a los VP en comparación a las demás clases. Este comportamiento se refleja cuantitativamente al determinar la sensibilidad de cada clase mediante (4.22), tal que la clase C alcanza un valor de 0,985, mientras que las clases A y B poseen valores de 0,643 y 0,75 respectivamente, evidenciando una diferencia notable. Además, la clase C presenta una precisión de 0,915, la cual es considerablemente menor que su sensibilidad. Al recopilar estos indicadores, es posible afirmar que el modelo hipotético analizado se encuentra ligeramente sesgado hacia su clase C, probablemente debido a su mayor representación dentro del conjunto de datos.

El tipo de análisis antes realizado, lejos de ser redundante, adquiere especial relevancia al considerar que la base de datos empleada para el entrenamiento del modelo propuesto presenta un marcado desbalance en la distribución de clases (véase Tabla 5.5).

En concordancia con el desafío que impone el desbalance anteriormente comentado, a la vez de respetar la tendencia en la implementación de métricas de desempeño en la literatura técnica [9, 10], se adopta el *f1-score* como métrica principal a maximizar dentro del proceso de optimización de hiperparámetros. Esta decisión de diseño busca establecer un equilibrio entre precisión y sensibilidad, penalizando tanto los altos índices de falsos positivos como de falsos negativos para cada una de las clases en igual medida. En consecuencia, la maximización del *f1-score* obliga al sistema a adoptar un comportamiento equilibrado y confiable, previniendo el sesgo hacia las clases mayoritarias a la vez de asegurar una correcta clasificación diagnóstica general, incluso para los estados anómalos de menor prevalencia.

Capítulo 5

Bases de datos

El desarrollo de modelos basados en redes neuronales requiere de bases de datos adecuadamente diseñadas y estructuradas. Estas deben permitir que, a través del proceso de entrenamiento, el modelo sea capaz de representar con exactitud los fenómenos que se desean predecir. En este sentido, la calidad, cantidad y diversidad de los datos empleados constituyen factores determinantes de la capacidad del modelo para reconocer patrones a partir de sus datos de manera efectiva y poder generalizar sus resultados [52]. En este contexto, la selección de una base de datos no solo representa una mera etapa preliminar del proceso de entrenamiento de la red, sino un elemento fundamental para definir su rendimiento y la validez de los resultados obtenidos.

La escasez de datos etiquetados relativos a la operación de una máquina sometida ante condiciones de falla desarrolladas naturalmente es un gran desafío a la hora de entrenar modelos de diagnóstico basados en redes neuronales. Esto se debe a que estas condiciones de avería se desarrollan de forma esporádica y la progresión de su severidad presenta alta variabilidad en función tanto de los equipos como de los ambientes en los cuales están insertos [53]. Por estos motivos, comúnmente se emplean bases de datos elaboradas mediante simulaciones computacionales o a través de la inducción controlada de fallas en máquinas dispuestas en entornos experimentales. En este último enfoque, el proceso de inducción consiste en someter un componente específico del motor (como el sistema de rodamientos, por ejemplo) ante condiciones anómalas, distintas de la operación normal, con el objetivo de alterar sus características mecánicas o eléctricas, buscando reproducir el comportamiento que este elemento tendría en el contexto de una falla real.

En coherencia con el enfoque experimental descrito, el presente trabajo fundamenta el entrenamiento y validación del modelo en dos fuentes de datos distintas. En primer lugar, se emplea la base de datos desarrollada por la Universidad Técnica Federico Santa María (UTFSM), la cual integra registros simultáneos de corriente y vibraciones obtenidos a partir la operación de un MI en condiciones saludables y bajo diversas condiciones de falla, en concreto, estas corresponden a defectos en su sistema de rodamientos (concretamente, en un elemento rodante), cortocircuito en espiras y a fallas de tipo mixta (considerando las dos previas simultáneamente). Este enfoque dual, tanto en términos de las variables registradas como en las fallas analizadas, permite que el modelo identifique patrones complejos e interdependientes entre los fenómenos eléctricos y mecánicos que ocurren en un MI en condiciones de avería. De esta forma, se busca una mayor robustez ante escenarios de degradación múltiple, superando limitaciones de algoritmos centrados en el análisis de

una única variable.

De forma complementaria, con el objetivo de evaluar la capacidad de generalización y adaptabilidad del modelo en cuestión, se aplican conjuntos de datos externos al utilizado durante el proceso de aprendizaje y prueba. Estos corresponden a las bases de datos públicas de las instituciones *Case Western Reserve Univeristy (CWRU)* y *Korea Advanced Institute of Science & Technology (KAIST)*, las cuales contienen registros vibratorios de MI trifásicos sometido a diversos tipos de fallas en su sistema de rodamientos, entre ellos, defectos en el elemento rodante.

A fin de profundizar en las especificaciones de cada uno de los conjuntos de datos antes descritos, en las siguientes secciones se presenta un desglose detallado para ambas. En estas, se aborda cada montaje experimental, características de las mediciones y de tipos de fallas inducidas en cada uno de estos entornos experimentales.

5.1. Base de datos de la Universidad Técnica Federico Santa María

5.1.1. Montaje experimental

La base de datos desarrollada por la institución en cuestión está constituida por mediciones experimentales obtenidas a partir de un banco de trabajo destinado al análisis de la operación de un MI bajo fallas inducidas de naturaleza mecánica y eléctrica. El montaje experimental utilizado consiste en el motor en cuestión conectado mediante un acople flexible a una máquina de inducción trifásica adaptada para su operación como generador autoexcitado, siendo su objetivo realizar carga mecánica sobre el eje del motor estudiado. Una visión detallada de este montaje se puede apreciar en la Figura 5.1.




Figura 5.1. Montaje implementado para la recolección de datos experimentales (UTFSM).

El motor en estudio y el generador son máquinas trifásicas de la marca *Siemens*, siendo los modelos 1LE0021 – 1AC4 y 1LE0102 – 1AC4 respectivamente. Los datos de placa de estas máquinas son presentados en la Tabla 5.1.

Tabla 5.1. Datos de placa del motor y generador ensayados.

| Parámetro nominal | Valor (motor) | Valor (generador) | Unidad de medida |
|--------------------------|---------------|-------------------|------------------|
| Frecuencia | 50 | 50 | Hz |
| Tensión (Δ/Y) | 230/400 | 230/400 | V |
| Corriente (Δ/Y) | 6,4/3,65 | 6,6/3,80 | A |
| Potencia | 1,5 | 1,5 | kW |
| FP | 0,74 | 0,76 | - |
| Velocidad de giro | 945 | 940 | rpm |
| Eficiencia (IE1) | 79,8 | 75,2 | % |
| Clase de eficiencia | IE2 | IE1 | No aplica |

El acoplamiento entre ambas máquinas dispuestas en el banco de pruebas es logrado mediante el acople flexible Rexnord Omega modelo ES10-R, mostrado con mayor detalle en la Figura 5.2. Este componente está diseñado para compensar posibles desalineaciones angulares o axiales entre los ejes acoplados, además de absorber vibraciones de alta frecuencia generadas durante la operación. Esta característica debe ser considerada al analizar las mediciones de vibración registradas, dado que influye en la amplitud y el contenido espectral de las señales vibratorias adquiridas.



Figura 5.2. Acople flexible Rexnord Omega modelo ES10-R utilizado en el banco de pruebas para la conexión motor-generador.

5.1.2. Instrumentación y adquisición de mediciones

Durante cada punto de operación implementado en el banco de pruebas, se registraron cuatro variables de forma simultánea. Las señales adquiridas corresponden a las vibraciones medidas en el soporte del rodamiento analizado y en la carcasa del motor, además de las corrientes de las fases a y b del estator. En términos instrumentales, estas mediciones se realizaron conforme a la siguiente configuración:

- **Para registros de vibraciones:** Se emplearon dos acelerómetros piezoeléctricos *CTC AC102 – 1A*, montados magnéticamente tanto sobre el soporte del rodamiento analizado como sobre la carcasa del MI. Estos sensores tienen una sensibilidad de 100 mV/g ($\pm 10\%$), rango dinámico de ± 50 g (*peak*) y respuesta en frecuencia limitada a $\pm 10\%$ en el rango de 2,0-10000 Hz. La señal de tensión resultante de cada uno de estos dispositivos es recibida por una punta de tensión *Pintek DP – 25* respectiva para cada uno. Este instrumento posee un ancho de banda de 25 MHz.
- **Para registros de corriente:** Se utilizaron las sondas de corriente *AEMC SL261*, las cuales tienen una sensibilidad de 100 mV/A (para el nivel de corriente registrado), con desfase angular $< 1,5^\circ$ y una frecuencia de muestreo de 100 kHz.

Las mediciones de los sensores de tensión y corriente detallados anteriormente se recolectan mediante el osciloscopio *Keysight InfiniiVision DSOX – 1204G*, registrando las señales en modo de alta resolución, lo cual implica una ventana de 1 s y una frecuencia de muestreo de 7680 Hz.

Dada la limitación en la cantidad de canales del osciloscopio en cuestión, no fue posible incluir la corriente de fase c del devanado de estator en el conjunto de registros experimentales, por lo cual se determinó esta señal mediante la relación:

$$i_c(t) = -(i_a(t) + i_b(t)) \quad (5.1)$$

5.1.3. Tipos de fallas inducidas

Las fallas inducidas en el sistema corresponden a defectos por cortocircuito entre espiras y daños en los rodamientos, afectando respectivamente al devanado del estator del MI y a los elementos rodantes del conjunto de rodamientos que conecta los ejes de esta máquina con el del generador. El procedimiento utilizado para inducir dichas fallas se detalla a continuación.

5.1.3.a. Falla en elemento rodante

Para poder simular este tipo de fallas, fue empleado el rodamiento de bola autoalineable *Craft* modelo 1207 EF-J31, el cual se muestra en la Figura 5.3, mientras que sus características geométricas específicas se presentan en la Tabla 5.2.




Figura 5.3. (a) Rodamiento Craft 1207 EF-J31, junto con su (b) esquema geométrico de referencia.

Tabla 5.2. Parámetros geométricos característicos del rodamiento Craft 1207 EF-J31.

| Parámetro | Valor [mm] |
|-----------------------------------|------------|
| Diámetro externo (D) | 35 |
| Diámetro interno (d) | 72 |
| Ancho (B) | 17 |
| Diámetro del elemento rodante (b) | 7,9 |

Con el propósito de simular una condición de falla insipiente, considerando este estado cuando el componente de degradación es menor al 12,5% (razón entre los diámetros del defecto y del elemento rodante) [54], se empleó un taladro eléctrico para generar una muesca controlada en uno de los elementos rodantes de dos sistemas de rodamientos Craft 1207 EF-J31, obteniéndose tres muestras experimentales: un rodamiento sano (sin daño inducido) y otros dos con muescas de 0,3 mm y 0,5 mm de diámetro respectivamente (equivalentes a 3,80% y 6,33% de degradación). El resultado de este procedimiento se ilustra en la Figura 5.4.




Figura 5.4. Rodamientos Craft 1207 EF-J31 sometidos a una perforación de un elemento rodante de (a) 0,3mm y (b) de 0,5mm.

5.1.3.b. Falla por cortocircuito entre espiras

Para simular esta condición de falla, se realizó una modificación estructural en el conexionado del devanado de estator del MI. Con el propósito de generar cortocircuitos artificiales entre espiras de una fase, se implementa una disposición de conexionado análoga a la configuración de *taps* en transformadores, habilitando puntos de conexión específicos que permiten establecer trayectos de conducción alternativos entre distintos tramos de una bobina en cada fase del devanado, tal como se aprecia en la Figura 5.5(a).


Similar a la falla anterior, existe un indicador porcentual del nivel de degradación del elemento analizado, el cual consiste en una proporción entre la cantidad de espiras cortocircuitadas con respecto al total del devanado. En este contexto, se desprende que una falla es incipiente cuando existe un valor del 3 % de este indicador 54. En términos del trabajo realizado, en la Tabla 5.3 se muestran los grados de severidad de los cortocircuitos inducidos en los ensayos realizados.

Tabla 5.3. Grados de severidad de falla por cortocircuito entre espiras para cada tipo de conexión entre el borne principal (número 1) y algún otro terminal.


| Terminal de cortocircuito inducido | Valor de componente de degradación |
|------------------------------------|------------------------------------|
| 2 | 0,64 % |
| 5 | 1,60 % |
| 8 | 2,56 % |
| 11 | 3,53 % |
| 18 | 5,76 % |

Finalmente, esta modificación estructural del MI se encapsuló en un tablero auxiliar dispuesto junto a la caja de conexiones de la máquina en cuestión. De esta forma, si es que

(por ejemplo) se quiere simular una falla de cortocircuito leve en el devanado de la fase W , basta con interconectar el borne de alimentación ($W1$) con el terminal azul marcado como “2” en el tablero mostrado en la Figura 5.5(b). A su vez, los terminales $U2$, $V2$ y $W2$ presentes en la Figura 5.5(c) pueden unirse entre sí formando una conexión de devanados del tipo estrella o alguna otra que se estime conveniente.



(a)



(b)



(c)

Figura 5.5. (a) Esquema de conexión del devanado de estator de la fase U con taps accesibles para la inducción controlada de fallas de cortocircuito entre espiras (esquema similar para las otras fases, junto con una vista (b) superior y (c) lateral de la aplicación de esta modificación constructiva en el MI ensayado.

5.1.4. Condiciones de operación analizadas

Para la conformación de la base de datos, se implementaron distintos puntos de operación del MI, con el propósito de abarcar una amplia gama de condiciones representativas de su comportamiento en estado sano y bajo fallas inducidas. En total, se obtuvieron 904 muestras de operación correspondientes a las diferentes combinaciones relativas al tipo de alimentación del MI, tipo de carga aplicada al eje y nivel de severidad de las fallas analizadas. Cada una de estas variaciones se describe a detalle a continuación.

5.1.4.a. Grados de carga

Como se menciona anteriormente, se realiza carga en el eje del MI mediante un generador de inducción, al cual se le conecta un banco resistivo trifásico en su estator. Debido a la condición de autoexcitación a la cual está sometido el generador, el valor posible del banco resistivo se encuentra limitado, por lo cual fue posible simular solo cuatro estados de operación mediante esta configuración experimental, los cuales son:

1. **T0:** En este punto de operación no se encuentra operando el generador de inducción, es decir, el MI se encuentra en estado de vacío.
2. **T1:** Se comienza la operación del generador, conectando únicamente el banco capacitivo a los bornes de su estator, estableciendo el estado de autoexcitación. Esto implica una operación en vacío para esta máquina.
3. **T2:** A partir del grado de carga presentado en $T1$, se conecta el banco resistivo de $90,69 [\Omega/fase]$ a los bornes del estator del generador, induciendo par electromagnético en el eje debido al flujo de corriente.
4. **T3:** Condición de operación similar a $T2$, en la cual se aumenta la resistencia del banco a $127,7 [\Omega/fase]$.

Todas las combinaciones descritas, junto con sus niveles de carga, se detallan en la Tabla [5.4](#).

Tabla 5.4. Niveles de carga aplicados sobre el MI durante la creación de la base de datos. El grado de carga porcentual presentado en la última columna es relativo al par nominal del motor.

| Punto de operación | Capacitancia en generador | Resistencia en generador | Carga en eje [Nm] | Carga en eje [%] |
|--------------------|---------------------------|--------------------------|-------------------|------------------|
| T0 | No conectada | No conectada | 0,68 | 4,78 |
| T1 | Conectada | No conectada | 6,56 | 45,95 |
| T2 | Conectada | 3 x 90,69 Ω | 14,62 | 102,76 |
| T3 | Conectada | 3 x 127,7 Ω | 15,69 | 110,25 |

5.1.4.b. Tipo de alimentación del motor

Con el objetivo de caracterizar el comportamiento del motor de inducción bajo distintas condiciones de energización, se implementaron tres tipos de alimentación durante la adquisición de los datos operativos. En todos los casos, la tensión de alimentación correspondió a un sistema trifásico de 230 V RMS por fase y una frecuencia nominal de 50 Hz. Estos métodos de alimentación se detallan a continuación.

1. **Balanceada:** Se implementó este tipo de alimentación mediante el simulador de red regenerativa, equipo el cual impone condiciones balanceadas en las tensiones de fase, enmascarando posibles desbalances naturales de la red eléctrica.
2. **Desbalanceada:** Con el equipo mencionado anteriormente, se implementaron tres condiciones de alimentación trifásica desbalanceada diferentes, con niveles del 1%, 2% y 3% respectivamente.

3. **Mediante inversor:** Este tipo de alimentación se logra mediante la implementación de los tres inversores monofásicos operando de forma coordinada (uno por cada fase). Cabe señalar que se implementó una estrategia de modulación por vector espacial, lo cual mejora la calidad espectral de la tensión en bornes de la máquina, disminuyendo la contaminación frecuencial intrínseca en comparación a otros métodos de modulación.

5.1.4.c. Severidad de fallas inducidas

Con el fin de evaluar la respuesta del MI ante distintos escenarios de deterioro, se definieron diversas condiciones de severidad de falla en los componentes estudiados. Estas configuraciones permitieron estudiar el comportamiento operativo del sistema tanto en estado saludable como bajo la presencia de fallas en su rodamiento y devanado de estator del motor, así como en situaciones donde ambos tipos de fallas coexisten. A continuación, se detallan las condiciones de operación consideradas para cada uno de los casos analizados.

1. **Operación sana:** Corresponde al funcionamiento del banco experimental sin la presencia de fallas inducidas. En este estado, el sistema de rodamientos utilizado no presenta muescas en sus elementos rodantes y no se realiza ningún cortocircuito controlado mediante el tablero auxiliar (Figura 5.5(c)).
2. **Falla en elemento rodante:** Como se detalla en la Sección 5.1.3.a del presente documento, existen tres muestras de rodamientos: una sin falla y dos con muescas de 0,3 [mm] y 0,5 [mm] en uno de sus elementos rodantes. En consecuencia, se obtuvieron tres puntos de operación relativos a esta falla, uno por cada rodamiento instalado al momento de realizar un ensayo.
3. **Falla por cortocircuito en espiras:** Con el propósito de obtener resultados experimentales representativos de la operación del motor de inducción bajo esta condición de falla, se llevaron a cabo ensayos variando el estado del cortocircuito controlado mediante las conexiones de los terminales disponibles en el tablero auxiliar. Esta metodología permitió registrar el comportamiento del sistema ante distintos grados de severidad y diversas localizaciones de la falla inducida en los devanados de cada fase del estator.
4. **Falla mixta:** Se combinan características de los estados descritos en los dos puntos anteriores.

Dentro de la base de datos, la cantidad de muestras relativas a cada una de las condiciones de operación antes descritas se presenta en la Tabla 5.5.

Tabla 5.5. Distribución de muestras por clase dentro de la base de datos UTFSM.

| Operación sana | Falla en elemento rodante | Falla por cortocircuito en espiras | Falla mixta | Total de muestras |
|----------------|---------------------------|------------------------------------|-------------|-------------------|
| 20 | 40 | 284 | 560 | 904 |

5.2. Base de datos de la Case Western Reserve University

Como aclaración previa, toda la información presentada en este apartado proviene de la página web oficial de la institución en cuestión [55].

5.2.1. Montaje experimental

La presente base de datos está constituida por mediciones experimentales obtenidas mediante un banco de pruebas diseñado para la operación de un MI trifásico sujeto a distintas condiciones de fallas inducidas en su sistema de rodamientos. El montaje implementado para llevar a cabo este cometido consiste en el MI acoplado mecánicamente a un dinamómetro, integrando entre estas máquinas un módulo de mediciones compuesto por un transductor de torque y un *encoder* (en la Figura 5.6 se presenta una visión general del montaje descrito). La función del dinamómetro es aplicar distintos niveles de carga sobre el motor, logrando así simular distintas condiciones de operación. En términos del MI, este corresponde a un equipo de fabricante *Reliance Electric* y potencia nominal de 2 [hp]. Sus respectivos datos de placa se encuentran disponibles en la Tabla 5.6.




Figura 5.6. Montaje implementado para la recolección de datos experimentales (CWRU). Adaptado de [55].

Tabla 5.6. Datos de placa del motor ensayado en la base de datos perteneciente a la CWRU.

| Parámetro nominal | Valor | Unidad de medida |
|------------------------|---------|------------------|
| Frecuencia | 60 | Hz |
| Tensión (Δ/Y) | 230/460 | V |
| Potencia | 2 | hp |
| FP | 0,72 | - |
| Velocidad de giro | 1725 | rpm |

5.2.2. Adquisición de mediciones

A diferencia de la base de datos de la UTFSM, durante el presente desarrollo experimental se registraron únicamente señales vibratorias. La captura de estos datos fue realizada mediante el uso de acelerómetros magnéticamente acoplados en tres puntos estratégicos del sistema: el extremo opuesto al acoplamiento motor-rodamiento (nombrado como “*fan-end*”), en el lado del acoplamiento en cuestión (nombrado como “*drive-end*”) y en la bancada del motor.

El registro de cada una de estas señales fue realizado mediante un equipo de adquisición de datos DAT de 16 canales, con el cual fueron capturadas las señales vibratorias en ambos extremos y, para algunos subconjuntos específicos, también en la bancada.

En términos generales, el total de la presente base de datos se divide en cuatro conjuntos principales:

1. Registros en condición saludable (con mediciones a 12.000 muestras por segundo).
2. Registros realizados bajo falla en el rodamiento del lado del acoplamiento (con mediciones a 12.000 muestras por segundo).
3. Registros realizados bajo falla en el rodamiento del lado del acoplamiento (con mediciones a 48.000 muestras por segundo).
4. Registros realizados bajo falla en el rodamiento del lado opuesto al acople (con mediciones a 12.000 muestras por segundo).

Sin embargo, considerando que la finalidad de implementar esta base de datos es la validación externa del sistema de diagnóstico desarrollado originalmente con los registros de la UTFSM (véase Sección 5.1), en la presente memoria de titulación se consideran únicamente el primer y segundo conjunto previamente presentado. Esta decisión se fundamenta en la búsqueda de una mayor homogeneidad entre conjuntos de datos, considerando tanto una mayor similitud en frecuencias de muestreo como el hecho de que ambos registros vibratorios son cercanos al rodamiento dañado. De esta forma, se busca comparar el desempeño del modelo en escenarios comparables, minimizando las distorsiones derivadas de las diferencias intrínsecas entre bancos de pruebas experimentales, tales como las velocidades de operación, la instrumentación empleada o el diseño mismo del MI.

Con respecto a los conjuntos seleccionados, los registros de ambas categorías fueron realizados bajo una frecuencia de muestreo de 12 [kHz]. En particular, los datos relativos a la operación saludable (primer conjunto) consisten en cuatro registros relativos al tipo de carga impuesta sobre el MI. La primera de estas muestras, relativa al motor operando en condición de vacío, posee una duración aproximada de 20 [s], mientras que los demás tres se extienden por 40 [s]. Por su parte, para el segundo conjunto (operación bajo falla), la duración de cada registro del motor en condición de falla dura poco más de 10 [s].

En el caso específico de la falla en el anillo externo del sistema de rodamientos, al tratarse de una falla estática (lo que quiere decir que el elemento dañado no se desplaza con el giro del eje), la posición relativa del sensor con respecto a la falla influye considerablemente en la intensidad de las propias mediciones. Debido este fenómeno, la presente base de datos cuenta con tres grupos de registros diferenciados de acuerdo a la posición

relativa del sensor: alineado, ortogonal u opuesto a la zona de carga (parte inferior del eje).

Dentro de la base de datos, la cantidad de muestras relativas al posicionamiento del sensor ortogonal y opuesto, cada una equivalen a solo dos tercios de las muestras que posee el subconjunto con el sensor alineado, lo cual demuestra un desbalance considerable en la cantidad de registros vibratorios dentro del subconjunto de la presente falla y, en términos totales, con respecto al total de la base de datos. Este hecho, sumado a que la presente memoria de título no tiene el objetivo de estimar la ubicación de una falla insipiente en el anillo externo, induce la decisión de descartar las mediciones de los subconjuntos minoritarios de muestras del tipo de fallas en el anillo externo, asegurando mayor homogeneidad entre las clases durante el proceso de validación.

5.2.3. Tipos de fallas inducidas

Como se ha mencionado previamente, esta base de datos cuenta únicamente con datos relativos a la operación del MI bajo tres tipos de fallas inducidas en su sistema de rodamientos. Específicamente, estos defectos fueron localizados respectivamente en su pista externa, pista interna y en uno de sus elementos rodantes.

El sistema de rodamientos empleado por la CWRU para la realización de estos ensayos corresponde a un rodamiento rígido con una hilera de bolas de ranura profunda, fabricado por la empresa *SKF* y siendo el modelo 6205 2RSJEM. Una imagen ilustrativa acompañada de un esquema de las características geométricas de esta pieza se presentan en la Figura 5.7, mientras que sus parámetros constructivos se muestran en la Tabla 5.7.




Figura 5.7. (a) Rodamiento SKF 6205 2RSJEM (imagen ilustrativa mostrada en la página web del fabricante [56]), junto con su (b) esquema geométrico de referencia.

Tabla 5.7. *Parámetros geométricos característicos del rodamiento SKF 6205 2RSJEM.*

| Parámetro | Valor (mm) |
|-----------------------------------|------------|
| Diámetro externo (D) | 52 |
| Diámetro interno (d) | 25 |
| Ancho (B) | 15 |
| Diámetro del elemento rodante (b) | 7,94 |

Para la inducción de los estados de degradación en cada elemento del sistema de rodamientos, se utiliza la técnica de mecanizado por descarga eléctrica (*EDM*, por sus siglas en inglés). De esta forma, en cada uno de los respectivos elementos fueron inducidas muescas de 0,007, 0,014, 0,021 y 0,028 [*in*] (0,1778, 0,3556, 0,5334 y 0,7112 [*mm*] respectivamente). Al normalizar estos valores con respecto al diámetro del elemento rodante (el cual está sujeto al tipo de falla que el modelo desarrollado busca predecir), se obtienen índices de degradación del 2,24 %, 4,48 %, 6,72 % y 8,96 % respectivamente. Cabe destacar que estos niveles de severidad son similares a los que posee la base de datos de la UTFSM (3,80 % y 6,33 %), lo cual asegura una base comparativa coherente para evaluar la capacidad de diagnóstico del modelo ante niveles de deterioro similares en ambos entornos experimentales.

5.2.4. Condiciones de operación analizadas

Las diversas condiciones de operación en sobre las cuales opera el MI están definidas en base a la intensidad de carga impuesta y el nivel de severidad relativo al diámetro de la muesca inducida (según lo presentado en la Sección 5.2.2). En este contexto, cabe destacar el hecho de que la naturaleza de la alimentación eléctrica del motor es constante, contrario a la base de datos de la UTFSM, la cual cuenta con los tipos de alimentación balanceada, desbalanceada y mediante inversor disponibles dentro de sus registros experimentales.

Si bien el total de muestras obtenidas al variar cada una de estas condiciones (sumado al posicionamiento del sensor para falla en anillo externo) es de 161 en total, solo son útiles para la presente memoria de título 40 muestras. Estos corresponden a los dos subconjuntos fundamentales para la validación del modelo: aquellos registros en operación sana y bajo fallas en el rodamiento del lado del acoplamiento (con frecuencia de muestreo de 12 [*kHz*]).

En términos de los grados de carga, existen cuatro condiciones operativas en función del nivel de potencia aplicado al eje mediante el dinamómetro. Estos corresponden la condición de vacío y tres niveles de carga constantes de 1, 2 y 3 [*hp*] (notar que 1 [*hp*] es equivalente a 0,7457 [*kW*]). Por su parte, los tipos de severidad (según fueron detallados en la Sección 5.2.3) son tres, relativos al diámetro de la muesca inducida en su respectivo elemento del sistema de rodamientos: 0,007 [*in*], 0,014 [*in*] y 0,021 [*in*].

A modo de síntesis, en la Tabla 5.8 se muestra la distribución de los registros vibratorios seleccionados, relativos a las categorías de operación en estado sano y sometido a falla en el rodamiento del lado del acoplamiento del motor (con frecuencia de muestreo de 12 [*kHz*]).

Tabla 5.8. Distribución de muestras por clase dentro de la base de datos de la CWRU.

| | Operación sana | Falla en elemento rodante | Falla en pista interna | Falla en pista externa |
|--------------------|----------------|---------------------------|------------------------|------------------------|
| Número de muestras | 4 | 12 | 12 | 12 |
| Duración [s] | 20-40 | 10 | 10 | 10 |

5.3. Base de datos de la Korean Advanced Institute of Science & Technology

La información presentada en este apartado tiene como origen el artículo realizado por la institución en cuestión disponible en [57].

5.3.1. Montaje experimental

La base de datos elaborada por esta institución se compone de registros experimentales obtenidos a partir de un banco de trabajo diseñado para estudiar el comportamiento de un MI trifásico que, al igual que el escenario previamente descrito en la sección anterior, opera bajo distintos tipos de defectos inducidos en uno de los rodamientos de su sistema mecánico. El montaje experimental acopla al MI con una caja de cambios de relación 1:2,07, transmitiendo el movimiento a través de un sistema de volantes de inercia hasta llegar a un freno de histéresis (tal cual se ilustra en la Figura 5.8). Este freno es el instrumento encargado de aplicar la carga mecánica en el eje, controlando así la velocidad de giro durante las pruebas.

El MI estudiado corresponde a un equipo de fabricante *Siemens* y potencia nominal de 3 hp. Un resumen de sus respectivos datos de placa se encuentra en la Tabla 5.9.

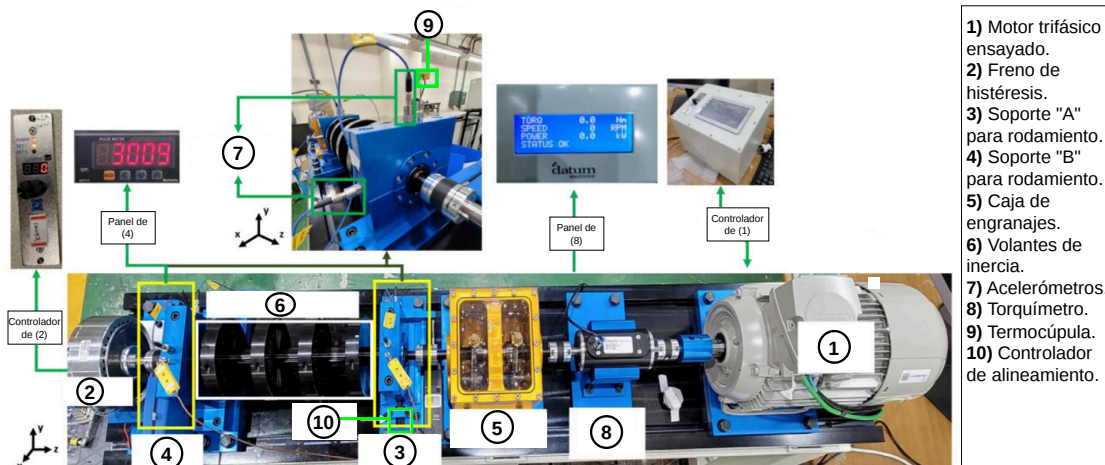


Figura 5.8. Montaje implementado para la recolección de datos experimentales (KAIST). Adaptado de [57].

Tabla 5.9. Datos de placa del motor ensayado en la base de datos perteneciente a la KAIST.

| Parámetro nominal | Valor | Unidad de medida |
|-------------------|-------|------------------|
| Frecuencia | 60 | Hz |
| Tensión | 380 | V |
| Potencia | 3 | hp |
| Velocidad de giro | 1770 | rpm |

5.3.2. Adquisición de mediciones

La base de datos de KAIST presenta registros adquiridos bajo dos escenarios operativos: condiciones de velocidad variable y operación estacionaria. En el primer conjunto, se integran registros sincronizados de diversas magnitudes físicas, siendo estas vibraciones, corrientes de estator, velocidad de giro en el tiempo, registros acústicos y térmicos. Sin embargo, debido a que este tipo de operación es fundamentalmente disímil con respecto a la analizada dentro de la base de datos de la UTFSM (donde los datos son adquiridos bajo operación estacionaria), no se toma en cuenta este subconjunto de información para el presente análisis. Esta decisión se fundamenta en el hecho de que el conjunto de entrenamiento principal para el modelo se obtiene justamente a partir de la base de datos de la UTFSM, por lo que evaluar su desempeño en un entorno no estacionario plantearía un marco de referencia estructuralmente incompatible.

En consecuencia, los registros que componen al subconjunto de operación estacionaria, el cual sí será el seleccionado para el análisis, consisten únicamente en señales vibratorias obtenidas gracias a cuatro acelerómetros piezoeléctricos de fabricante *PCB* y modelo *352C34*. Estos sensores fueron instalados en los ejes x e y de los soportes A y B del banco de pruebas (véase Figura 5.8). Luego, las señales resultantes fueron capturadas mediante un sistema de adquisición *Siemens SCADAS* modelo *Mobile 5PM50* bajo una frecuencia de muestreo de $25,6 \text{ kHz}$. En cuanto a la extensión de estos registros, se capturaron ventanas de 600 s para cada uno de los puntos de operación definidos en base al estado del sistema: sano, falla en elemento rodante, falla en pista externa y falla en pista interna.

5.3.3. Tipos de fallas inducidas

De forma análoga a la metodología empleada en la base de datos de la CWRU, KAIST ha desarrollado su base de datos para representar tres tipos de anomalías mecánicas en el sistema de rodamientos del MI. El rodamiento empleado para estos ensayos se encuentra dispuesto en el soporte A de su banco de pruebas (véase Figura 5.8). Concretamente, el rodamiento en cuestión es fabricado por *NSK* y su modelo corresponde al *6205 DDU*, el cual es un rodamiento rígido de una hilera de nueve elementos rodantes. Una imagen ilustrativa, acompañada de un esquema de las características geométricas de esta pieza se presentan en la Figura 5.9, mientras que sus parámetros constructivos se muestran en la Tabla 5.10.




Figura 5.9. (a) Rodamiento NSK 6205 DDU (imagen ilustrativa mostrada en la página web del fabricante [58]), junto con su (b) esquema geométrico de referencia.

Tabla 5.10. Parámetros geométricos característicos del rodamiento NSK 6205 DDU.

| Parámetro | Valor (mm) |
|-----------------------------------|------------|
| Diámetro externo (D) | 52 |
| Diámetro interno (d) | 25 |
| Ancho (B) | 15 |
| Diámetro del elemento rodante (b) | 7,90 |

A diferencia de la base de datos de la UTFSM, que define sus defectos en los elementos rodantes mediante muescas de diámetros específicos (con índices de degradación del 3,80% y 6,33%), el subconjunto de registros de operación estacionaria del KAIST, con muestras de duración de 600 s, emplea una técnica de inducción de falla distinta, basada en la provocación de un desprendimiento superficial de material (también conocido como “*spalling*”) mediante el uso de puntas de diamante. Si bien el tamaño exacto de esta imperfección no es cuantificada dentro de los registros de KAIST para este tipo de ensayo, la naturaleza de la falla por desprendimiento representa una condición de daño superficial diferente a la inducción de muescas de la UTFSM. En este sentido, evaluar el modelo híbrido con estos registros permite contrastar su capacidad de generalización frente a un formato de avería estructuralmente distinta. Así, se espera observar cómo la red neuronal responde ante la contaminación espectral generada por una superficie de rodadura con desgaste continuo (*spalling*), en comparación con la respuesta ante un defecto puntual y mecanizado, evaluando así su capacidad de adaptabilidad en el aprendizaje de cada tipo de firma de falla.

5.3.4. Condiciones de operación analizadas

Según fue comentado anteriormente, la presente base de datos cuenta con condiciones de operación bajo velocidad variable (no-estacionario) y constante (estacionario). En el contexto del presente trabajo de título, solo se considera este último escenario operativo, el cual es caracterizado por una alimentación del MI balanceada, manteniendo una velocidad de giro fija de 3010 *rpm* luego de la caja de cambios.

Las condiciones de operación descritas son realizadas en base a cuatro puntos de operación; uno por cada defecto en el rodamiento (elemento rodante, pista interna y externa) en adición a la condición saludable del equipo. Cada una de estas se realiza de forma invariante a lo largo de 600 *s* de medición bajo condición de vacío. El resultado de este proceso se sintetiza en la Tabla [5.11](#).

Tabla 5.11. *Distribución de muestras por clase dentro de la base de datos de la KAIST.*

| | Operación sana | Falla en elemento rodante | Falla en pista interna | Falla en pista externa |
|---------------------------|-----------------------|----------------------------------|-------------------------------|-------------------------------|
| Número de muestras | 1 | 1 | 1 | 1 |
| Duración [s] | 600 | 600 | 600 | 600 |

Sin embargo, para fines del entrenamiento del modelo trabajado, se selecciona una porción de 200 *s* por archivo, equivalente a 400 muestras cada uno luego de la aplicación de la EAD de ventaneo temporal (descrito en la Sección [3.1](#)). Esta reducción controlada se fundamenta en la necesidad de establecer un universo de muestras homogéneo entre esta base de datos y el conjunto homólogo de la UTFSM, luego de la aplicación de las EAD. De esta forma, se garantiza un punto de partida balanceado para la comparativa de desempeño.

Capítulo 6

Metodología

6.1. Esquema general del sistema de diagnóstico

El sistema de diagnóstico desarrollado fundamenta su operación en un flujo de procesamiento secuencial, el cual tiene su origen en el ingreso de las señales crudas al sistema. Posteriormente estas son sometidas a una etapa de preprocesamiento, en la cual se integran de las herramientas de tratamiento de datos tratadas en el Capítulo 3, tal de introducir los tensores resultantes en un modelo de DL fundamentado en base a las arquitecturas descritas en el Capítulo 4.

La etapa de preprocesado (o de tratamiento de datos) transforma las señales crudas unidimensionales en representaciones tiempo-frecuencia bidimensionales (espectrogramas). Consecuentemente, el principio de operación del sistema de diagnóstico se sustenta en el procesado de imágenes. A partir de estas, la red neuronal que compone el modelo de IA implementado tiene la labor de reconocer patrones de falla dentro de los espectrogramas y procesarlos para generar un diagnóstico efectivo. Desde un punto de vista concreto, es conocido que algunos de estos patrones se manifiestan a partir de aumentos anómalos en la densidad de energía espectral en torno a las modulaciones que provocan las frecuencias características de falla sobre las variables de vibraciones y corriente (según lo tratado en las secciones 2.2 y 2.3). Sin embargo, debido al “problema de la caja negra” inherente a las arquitecturas de DL (discutido en la Sección 4.1), pueden llegar a existir múltiples otros patrones latentes dentro del conjunto de datos de entrenamiento que el sistema pueda reconocer para predecir la condición operativa del MI.

Desde un punto de vista estructural, el modelo está diseñado bajo un formato de entrada flexible, capaz de operar bajo dos modalidades: el enfoque multivariable y el monovariable. El primero de estos corresponde a la forma principal del sistema de diagnóstico, la cual busca incorporar el reconocimiento de patrones de falla de naturaleza mecánica y eléctrica a través de los espectrogramas de señales vibratorias y de módulo del vector de Clarke en el tiempo. Por otra parte, la arista monovariable busca comprobar el desempeño del modelo ante una menor cantidad de información operativa, evaluando de esta forma la calidad diagnóstica de cada fuente de información (señal). A su vez, mediante este enfoque es posible generar un marco de análisis común sobre el cual evaluar la respuesta del sistema entrenado mediante bases de datos diferentes.

Según lo anteriormente descrito, el sistema de diagnóstico se compone por las siguien-

tes etapas (según lo esquematizado en la Figura 6.1): el preprocesamiento de señales y su procesamiento por el modelo híbrido de clasificación, dentro del cual es realizado el diagnóstico. Ambas etapas serán descritas detalladamente en las posteriores secciones del presente capítulo.

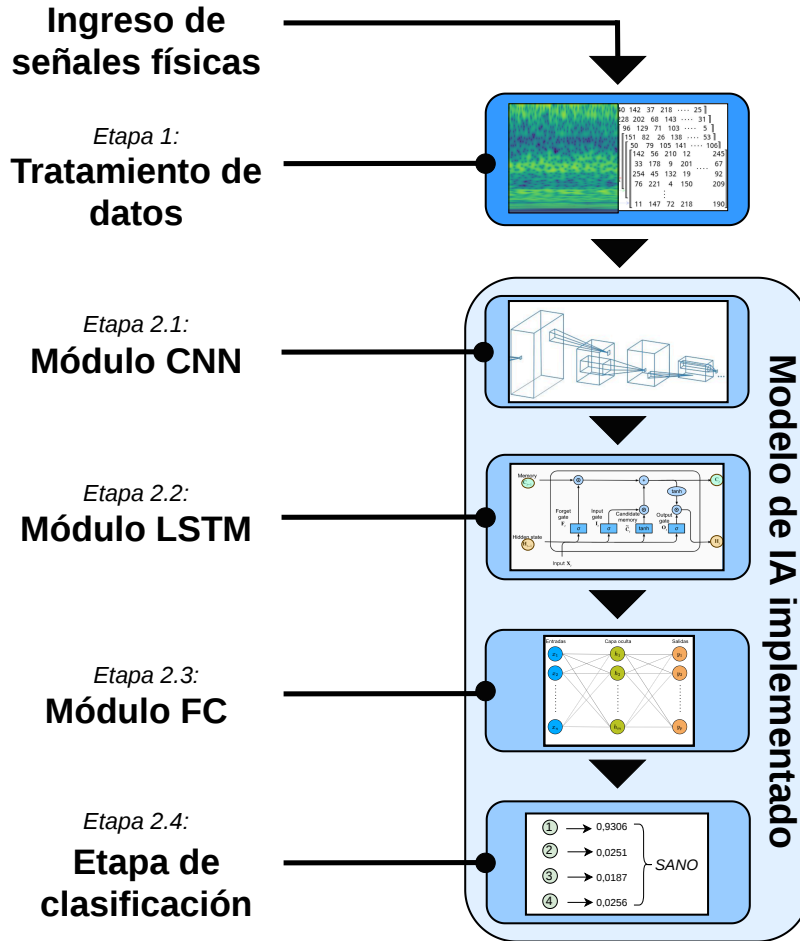


Figura 6.1. Diagrama completo del sistema de diagnóstico desarrollado.

6.2. Tratamiento de datos

En la presente sección se describen los procedimientos orientados a la transformación de las señales de entrada en tensores compatibles con la arquitectura del modelo de IA. Además, se detalla la creación de la base de datos para su entrenamiento, considerando EAD para aumentar el volumen de las muestras, de esta forma disminuyendo su nivel de desbalance inherente. Este procedimiento se lleva a cabo tanto por rigor metodológico como para responder uno de los objetivos específicos definidos en la presente memoria de título.

La presente sección sistematiza los procedimientos técnicos orientados a la adecuación de las señales de entrada y su posterior transformación en tensores bidimensionales compatibles con la arquitectura del modelo de IA implementado. De forma complementaria, se detalla la conformación de la base de datos orientada al entrenamiento, la cual fue aumentada mediante la aplicación de EAD. La implementación de estas técnicas cumple un doble propósito; incrementar sintéticamente el volumen de muestras para mitigar el desbalance de clases inherente a los registros físicos originales (base de datos de la UTFSM) y responder metodológicamente al objetivo específico afín definido en esta memoria de título.

6.2.1. Aplicación de estrategia de aumento de datos

Según fue comentado anteriormente, la implementación de las EAD tiene por objetivo principal aligerar el desbalance severo que existe la distribución de muestras por clase propio de la base de datos de la UTFSM (véase Tabla 5.5). En concreto, el procedimiento busca aumentar el volumen de muestras relativas a la operación sana y falla en elemento rodante, ya que estas cuentan solo un 3,6% y 7,1% del total de muestras que posee la clase mayoritaria (falla mixta), lo cual evidencia una disparidad considerable, la cual debe ser aminorada para evitar un posible sesgo del modelo con respecto al diagnóstico de sus clases mayoritarias.

En términos ejecutivos, las EAD son aplicadas al importar cada una de las señales crudas al momento de realizar la base de datos. En este contexto, el primer método aplicado consiste en incorporarles AWGN, cuya magnitud se define aleatoriamente entre 2% – 5% de la desviación estándar de la señal respectiva sobre la cual es aplicada. De forma complementaria, se implementa la estrategia de ventaneo temporal, segmentando cada una de las muestras en dos ventanas de 0,5 [s]. Esta segmentación es admisible ya que las muestras dentro de la base de datos de la UTFSM poseen una duración de 1 [s] en operación estacionaria. Naturalmente, debido a que existen instancias en las cuales el modelo procesa dos señales simultáneas, el tramo de ventaneo es coherente en ambas en toda instancia. La implementación de ambas EAD resultan en una nueva distribución de la base de datos, la cual se presenta en la Tabla 6.1

Tabla 6.1. *Distribución de muestras por clase dentro de la base de datos UTFSM luego de la implementación de EAD.*

| Operación sana | Falla en elemento rodante | Falla por cortocircuito en espiras | Falla mixta | Total de muestras |
|----------------|---------------------------|------------------------------------|-------------|-------------------|
| 80 | 160 | 568 | 1120 | 1928 |

Por otra parte, para la confección de la base de datos relativa a la validación del modelo (teniendo esta origen en los registros de la CWRU), es realizada mediante un procedimiento similar al anterior. Sin embargo, el objetivo de la aplicación de EAD no es disminuir la brecha relativa al número de muestras por clase, sino la estandarización temporal de las muestras con respecto al conjunto de datos original. El procedimiento en cuestión consiste únicamente en dividir las señales de varios segundos de duración en ventanas homogéneas de 0,5 [s], equiparando su duración con respecto a la establecida para el conjunto de datos basados en los registros de la UTFSM. De esta forma, se genera una mayor homogeneidad en los espectrogramas relativos a cada conjunto de datos, garantizando una mayor coherencia de cara al proceso de validación externa del modelo. De esta forma, se genera la distribución de muestras presentada en la Tabla [6.2](#).

Tabla 6.2. *Distribución de muestras por clase dentro de la base de datos CWRU luego de la implementación de EAD.*

| Operación sana | Falla en elemento rodante | Falla en pista externa | Falla en pista interna | Total de muestras |
|----------------|---------------------------|------------------------|------------------------|-------------------|
| 280 | 240 | 240 | 240 | 1000 |

6.2.2. Procedimiento de generación de espectrogramas

Este proceso, aplicado tanto para señales de corriente como de vibraciones, consiste en un flujo secuencial relativo a la conversión de información desde el archivo que contiene los registros brutos (de la base de datos que corresponda) hasta la creación de un espectrograma en formato de imagen (de extensión *.png*). En el caso específico de las señales de corriente, se incorpora una etapa adicional, la cual consiste en la determinación del módulo de vector de corriente de Clarke, integrando las tres corrientes trifásicas para su cálculo, obteniendo de esta forma la señal que será procesada según el procedimiento antes descrito.

Una vez importadas las señales en un entorno de desarrollo (implementado en lenguaje *Python*), se procede a la aplicación de la ST. Cabe destacar que este tipo de aplicación requiere la definición previa de límites de frecuencia de análisis. Con respecto a esto, el límite más inmediato se presenta en la frecuencia de muestreo (directamente relacionada con la frecuencia de Nyquist), la cual, en las bases de datos utilizadas son 7680 [Hz] para UTFSM y 12 [kHz] para CWRU, las cuales son considerablemente distintas. Esta heterogeneidad impone la necesidad de definir rangos de frecuencia de análisis estandarizados entre bases de datos para la generación de los espectrogramas.

Para la delimitación del rango de frecuencia en cuestión, se contrastó la teoría con los

registros operativos de la base de datos de la UTFSM. En este aspecto, si bien la literatura clásica, como Penman et. al [33] sugieren que, para el diagnóstico de cortocircuitos en espiras basta con monitorear componentes frecuenciales de falla obtenidos con bajos índices armónicos k y n (según la expresión (2.7)) son suficientes para realizar un diagnóstico del estado de un MI (en su caso particular, se consideran hasta los 84 [Hz]). Sin embargo, una inspección espectral exhaustiva realizada sobre la base de datos de la UTFSM reveló un comportamiento diferente. En concreto, se inspeccionó el crecimiento en magnitud de los componentes frecuenciales de falla a medida se aumentaba la severidad bajo alimentación y carga constantes. Al analizar la evolución de los componentes frecuenciales de falla frente al incremento de la severidad, se detectaron patrones de crecimiento energético significativos distribuidos hasta los 700 [Hz], en donde posterior a este valor el nivel energético medio del espectro era considerablemente menor a la franja de análisis. Por este motivo, el rango de análisis sobre el cual se aplica la ST para las señales de módulo del vector de corrientes de Clarke en el tiempo es entre 0 y 700 [Hz].

De forma análoga, para las señales vibratorias, los límites de análisis de frecuencia fueron determinados mediante la correlación visual de las muestras relativas a la base de datos UTFSM, buscando componentes de falla característicos según la expresión (2.4). Este análisis evidencia la existencia de componentes frecuenciales que evolucionan con la severidad de la falla tanto en bandas de baja como de alta frecuencia, observándose actividad relevante hasta los 3000 [Hz]. En consecuencia, este valor se fijó como el límite superior para el procesamiento de las señales mecánicas.

A modo de aclaración, el nivel energético que poseen los componentes frecuenciales de falla es, en esencia, una característica extraída manualmente bajo criterios de conocimiento experto. En este sentido, la naturaleza misma de los modelos de DL permite el reconocimiento de patrones altamente abstractos que no necesariamente se correlacionan con estos indicadores “clásicos”, por lo que podría llegar a suceder que el modelo no considere esta clase de indicadores para realizar un diagnóstico (o que, al menos, no sean los indicadores principales). Sin embargo, estas características sirven como marco de análisis desde un punto de vista técnico en la materia, por lo cual de todas formas serán consideradas como referencia para el ajuste de límites en frecuencia para la creación de los espectrogramas.

En base a estos límites de análisis en cuestión, se procede a construir los espectrogramas relativos a la construcción del conjunto de entrenamiento. Debido al uso mismo que se le da a estos espectrogramas (muestras para el entrenamiento del modelo), se busca minimizar la presencia de regiones locales sin información útil para el diagnóstico. Por ende, estos se generan eliminando la totalidad de los elementos gráficos auxiliares, tales como etiquetas, ejes, leyendas o márgenes en blanco. Esta decisión implica que el tensor que finalmente ingresa al módulo convolucional del modelo contenga exclusivamente información espectral de la señal, optimizando la eficiencia computacional y evitando que el modelo aprenda sesgos a partir de elementos visuales irrelevantes. En la Figura 6.2 se presentan dos muestras resultantes del proceso tratado en la presente sección.




Figura 6.2. Ejemplares resultantes del proceso de creación de espectrogramas. Se muestra una representación de (a) módulo de corrientes de Clarke en el tiempo y (b) vibración en el sistema de rodamientos.

6.2.3. Creación de base de datos para el entrenamiento y validación del modelo

Posterior a la aplicación de las EAD y la creación de los espectrogramas, se procede a la elaboración y segregación de la base de datos destinada para los procesos de entrenamiento y validación del modelo. En esta etapa, cada una de las imágenes generadas son almacenadas, conservando un número relativo a su clase de origen dentro del nombre de su archivo. Esta etiqueta, siendo equivalente a los números desde el 0 al 3, representando respectivamente las clases de operación sana, falla en elemento rodante, cortocircuito en espiras y mixta. Este proceso de etiquetado es de suma relevancia, ya que permite ligar cada muestra en específico a su respectiva clase durante el procesamiento del modelo tanto en entrenamiento, sub-validación y prueba, lo cual es un pilar fundamental que permite comparar las predicciones del modelo con el estado real del motor dentro de dicha muestra.

Una vez generado todo el conjunto de espectrogramas a utilizar, se procede a realizar una segregación de base de datos, creando tres subconjuntos de datos, siendo estos descritos a continuación:

1. Subconjunto de entrenamiento:

Constituye el subconjunto mayoritario de datos, los cuales están referidos al proceso de entrenamiento estructural de la arquitectura de redes neuronales. Esto quiere decir que en base a estos datos se ajustan los parámetros entrenables del modelo.

2. Subconjunto de sub-validación:

Es utilizada para la evaluación concurrente del modelo durante los procesos de ajuste de hiperparámetros, lo cual permite a Optuna el determinar métricas clave las cuales le permiten tomar la decisión de podar una rama de análisis o mantenerse en ese subconjunto de búsqueda.

3. Subconjunto de prueba:

Exclusivo de la etapa de entrenamiento, este subconjunto se utiliza para calcular las métricas de evaluación de desempeño. Al no interferir con el proceso de entrenamiento, su implementación es útil para evaluar la capacidad de generalización del modelo.

Para las pruebas de búsqueda de hiperparámetros, la distribución con la cual es segmentada la base de datos total es de un 70 % – 15 % – 15 % respectivamente para cada subconjunto antes descrito. Para el resto de pruebas, se unen los subconjuntos de entrenamiento y sub-validación, generando una distribución 85 % – 15 % (esto es aplicado al conjunto de datos derivado tanto de los registros de la UTFSM como de la CWRU). Cabe señalar que, para disminuir la probabilidad de sesgos y sobreajuste del modelo, la distribución de muestras por clase dentro de los subconjuntos mismos se encuentra estratificada, tal de asegurar la presencia de cada una de las clases de forma homogénea dentro de cada subconjunto, de acuerdo a su peso con respecto a la base de datos completa.

6.3. Arquitectura del modelo desarrollado

Desde un punto de vista estructural, el modelo de IA implementado consiste en una arquitectura de DL híbrida conformada por tres módulos (según se aprecian en el diagrama del sistema disponible en la Figura 6.1): el módulo CNN (utilizado para la extracción de características), seguido del LSTM (para el modelamiento secuencial) y, a la salida de este último, el módulo FC (el cual se usa de forma auxiliar para permitir la etapa de clasificación). Esta topología busca integrar la capacidad de extracción de características espaciales de una CNN con el modelamiento de patrones secuenciales de las redes recurrentes tipo LSTM. De esta forma, se busca lograr un modelo robusto, capaz de aislar las huellas espectrales en las respuestas que afectan las variables de la máquina y reconocer los patrones latentes que permiten ejercer un diagnóstico certero.

Adicionalmente, en términos de diseño y parametrización, los hiperparámetros de los distintos módulos del modelo fueron asignados de forma tal de mantener cierta rigidez estructural a la entrada y salida del modelo (garantizando la consistencia dimensional de los datos), mientras que las capas intermedias admiten un ajuste de hiperparámetros mediante el algoritmo de optimización (véase Sección 4.3), ajustando la estructura de la red de forma tal que se maximice su indicador de desempeño: el *f1-score*. En este respecto, tanto la distribución de los hiperparámetros como la dinámica del flujo tensorial a través de cada módulo se detallan en las subsecciones siguientes.

6.3.1. Módulo convolucional

Este módulo cumple una función esencial dentro del modelo: la extracción automática de características a partir de los tensores de entrada, transformando esta estructura tridimensional en mapas de características de un alto nivel de abstracción. Esta acción es realizada para su posterior procesamiento por el módulo LSTM.

Para el desarrollo de esta memoria, se han definido dos arquitecturas diferenciadas relativas a la naturaleza de la entrada del presente módulo, de acuerdo a la cantidad de señales procesadas simultáneamente. La primera y principal configuración consiste en un

tensor de 6 canales, el cual se conforma por una concatenación de los tres canales RGB representativos de los espectrogramas del módulo del vector de Clarke en el tiempo y vibración registrada en el rodamiento (tal como se muestra en la Figura 6.3). Por otra parte, la segunda configuración se basa en el uso de una sola señal para el diagnóstico, por consecuencia, el tensor en cuestión posee solo tres canales.

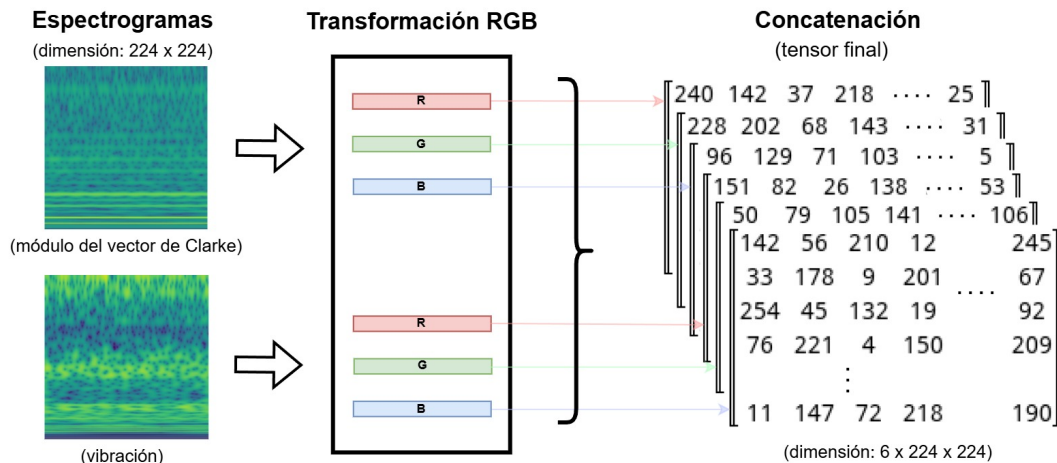


Figura 6.3. Diagrama de la transformación tensorial de los espectrogramas de módulos del vector de Clarke en el tiempo y vibraciones a la entrada del módulo convolucional. Los datos incluidos en el tensor son meramente referenciales.

La implementación de esta arquitectura de entradas diferenciadas responde a un doble propósito: evaluar la robustez del modelo ante la presencia de distintos niveles de información, buscando verificar su capacidad discriminatoria ante una única o múltiples fuentes de información. Por otra parte, esta distinción resulta necesaria para validar el modelo con registros operativos distintos a la del proceso de entrenamiento, ya que este se entrena considerando espectrogramas de señales de corriente y vibración captadas simultáneamente, mientras la de la base de datos empleada para el proceso de validación (proveniente de los registros de la CWRU) contiene únicamente señales vibratorias (además de solo considerar fallas en su sistema de rodamientos). De esta forma, se puede contrastar el desempeño del modelo frente a entornos similares entre los conjuntos de entrenamiento y validación.

Respecto a su estructura interna, una vez los tensores originales hacen ingreso al módulo, atraviesa tres etapas secuenciales, cada una conformada por una capa convolucional bidimensional seguida de una de *maxpooling*. La primera de estas está encargada de la extracción de características locales presentes en cada espectrograma, mientras que la segunda busca reducir el volumen del tensor, preservando la información más relevante para formar el mapa de características relativo a cada salida de una capa convolucional bidimensional. Esta operación permite concentrar la información de mayor relevancia local de cada región del mapa, mitigando la redundancia espacial durante el cómputo, reduciendo la carga computacional del modelo sin comprometer de manera significativa su efectividad.

Al combinar tres bloques compuestos de una capa convolucional bidimensional y la de *maxpooling*, se busca que el modelo detecte patrones progresivamente más complejos, comenzando por rasgos locales simples dentro de regiones puntuales de un espectrograma, hacia características mucho más abstractos.

Cabe señalar que, dentro de las capas convolucionales bidimensionales, se añade la función de activación *ReLU*, la cual busca introducir no-linealidad en el módulo de forma computacionalmente eficiente, aportando tanto al establecimiento de patrones complejos como optimizando el desempeño del modelo.

Además, con el fin de prevenir el sobreajuste del modelo, se integran instancias de *dropout* en la segunda y tercera capa convolucional bidimensional. Este mecanismo de regularización opera mediante la desactivación aleatoria de un porcentaje de neuronas durante cada iteración del proceso de entrenamiento. Este acto obliga a la red a no depender de rutas neuronales específicas, favoreciendo así una representación interna más distribuida y robusta ante datos de entrada variados.

La configuración estructural detallada relativa a los parámetros de estas capas, junto con la evolución dimensional de los tensores que las atraviesan, se presenta en la Tabla 6.3. Cabe destacar que tanto el número de *kernels* en los dos primeros bloques como el valor del parámetro de *dropout* son parte del espacio de búsqueda de hiperparámetros asignados al algoritmo de optimización Optuna (mayor detalle en la Sección 4.3). En consecuencia, los valores finales seleccionados para la arquitectura definitiva se reportan y analizan en el Capítulo 7.

Tabla 6.3. Esquema de la estructura en capas del módulo convolucional implementado.

| Tipo de capa | N° kernels | Tamaño de kernel | Función de activación | Dropout | Dimensión en la salida |
|-----------------|------------|------------------|-----------------------|---------|------------------------|
| Entrada | - | - | - | - | [6, 224, 224] |
| Convolucional 1 | K_1 | 3 | ReLU | - | $[K_1, 224, 224]$ |
| Maxpool 1 | K_1 | 2 | - | - | $[K_1, 112, 112]$ |
| Convolucional 2 | K_2 | 3 | ReLU | Dr | $[K_2, 112, 112]$ |
| Maxpool 2 | K_2 | 2 | - | - | $[K_2, 56, 56]$ |

Según se muestra en la Tabla 6.3, el tensor a la salida del actual módulo corresponde a un mapa de características tridimensional de tamaño $[K_2, 56, 56]$. Para coincidir con el formato de entrada del módulo LSTM, este debe ser adaptado dimensionalmente, debido a que la red recurrente opera bajo secuencias de estructura bidimensional. El procedimiento de adaptación se realiza en dos etapas sucesivas; aplanamiento y permutación, las cuales se describen a continuación.

- **Aplanamiento:** Esta operación consiste en colapsar las dimensiones de canales y altura del tensor original, reordenando sus valores de manera continua sin alterar la coherencia espacial de los datos. En este aspecto, el tensor de dimensiones $[K_2, 56, 56]$ se transforma en uno de $[(K_2 \cdot 56), 56]$.
- **Permutación:** Posteriormente, las dimensiones del tensor bidimensional resultante se intercambian, tal de adecuar la estructura de datos al formato de entrada esperado por el módulo LSTM. Conceptualmente, esta permutación tiene por objetivo alinear la dimensión temporal original de los espectrogramas (ancho de la resolución de entrada de 224×224) con la dimensión secuencial de la red recurrente. En términos estructurales, el tensor de $[(K_2 \cdot 56), 56]$ es transformado a $[56, (K_2 \cdot 56)]$, obteniendo así la entrada al próximo módulo LSTM del modelo.

A modo de adelanto, el espacio de búsqueda del hiperparámetro K_2 se encuentra en un rango aproximado de entre 60 y 80, lo cual da como resultado una estructura de entre 3000 y 4500 pasos temporales para la red LSTM. Esta densidad de información secuencial es uno de los motivos por los cuales se selecciona este tipo de arquitectura recurrente por sobre otra de mayor simplicidad, ya que de otra forma hubiera existido un riesgo considerable de caer en problemas como la explosión o desvanecimiento de gradiente (explicados con mayor profundidad en la Sección 4.2.3 del presente informe) durante el proceso de entrenamiento.

Por otra parte, el flujo de información anteriormente descrito aplica para ambas configuraciones del modelo de acuerdo al número de entradas (una o dos señales). Sin embargo, para el caso en que este posee una entrada multivariable, la arquitectura de CNN en cuestión está diseñada para procesar cada espectrograma de forma independiente, lo cual implica que cada uno posee parámetros entrenables dedicados al análisis exclusivo de dicho de señal. Esta estrategia evita generar redundancias durante el proceso de cómputo relativo a la operación misma del modelo, reduciendo así la carga computacional que conlleva la ejecución del sistema de diagnóstico completo.

6.3.2. Módulo LSTM

Este módulo, representativo del componente recurrente del modelo híbrido propuesto, tiene la función de caracterizar los patrones secuenciales y relaciones dinámicas en los mapas de características extraídas por la CNN.

Estructuralmente, su arquitectura está determinada por el tamaño de la capa oculta (hs), la cual fija su capacidad de memoria a través del control de la dimensionalidad de los vectores de estado oculto (h_t) y estado de celda (c_t). En el modelo propuesto, el hs se determina automáticamente según los criterios del algoritmo de optimización Optuna (véase sección 4.3 del presente documento), de forma similar al ajuste de algunos hiperparámetros del módulo convolucional.

Desde una perspectiva operativa, el módulo procesa el tensor de salida de la CNN (el cual posee dimensión $[28, 3584]$) mediante un mecanismo de flujo iterativo a lo largo de los 28 índices temporales definidos. En cada una de estas iteraciones, la celda LSTM actualiza sus variables de estado internas basándose en la interacción de cada vector de características de dimensión $[1, 3584]$, junto con la memoria acumulada, permitiendo al sistema modelar las dependencias secuenciales entre los patrones espectrales. De esta forma, la salida del presente módulo corresponde al tensor h_t asociado al último componente secuencial analizado, siendo representativo de la memoria final que resume los patrones dinámicos aprendidos por la red a lo largo de todo el proceso de análisis (tal como se muestra en la Figura 6.4). El resultado de esta operación crea una estructura de datos en la salida de dimensión $[1, hs]$, el puede ser interpretado simplemente como un vector.




Figura 6.4. Diagrama del flujo de información a través del módulo LSTM.

A diferencia del ajuste dimensional ocurrido entre los módulos convolucional y LSTM, en esta oportunidad no es menester adaptar dimensionalmente el tensor de salida, ya que ambos módulos LSTM y FC operan sobre conjuntos de datos de igual estructura. De esta forma, el vector de $[1, hs]$ (representado por h_{t28} en la Figura 6.4) representa simultáneamente tanto la salida del módulo recurrente como la entrada directa al posterior bloque totalmente conectado.

6.3.3. Módulo FC

Este bloque constituye la etapa final del modelo propuesto, estando encargado de transformar el vector del último estado secuencial generado por la LSTM en una salida numérica interpretable para el sistema de diagnóstico. En consecuencia, más que un aporte en la detección de patrones o extracción de características de los datos de entrada, representa una herramienta que apoya en la clasificación de estados del MI de acuerdo a las clases establecidas inicialmente.

En términos estructurales, esta red corresponde a una capa densa lineal, la cual recibe como entrada el tensor de dimensiones $[1, hs]$, para luego conectarse directamente a una capa de salida de $[1, 4]$, siendo esta coherente con las cuatro posibles clases asignables para el estado del motor analizado. Durante esta etapa de transición, cada elemento del tensor de entrada es ponderado mediante los pesos y sesgos entrenables propios de cada neurona del módulo, de modo que la red aprenda a asociar los datos secuenciales recibidos con las cuatro categorías de salida. De esta forma, los valores brutos obtenidos a la salida de cada una de las cuatro neuronas son conocidos como *logits*, los cuales establecen las fronteras de decisión del modelo.

Con el objetivo de dotar a los *logits* de interpretabilidad diagnóstica, se acopla la

función de activación *softmax*. Matemáticamente, esta operación toma el vector de valores no normalizados de dimensión $[1, 4]$ y aplica una transformación exponencial normalizada, mapeando la salida del modelo hacia una distribución de probabilidad discreta, donde la suma de los cuatro componentes es estrictamente igual a 1, lo que permite cuantificar el grado de certeza estadística del modelo para cada clase respectiva antes de emitir el diagnóstico definitivo.

6.4. Procesos de entrenamiento y validación

Según se ha dado a entender con anterioridad dentro del presente documento, el procedimiento por el cual el modelo de DL es desarrollado consta de dos etapas: la búsqueda de hiperparámetros óptimos y el proceso de entrenamiento ante la base de datos establecida. En mayor extensión, la primera de estas etapas está determinada en base a múltiples ajustes previos a la ejecución de la búsqueda en cuestión. La configuración más básica se encuentra en el espacio de búsqueda que Optuna recorre en búsqueda del desempeño óptimo del modelo. Dentro del contexto del modelo desarrollado en este trabajo de título, son definidos para este fin los siguientes hiperparámetros y sus respectivos espacios de búsqueda:

- **Tasa de aprendizaje:** Regula la magnitud del ajuste aplicado sobre los parámetros convencionales del modelo (pesos y sesgos) durante el proceso de entrenamiento. Una tasa excesivamente alta podría llegar a causar divergencia durante este entrenamiento, mientras que valores demasiado bajos ralentizan la convergencia o pueden llegar a causar estancamiento en mínimos o máximos locales (según sea el caso). Para el presente estudio, se asigna un espacio de búsqueda para este hiperparámetro entre 0,0001 y 0,001 con asignación de número real.
- **Tamaño de lote:** También conocido como “*batch size*”, este hiperparámetro define la cantidad de muestras procesadas simultáneamente antes de realizar una actualización de sus parámetros convencionales. Este valor influye directamente en la estabilidad del mecanismo de actualización y en el tiempo de entrenamiento, ya que lotes más grandes tienden a producir estimaciones más estables y coherentes, pero demandan mayor capacidad computacional. Por el contrario, valores pequeños aumentan la variabilidad del gradiente y pueden acelerar la convergencia inicial del modelo, pero a costa de una menor estabilidad. Dentro del estudio, se consideran valores pares entre 10 y 20.
- **Probabilidad de *dropout* (D_r):** Define la proporción de neuronas dentro de una capa que son desactivadas de forma aleatoria durante el entrenamiento con el objetivo de reducir el sobreajuste, mejorando así la capacidad de generalización de una red. Una tasa moderada contribuye a evitar que el modelo dependa en exceso de rutas neuronales específicas, mientras que una tasa excesiva puede eliminar consistentemente información relevante para la caracterización de patrones en los datos de entrada. En el modelo propuesto, este hiperparámetro se aplica dentro de la segunda y tercera capa convolucional del módulo respectivo y su espacio de búsqueda se establece entre 0,1 y 0,5 con asignación de un número real.
- **Número de *kernels* (K_1 y K_2):** Controla la cantidad de *kernels* y, en consecuencia, el número de mapas de características generados en la primera y segunda capa

convolucional del módulo CNN. Un incremento de este valor permite al modelo capturar patrones espaciales más complejos en los espectrogramas de entrada, producto del aumento en la dimensionalidad de los tensores intermedios. Sin embargo, este ajuste conlleva a su vez un incremento en el número de parámetros convencionales, lo cual eleva tanto el riesgo de sobreajuste del modelo como el costo computacional durante su ejecución. Para el presente estudio, los espacios de búsqueda para K_1 y K_2 se fijaron respectivamente entre 20 – 44 y 60 – 84, considerando únicamente valores enteros pares. Esta restricción surge en el principio de funcionamiento del módulo CNN, el cual consiste en un análisis segmentado y simétrico entre los dos espectrogramas de entrada, por lo cual es requerido que los *kernels* de cada capa se subdividan equitativamente.

- **Tamaño del estado oculto (hs):** Define la dimensionalidad de los vectores de estados ocultos y de celda presentes en el módulo LSTM. Similar al fenómeno de los *kernels*, valores muy altos ayudan al módulo a representar patrones secuenciales más complejos, pero aumentan el tiempo de cómputo del modelo y riesgo de sobreajuste. Para este trabajo, se establece un espacio de búsqueda distribuido entre los valores 128 y 288 separado con saltos discretos de 32.

En cuanto a la ejecución misma del proceso de optimización, el *framework* de Optuna emplea el estimador TPE⁸ para realizar una exploración bayesiana del espacio de hiperparámetros. Según fue comentado en la Sección 4.4, la función objetivo del estudio se orienta a maximizar el *f1-score* promedio de entre las cuatro clases. Por otra parte, para maximizar la eficiencia en los tiempos de cómputo global, se implementa un mecanismo de poda temprana, el cual fue configurado para abortar dinámicamente cada una de las iteraciones con desempeño subóptimo sostenido dentro de un subconjunto acotado de hiperparámetros dentro del espacio de búsqueda. Este proceso de poda se realiza tras un período de tolerancia de 15 épocas. Aquellos ensayos⁹ que superaron este filtro contemplaron un régimen de entrenamiento máximo de 40 épocas, garantizando la estabilización adecuada de los gradientes para la evaluación definitiva del desempeño. El ajuste de estos parámetros de épocas debe ser realizado considerando el *trade-off* que impone el dar más tiempo para el asentamiento de pesos y sesgos óptimos dentro de la red (en función de la cantidad de épocas) en desmedro del tiempo de cómputo que esta ejecución implica. En el caso particular de las iteraciones con Optuna realizadas en la presente memoria de título, estos procesos poseen una duración aproximada de entre 14 a 30 horas, rondando un número de entre 100 y 120 ensayos realizados para distintas configuraciones de espacios de búsqueda afines.

Una vez definidos los ajustes de hiperparámetros de un modelo, este procede a ser entrenado. Dentro de este proceso, se unen los subconjuntos de entrenamiento y de prueba descritos en la Sección 6.2.3, formando un nuevo subconjunto que contiene el 85 % de la base de datos completa. Una vez preparados los ajustes previos del entrenamiento, nace otro *trade-off*: la cantidad de épocas de entrenamiento para asegurar un correcto aprendizaje del conjunto de entrenamiento a la vez de evitar el sobreajuste. El proceso por el cual fue asignado el número de épocas fue determinado de forma empírica, ya que, por una parte, la arquitectura específica del modelo implementado no es estandarizada dentro de la literatura, y por otra parte, la base de datos madre (perteneciente a la UTFSM) no alcanza

⁸Siglas en inglés de “*Tree-structured Parzen Estimator*”.

⁹También denominados “*trials*”, dentro de la jerga técnica de Optuna.

la popularidad suficiente como para que exista una cantidad suficiente de investigaciones afines que permitan dilucidar un número aproximado. Bajo estas limitaciones, luego de la realización intensiva de ensayos sobre arquitecturas afines y distintas configuraciones de la base de datos, se determinó una cantidad de épocas de entrenamiento que balanceaban el desempeño con el sobreajuste, la cual es de 200 épocas. Según lo anterior, se adopta esta cantidad para las distintas instancias de entrenamiento de forma estandarizada.

Luego del ajuste de todos los parámetros del modelo resultantes del proceso de entrenamiento, se evalúa su desempeño en base al subconjunto de prueba (equivalente al 15% de la base de datos general). Esto permite cuantificar el desempeño final del modelo en base a las métricas objetivo $f1 - score$ y precisión. Naturalmente, dentro de este ensayo se detiene el proceso de actualización de pesos y sesgos del modelo.

Finalmente, el proceso de validación del modelo consiste en dos apartados: prueba de adaptación y generalización. La primera se fundamenta en la evaluación de la capacidad que tiene el modelo de sostener un buen desempeño ante distintas bases de datos. Por otra parte, la evaluación de generalización radica en probar un modelo entrenado (lo que quiere decir que sus parámetros se encuentran definidos en base a un proceso de entrenamiento previo) con respecto a otra base de datos distinta.

Capítulo 7

Resultados y análisis

En una primera instancia, se evalúa el desempeño del modelo considerando los espectrogramas de las señales de vibración registradas en el rodamiento y corriente de la fase *a* provenientes originalmente de la base de datos de la UTFSM. En este contexto, se procede a realizar una búsqueda de hiperparámetros óptimos a través de Optuna, obteniendo como resultado los datos presentados en la Tabla 7.1.

Tabla 7.1. *Hiperparámetros óptimos encontrados por el algoritmo de Optuna para la iteración inicial del modelo.*

| Tamaño de lote | Tasa de aprendizaje | Dr | K_1 | K_2 | h_s |
|----------------|---------------------|---------|-------|-------|-------|
| 12 | 7,11e-4 | 43,38 % | 18 | 40 | 128 |

Luego de entrenar al modelo bajo estos hiperparámetros, se evalúa su desempeño bajo el subconjunto de pruebas, obteniendo la matriz de confusión presentada en la Figura 7.1(a). A su vez, a partir de estos resultados se obtienen los indicadores de desempeño por clase recopilados en la Tabla 7.1(b).

Pese a que el modelo presenta buenos indicadores en las clases mayoritarias (fallas por cortocircuito y mixtas), los resultados generales obtenidos en esta etapa experimental revelan un rendimiento deficiente, alcanzando un *f1-score* promedio por clase de aproximadamente 48 %, debido a su pobre desempeño en las clases minoritarias. Para identificar las causas raíz de este bajo desempeño, se analiza la matriz de confusión de la Figura 7.1(a). El análisis visual de dicha matriz evidencia dos fenómenos inherentes a la distribución de los datos:

1. **Desbalance severo de clases:** Según lo comentado anteriormente, existe disparidad significativa en la cantidad de muestras disponibles por categoría. Las clases correspondientes al estado sano y con falla en rodamiento constituyen las clases minoritarias, presentando un número de instancias drásticamente inferior en comparación con las clases de falla en cortocircuito y falla mixta, las cuales dominan la distribución del conjunto de datos. Cabe destacar que, dado que el conjunto de prueba fue generado mediante una segregación estratificada, este desbalance no es producto del muestreo aleatorio, sino que refleja la asimetría estructural de la base de datos con la que se entrenó el modelo.

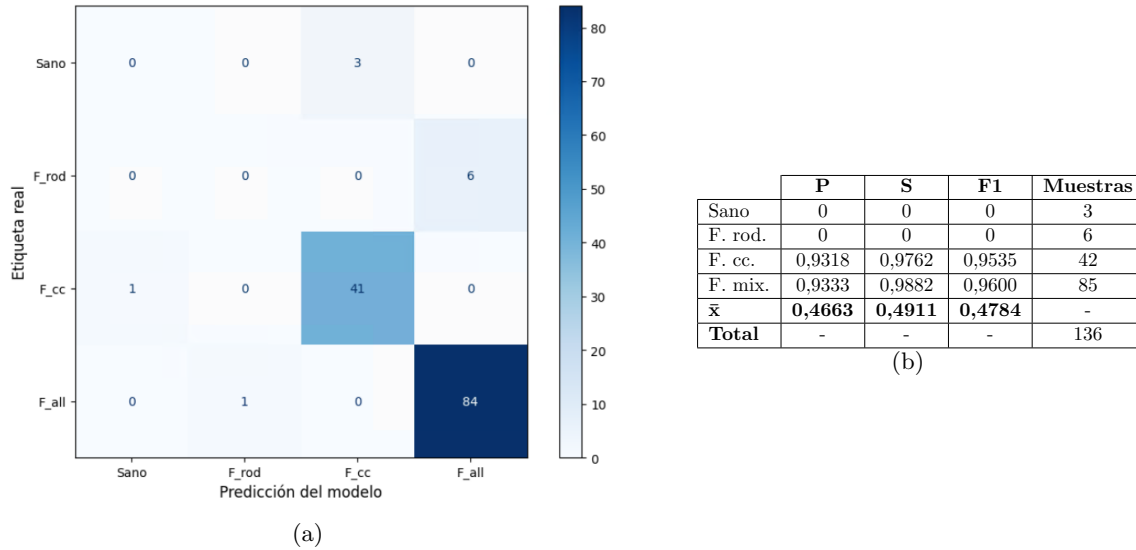


Figura 7.1. Resultados del modelo dual ante entrada de vibración en el rodamiento y corriente de fase a. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas.

2. **Sesgo de predicción hacia clases mayoritarias:** El modelo exhibe un sesgo hacia la predicción de clases mayoritarias. La matriz de confusión muestra que el clasificador tiende a etiquetar erróneamente las instancias de las clases minoritarias (estado sano y falla en rodamiento), asignándolas sistemáticamente a las categorías con mayor representación (fallas por cortocircuito en espiras y mixta). Este comportamiento sugiere que, ante la escasez de características discriminantes para las clases minoritarias durante el entrenamiento, la red neuronal opta por predecir las clases más frecuentes, sacrificando así la sensibilidad en los modos de falla con menor número de muestras.

Con el propósito de mitigar los efectos adversos del desbalance de clases y reducir el sesgo del clasificador, se implementa la EAD descrita en la Sección 6.2.1 del presente informe, permitiendo reestructurar la distribución del conjunto de entrenamiento al aumentar sintéticamente las muestras de clases minoritarias, reduciendo así la brecha de representatividad entre las clases antes comentadas, proporcionando al modelo un escenario de aprendizaje más equilibrado en comparación al anterior. Además, a diferencia del caso anterior, se incorporan a la entrada del modelo los espectrogramas de módulo del vector de Clarke en lugar de solo la corriente de fase a.

Bajo este nuevo conjunto de datos, se repite el proceso de búsqueda de hiperparámetros mediante Optuna, obteniendo los valores presentes en la Tabla 7.2. Luego, se procede a evaluar el rendimiento del modelo ante este nuevo conjunto de datos, generando de esta forma la matriz de confusión y el conjunto de indicadores por clase presentados en la Figura 7.2(a) y la Tabla 7.2(b) respectivamente.

Tabla 7.2. Hiperparámetros óptimos encontrados por el algoritmo de Optuna para el modelo luego de aplicar las EAD sobre la base de datos.

| Tamaño de lote | Tasa de aprendizaje | Dr | K_1 | K_2 | h_s |
|----------------|---------------------|---------|-------|-------|-------|
| 12 | 3,95E-4 | 36,94 % | 17 | 46 | 128 |

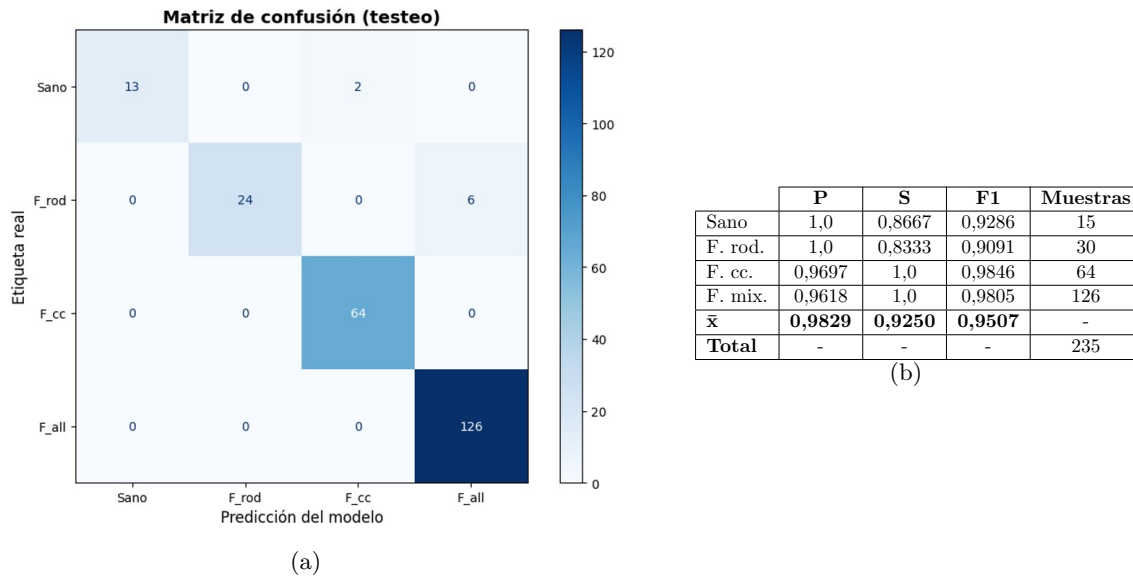


Figura 7.2. Resultados del modelo dual ante entrada de vibración en el rodamiento y módulo del vector de Clarke. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas.

Luego de la implementación de esta EAD se aprecia una mejora considerable en el indicador global de desempeño. En concreto, el $f1$ -score promedio por clase ascendió desde un valor inicial cercano al 48 % hasta alcanzar un 91,02 %. Este salto cuantitativo valida la hipótesis de que el déficit inicial no radicaba en la arquitectura del modelo, sino en la insuficiencia de información representativa para las clases minoritarias.

Al desglosar este desempeño por categorías, se observan dos comportamientos diferenciados:

1. **Consolidación de clases mayoritarias:** Las clases que originalmente contaban con mayor representación (falla por cortocircuito y mixta) mostraron un ligero incremento en sus métricas, estabilizándose en valores de $f1$ -score superiores al 97 %. Esto indica que la inyección de datos sintéticos no degradó la capacidad del modelo para reconocer los patrones que ya dominaba.
2. **Mejor capacidad de reconocimiento de clases minoritarias:** Las clases representativas del estado sano y en falla en rodamiento, cuyos parámetros de desempeño originalmente eran nulos, mostraron una mejora significativa, alcanzando un $f1$ -score de 92,86 % y 88,89 % respectivamente.

Según lo anteriormente comentado, se muestra que la inclusión de las EAD, junto con la herramienta del módulo del vector de Clarke en el tiempo, mejora considerablemente el

desempeño del modelo para todas las clases, incluso las mayoritarias.

Al apreciar con mayor detalle la matriz de confusión de la Figura 7.2(a), en concreto, a los falsos negativos de las clases “Sano” y “F_rod”, se evidencia que el modelo aún conserva un pequeño sesgo hacia las clases predominantes. Sin embargo, estas falencias del modelo pierden criticidad frente a una de las fortalezas más destacables: la ausencia total de falsos positivos para la clase “Sano”. Tal como se observa en la primera columna de la matriz, el modelo no etiqueta erróneamente ninguna de las condiciones de falla como un estado de funcionamiento saludable. Este hecho, al apreciarlo desde la disciplina del monitoreo de condiciones, implica que un sistema de monitoreo garantiza que ninguna condición de falla en el activo pase desapercibida. A su vez, desde la perspectiva de la confiabilidad, es preferible contar con un sistema de monitoreo que ocasionalmente levante una falsa alarma (diagnosticando fallas en un equipo sano) a uno que omita daños reales, mitigando de esta forma el riesgo de paradas imprevistas de la producción debido a fallos catastróficos en el activo.

Una vez establecida la robustez del modelo dual, se procede a comprobar su desempeño a la hora de ser alimentado por una señal única. En este respecto, fueron realizadas pruebas para los espectrogramas relativos a todas las señales disponibles en la base de datos de la UTFSM: vibración en el soporte del rodamiento fallado, vibración en la carcasa del MI estudiado, cada una de las corrientes trifásicas de estator y su respectiva señal del módulo del vector de Clarke en el tiempo. En la Tabla 7.3 se presenta un resultado resumido de los parámetros de desempeño promedio para cada uno de los escenarios antes planteados. A partir de esta última Tabla 7.3, se deduce que el modelo monovariado no es capaz de

Tabla 7.3. *Desempeño del modelo evaluado ante diferentes características y señales de entrada.*

| Señales | Desempeño | |
|-----------------------------|-----------|----------|
| | Precisión | F1-Score |
| Módulo del vector de Clarke | 0,843 | 0,814 |
| Vibración en rodamiento | 0,731 | 0,732 |
| Vibración en carcasa | 0,772 | 0,748 |
| Corriente fase <i>a</i> | 0,654 | 0,647 |
| Corriente fase <i>b</i> | 0,711 | 0,692 |
| Corriente fase <i>c</i> | 0,678 | 0,637 |


realizar detecciones confiables a partir del entrenamiento con registros provenientes de la base de datos UTFSM. Por otra parte, estos registros comparativos muestran el valor que posee el módulo del vector de Clarke para el diagnóstico de estados, poseyendo el mejor desempeño para el modelo monovariado en comparación al resto de señales barajadas. Más aún, al apreciar la superioridad de entre un 12% y 17% con respecto al desempeño unitario de las corrientes de estator, confirma los supuestos iniciales planteados en la Sección 3.2, los cuales dictaban que el análisis de este módulo en el tiempo es siempre preferible ante el unitario de las corrientes. Esto ya que la señal de Clarke tiene la capacidad de representar fenómenos electromagnéticos enmascarados por el enfoque basado en una corriente unitaria.

Una vez evaluadas las métricas para los conjuntos de datos con origen en los registros de la UTFSM, se procede a someter al modelo a una etapa de validación utilizando la base de datos de la CWRU y KAIST. El objetivo de esta fase es evaluar la capacidad

de adaptabilidad de la arquitectura propuesta frente a señales provenientes de un sistema electromecánico con características constructivas, modos de falla y condiciones de adquisición distintas a las bases del entrenamiento original. Para la realización de este menester, se consideran todos los tipos de falla presentes en cada base de datos, lo cual permite analizar el comportamiento del modelo ante diversos tipos de falla. Sin embargo, el interés principal radica en el desempeño ante las clases relativas a la operación sana y bajo falla en elemento rodante, ya que son dos de las fallas originales que se planteaban para el sistema de diagnóstico.

A partir de lo anteriormente comentado, se realizan las pruebas de validación sobre el conjunto de datos de la CWRU. En esta, se realiza una segregación de subconjuntos y estratificación de muestras de forma idéntica al proceso de entrenamiento del modelo con la base de datos de la UTFSM. Una vez concluido este ajuste preliminar, son obteniendo los indicadores de desempeño de la Tabla 7.3(b) y la matriz de confusión de la Figura 7.3(a). En esta última, las etiquetas en los ejes representan el tipo de falla en el rodamiento, tal que:

- ER: Falla en elemento rodante.
- PE: Falla en pista externa.
- PI: Falla en pista interna.



(a)

| | P | S | F1 | Muestras |
|--------------|------------|------------|------------|----------|
| Sano | 1,0 | 1,0 | 1,0 | 42 |
| F. rod. | 1,0 | 1,0 | 1,0 | 36 |
| F. PE | 1,0 | 1,0 | 1,0 | 36 |
| F. PI. | 1,0 | 1,0 | 1,0 | 36 |
| \bar{x} | 1,0 | 1,0 | 1,0 | - |
| Total | - | - | - | 150 |

(b)

Figura 7.3. Resultados del modelo entrenado en base a registros de la CWRU. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas.

En este contexto, se realiza un procedimiento homólogo para evaluar el modelo según la base de datos de KAIST, obteniendo los resultados de la Figura 7.4.

Los resultados obtenidos tras someter al modelo a estas diferentes bases de dato evidencian un desempeño excelente a la hora de clasificar los modos de falla respectivos, pese a que estos no han sido con los cuales fue concebido el modelo originalmente. Tal como se observa en las respectivas tablas de métricas de desempeño, el algoritmo alcanzó una precisión, sensibilidad y *f1-score* de 100 % para la totalidad de las categorías evaluadas.

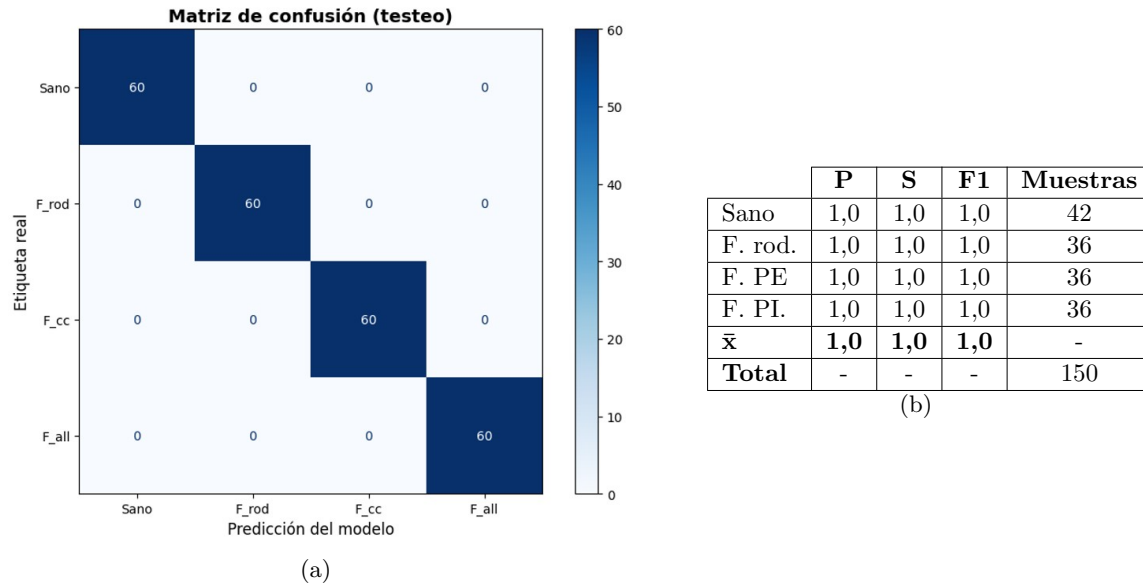


Figura 7.4. Resultados del modelo entrenado en base a registros de la CWRU. Se presentan la (a) matriz de confusión y su (b) tabla de parámetros de desempeño derivadas.

Al contrastar este desempeño ideal con los resultados presentados en la Figura 7.2 y, en especial, en la Tabla 7.3, basados en los registros de la UTFSM. El modelo posee discrepancias no menores con respecto a su adaptabilidad ante diferentes conjuntos de datos de entrenamiento, en particular ante su versión monovariable.

Capítulo 8

Conclusiones

El presente trabajo de título culminó con el desarrollo exitoso de un algoritmo de detección y diagnóstico de fallas para motores de inducción, basado en modelos de aprendizaje supervisado. Se demostró que la integración de técnicas de inteligencia artificial con herramientas de tratamiento de datos permiten automatizar el diagnóstico del estado de un MI sometido a diversas condiciones de falla de distinta naturaleza en entornos experimentales controlados. De esta forma, se espera aportar, aunque sea con un grano de arena, a la transición hacia estrategias de mantenimiento predictivo más eficientes y robustas.

Fue realizada una caracterización de las principales causas de falla en los motores de inducción trifásicos mediante una revisión bibliográfica relativa a estudios de alto valor académico. Este análisis permitió identificar las averías en el estator y en el sistema de rodamientos como las más prevalentes en motores de inducción. En consecuencia, y considerando la disponibilidad de datos experimentales suficientes para el entrenamiento, el sistema de diagnóstico se centró específicamente en las fallas por cortocircuitos entre espiras y las en elementos rodantes del sistema de rodamientos. Esta decisión impuso una cota al alcance del algoritmo, aunque sin desmedro de atacar a los principales conjuntos de falla que representan la mayor incidencia de paradas no programadas en la industria.

En términos del análisis de estas fallas seleccionadas, se consolidó una base de datos robusta de señales representativas de la operación sana y bajo falla. En este sentido, a partir de los registros provenientes de la UTFSM, se estructuró un conjunto de espectrogramas que capturaron la firma dinámica de los modos de falla seleccionados. La calidad y organización de esta base de datos fueron determinantes para el desempeño posterior del modelo, validando la importancia de esta etapa de preprocesamiento de las señales vibratorias y de corriente de estator.

El entrenamiento del algoritmo de aprendizaje supervisado satisfizo las expectativas de diseño. La implementación de estrategias de aumento de datos, sumada a la optimización de hiperparámetros con Optuna, dotó al modelo de una gran capacidad de generalización. Esto permitió el reconocimiento de patrones de falla aun en presencia de señales ausentes en el conjunto de datos original. La robustez y adaptabilidad del modelo se evidencia mediante una validación con una base de datos externa al proceso de entrenamiento, perteneciente a las instituciones CWRU y KAIST, obteniendo a partir ambas una métrica *f1-score* del 100%.

A pesar de alcanzar un desempeño global sobresaliente, con una precisión promedio

por clase de 98,29 %, el modelo definitivo presenta ligeras desviaciones en la predicción de las categorías minoritarias. Sin embargo, un análisis detallado de los resultados revela que estos errores carecen de mayor importancia en comparación con los aciertos. Las clasificaciones erróneas de mayor criticidad se limitan a diagnosticar una falla en cortocircuito cuando el equipo opera de forma saludable, ergo, una falsa alarma. En el contexto del mantenimiento industrial, el riesgo de mayor severidad ligado a una predicción errónea radica en los falsos negativos (diagnosticar como sano a un motor en condición de falla). En este contexto, el modelo propuesto, en su versión bi-variable, se elude a cabalidad este escenario, ya que se registran cero predicciones erradas de este tipo. Lo anterior ratifica la viabilidad técnica del algoritmo desarrollado, privilegiando la seguridad del activo al asegurar que ninguna condición anómala pase desapercibida durante la operación.

Trabajo futuro

A partir de los resultados obtenidos y considerando las limitaciones inherentes a los entornos experimentales abordados en el presente documento, se identifican las siguientes líneas de investigación futuras:

1. **Ampliación de capacidad de clasificación ante distinta naturaleza de datos de falla:** Se propone evaluar la capacidad de generalización del modelo desarrollado mediante un espectro de datos más amplio. En este sentido, el enfoque es multimodal: una de las aristas de esta búsqueda puede materializarse en la implementación de registros operativos relativos a diferentes condiciones de falla (tales como barras rotas en el rotor, excentricidad, entre otras), así como la integración de nuevas variables físicas operativas diferentes a las utilizadas (entre estas: temperatura, emisiones acústicas, etc). Por otra parte, dado que el procesamiento de datos se fundamenta en el ATF, el algoritmo posee el potencial teórico para diagnosticar el estado de un MI bajo regímenes de operación no estacionarios. Explorar esta vía permitiría expandir significativamente las fronteras de análisis del sistema actual.
2. **Optimización computacional e implementación IoT¹⁰:** Si bien el presente algoritmo alcanzó un alto desempeño de clasificación, durante su desarrollo frecuentemente se priorizó la eficacia diagnóstica por sobre la eficiencia en el consumo de recursos computacionales. Por ende, se hace necesario realizar un análisis de eficiencia exhaustivo desde una perspectiva de ingeniería informática, buscando optimizar el código fuente para reducir la carga computacional y los tiempos de simulación, sin desmedro los índices de desempeño. Esta optimización estructural está orientada a viabilizar este algoritmo ante escenarios de integración en sistemas embebidos de naturaleza IoT, permitiendo el monitoreo de condición de activos eléctricos en tiempo real dentro de entornos industriales.
3. **Desarrollo de una herramienta de software con interfaz de usuario:** En la línea de la implementación IoT anteriormente descrita, se plantea el encapsulamiento del sistema de diagnóstico desarrollado en una aplicación de *software* integral, con interfaz gráfica de usuario. Este desarrollo facilitaría la ejecución del proceso de clasificación de estados de un MI por parte de un operador que no necesariamente posea conocimientos expertos en el ámbito de mantenimiento de maquinaria eléctrica

¹⁰Del inglés “Internet of Things”.

ni habilidades de programación como para manipular código fuente. De este modo, la herramienta lograría entregar diagnósticos sobre la condición de los activos de manera directa, autónoma y accesible para el entorno industrial.

Bibliografía

- [1] R. Mobley. *An Introduction to Predictive Maintenance*. 2.^a ed. Burlington, EEUU: Butterworth-Heinemann, 2002.
- [2] D. Siyambalapitiya y P. McLaren. «Reliability improvement and economic benefits of on-line monitoring systems for large induction machines». En: *IEEE Transactions on Industry Applications* 26.6 (1990), págs. 1018-1025. DOI: [10.1109/28.62371](https://doi.org/10.1109/28.62371).
- [3] S. Nandi, H. Toliyat y X. Li. «Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review». En: *IEEE Transactions on Energy Conversion* 20.4 (2005), págs. 719-729. DOI: [10.1109/TEC.2005.847955](https://doi.org/10.1109/TEC.2005.847955).
- [4] «Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part I». En: *IEEE Transactions on Industry Applications* IA-21.4 (1985), págs. 853-864. DOI: [10.1109/TIA.1985.349532](https://doi.org/10.1109/TIA.1985.349532).
- [5] «Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part II». En: *IEEE Transactions on Industry Applications* IA-21.4 (1985), págs. 865-872. DOI: [10.1109/TIA.1985.349533](https://doi.org/10.1109/TIA.1985.349533).
- [6] «Report of Large Motor Reliability Survey of Industrial and Commercial Installations: Part 3». En: *IEEE Transactions on Industry Applications* IA-23.1 (1987), págs. 153-158. DOI: [10.1109/TIA.1987.4504880](https://doi.org/10.1109/TIA.1987.4504880).
- [7] P. Albrecht et al. «Assessment of the Reliability of Motors in Utility Applications - Updated». En: *IEEE Transactions on Energy Conversion* EC-1.1 (1986), págs. 39-46. DOI: [10.1109/TEC.1986.4765668](https://doi.org/10.1109/TEC.1986.4765668).
- [8] M. El Hachemi Benbouzid. «A review of induction motors signature analysis as a medium for faults detection». En: *IEEE Transactions on Industrial Electronics* 47.5 (2000), págs. 984-993. DOI: [10.1109/41.873206](https://doi.org/10.1109/41.873206).
- [9] Y. Liu y A. M. Bazzi. «A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art». En: *ISA Transactions* 70 (2017), págs. 400-409. DOI: <https://doi.org/10.1016/j.isatra.2017.06.001>.
- [10] R. Sánchez et al. «Evaluation of Hand-Crafted Feature Extraction for Fault Diagnosis in Rotating Machinery: A Survey». En: *Sensors* 24.16 (2024), pág. 5400. DOI: [10.3390/s24165400](https://doi.org/10.3390/s24165400).
- [11] R. Zhao et al. «Deep learning and its applications to machine health monitoring». En: *Mechanical Systems and Signal Processing* 115 (2019), págs. 213-237. DOI: [10.1016/j.ymsp.2018.05.050](https://doi.org/10.1016/j.ymsp.2018.05.050).

- [12] Y. Lei et al. «Applications of machine learning to machine fault diagnosis: A review and roadmap». En: *Mechanical Systems and Signal Processing* 138 (2020), págs. 106587. DOI: [10.1016/j.ymssp.2019.106587](https://doi.org/10.1016/j.ymssp.2019.106587).
- [13] A. Zhang et al. *Dive into Deep Learning*. 1.^a ed. Cambridge University Press, 2023. DOI: [10.48550/arXiv.2106.11342](https://doi.org/10.48550/arXiv.2106.11342).
- [14] J. Xu et al. «Fault Diagnosis Method of Permanent Magnet Synchronous Motor Based on CNN-LSTM-Attention». En: *2025 IEEE 20th Conference on Industrial Electronics and Applications (ICIEA)*. 2025. DOI: [10.1109/ICIEA65512.2025.11148794](https://doi.org/10.1109/ICIEA65512.2025.11148794).
- [15] X. Zeng y X. Feng. «Bearing Fault Diagnosis with Small Sample Sizes Based on CNN-SE-LSTM Transfer Learning». En: *2025 40th Youth Academic Annual Conference of Chinese Association of Automation (YAC)*. 2025, págs. 2617-2622. DOI: [10.1109/YAC66630.2025.11149878](https://doi.org/10.1109/YAC66630.2025.11149878).
- [16] S. Sun et al. «Study on the fault diagnosis of rolling bearings based on the CNN-BiLSTM method». En: *2023 6th International Conference on Renewable Energy and Power Engineering (REPE)*. 2023, págs. 136-140. DOI: [10.1109/REPE59476.2023.10512182](https://doi.org/10.1109/REPE59476.2023.10512182).
- [17] P. Zhang et al. «A survey of condition monitoring and protection methods for medium-voltage induction motors». En: *IEEE Transactions on Industry Applications* 47.1 (2011), págs. 34-46. DOI: [10.1109/TIA.2010.2090839](https://doi.org/10.1109/TIA.2010.2090839).
- [18] L. Niemeyer. «A generalized approach to partial discharge modeling». En: *IEEE Transactions on Dielectrics and Electrical Insulation* 2.4 (1995), págs. 510-528. DOI: [10.1109/94.407017](https://doi.org/10.1109/94.407017).
- [19] G. Stone et al. *Electrical Insulation for Rotating Machines*. 2.^a ed. Hoboken, EEUU: John Wiley Sons, Inc., 2014.
- [20] R. Randall. *Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace Applications*. 2.^a ed. Hoboken, EEUU: Wiley, 2021.
- [21] LFD. *Catálogo de rodamientos de bolas de LFD*. Sitio web de LFD. [Online]. Accedido: 25 de junio de 2025. URL: <https://www.lfd.eu/es/rodamientos-de-bolas-de-lfd.html>.
- [22] J. Zarei y J. Poshtan. «An Advanced Park's Vectors Approach for Bearing Fault Detection». En: *2006 IEEE International Conference on Industrial Technology*. 2006, págs. 1472-1479. DOI: [10.1109/ICIT.2006.372562](https://doi.org/10.1109/ICIT.2006.372562).
- [23] S. Gunasekaran et al. «Condition Monitoring and Diagnosis of Outer Raceway Bearing Fault using Support Vector Machine». En: *2018 Condition Monitoring and Diagnosis (CMD)*. 2018, págs. 1-6. DOI: [10.1109/CMD.2018.8535744](https://doi.org/10.1109/CMD.2018.8535744).
- [24] ISO. *Rolling bearings—Damage and failures—Terms, characteristics and causes*. Disponible en: BSI Standards Publication. 2017.
- [25] S. McNerny e Y. Dai. «Basic Vibration Signal Processing for Bearing Fault Detection». En: *IEEE Transactions on Education* 46.1 (2003), págs. 149-156. DOI: [10.1109/TE.2002.808234](https://doi.org/10.1109/TE.2002.808234).
- [26] B. Li et al. «Neural-network-based Motor Rolling Bearing Fault Diagnosis». En: *IEEE Transactions on Industrial Electronics* 47.5 (2000), págs. 1060-1069. DOI: [10.1109/41.873214](https://doi.org/10.1109/41.873214).

- [27] G. Enríquez. *Pruebas y mantenimiento a equipos eléctricos*. 1.^a ed. México: Limusa Noriega, 2005.
- [28] J. Fraile Mora. *Máquinas Eléctricas*. 6.^a ed. Aravaca, Madrid, España: McGraw-Hill/Interamericana de España, 2008.
- [29] H. Tiismus et al. «Design and Performance of Laser Additively Manufactured Core Induction Motor». En: *IEEE Access* 10 (mayo de 2022), págs. 50137-50152. DOI: [10.1109/ACCESS.2022.3173317](https://doi.org/10.1109/ACCESS.2022.3173317).
- [30] A. Shakeel. «High temperature and high electrical resistance multilayer polyimide nanodielectrics for electric motors insulation». Doctoral dissertation. Université Montpellier, 2020. URL: <https://tel.archives-ouvertes.fr/tel-03191962>.
- [31] O. Gubarevych, S. Goolak y S. Golubieva. «Systematization and Selection of Diagnosing Methods for the Stator Windings Insulation of Induction Motors». En: *Revue Roumaine des Sciences Techniques, Série Électrotechnique et Énergétique* (oct. de 2022), págs. 445-450.
- [32] G. Joksimović y J. Penman. «The detection of inter-turn short circuits in the stator windings of operating motors». En: *IEEE Transactions on Industrial Electronics* 47.5 (2000), págs. 1078-1084. DOI: [10.1109/41.873216](https://doi.org/10.1109/41.873216).
- [33] J. Penman et al. «Detection and location of interturn short circuits in the stator windings of operating motors». En: *IEEE Transactions on Energy Conversion* 9.4 (1994), págs. 652-658. DOI: [10.1109/60.368345](https://doi.org/10.1109/60.368345).
- [34] W. Thomson. «On-line MCSA to diagnose shorted turns in low voltage stator windings of 3-phase induction motors prior to failure». En: *Conference Record of the 2001 IEEE Industry Applications Conference. 36th IAS Annual Meeting*. Vol. 2. 2001, págs. 891-898. DOI: [10.1109/IEMDC.2001.939425](https://doi.org/10.1109/IEMDC.2001.939425).
- [35] A. Bellini et al. «Diagnosis of bearing faults in induction machines by vibration or current signals: A critical comparison». En: *IEEE Transactions on Industry Applications* 46.4 (2010), págs. 1350-1359. DOI: [10.1109/TIA.2010.2049623](https://doi.org/10.1109/TIA.2010.2049623).
- [36] G. Salles et al. «Monitoring of induction motor load by neural network techniques». En: *IEEE Transactions on Power Electronics* 15.4 (2000), págs. 762-768. DOI: [10.1109/63.849047](https://doi.org/10.1109/63.849047).
- [37] S. Vishwakarma et al. «Attention-enhanced Alexnet for improved radar micro-Doppler signature classification». En: *IET Radar, Sonar & Navigation* 17.4 (2023), págs. 652-664. DOI: [10.1049/rsn2.12369](https://doi.org/10.1049/rsn2.12369).
- [38] W. Zhang et al. «A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals». En: *Sensors* 17.2 (2017), pág. 425. DOI: [10.3390/s17020425](https://doi.org/10.3390/s17020425).
- [39] J. Wodecki et al. «Analysis of Clarke Vector Hodograph Shape for Diagnostics of Inter-Turn Fault in Stators of Induction Electric Motors». En: *IEEE Transactions on Industrial Electronics* 2 (2026). DOI: [10.1109/TIE.2025.3595985](https://doi.org/10.1109/TIE.2025.3595985).
- [40] B. Boashash, ed. *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference*. Amsterdam: Elsevier, 2003. ISBN: 978-0-12-398499-9.

- [41] V. Chilukuri y P. Sarkar. «Time-Frequency Analysis Tool for Intelligent Condition Monitoring Diagnostics». En: *2022 International Conference for Advancement in Technology (ICONAT)*. Goa, India, 2022. DOI: [10.1109/ICONAT53423.2022.9725824](https://doi.org/10.1109/ICONAT53423.2022.9725824).
- [42] R. Stockwell, L. Mansinha y R. Lowe. «Localization of the complex spectrum: the S transform». En: *IEEE Transactions on Signal Processing* 44.4 (1996), págs. 998-1001. DOI: [10.1109/78.492555](https://doi.org/10.1109/78.492555).
- [43] R. Zhao et al. «Deep learning and its applications to machine health monitoring». En: *Mechanical Systems and Signal Processing* 115 (2019), págs. 213-237. DOI: [10.1016/j.ymsp.2018.05.050](https://doi.org/10.1016/j.ymsp.2018.05.050).
- [44] Y. Bathaee. «The Artificial Intelligence Black Box and the Failure of Intent and Causation». En: *Harvard Journal of Law & Technology* 31.2 (2018), págs. 889-938.
- [45] Z. Lipton. «The Mythos of Model Interpretability: In machine learning, the concept of interpretability is both important and slippery». En: *ACM Queue* 16.3 (2018), págs. 31-57. DOI: [10.1145/3236386.3241340](https://doi.org/10.1145/3236386.3241340).
- [46] S. Meduri. «Activation Functions in Neural Networks: A Comprehensive Overview». En: *International Journal of Research in Computer Applications and Information Technology (IJRCAIT)* 7.2 (2024), págs. 214-227. DOI: [10.5281/zenodo.13950374](https://doi.org/10.5281/zenodo.13950374).
- [47] Y. LeCun et al. «Gradient-based learning applied to document recognition». En: *Proceedings of the IEEE* 86.11 (1998), págs. 2278-2324. DOI: [10.1109/5.726791](https://doi.org/10.1109/5.726791).
- [48] A. Ghosh et al. «Fundamental Concepts of Convolutional Neural Network». En: ed. por Valentina E. Balas, Raghvendra Kumar y Rajashree Srivastava. 2020, págs. 519-567. DOI: [10.1007/978-3-030-32644-9_36](https://doi.org/10.1007/978-3-030-32644-9_36).
- [49] D. Rumelhart, G. Hinton y R. Williams. «Learning representations by back-propagating errors». En: *Nature* 323.6088 (1986), págs. 533-536. DOI: [10.1038/323533a0](https://doi.org/10.1038/323533a0).
- [50] S. Hochreiter y J. Schmidhuber. «Long Short-Term Memory». En: *Neural Computation* 9.8 (1997), págs. 1735-1780. DOI: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735).
- [51] T. Akiba et al. «Optuna: A Next-generation Hyperparameter Optimization Framework». En: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2019. DOI: [10.1145/3292500.3330701](https://doi.org/10.1145/3292500.3330701).
- [52] S. Mohammed et al. «The effects of data quality on machine learning performance on tabular data». En: *Information Systems* 132 (2025), págs. 102549. ISSN: 0306-4379. DOI: [10.1016/j.is.2025.102549](https://doi.org/10.1016/j.is.2025.102549).
- [53] I. Polymeropoulos et al. «Bridging AI and Maintenance: Fault Diagnosis in Industrial Air-Cooling Systems Using Deep Learning and Sensor Data». En: *Machines* 13.10 (2025), págs. 909. DOI: [10.3390/machines13100909](https://doi.org/10.3390/machines13100909).
- [54] M Benninger, M. Liebschner y C. Kreischer. «Fault Detection of Induction Motors with Combined Modeling- and Machine-Learning-Based Framework». En: *Energies* 16.8 (2023). DOI: [10.3390/en16083429](https://doi.org/10.3390/en16083429).
- [55] Case Western Reserve University. *Bearing Data Center*. Accedido: 2026-01-02. 2003. URL: <https://engineering.case.edu/bearingdatacenter>.
- [56] SKF. *6205 2RSJEM - Rodamientos rígidos de bolas*. Accedido: 2026-01-04. URL: <https://www.skf.com/cl/productinfo/productid-6205%20RSJEM>.

-
- [57] W. Jung et al. «Vibration, acoustic, temperature, and motor current dataset of rotating machine under varying operating conditions for fault diagnosis». En: *Data in Brief* 48 (2023), pág. 109049. DOI: [10.1016/j.dib.2023.109049](https://doi.org/10.1016/j.dib.2023.109049).
- [58] NSK. *6205 APN - Single-Row Deep Groove Ball Bearings*. Accedido: 2026-03-08. URL: <https://www.oss.nsk.com/products/bearings/ball-bearings/deep-groove-ball-bearings/single-row-deep-groove-ball-bearings/6205-apn.html>.