

Desarrollo de un modelo de Inteligencia Artificial para el diagnóstico de fallas en motores de inducción trifásicos

Carlos Ignacio Tobar Lomas

2025

*Requisito parcial para obtener el título de:
Ingeniero Civil Electricista*

Profesor Guía:

Dr. Johnny Wladimir Rengifo Santana (UTFSM)

Profesores Correferentes:

Dr. Antonio Sánchez Squella (UTFSM)

Dr. Danilo Estay Barrientos (UTFSM)

Santiago, Agosto 2025.



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 modelo de Inteligencia Artificial para el diagnóstico de fallas en motores de inducción trifásicos

Nombre del candidato(a): Carlos Ignacio Tobar Lomas

Carrera / Grado: Ingeniería Civil Eléctrica

Campus: Santiago, San Joaquín **Departamento:** 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: 21/10/25

Firma:

Estudiante o Candidato(a):

Fecha: 21/10/25

Firma:

Carlos Tobar

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.

“Un gran hombre siempre se recupera de una derrota, pero un mediocre nunca se repone del éxito”.
— *Eduardo Bonvallet (El gurú)*

Agradecimientos

*A mi familia —mi abuela **Gladys**, mi abuelo **Antonio**, mi madre **Isabel** y mi tía **Charito**— por ser mi sostén incondicional. Sentí su cariño en los gestos cotidianos: en cada almuerzo y comida preparados con paciencia, en esas onces a deshora cuando el tiempo no alcanzaba, en cada momento en que no podía ocuparme de mí por cumplir con mis deberes de estudiante y ustedes aparecían para ofrecerme apoyo y descanso. Gracias por cuidarme para que yo pudiera seguir; por la calma, la confianza y el abrigo que me devolvían fuerzas.*

*A la memoria de mi abuelo **Antonio**. No estuviste al final del camino, pero fuiste tú quien encendió la chispa: me enseñaste a desarmar y volver a armar; a pensar, comprender y reparar; a mirar el mundo con curiosidad e ingenio. Cada logro lleva la huella de tu paciencia y dedicación.*

*A **Constanza**, mi compañera y confidente, por brindarme siempre el aliento necesario para continuar. Gracias por creer en mí cada vez que dudaba, por sostenerme en cada desvelo y por comprenderme siempre; por darme el tiempo que este sueño exigía y por acompañarme, incluso cuando el camino se hacía largo. Tu apoyo, tu comprensión y tu cariño fueron calma, tranquilidad y fortaleza. Sin ti, este trabajo no habría sido posible.*

*A mis **amigos de universidad**, por la amistad que nos sostuvo durante las largas jornadas de estudio, por las conversaciones que aclararon ideas y por las risas que aligeraron el camino. Este logro también es suyo.*

*A mis profesores, por su dedicación y por abrirme puertas al conocimiento con rigor y humanidad. En especial, al profesor **Johnny**, por su guía, paciencia y comprensión; por orientar mi trabajo con criterio y escuchar con atención cada duda y cada propuesta.*

*Al equipo de **pañol de Ingeniería Eléctrica y a los colegas de Ingeniería Mecánica**, por su disposición y oficio para volver tangible lo que partió como ideas y bocetos.*

Por último, a todas las personas que, de una u otra forma, aportaron a este proceso: gracias por su tiempo, sus consejos y su apoyo. Este hito es el resultado de un esfuerzo compartido.

Nomenclatura

AUC	: Área Bajo la Curva (Area Under the Curve).
ANN	: Red Neuronal Artificial (Artificial Neural Network).
CNN	: Red Neuronal Convolutacional (Convolutional Neural Network).
CWT	: Transformada Wavelet Continua (Continuous Wavelet Transform).
CSCF	: Velocidad Constante, Frecuencia Constante (Constant Speed, Constant Frequency).
DAL	: Desplazamiento de Apoyos Lejanos.
DAC	: Desplazamiento de Apoyos Cercanos.
DAG	: Grafo Acíclico Dirigido (Directed Acyclic Graph).
DL	: Aprendizaje Profundo (Deep Learning).
DOIG	: Generador de Inducción de Doble Salida (Double-Output Induction Generator).
DWT	: Transformada Wavelet Discreta (Discrete Wavelet Transform).
EPRI	: Electric Power Research Institute.
FFT	: Transformada Rápida de Fourier (Fast Fourier Transform).
FNN	: Red Neuronal Feedforward (Feedforward Neural Network).
FN	: Falso Negativo (False Negative).
FP	: Falso Positivo (False Positive).
FPR	: Tasa de Falsos Positivos (False Positive Rate).
FL	: Lógica Difusa (Fuzzy Logic).
GA	: Algoritmo Genético (Genetic Algorithm).
IEEE	: Institute of Electrical and Electronics Engineers.
IA	: Inteligencia Artificial (Artificial Intelligence).
K-NN	: k Vecinos Más Cercanos (k-Nearest Neighbors).
LVU	: Desbalance de Tensión de Línea (Line-Voltage Unbalance).
MAV	: Valor Absoluto Medio (Mean Absolute Value).
MCSA	: Análisis de Firma de Corriente de Motor (Motor Current Signature Analysis).
MI	: Máquina de Inducción.
MMF	: Fuerza Magnetomotriz (Magnetomotive Force).
OVO	: Uno-contra-Uno (One-Versus-One).
OVA	: Uno-contra-Todos (One-Versus-All).
PCA	: Análisis de Componentes Principales (Principal Component Analysis).
PVU	: Desbalance de Tensión de Fase (Phase-Voltage Unbalance).
RBF	: Función de Base Radial (Radial Basis Function).
RF	: Bosque Aleatorio (Random Forest).

ROC	: Característica Operativa del Receptor (Receiver Operating Characteristic).
RMS	: Valor Cuadrático Medio (Root Mean Square).
RNN	: Red Neuronal Recurrente (Recurrent Neural Network).
RWE	: Energía Wavelet Relativa (Relative Wavelet Energy).
SEIG	: Generador de Inducción Auto-excitado (Self-Excited Induction Generator).
SRM	: Minimización del Riesgo Estructural (Structural Risk Minimization).
ST	: Transformada de Stockwell (Stockwell Transform).
STD	: Desviación Estándar (Standard Deviation).
STFT	: Transformada de Fourier de Tiempo Corto (Short-Time Fourier Transform).
SVC	: Clasificación por Vectores de Soporte (Support Vector Classification).
SVM	: Máquina de Vectores de Soporte (Support Vector Machine).
SVPWM	: Modulación PWM de Vector Espacial (Space-Vector Pulse Width Modulation).
TN	: Verdadero Negativo (True Negative).
TP	: Verdadero Positivo (True Positive).
TPR	: Tasa de Verdaderos Positivos (True Positive Rate).
VMD	: Descomposición Modal Variacional (Variational Mode Decomposition).
VSCF	: Velocidad Variable, Frecuencia Constante (Variable Speed, Constant Frequency).
VSI	: Inversor Fuente de Tensión (Voltage Source Inverter).
VSVF	: Velocidad Variable, Frecuencia Variable (Variable Speed, Variable Frequency).
VUF	: Factor de Desbalance de Tensión (Voltage Unbalance Factor).
CVUF	: Factor Complejo de Desbalance de Tensión (Complex Voltage Unbalance Factor).
WFL	: Longitud de Forma de Onda (Waveform Length).

Índice de Contenidos

Agradecimientos	II
Nomenclatura	III
Índice de Contenidos	I
Índice de Figuras	IV
Índice de Tablas	VII
Resumen	1
Resumen	2
1. Introducción	3
2. Fallas en Máquinas de Inducción	9
2.1. Tipos de fallas	9
2.1.1. Fallas mecánicas	9
2.1.1.a. Fallas en rodamientos	10
2.1.1.b. Excentricidad	11
2.1.1.c. Rotura de barra de rotor	11
2.1.2. Fallas eléctricas	12
2.1.2.a. Cortocircuito entre espiras del devanado de estator	12
3. Características representativas para la clasificación y el diagnóstico de fallas	13
3.1. Relevancia de la selección de características en clasificadores basados en IA	13
3.2. Tipos de características y su clasificación	14
3.2.1. Características en el dominio del tiempo	15
3.2.2. Características en el dominio de la frecuencia	15
3.2.3. Características en el dominio tiempo-frecuencia	16
3.3. Elección de características utilizadas	17
3.3.1. Características en el dominio del tiempo utilizadas	17
3.3.1.a. Valor RMS (Root Mean Square)	17
3.3.1.b. Desviación estándar	17
3.3.1.c. Curtosis (Kurtosis)	18
3.3.1.d. Asimetría (Skewness)	18

3.3.1.e.	Factor de cresta (Crest Factor)	18
3.3.1.f.	Factor de impulso (Impulse Factor)	18
3.3.1.g.	Factor de forma (Shape Factor)	18
3.3.1.h.	Factor de espaciamento (Clearance Factor)	18
3.3.1.i.	Valor pico a pico (Peak-to-Peak)	19
3.3.2.	Características en el dominio tiempo-frecuencia utilizadas	19
3.3.2.a.	Transformada Wavelet Discreta y niveles de descomposición	19
3.3.2.b.	Energía Wavelet Relativa (RWE)	20
3.3.2.c.	Características S1, S2 y S3 aplicados a corriente	20
4.	Modelos de Inteligencia Artificial	22
4.1.	Tipos de IA aplicados a diagnóstico	22
4.2.	Fundamentos teóricos del modelo SVM	23
4.2.1.	Principio básico de funcionamiento del SVM como clasificador	24
4.2.2.	Margen suave y parámetro de penalización C	25
4.2.3.	Formulación dual y funciones núcleo (<i>kernel</i>)	27
4.2.4.	Extensión a problemas multiclase (SVM Multiclase)	29
4.2.4.a.	Clasificación uno-contra-todos	30
4.2.4.b.	Clasificación Uno-Contra-Uno	30
4.2.5.	Clasificación de grafo acíclico dirigido (DAG)	31
4.3.	Métricas de evaluación aplicadas a SVM	31
4.3.1.	Precisión global (Accuracy)	32
4.3.2.	Precisión (Precision)	32
4.3.3.	Sensibilidad (Recall)	32
4.3.4.	F1-score	32
4.3.5.	Modos de agregación global	33
4.3.5.a.	Promedio-micro (Micro-average)	33
4.3.5.b.	Promedio-macro (Macro-average)	33
4.3.5.c.	Promedio ponderado (Weighted-average)	33
4.3.5.d.	Precisión balanceada (Balanced Accuracy)	34
4.4.	Consideraciones para el ajuste del modelo SVM	34
4.4.1.	Descripción de los datos y estructura del conjunto	34
4.4.2.	Preprocesamiento	34
4.4.3.	Configuración del modelo SVC	35
4.4.4.	Validación cruzada y selección de hiperparámetros	35
4.4.5.	Ajuste final e interpretación del parámetro γ	35
5.	Implementación del banco de pruebas	36
5.1.	Diseño y estructura del nuevo banco de pruebas	36
5.2.	Generador de inducción y carga eléctrica	38
5.3.	Motor de pruebas	39
5.3.1.	Características de fábrica	39
5.3.2.	Características del motor modificado	41
5.4.	Acoplamiento y alineación del sistema motor-eje-generador	43
5.5.	Rodamientos de prueba	45
6.	Base de datos experimental	47
6.1.	Montaje experimental	47

6.2.	Adquisición de datos e instrumentos de adquisición	48
6.3.	Definición de escenarios de pruebas	49
6.3.1.	Niveles de carga mecánica	49
6.3.2.	Tipos de alimentación para el motor de pruebas	50
6.3.3.	Defectos inducidos en el motor de pruebas	50
6.3.3.a.	Defectos en los rodamientos de prueba	51
6.3.3.b.	Defectos en el devanado de estator del motor de pruebas	51
6.4.	Forma de onda de las señales registradas	52
6.5.	Observaciones y limitaciones de la base de datos	55
7.	Resultados y análisis	57
7.1.	Señales con ruido sintético de tipo Gaussiano	57
7.2.	Visualización y validación de las características seleccionadas	59
7.2.1.	Características en el dominio del tiempo	60
7.2.2.	Características en el dominio tiempo-frecuencia	61
7.2.2.a.	Cálculo de niveles de descomposición	61
7.2.2.b.	Elección de niveles de mayor energía	62
7.2.2.c.	Visualización de características en el dominio tiempo-frecuencia	65
7.3.	Resultados de los clasificadores entrenados	66
7.3.1.	Clasificador 1: todas las señales medidas	67
7.3.2.	Clasificador 2: solo vibraciones	69
7.3.3.	Clasificador 3: solo corrientes	72
7.3.4.	Clasificador 4: vibración de soporte y corrientes	74
7.3.5.	Clasificador 5: vibración de motor y corrientes	77
8.	Conclusiones y recomendaciones para trabajos futuros	81
A.	Generador de inducción autoexcitado	84
A.1.	Clasificación de generadores de inducción según esquema de operación	84
A.2.	Fenómeno de auto-excitación y formación de tensión	85
A.3.	Selección de capacitancia para operación del SEIG	86
A.3.1.	Curva de magnetización y capacitancia máxima	86
A.3.2.	Requerimientos de capacitancia y para un SEIG	87
B.	Alineación del sistema motor-eje-generador	89
B.1.	Método de los comparadores alternados	89
B.2.	Ventajas y desventajas del método de los comparadores alternados	92
C.	Tensiones desbalanceadas	93
C.1.	Desequilibrio de tensión	93
C.2.	Factor de Desequilibrio Complejo de Tensiones	93
C.3.	Cálculo de tensiones desequilibradas	94

Índice de Figuras

1.1.	Tipos de fallas comunes en motores de inducción. [5]	5
1.2.	Diagnóstico de fallas basado en IA. [5]	7
2.1.	Estudio de fallas realizado por el EPRI. [9]	10
2.2.	Estudio de fallas realizado por la IEEE. [9]	10
2.3.	Estructura detallada de un rodamiento [12].	10
4.1.	Ilustración de un SVM básico de dos clases[21].	25
4.2.	Efecto del parámetro de penalización C en la frontera de decisión del SVM para un núcleo tipo RBF.	26
4.3.	Efecto del tipo de núcleo sobre la forma del hiperplano generado en un clasificador SVM binario con $C = 1$.	28
4.4.	Efecto del parámetro de ancho de banda γ en la frontera de decisión del SVM para un núcleo tipo RBF con $C = 1$.	29
5.1.	Vista lateral del banco de pruebas original.[36]	36
5.2.	Vista (a) lateral y (b) superior del nuevo banco de pruebas instalado.	37
5.3.	Vista (a) exterior e (b) interior del banco de capacitores utilizado.	39
5.4.	Banco de cargas resistivas utilizado.	39
5.5.	Interior del estator y devanado estatórico original del motor de pruebas.	41
5.6.	Diagrama del bobinado para la (a) fase A y del (b) bobinado completo del motor de pruebas.	41
5.7.	Esquema referencial del rebobinado para el devanado de estator de la fase U en el motor de pruebas.	42
5.8.	Vista (a) lateral y (b) superior del MI rebobinado con caja para terminales y derivaciones.	43
5.9.	(a) Acoplamiento Rexnord Omega modelo ES10-R junto con su (b) juego de masas.	44
5.10.	(a) Rodamiento Craft 1207 EF-J31 y su (b) esquema referencial de dimensiones.	45
6.1.	Montaje experimental realizado durante la toma de muestras.	48
6.2.	Rodamientos con (a) orificio de 0,3mm de diámetro y con (b) orificio de 0,5mm de diámetro en un elemento rodante.	51
6.3.	Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación balanceada, falla eléctrica severa en la fase A y carga del 45,95 % del par nominal del motor.	53

6.4.	Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación desbalanceada del 3 %, sin fallas y carga del 4,78 % del par nominal del motor.	54
6.5.	Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación desbalanceada del 1 %, falla incipiente en la fase C, muesca de 5mm en el elemento rodante del rodamiento, y carga del 102,76 % del par nominal del motor.	55
6.6.	Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación mediante inversor, falla incipiente en la fase B, muesca de 3mm en el elemento rodante del rodamiento, y carga del 110,25 % del par nominal del motor.	56
7.1.	Formas de onda de (a) vibraciones y (b) corrientes, con ruido gaussiano del 3 % de su desviación estándar, bajo operación con alimentación balanceada, falla eléctrica severa en la fase A, y carga del 45,95 % del par nominal del motor.	58
7.2.	Descomposición PCA en (a) dos dimensiones y (b) tres dimensiones para las características en el dominio del tiempo utilizadas.	60
7.3.	Reconstrucción de los niveles de detalle de la DWT para las señales de (a) vibración de soporte y (b) corriente de fase A, bajo operación con alimentación balanceada, falla incipiente en la fase A, muesca de 3mm en el elemento rodante del rodamiento, y carga del 4,78 % del par nominal del motor.	62
7.4.	Frecuencia de aparición de los niveles más energéticos para las señales de vibración (a) en el soporte y (b) en el motor.	63
7.5.	Frecuencia de aparición de los niveles más energéticos para las señales de corriente (a) en fase A, (b) en fase B y (c) en fase C.	64
7.6.	Descomposición PCA en (a) dos dimensiones y (b) tres dimensiones para las características en el dominio del tiempo-frecuencia utilizadas.	65
7.7.	Matriz de confusión obtenida para el clasificador 1 (todas las señales). . .	68
7.8.	Curvas ROC para el clasificador 1 (todas las señales).	69
7.9.	Matriz de confusión obtenida para el clasificador 2 (solo señales de vibración).	70
7.10.	Curvas ROC para el clasificador 2 (solo señales de vibración).	71
7.11.	Matriz de confusión obtenida para el clasificador 3 (solo señales de corriente). . .	73
7.12.	Curvas ROC para el clasificador 3 (solo señales de corriente).	74
7.13.	Matriz de confusión obtenida para el clasificador 4 (vibración de soporte y corrientes).	75
7.14.	Curvas ROC para el clasificador 4 (vibración de soporte y corrientes). . .	76
7.15.	Matriz de confusión obtenida para el clasificador 5 (vibración de motor y corrientes).	78
7.16.	Curvas ROC para el clasificador 5 (vibración de motor y corrientes). . . .	79
A.1.	Curva de magnetización y fenómeno de autoexcitación y formación de tensión [46].	85
A.2.	Curva de magnetización y recta de impedancia capacitiva para el SEIG. .	86
A.3.	Circuito equivalente en estado estacionario por fase en pu de un SEIG con carga RL.	87

B.1.	Montaje del método de comparadores alternados para la alineación de los elementos (a) generador-eje y (b) eje-motor.	89
B.2.	Convenio de sentidos positivos en los planos horizontal y vertical.	90
B.3.	Esquema de alineación y relaciones geométricas en el método de comparadores alternados.	91
C.1.	Variación de la forma del triángulo de tensiones para un mismo VUF y distinto ángulo θ . [50]	95
C.2.	Triángulo formado por tensiones trifásicas desequilibradas [51].	96

Índice de Tablas

5.1.	Datos de placa para el generador de inducción autoexcitado.	38
5.2.	Datos de placa para máquina de pruebas.	40
5.3.	Parámetros de fábrica estimados para el motor de pruebas, en por unidad base propia.	40
5.4.	Parámetros estimados para el motor de pruebas rebobinado, en por unidad base propia.	43
5.5.	Características del acoplamiento para el motor de pruebas.[42]	44
5.6.	Dimensiones de rodamiento de bola autoalineable Craft modelo 1207 EF-J31.	46
5.7.	Frecuencias naturales para el rodamiento de bola autoalineable Craft modelo 1207 EF-J31 a una velocidad de giro de 999 RPM.	46
6.1.	Cortocircuitos inducidos en cada fase del devanado de estator.	52
7.1.	Descomposición en frecuencia para DWT de nueve niveles.	61
7.2.	Resumen de hiperparámetros y resultados del entrenamiento del clasificador 1 (todas las señales).	67
7.3.	Reporte de clasificación en el conjunto de prueba para el clasificador 1 (todas las señales).	68
7.4.	Resumen de hiperparámetros y resultados del entrenamiento del clasificador 2 (solo señales de vibración).	70
7.5.	Reporte de clasificación en el conjunto de prueba para el clasificador 2 (solo señales de vibración).	71
7.6.	Resumen de hiperparámetros y resultados del entrenamiento del clasificador 3 (solo señales de corriente).	72
7.7.	Reporte de clasificación en el conjunto de prueba para el clasificador 3 (solo señales de corriente).	73
7.8.	Resumen de hiperparámetros y resultados del entrenamiento del clasificador 4 (vibración de soporte y corrientes).	75
7.9.	Reporte de clasificación en el conjunto de prueba para el clasificador 4 (vibración de soporte y corrientes).	76
7.10.	Resumen de hiperparámetros y resultados del entrenamiento del clasificador 5 (vibración de motor y corrientes).	77
7.11.	Reporte de clasificación en el conjunto de prueba para el clasificador 5 (vibración de motor y corrientes).	79
A.1.	Parámetros estimados para la máquina generadora, en por unidad base propia.	87

Resumen

La presente memoria aborda el diagnóstico de fallas en motores de inducción trifásicos mediante aprendizaje automático, considerando el desbalance de clases propio de datos reales. Se plantea e implementa un pipeline reproducible con SVM de núcleo RBF que opera sobre señales de vibración (en la carcasa del rodamiento fallado y en el propio motor) y corrientes trifásicas. El flujo de trabajo contempla estandarización, partición estratificada en entrenamiento y prueba, ajuste de hiperparámetros vía grid search con validación cruzada y ponderación por clase, empleando F1-macro como criterio de optimización para asegurar un desempeño equilibrado entre categorías.

Los resultados evidencian que la información vibracional es clave para discriminar fallas mecánicas y condición sana. El mejor compromiso entre desempeño y complejidad se obtiene con vibraciones únicamente (F1-macro $\approx 0,98$ y AUC $\approx 1,00$). La combinación de todas las señales entrega un rendimiento ligeramente peor (F1-macro $\approx 0,97$ y AUC $\approx 1,00$), mientras que el uso exclusivo de corrientes experimenta una degradación apreciable. En conjunto, el esquema propuesto demuestra alta exactitud y robustez frente al desbalance, y ofrece una base metodológica replicable para su futura implementación en sistemas de monitoreo y mantenimiento predictivo.

Abstract

This thesis addresses the diagnosis of faults in three-phase induction motors using machine learning, explicitly considering the class imbalance typically present in real data. A reproducible pipeline based on an RBF-kernel SVM is proposed and implemented, operating on vibration signals (measured on the failed bearing housing and on the motor itself) and three-phase currents. The workflow includes standardization, stratified train/test splitting, hyperparameter tuning via grid search with cross-validation and class weighting, and uses F1-macro as the optimization criterion to ensure balanced performance across categories.

The results show that vibrational information is essential to discriminate mechanical faults from the healthy condition. The best performance–complexity trade-off is obtained using vibration signals only (F1-macro $\approx 0,98$, AUC $\approx 1,00$). Combining all signals yields slightly lower performance (F1-macro $\approx 0,97$, AUC $\approx 1,00$), while using only current signals leads to a noticeable degradation. Overall, the proposed scheme demonstrates high accuracy and robustness to class imbalance, providing a replicable methodological basis for future deployment in monitoring and predictive maintenance systems.

Capítulo 1

Introducción

El diagnóstico y protección de fallas en las máquinas eléctricas es tan antiguo como las propias máquinas. Si bien, en un comienzo el enfoque se centraba en utilizar protecciones simples, como sobrecorriente, sobretensión, falla a tierra, etc., para garantizar un funcionamiento seguro y confiable, hoy en día, a medida que las tareas realizadas por estas máquinas se hacen cada vez más complejas, se ha vuelto muy importante diagnosticar las fallas desde su origen. Con el pasar de los años, la industria ha requerido de métodos y herramientas cada vez más eficaces para diagnosticar y evaluar el estado de salud de las máquinas eléctricas, esto con el fin de desarrollar un sistema de supervisión sofisticado que permita tomar las decisiones correctas en el momento oportuno, evitando averías en los equipos y, por tanto, paradas de producción imprevistas, las cuales ocasionan graves pérdidas financieras [1, 2].

Gracias a su robustez, bajo coste de mantenimiento y capacidad de trabajar con fuentes de energía ampliamente disponibles, los motores de inducción (MI) se convierten en el principal medio de sistemas de conversión de energía en la industria [3] y, por ende, en la columna vertebral del mundo industrial siendo un componente crítico de muchos procesos industriales, tanto así, que incluso se integran en equipamiento disponible de forma comercial, donde los equipos impulsados por motores proporcionan capacidades básicas esenciales para el éxito industrial y la seguridad de los equipos y del personal [4]. Dentro de la industria, los MI desempeñan un papel de vital importancia, sobre todo en las aplicaciones relacionadas con la generación de energía mecánica, fabricación y transporte, donde algunas de sus aplicaciones más comunes son en el uso de bombas, compresores, sopladores, ventiladores, máquinas herramienta, grúas, transportadores y vehículos eléctricos. Así, más del 50 % de la energía eléctrica total generada en el mundo es utilizada principalmente por motores de inducción, los que consumen alrededor del 60 % de la electricidad industrial [5].

Dada la relevancia de dichos motores, la confiabilidad y disponibilidad de estos es crucial para garantizar un funcionamiento continuo y sin problemas de los procesos industriales. A pesar de aquello, los MI están constantemente expuestos a condiciones desfavorables (y en ocasiones inevitables) de alto estrés mecánico, eléctrico, térmico y ambiental durante todo su funcionamiento, esto producto de las variaciones en la carga externa, las desviaciones en el suministro de energía, los excesos de calor y puntos calientes, las lubricaciones y sellado inadecuado, exposición a ambientes polvorientos, posibles defectos de fabricación y/o instalación, entre otros, provocando una fuerte disminución de su vida útil, la que,

en conjunto con su envejecimiento natural, concluyen en fatigas inevitables que provocan fallos en el interior de la máquina [3, 4].

De esta manera, las principales averías de las máquinas eléctricas se pueden clasificar, en términos generales, como sigue:

1. Fallas del estator que resultan en la apertura o cortocircuito de uno o más de un devanado de fase de estator.
2. Conexión anormal de los devanados del estator.
3. Barra del rotor rota o anillos extremos del rotor agrietados.
4. Irregularidades estáticas y/o dinámicas del entrehierro.
5. Eje doblado, que puede provocar un roce entre el rotor y el estator.
6. Devanado inductor del rotor en cortocircuito.
7. Fallas en rodamientos y caja de cambios.

Estas averías producen uno o más de los siguientes síntomas sobre las máquinas: tensiones de entrehierro y corrientes de fase desequilibradas, aumento de las pulsaciones del par, disminución del par medio, aumento de pérdidas y reducción de la eficiencia, calentamiento excesivo, entre otros [1]. Una descripción mucho más detallada de las causas y efectos de cada una de las fallas mencionadas sobre la máquina se puede encontrar en [1, 4-6]. Se indica además que del total de averías posibles en un MI, alrededor de un 41 %-42 % corresponden a daños en los rodamientos de la máquina, cerca de un 28 %-36 % corresponden a daños en el devanado de estator de la máquina, entre un 8 %-9 % son averías relacionadas con fallos en el rotor y entre un 14 %-28 % corresponden a otro tipo de fallas [5]. En la Figura 1.1 se agrupan las fallas anteriormente mencionadas, según correspondan a fallas de tipo eléctricas o de tipo mecánicas.

A partir de lo anterior, resulta evidente que con el rápido desarrollo de la tecnología y la ciencia, los equipos mecánicos en la industria moderna se vuelven cada vez más útiles y complejos. En particular, la máquina de inducción se encuentra entre los equipos más importantes en las aplicaciones industriales modernas y por ende, el diagnóstico de fallas en dicha máquina se convierte en el aspecto más crítico en el diseño y mantenimiento de una gran cantidad de sistemas. En resumen, el diagnóstico de fallas es una técnica de detección, aislamiento e identificación de fallas, que puede usarse aplicado a la información sobre el estado de funcionamiento del equipo [7].

En el diagnóstico de fallas existen tres tareas básicas, enumeradas a continuación:

1. Determinar si el equipo está averiado o no.
2. Encontrar la falla incipiente y su motivo, en caso de que el equipo se encuentre efectivamente averiado.
3. Predecir la tendencia del desarrollo de dicha falla.

Por lo tanto, en su esencia, el diagnóstico de fallas puede considerarse como un problema de reconocimiento de patrones y señales relacionadas con el estado de la máquina y con las averías existentes en esta [7]. Así, para la detección de dichos patrones y señales se han desarrollado diversos métodos de diagnóstico, los cuales pueden involucrar diversos campos de la ciencia y la tecnología. Dentro de dichos métodos para la detección de fallas se destacan [1, 5]:




Figura 1.1: Tipos de fallas comunes en motores de inducción. [5]

1. Monitoreo de flujo magnético (o flujo de fuga axial), incluyendo el monitoreo del par del entrehierro.
2. Reconocimiento por rayos infrarrojos.
3. Monitoreo de emisiones de radiofrecuencia (RF);
4. Medición del ruido acústico.
5. Monitoreo de temperatura.
6. Medición de descargas parciales.
7. Análisis de velocidad angular instantánea.
8. Análisis de potencia instantánea.
9. Pruebas de sobretensión
10. Análisis químicos (residuos de aceite lubricante, gas refrigerante).
11. Monitoreo de vibraciones.
12. Análisis de firma de corriente del motor (MCSA).

De esta manera, las técnicas de medición modernas en combinación con el procesamiento y la adquisición de datos computarizados avanzados hacen posible la monitorización de máquinas de inducción, donde herramientas de evaluación que utilizan el análisis en el dominio del tiempo mediante valores característicos para determinar cambios en las tendencias de las mediciones, el análisis de espectro para determinar tendencias de frecuencias, relaciones de amplitud y/o fase, así como el análisis mediante la transformada wavelet para detectar patrones transitorios en bandas de frecuencia específicas, se vuelven

cada vez más importantes para la detección de fallas incipientes [4].

De la literatura, se encuentra que el monitoreo basado en vibración y corriente es preferido para el diagnóstico de fallas en MI, debido a que estas técnicas no son intrusivas, son confiables y económicas, tienen gran efectividad y alta precisión en el análisis de señales que indican el estado actual de la máquina, son fácilmente medibles (lo que ayuda al procesamiento de señales), tienen una gran capacidad de detectar y distinguir la mayoría de fallas mecánicas y eléctricas, y las corrientes y vibraciones del motor se pueden registrar de forma on-line, por lo que es posible realizar la detección de fallas de forma on-line. De esta forma, mediante el uso de técnicas de procesamiento de señales adecuadas, es posible identificar desviaciones en las señales de corrientes y vibraciones producidas por diferentes fallas en el MI [5]. Además, las técnicas de medición modernas en combinación con el procesamiento y la adquisición de datos computarizados avanzados hacen posible la monitorización de los MI mediante herramientas de evaluación que utilizan el análisis de valores característicos extraídos de las señales para determinar cambios en las tendencias de las mediciones [4].

El análisis en el dominio del tiempo se basa directamente en la propia forma de onda temporal de la señal registrada. Este análisis calcula características descriptivas de la forma de onda de las señales en el tiempo como la media, el valor pico, intervalo pico a pico, desviación estándar, factor de cresta, o estadísticas de alto orden como media cuadrática, asimetría, curtosis, etc. Por otro lado, el análisis en el dominio de la frecuencia se basa en el análisis de la señal transformada al dominio de la frecuencia. La ventaja de este análisis por sobre el análisis en el dominio del tiempo es su capacidad para identificar y aislar fácilmente ciertos componentes de frecuencia de interés. La idea principal del análisis del espectro es observar todo el espectro u observar de cerca ciertos componentes de frecuencia de interés y así extraer características de la señal. Además, se han desarrollado técnicas de análisis tiempo-frecuencia, las que analizan señales de forma de onda tanto en el dominio del tiempo como de la frecuencia, esto con el fin de solventar la incapacidad que tienen los métodos de análisis en el dominio de la frecuencia para manejar señales de formas de onda no estacionarias, las cuales son muy comunes cuando ocurren fallas en la maquinaria [8].

Por otro lado, debido a la gran variabilidad de las señales de respuesta y a la gran cantidad de métodos para el procesamiento de dichas señales, es casi imposible reconocer patrones de falla de forma directa. Por esta razón, se requiere de un sistema de diagnóstico de fallas que permita procesar los datos que se recopilan durante las mediciones de variables (extracción de características) y que pueda reconocer la falla existente en el MI (si es que la hay).

En este contexto, los sistemas de diagnóstico basados en Inteligencia Artificial (IA), han atraído gran atención por parte de muchos investigadores debido a que se ha presentado como una poderosa herramienta de reconocimiento de patrones de fallas, mostrando resultados prometedores en el reconocimiento de fallas de maquinaria rotativa [7].

Cabe destacar que los sistemas inteligentes de diagnóstico de fallas más comunes se construyen en base al preprocesamiento de señales mediante la extracción de características, utilizando algoritmos que puedan transformar los patrones de entrada para que puedan representarse mediante vectores de características de baja dimensión para facilitar su comparación y clasificación. Finalmente, los vectores de características se utilizan como entrada de técnicas de IA, las que realizan el reconocimiento de la falla. Ejemplos de sistemas in-

teligentes para el diagnóstico de fallas son: la red neuronal artificial (ANN), lógica difusa (FL), algoritmo genético (GA), modelo oculto de Markov, algoritmos de k-vecinos más cercanos (k-NN), clasificador bayesiano, máquinas de vectores de soporte (SVM), algoritmos de aprendizaje profundo (DL), entre otros [5, 7]. La Figura 1.2 muestra un esquema para diagnosticar fallas mediante el uso de IA, donde se muestran los pasos de medición y registro de señales, extracción y selección de características, y predicción del tipo de falla mediante el modelo entrenado.




Figura 1.2: Diagnóstico de fallas basado en IA. [5]

Dicho lo anterior, es claro que el diagnóstico y detección de fallas en las máquina eléctricas, en particular en los MI, es un aspecto fundamental que permite a las industrias tomar decisiones para evitar averías en estos equipos y con ello paradas de producción imprevistas que puedan ocasionar graves pérdidas financieras. En este sentido, la búsqueda de métodos y formas de diagnosticar que permitan identificar con exactitud el tipo de falla o avería que tiene la máquina es un hecho que se requiere de manera indiscutible. De esta manera, la inclusión de la Inteligencia Artificial para elaborar un sistema inteligente de diagnóstico de fallas que permita identificar el tipo de falla y a la vez entregue información precisa sobre esta es un hecho que llama la atención de la comunidad. Día tras día, con la mejora de la tecnología los modelos de IA han ido desarrollándose y complementándose de mejor manera, al punto en que estos pueden realizar tareas, como por ejemplo el reconocimiento de patrones de fallas, con gran precisión.

Dicho esto, en el presente trabajo se busca elaborar un sistema de reconocimiento y diagnóstico de fallas en base a modelos de Inteligencia Artificial, aplicando técnicas de

preprocesamiento de señales, con el fin de obtener un modelo capaz identificar y clasificar el tipo de falla existente en el motor estudiado. En particular, se propone como objetivo principal:

- Desarrollar un modelo de Inteligencia Artificial para diagnosticar fallas de cortocircuito y de rodamientos en motores de inducción trifásicos mediante el análisis característico de vibraciones y/o corrientes de estator.

Para ello, se deberán cumplir los siguientes objetivos secundarios:

- Revisar la bibliografía existente hasta la fecha en el área del desarrollo de modelos de Inteligencia Artificial para el diagnóstico de fallas en máquinas de inducción.
- Implementar una configuración que permita recopilar mediciones de corrientes de estator y de vibraciones en un motor de inducción trifásico con cortocircuitos entre sus devanados y/o fallas en sus rodamientos.
- Seleccionar algoritmos adecuados para la caracterización y clasificación de mediciones de corriente y de vibraciones de un motor de inducción trifásico con y sin fallas.
- Implementar los modelos de Inteligencia Artificial en función de los algoritmos previamente seleccionados y las mediciones obtenidas de los ensayos al motor de inducción trifásico.
- Evaluar y comparar el desempeño de los modelos de Inteligencia Artificial desarrollados.

Capítulo 2

Fallas en Máquinas de Inducción

Los motores de inducción (MI) son esenciales en la industria moderna debido a su versatilidad, robustez y capacidad para operar bajo condiciones adversas. Representan aproximadamente el 60 % del consumo eléctrico en entornos industriales y son ampliamente utilizados en aplicaciones críticas como bombas, compresores, ventiladores y transportadores [9, 10]. Sin embargo, estas máquinas están expuestas a diversos factores mecánicos, eléctricos y ambientales que pueden reducir su vida útil y provocar fallas. Las más comunes incluyen daños en los rodamientos, cortocircuitos en los devanados del estator y excentricidad del rotor, que representan más del 75 % de las averías reportadas según estudios realizados por IEEE y EPRI [1, 6].

Dada su relevancia en la industria y los diversos usos que se les da, los MI se encuentran constantemente expuestos a condiciones adversas y desfavorables, por lo que, a lo largo de los años, los investigadores han dedicado un gran esfuerzo al estudio de sus principales fallas y averías. En este capítulo se abordarán las principales fuentes de fallas en los MI, presentando su clasificación e indicando sus causas. Además, dado que uno de los objetivos de este trabajo se centra en el estudio de fallas en rodamiento y cortocircuito en los devanados de estator, se pondrá especial énfasis en dichas averías, mencionando también los efectos que estas tienen sobre los espectros de corriente y vibración en el motor.

2.1. Tipos de fallas

En general, los MI son altamente susceptibles a sufrir distintos tipos de fallas, ya sean fallas internas, externas y/o ambientales. En este sentido, las fallas internas pueden clasificarse en función de su origen, es decir, mecánicos y eléctricos, o en función de su ubicación, es decir, rotor, estator, rodamientos u otros [9]. De tal manera, en busca de establecer las fallas internas más recurrentes en los MI, dos organismos distintos (IEEE y EPRI) se han dedicado al análisis y estudio de estas, obteniendo los resultados presentados en la Figura 2.1 y 2.2.

2.1.1. Fallas mecánicas

Las fallas mecánicas ocurren en los rodamientos y en el rotor de la máquina, estando ligadas principalmente a sobrecargas de la máquina o defectos de fabricación [11]. Los 3




Figura 2.1: Estudio de fallas realizado por el EPRI. [9]




Figura 2.2: Estudio de fallas realizado por la IEEE. [9]

tipos de fallas mecánicas más comunes en los MI son fallas en rodamientos, excentricidad, y rotura de barra de rotor.

2.1.1.a. Fallas en rodamientos

Según los estudios realizados por la IEEE y el EPRI, un 42% de los fallos ocurridos en los MI son en sus rodamientos [9]. La mayoría de las máquinas eléctricas utilizan rodamientos de bolas o elementos rodantes que giran en pistas de rodadura dentro de los anillos exteriores e interiores. En función de la ubicación del fallo local, las fallas en rodamientos pueden dividirse en cuatro tipos: fallas de anillo interior, fallas de anillo exterior, fallas de elemento rodante y fallas de jaula o tren [12]. Incluso en operaciones normales equilibradas con buena alineación del eje, pueden producirse fallos por fatiga, donde las vibraciones, el estrés interno, la excentricidad inherente o las corrientes del rodamiento debidas a la electrónica de potencia tienen influencia en el desarrollo de tales fallos [13].

A modo de comprender mejor las partes de un rodamiento, se presenta en la Figura 2.3 la estructura detallada de este.




Figura 2.3: Estructura detallada de un rodamiento [12].

Cabe destacar, que cada defecto en el sistema de rodamientos se refleja con una característica específica en el espectro de frecuencias vibratorio, cuyo valor y amplitud dependen de la velocidad de rotación del eje, la ubicación del fallo y las dimensiones del rodamiento. En función de lo anterior, se presentan a continuación las relaciones en el espectro de

frecuencia para cada una de las fallas posibles en el sistema de rodamientos [9]:

1. Frecuencia de pista externa:

$$f_o = \frac{N_b}{2} f_r \left(1 - \frac{d}{D} \cos \delta \right) \quad (2.1)$$

2. Frecuencia de pista interna:

$$f_i = \frac{N_b}{2} f_r \left(1 + \frac{d}{D} \cos \delta \right) \quad (2.2)$$

3. Frecuencia de defecto de elemento rodante:

$$f_b = \frac{D}{2d} f_r \left[1 - \left(\frac{d}{D} \cos \delta \right)^2 \right] \quad (2.3)$$

4. Frecuencia de defecto en la jaula de contención:

$$f_c = \frac{1}{2} f_r \left(1 - \frac{d}{D} \cos \delta \right) \quad (2.4)$$

Para las relaciones presentadas anteriormente se cumple que N_b es el número de elementos rodantes en el rodamiento, f_r es la velocidad del rotor, d es el diámetro del elemento rodante, D es el diámetro efectivo del rodamiento y δ es el ángulo de contacto entre el elemento rodante y la jaula.

2.1.1.b. Excentricidad

En un motor de inducción, la excentricidad del rotor y el estator también se considera uno de los principales fallos, ya que contribuye en un porcentaje considerable al fallo del motor. La excentricidad da lugar a fuerzas radiales desequilibradas que pueden incluso provocar roces entre el estator y el rotor, pudiendo dañar ambas partes. Si existe excentricidad en el motor significa que existe una asimetría o desalineamiento. Además, la excentricidad estática se produce cuando el núcleo del estator tiene forma ovalada o cuando el rotor está mal instalado. La excentricidad dinámica se produce cuando el centro del rotor no está alineado con el centro de rotación, siendo función del espacio y el tiempo. [9, 10, 12, 14]

$$f_{ecc} = \left[(R \pm n_d) \left(\frac{1-s}{p} \right) \pm n_{\omega s} \right] \cdot f_0 \quad (2.5)$$

Donde R es el número de ranuras del rotor, $n_d = \pm 1$ es el orden de la excentricidad, $n_{\omega s} = 1, 3, 5, \dots$, es el orden armónico de la fuerza magnetomotriz, p los pares de polos y f_0 la frecuencia fundamental de la red.

2.1.1.c. Rotura de barra de rotor

Una barra rota del rotor causa asimetría y produce un campo giratorio hacia atrás. Se genera un campo aumentado alrededor de la barra rota debido a la falta de desmagnetización en la barra defectuosa. Así, la densidad de flujo es progresivamente mayor cerca de la región defectuosa. El resultado indica que la degradación en el orden del par es del 2-4 % con una barra rota, mientras que se sitúa entre el 10 y el 15 %, para tres a cinco barras rotas [10]

2.1.2. Fallas eléctricas

Las fallas de tipo eléctricas son las que ocurren en los devanados de estator y rotor. Debido a que se está trabajando con un MI, solo se abordarán las fallas en el devanado de estator.

2.1.2.a. Cortocircuito entre espiras del devanado de estator

Este tipo de fallas puede ocurrir debido a problemas de aislamiento en las bobinas. La aparición de un cortocircuito entre espiras en el devanado del estator es indicio de que la máquina se encuentra en una etapa inicial para el fallo total de su devanado [11, 14].

A partir de la simulación del modelo de cortocircuito entre espiras, la corriente de cortocircuito fluye en los devanados de cortocircuito entre espiras. Esto inicia un MMF negativo, que reduce el MMF neto de la fase del motor. Por lo tanto, la forma de onda del flujo del entrehierro, que cambia por la distorsión de la MMF neta, induce frecuencias armónicas en la corriente del devanado del estator como [14]:

$$f_{\text{stator}} = \left[\frac{n}{p}(1 - s) \pm k \right] \cdot f_0 \quad (2.6)$$

Donde p es el número de pares de polos, $n = 1, 2, 3, \dots$, y $k = 1, 3, 5, \dots$, respectivamente.

Capítulo 3

Características representativas para la clasificación y el diagnóstico de fallas

La selección de características constituye una etapa fundamental en el procesamiento de datos para el diagnóstico de fallas en motores de inducción trifásicos. Esta etapa consiste en extraer atributos numéricos representativos a partir de las señales adquiridas (como vibraciones y corrientes), con el propósito de detectar patrones que permitan distinguir de manera robusta entre de operación saludables y defectuosas. Su relevancia radica en que actúa como enlace entre las señales adquiridas y los modelos de clasificación, determinando la calidad de la información que se entrega al modelo.

Una característica corresponde a un valor numérico derivado de la señal pura, que condensa propiedades como su forma, energía, simetría o dispersión. Así, una selección adecuada permite reducir la dimensionalidad del problema, aumentar la robustez frente al ruido, mejorar la generalización a nuevas condiciones y facilitar la interpretación del modelo [1, 15]. Por el contrario, una selección inadecuada puede limitar la precisión del clasificador y reducir su capacidad de detección de fallas. De esta manera, esta etapa requiere de criterios informados que influyen directamente en el rendimiento y reflejan el conocimiento experto sobre el sistema analizado [16].

En este capítulo se introduce el concepto de selección de características como una etapa clave en el diagnóstico de fallas, resaltando su relevancia e influencia directa en el desempeño de clasificadores basados en Inteligencia Artificial. Se presenta una clasificación general de los tipos de características según su dominio de análisis (temporal, frecuencial y tiempo-frecuencia). Finalmente, se describen las características empleadas en este trabajo, indicando su definición matemática.

3.1. Relevancia de la selección de características en clasificadores basados en IA

En sistemas modernos de diagnóstico de fallas, la Inteligencia Artificial (IA) y el aprendizaje automático se han consolidado como herramientas eficaces para detectar patrones complejos y no lineales en las señales adquiridas. En este contexto, el conjunto de carac-

terísticas utilizadas como entrada al modelo es determinante para su desempeño, ya que condiciona su capacidad para distinguir entre clases de fallas, generalizar frente a nuevas condiciones operacionales y mantener estabilidad frente al ruido. En [1] se destaca que el éxito de estos sistemas depende en gran medida de las características extraídas desde las señales, ya que encapsulan la información específica de falla. Así, cuando dichas características son obtenidas mediante técnicas adecuadas de extracción y procesamiento, es posible alcanzar altos niveles de precisión en la clasificación, incluso en condiciones operacionales desafiantes.

Por ejemplo, en [17] se emplea un sistema basado en extracción de características mediante redes convolucionales (CNN), seguido por una etapa de selección optimizada de características y posterior clasificación con SVM. Este enfoque permitió mejorar la precisión del modelo desde un 96,67 % con características individuales hasta un 99,11 % al aplicar fusión y selección de características, alcanzando finalmente un valor en la métrica *F1-score* del 100 % con el ajuste de hiperparámetros.

Asimismo, en [18] se evalúa el rendimiento de distintos clasificadores, incluyendo SVM, Random Forest, k-NN, redes neuronales feedforward (FNN) y recurrentes (RNN), utilizando un conjunto de datos que combinan características estadísticas con características obtenidas mediante la Transformada Wavelet Discreta (DWT), desde la corriente del motor. Los modelos alcanzaron precisiones de clasificación iguales o superiores al 96 %, destacando Random Forest y FNN con un 100 % de exactitud. Estos resultados refuerzan la efectividad del uso combinado de características relevantes para el diagnóstico automático de fallas eléctricas en motores de inducción.

Por otro lado, en [19] se emplean características extraídas mediante la Transformada de Stockwell (ST) aplicadas a señales de corriente del estator, y entrenaron dos modelos SVM para la detección de fallas incipientes. Mediante esta metodología, se reportó una precisión del 100 % en el caso de fallas entre espiras y del 91,66 % para fallas a tierra, en un entorno experimental que reproduce condiciones industriales reales.

Finalmente, en [20] se menciona que, incluso, mediante el uso de características simples en el dominio de la frecuencia, específicamente las amplitudes espectrales en $30Hz$ y $90Hz$ de las corrientes de estator del motor, y utilizando SVM como clasificador, fue posible diagnosticar condiciones de falla en rodamientos con precisiones que alcanzaron el 94,2 % en escenarios de múltiples fallas, y hasta un 100 % en configuraciones individuales como rayaduras o perforaciones.

Así, las evidencias empíricas presentadas refuerzan que la etapa de selección de características no solo actúa como filtro informativo, sino que constituye un puente entre el conocimiento técnico del sistema y la capacidad predictiva de los modelos de Inteligencia Artificial.

3.2. Tipos de características y su clasificación

Las señales adquiridas desde motores eléctricos, como la corriente del estator o la vibración mecánica, contienen información compleja que varía en función del tipo y severidad de la falla. Para facilitar su análisis y diagnóstico automático, resulta indispensable aplicar técnicas de extracción de características adecuadas al tipo de señal, a la dinámica del sistema y al defecto a identificar. En la literatura, es común clasificar estas características según el dominio desde el cual se calculan: tiempo, frecuencia o tiempo-frecuencia. Ca-

da uno ofrece ventajas y limitaciones que dependen de la condición operacional y de la naturaleza del fallo.

3.2.1. Características en el dominio del tiempo

Las características en el dominio del tiempo, se definen como indicadores cuantitativos calculados directamente sobre la forma de onda de una señal, sin necesidad de aplicar sobre esta transformaciones hacia otros dominios. Dichas métricas permiten capturar, numéricamente, propiedades fundamentales de la señal, como su amplitud, simetría, dispersión y forma, a través de estadísticos como la media, la desviación estándar, la curtosis, la skewness, entre otros [5]. Dado a que estas se obtienen aplicando medidas estadísticas clásicas sobre la forma de onda original de la señal, también son llamadas características estadísticas.

Una de las principales ventajas de las características en el dominio del tiempo es la simplicidad de su cálculo e implementación simple [12]. Al no requerir transformaciones de dominio ni algoritmos complejos, estas medidas presentan un bajo costo computacional y resultan especialmente adecuadas para sistemas de monitoreo y diagnóstico en línea [5]. Además, se ha evidenciado que métricas estadísticas como la desviación estándar, la asimetría (skewness) y la curtosis (kurtosis) presentan una alta sensibilidad frente a los pulsos inducidos por fallas en motores de inducción, especialmente en defectos de elementos rodantes [21].

Sin embargo, pese a su sencillez y eficiencia, las características en el dominio del tiempo suelen tener una sensibilidad limitada para la detección de fallas incipientes o cuando los registros se obtienen en entornos ruidosos [12], ya que no permiten aislar el contenido espectral de la señal. En este sentido, este tipo de características presentan desventajas importantes frente a características extraídas en otros dominios, dado que las señales extraídas para el diagnóstico son, en general, altamente no estacionarias y/o se encuentran contaminadas con ruido, lo que puede enmascarar los componentes de frecuencia asociados a las fallas [5].

Dada la revisión de la literatura, las características en el dominio del tiempo siguen siendo ampliamente utilizadas para el diagnóstico y monitoreo de motores eléctricos. Así, entre las métricas más recurrentes se encuentran: el valor cuadrático medio (RMS), la media, la desviación estándar (STD), la curtosis, la skewness, momentos estadísticos de orden superior, el factor de cresta, el factor de forma, el factor de impulso, el clearance factor, la longitud de forma de onda (WFL) y el valor absoluto medio (MAV). Estas métricas permiten capturar distintos aspectos de la forma de onda, tales como su energía, simetría, dispersión y comportamiento impulsivo.

3.2.2. Características en el dominio de la frecuencia

Las características en el dominio de la frecuencia son indicadores o parámetros extraídos a partir de la representación espectral de una señal, obtenidos al transformar una señal en el dominio del tiempo al dominio de la frecuencia, generalmente, mediante la Transformada Rápida de Fourier (FFT). Este análisis permite descomponer una señal temporal discreta en un conjunto de componentes en frecuencia, describiendo el contenido espectral de dicha señal, es decir, las frecuencias que componen la señal y la amplitud de dichas frecuencias [8, 22].

Una de las principales ventajas de utilizar este tipo de características es su capacidad para identificar y aislar fácilmente componentes de frecuencia específicos de fallas, los cuales se manifiestan como picos o bandas laterales en el espectro de frecuencia [12]. De esta manera, es posible asociar cada firma directamente con fallas específicas que pueden detectarse mediante el análisis de las frecuencias características. Además, la magnitud de las componentes espectrales de falla suele estar directamente relacionada con la severidad del fallo, por lo que, un aumento en la amplitud de una frecuencia de falla característica específica puede indicar una progresión del daño [23].

A pesar de sus ventajas, el diagnóstico de máquinas mediante el uso de características en el dominio de la frecuencia presenta limitaciones importantes cuando las señales registradas son del tipo no estacionarias. En estos casos, las propiedades de la señal varían con el tiempo y las firmas espectrales pueden verse difíciles de identificar, disminuyendo la efectividad del diagnóstico [12]. Además, la presencia de ruido puede dificultar la localización precisa de componentes relevantes puesto que las firmas de fallas, especialmente en sus etapas tempranas, pueden tener una relación señal/ruido extremadamente baja [24].

En cuanto a sus aplicaciones reales, diversos estudios han demostrado el uso efectivo de estas características en entornos industriales. Por ejemplo, de [14] se detalla cómo el “Análisis de la firma de corriente del motor (MCSA, por sus siglas en inglés)” permitió detectar fallas tempranas en rodamientos gracias a frecuencias específicas. Del mismo modo, en [12] se resalta el uso de bandas laterales generadas por el desbalance en el rotor como indicador fiable de fallas en jaula de ardilla.

Entre las características y métodos más utilizados se encuentran: análisis del contenido energético en bandas específicas, búsqueda de amplitud de armónicos principales, índices de modulación de frecuencias características, la relación entre frecuencias laterales y centrales, así como la detección de patrones espectrales estacionarios o persistentes. Algunas investigaciones también combinan múltiples métricas con el fin de mejorar la sensibilidad del diagnóstico.

3.2.3. Características en el dominio tiempo-frecuencia

Las características en el dominio tiempo-frecuencia combinan información temporal y espectral, permitiendo representar señales no estacionarias que presentan variaciones locales a lo largo del tiempo. Este enfoque es especialmente adecuado para el diagnóstico de fallas en máquinas rotativas donde las condiciones operativas y de carga cambian de forma dinámica [8].

A diferencia del análisis clásico en frecuencia, las transformadas tiempo-frecuencia mantienen simultáneamente información temporal y espectral, por lo que revelan cambios locales de frecuencia en señales cuyo contenido varía con el tiempo, situación habitual durante fallas o transitorios de arranque. Además, al ofrecer resolución en ambos dominios, permiten detectar de forma precisa patrones breves e impulsivos asociados a defectos incipientes, superando la limitación de la FFT [8, 12].

No obstante, estas técnicas suelen requerir mayor capacidad computacional y un diseño cuidadoso de los parámetros, como la selección del tipo de wavelet, la ventana para STFT o el algoritmo de reducción de ruido, lo que puede dificultar su aplicación en tiempo real [12].

En aplicaciones reales, las características en el dominio tiempo-frecuencia han mostrado alta efectividad en el diagnóstico de fallas en motores eléctricos. Por ejemplo, en [3] se

utiliza la Transformada Wavelet Discreta (DWT) sobre señales de corriente, extrayendo métricas como energía, y normas estadísticas para usar en modelos de clasificación supervisados. Asimismo, en [18], también se utiliza la DWT para obtener características que, junto a modelos como SVM, RNN y Random Forest, logran alta precisión en la detección de fallas leves entre espiras. En conjunto, estos estudios evidencian que el análisis tiempo-frecuencia mejora significativamente la detección en condiciones de ruido o variabilidad operacional.

Las técnicas más utilizadas incluyen la transformada wavelet continua (CWT), la transformada wavelet discreta (DWT), la transformada de Fourier de tiempo corto (STFT), la distribución de Wigner-Ville, o técnicas variantes de las ya mencionadas [3, 8].

3.3. Elección de características utilizadas

Para la elección de características a utilizar en este trabajo se adopta un enfoque combinado que integra características estadísticas en el dominio del tiempo junto con características en el dominio tiempo-frecuencia que derivan de la Transformada Wavelet Discreta (DWT, por sus siglas en inglés).

La selección de dichas características se fundamenta en criterios respaldados por estudios previos, priorizando su sensibilidad ante fallas específicas, su aplicabilidad en señales reales y su bajo costo computacional. Además, se consideraron atributos con base teórica sólida y evidencia empírica en contextos similares, lo cual refuerza su validez para un sistema de diagnóstico automático.

3.3.1. Características en el dominio del tiempo utilizadas

A continuación se presenta una descripción de las características en el dominio del tiempo utilizadas en este trabajo, su formulación matemática y aplicación en el contexto del diagnóstico de fallas en motores de inducción. Estas características fueron aplicadas a las señales de vibración (soporte y motor) medidas y a la magnitud del fasor espacial de corriente, calculada a partir de las tres corrientes de fase registradas.

3.3.1.a. Valor RMS (Root Mean Square)

El valor RMS mide la potencia efectiva de una señal. Es útil para identificar cambios globales en la amplitud de las señales. Su uso ha demostrado eficacia en el monitoreo de condiciones de carga anómalas:

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.1)$$

3.3.1.b. Desviación estándar

Indica la dispersión de la señal respecto de su media. Permite detectar inestabilidad o ruido estructural:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.2)$$

3.3.1.c. Curtosis (Kurtosis)

La curtosis evalúa la prominencia de los picos en una señal, siendo particularmente útil para identificar impactos breves generados por fallas en rodamientos:

$$\text{Kurtosis} = \frac{1}{N\sigma^4} \sum_{i=1}^N (x_i - \mu)^4 \quad (3.3)$$

3.3.1.d. Asimetría (Skewness)

La asimetría mide el grado de simetría de la señal con respecto a su media. Valores distintos de cero pueden reflejar fallas mecánicas asociadas a desbalance estructural:

$$\text{Skewness} = \frac{1}{N\sigma^3} \sum_{i=1}^N (x_i - \mu)^3 \quad (3.4)$$

3.3.1.e. Factor de cresta (Crest Factor)

Este indicador permite detectar transitorios breves de alta magnitud, como los producidos por impactos en componentes mecánicos:

$$\text{Crest Factor} = \frac{x_{\text{pico}}}{\text{RMS}} \quad (3.5)$$

3.3.1.f. Factor de impulso (Impulse Factor)

El factor de impulso se utiliza para la detección temprana de fallas en rodamientos al relacionar el valor pico con la media absoluta de la señal:

$$\text{Impulse Factor} = \frac{x_{\text{pico}}}{\frac{1}{N} \sum |x_i|} \quad (3.6)$$

3.3.1.g. Factor de forma (Shape Factor)

Este indicador describe la forma general de la señal y es útil para detectar cambios suaves en el comportamiento del sistema:

$$\text{Shape Factor} = \frac{\text{RMS}}{\frac{1}{N} \sum |x_i|} \quad (3.7)$$

3.3.1.h. Factor de espaciamento (Clearance Factor)

El factor de espaciamento ha sido empleado como característica sensible en sistemas con fricción o contacto mecánico variable:

$$\text{Clearance Factor} = \frac{x_{\text{pico}}}{\left(\frac{1}{N} \sum \sqrt{|x_i|} \right)^2} \quad (3.8)$$

3.3.1.i. Valor pico a pico (Peak-to-Peak)

Este valor representa la diferencia entre los extremos de la señal, siendo útil para detectar vibraciones amplificadas o anomalías abruptas:

$$\text{Peak-to-Peak} = x_{\max} - x_{\min} \quad (3.9)$$

3.3.2. Características en el dominio tiempo-frecuencia utilizadas

3.3.2.a. Transformada Wavelet Discreta y niveles de descomposición

Como se mencionó anteriormente, este trabajo emplea características en el dominio tiempo-frecuencia, extraídas a partir de la aplicación de la Transformada Wavelet Discreta (DWT). Esta técnica permite descomponer señales no estacionarias en componentes localizados simultáneamente en tiempo y frecuencia, lo que resulta especialmente útil para el análisis de señales transitorias y complejas. La DWT se implementa mediante filtros pasa bajos y pasa altos que dividen la señal original en sub-bandas de frecuencia. Como resultado, se obtienen coeficientes de aproximación (A_{cf}) y detalle (D_{cf}), que representan diferentes escalas de la señal. Para una señal muestreada $L(n)$, estos coeficientes se definen como [3]:

$$A_{cf}(n) = \sum_{i=-\infty}^{\infty} L(n) \cdot g(2i - n), \quad D_{cf}(n) = \sum_{i=-\infty}^{\infty} L(n) \cdot h(2i - n), \quad (3.10)$$

donde $g(n)$ y $h(n)$ corresponden a los coeficientes del filtro pasa bajos y pasa altos, respectivamente.

Un aspecto clave en la aplicación de la DWT es la elección de la wavelet madre. Para este estudio se ha seleccionado la función Daubechies de orden 8 (db8) como wavelet madre, ampliamente utilizada en el diagnóstico de fallas debido a su capacidad para representar con precisión eventos localizados en señales no estacionarias [25].

Por otro lado, la determinación del número de niveles de descomposición es un factor crítico en el desempeño del análisis por wavelet. Una selección adecuada permite capturar componentes de baja frecuencia asociadas a fallas progresivas, sin perder sensibilidad frente a eventos de alta frecuencia, como transitorios o impactos mecánicos. Según la literatura, el número óptimo de niveles de descomposición, denotado como n_{ls} , depende de la relación entre la frecuencia de muestreo f_s y la frecuencia fundamental de la red f_1 , y se estima mediante la siguiente expresión [18]:

$$n_{ls} > \text{int} \left(\frac{\log \left(\frac{f_s}{f_1} \right)}{\log(2)} \right) + 1 \quad (3.11)$$

Dado que la relación anterior establece una cota inferior para la selección del número de niveles, es común añadir un nivel adicional para cumplir con el criterio y mejorar la resolución del análisis. Así, el número final de niveles se define como [3]:

$$n_{ls} = \text{int} \left(\frac{\log \left(\frac{f_s}{f_1} \right)}{\log(2)} \right) + 2 \quad (3.12)$$

Esta configuración permite cubrir eficazmente el rango de frecuencias relevante para detectar fallas incipientes.

Una vez abordada la base teórica de la Transformada Wavelet, es posible comprender con mayor claridad el proceso de obtención de las características utilizadas en este trabajo. En particular, se han seleccionado dos tipos de indicadores complementarios derivados de la descomposición wavelet y orientados al análisis de señales de distinta naturaleza:

1. Energía Wavelet Relativa (RWE, por sus siglas en inglés), aplicada exclusivamente a las señales de vibración.
2. Métricas S1, S2 y S3, calculadas directamente de las señales de corriente por fase (A, B y C).

Ambos tipos de características son empleados como variables de entrada para los clasificadores, permitiendo capturar información tanto de naturaleza mecánica como eléctrica del sistema en estudio.

3.3.2.b. Energía Wavelet Relativa (RWE)

La RWE permite cuantificar la proporción de energía contenida en cada nivel de detalle respecto al total de energía de la señal descompuesta, proporcionando una representación de cómo se distribuye la energía de la señal en distintas bandas de frecuencia, facilitando así la detección de patrones anómalos localizados. Esta métrica se define de la siguiente manera:

$$\text{RWE}_j = \frac{E_j}{\sum_{k=1}^L E_k}, \quad \text{con} \quad E_j = \sum_n |d_j[n]|^2 \quad (3.13)$$

Donde $d_j[n]$ son los coeficientes de detalle del j -ésimo nivel, L es el número total de niveles (9 en este trabajo) y E_k es la energía total del k -ésimo nivel.

Cabe destacar que, en este trabajo, se utiliza como característica de entrada al clasificador el valor de RWE correspondiente al nivel de descomposición con mayor concentración de energía para cada señal de vibración. De este modo, se obtiene un único valor representativo de RWE por cada señal de vibración analizada.

3.3.2.c. Características S1, S2 y S3 aplicados a corriente

. Esta estrategia busca capturar asimetrías en la distribución de energía entre fases, propias de fallas eléctricas como cortocircuitos incipientes entre espiras.

Las características S1, S2 y S3 fueron propuestas para capturar, en forma condensada, el comportamiento energético de los coeficientes wavelet de las señales de corriente. Se definen como razones entre las energías más representativas de cada fase, extraídas desde el nivel de mayor contenido energético tras la descomposición wavelet. Su formulación matemática es la siguiente [18]:

$$S_1 = \frac{E_{dia}}{E_{dib}}, \quad (3.14)$$

$$S_2 = \frac{E_{dib}}{E_{dic}}, \quad (3.15)$$

$$S_3 = \frac{E_{dic}}{E_{dia}}. \quad (3.16)$$

Donde E_{dia} , E_{dib} y E_{dic} , corresponde a la energía del nivel de descomposición (mediante la DWT) más energético de la señal de corriente de la fase A, B y C, respectivamente. De esta manera, se obtienen tres valores representativos para las corrientes del motor medidas.

Capítulo 4

Modelos de Inteligencia Artificial

La Inteligencia Artificial (IA) se ha convertido en una herramienta fundamental en el diagnóstico de fallas en máquinas rotativas debido a su capacidad de identificar patrones complejos a partir de señales eléctricas y mecánicas que, de otro modo, serían difíciles de interpretar mediante métodos tradicionales. Esta tecnología permite modelar relaciones no lineales entre variables, adaptarse a condiciones cambiantes del entorno y realizar tareas de clasificación sin necesidad de una programación explícita para cada caso específico [7].

En el contexto del diagnóstico de fallas en motores de inducción trifásicos, la IA permite superar muchas de las limitaciones de los métodos convencionales, como la necesidad de supervisión humana constante, la alta dependencia del conocimiento experto y la dificultad para detectar fallas incipientes. Entre las técnicas más comunes se encuentran las redes neuronales artificiales (ANN), máquinas de vectores de soporte (SVM), algoritmos de vecinos más cercanos (k-NN), árboles de decisión (DT) o bosques aleatorios (RF) y modelos híbridos que combinan procesamiento de señales con algoritmos de clasificación [1].

La principal ventaja de estos modelos es que no requieren conocimientos a priori sobre el comportamiento exacto del sistema, ya que pueden aprender directamente desde los datos históricos de operación. Esto permite una mayor generalización a nuevas condiciones operativas, así como una detección más robusta frente a señales ruidosas o parcialmente corrompidas [26].

Desde un enfoque industrial, la incorporación de sistemas de diagnóstico inteligente ha demostrado reducir tiempos de inactividad, mejorar la planificación del mantenimiento y aumentar la seguridad operacional. Esto ha motivado un creciente interés en el desarrollo de sistemas de mantenimiento predictivo basados en IA, especialmente en sectores donde la confiabilidad de los motores es crítica para la continuidad productiva [7, 26].

4.1. Tipos de IA aplicados a diagnóstico

Los enfoques de Inteligencia Artificial utilizados para el diagnóstico de fallas en motores eléctricos pueden clasificarse en tres grandes categorías: aprendizaje supervisado, no supervisado y métodos híbridos que integran técnicas de procesamiento de señales con modelos de IA [7, 26].

El aprendizaje supervisado se basa en el uso de conjuntos de datos previamente etiquetados para entrenar algoritmos capaces de clasificar condiciones de operación normales

y defectuosas. Entre los modelos más utilizados en este enfoque destacan las Máquinas de Vectores de Soporte (SVM), Redes Neuronales Artificiales (ANN), Árboles de Decisión (DT), k-Vecinos más Cercanos (k-NN) y Bosques Aleatorios (RF) [26]. Estas técnicas han demostrado una alta precisión cuando se dispone de una base de datos representativa, permitiendo la clasificación efectiva de diversos tipos de fallas, como desequilibrio, excentricidad, fallas en rodamientos o rotura de barras del rotor.

En contraste, el aprendizaje no supervisado no requiere etiquetas, y se centra en detectar agrupaciones naturales o anomalías dentro de los datos. Aunque su aplicación es más limitada en la literatura sobre motores de inducción, este enfoque puede ser útil en escenarios donde las fallas no han sido previamente catalogadas o cuando se busca un análisis exploratorio de grandes volúmenes de datos [7].

Más recientemente, han ganado protagonismo los enfoques híbridos que combinan procesamiento de señales con modelos de clasificación. Este enfoque consiste en aplicar técnicas como la Transformada de Fourier (FFT), la Transformada Wavelet Continua o Discreta (DWT o CWT), o la Descomposición en Modos Variacionales (VMD) para extraer características representativas de las señales eléctricas o mecánicas del motor, y posteriormente alimentar estas características a algoritmos de aprendizaje supervisado [17, 26]. Estas técnicas permiten capturar tanto información en frecuencia como en el dominio del tiempo, lo que resulta clave para la detección temprana de fallas.

Además, el auge del Aprendizaje Profundo (DL) ha introducido arquitecturas más complejas como las Redes Neuronales Convolucionales (CNN) y las Redes Neuronales Recurrentes (RNN), las cuales tienen la capacidad de realizar la extracción automática de características. Estos modelos han sido utilizados en conjunto con clasificadores como SVM para mejorar la generalización y precisión del diagnóstico en casos complejos [17]. Sin embargo, su entrenamiento requiere gran cantidad de datos, alta capacidad computacional y cuidado en la selección de hiperparámetros.

La elección entre estos enfoques depende de múltiples factores como la disponibilidad de datos etiquetados, el tipo de señales disponibles, la necesidad de interpretación del modelo y las restricciones computacionales. De esta forma, en entornos industriales, suele priorizarse el balance entre precisión, robustez frente al ruido y facilidad de implementación, al momento de seleccionar el modelo.

4.2. Fundamentos teóricos del modelo SVM

Las Máquinas de Vectores de Soporte (Support Vector Machines o SVM, por sus siglas en inglés) son un método de aprendizaje supervisado basado en la teoría del aprendizaje estadístico, que se utiliza para el reconocimiento de patrones y tareas de clasificación y regresión. Fue desarrollado por Vapnik en la década de 1990 y este ha ganado popularidad debido a su excelente capacidad de generalización y su capacidad para trabajar eficazmente incluso con un número reducido de muestras de entrenamiento [27]. A diferencia de los métodos de aprendizaje tradicionales, que buscan minimizar el error en el conjunto de entrenamiento, el SVM se basa en el principio de Minimización del Riesgo Estructural (SRM, por sus siglas en inglés), que optimiza un límite superior del error de generalización, lo que resulta en una mejor capacidad predictiva en datos no vistos [27, 28].

En el contexto del monitoreo de condición y diagnóstico de fallas, el SVM se emplea para reconocer patrones específicos a partir de señales adquiridas de las máquinas. Las fallas

en equipos mecánicos, como los motores de inducción (IM), pueden generar vibraciones y cambios en las señales de corriente o vibración que, una vez procesadas, pueden ser utilizadas como características o patrones de fallas para identificar los defectos. En este sentido, el SVM es particularmente ventajoso para el campo de estudio debido a la dificultad de obtener suficientes muestras de fallas en situaciones prácticas. [27] Las aplicaciones de este modelo incluyen la detección de fallas en rodamientos, rotores, devanados del estator, desequilibrio de fases, y fallas mecánicas como rotor desequilibrado o desalineado.

Las Máquinas de Vectores de Soporte (Support Vector Machines o SVM, por sus siglas en inglés) constituye una técnica de aprendizaje supervisado ampliamente utilizada para el reconocimiento de patrones o en tareas de clasificación y regresión. Su aplicación en el diagnóstico de fallas en maquinaria rotativa ha sido ampliamente documentada debido a su robustez, capacidad para manejar espacios de alta dimensionalidad, y desempeño competitivo incluso ante conjuntos de datos desbalanceados [7]. Además, su formulación matemática permite un control explícito del equilibrio entre complejidad del modelo y error de entrenamiento, lo cual resulta ventajoso en aplicaciones industriales donde la interpretabilidad y generalización son críticas [29].

4.2.1. Principio básico de funcionamiento del SVM como clasificador

El objetivo de un clasificador SVM es encontrar un hiperplano óptimo de separación en un espacio de características, utilizando las muestras de entrenamiento disponible. Este hiperplano busca maximizar el margen entre las clases de forma que puede llegar a separar el conjunto de vectores sin errores. De esta forma, el SVM se puede explicar mediante cuatro conceptos básicos: el hiperplano separador, el hiperplano de margen máximo, el margen blando y la función del núcleo [21, 30].

Al considerando un problema de clasificación binaria, con su vector de entrada $(\mathbf{x}_i, y_i)_{i=1}^n$, donde $\mathbf{x}_i \in \mathbb{R}^d$ son las muestras extraídas del conjunto de entrenamiento e $y_i \in \{-1, +1\}$ son sus respectivas etiquetas, es posible encontrar el hiperplano $f(x) = 0$ que separa perfectamente las muestras cuando los datos son linealmente separables. Dicho hiperplano viene dado por la relación[27]:

$$f(\mathbf{x}) = \mathbf{w}^\top \mathbf{x} + b = \sum_{i=1}^n w_i x_i + b = 0, \quad (4.1)$$

donde $\mathbf{w}$ es el vector normal al hiperplano y b un escalar que define la distancia del hiperplano al origen.

Mediante la función de decisión $\text{sign}(f(x))$, se logra crear un hiperplano separador que clasifica los datos de entrada en clase positiva o clase negativa, y que satisface el siguiente conjunto de restricciones[27]:

$$y_i f(\mathbf{x}_i) = y_i (\mathbf{w}^\top \mathbf{x}_i + b) \geq 1 \quad \text{para } i = 1, 2, \dots, n. \quad (4.2)$$

Luego, para encontrar el hiperplano óptimo que maximiza el margen, se debe resolver el siguiente problema de optimización cuadrática:

$$\begin{aligned} & \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{sujeto a } y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad i = 1, 2, \dots, n. \end{aligned} \quad (4.3)$$

Cabe destacar que el hiperplano óptimo es aquel que forma el margen máximo, es decir, es el que forma la menor distancia entre él y la muestra más cercana de cada clase [21].

Otro concepto clave son los denominados vectores de soporte. Estos son un subconjunto de las muestras de entrenamiento, y tienen la particularidad de que se encuentran directamente en el margen o dentro del margen. Los vectores de soporte son los únicos puntos que influyen en la definición del hiperplano óptimo y, sorprendentemente, si su número es pequeño en relación con el conjunto de entrenamiento, la capacidad de generalización del modelo puede ser alta, independientemente de la dimensionalidad del espacio de características [31].

A modo de ejemplo, en la Figura 4.1 se muestra la constitución de un hiperplano óptimo y los vectores de soporte que forman el margen máximo, para dos conjuntos de datos linealmente separables [21, 27].




Figura 4.1: Ilustración de un SVM básico de dos clases [21].

4.2.2. Margen suave y parámetro de penalización C

Como se mencionó anteriormente, cuando las clases son perfectamente separables basta con utilizar la ecuación (4.3) para encontrar un hiperplano óptimo. Sin embargo, en general, los datos disponibles no siempre son perfectamente separables, por lo tanto, algunos puntos de datos de entrenamiento no logran satisfacer las condiciones de restricción. Así, para encontrar el hiperplano óptimo, resulta necesario introducir una variable C conocida como parámetro de penalización al problema de minimización, definiendo una nueva formulación conocida como clasificador SVM de margen suave [21]:

$$\begin{aligned} \min_{\mathbf{w}, b, \xi} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\ \text{sueto a:} \quad & y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \quad i = 1, \dots, n, \\ & \xi_i \geq 0, \quad i = 1, \dots, n. \end{aligned} \tag{4.4}$$

donde las variables ξ_i definen las variables de holgura positivas, que son necesarias para

permitir la mala clasificación de algunas muestras con el fin de reducir la complejidad en el cálculo.

Con esta nueva formulación el clasificador se vuelve más robusto a observaciones individuales atípicas y se mejora la clasificación general de la mayoría de los datos de entrenamiento, puesto que permite que algunas observaciones queden en el lado incorrecto del margen o incluso del hiperplano [32].

Por otro lado, el parámetro de penalización C es crucial, ya que establece un límite para la cantidad y severidad de las observaciones atípicas, controlando el equilibrio entre la complejidad del modelo y la tolerancia a errores de clasificación. Dicho esto, un valor alto de C fuerza al modelo a clasificar correctamente todas las muestras, lo que puede llevar al sobreajuste, mientras que un valor bajo permite errores en el entrenamiento a cambio de un margen más amplio y mayor capacidad de generalización [32]. En general, la elección adecuada de C se realiza mediante una técnica llamada búsqueda por rejilla, con el fin de evaluar diversos valores para el parámetro en un solo ajuste del modelo [29].




Figura 4.2: Efecto del parámetro de penalización C en la frontera de decisión del SVM para un núcleo tipo RBF.

En la Figura 4.2 se aprecia cualitativamente el efecto del parámetro de penalización sobre el hiperplano generado y la frontera de decisión para un clasificador binario SVM con

núcleo RBF. En esta, se muestra que la frontera se vuelve más compleja y el modelo acepta menos valores incorrectos (menor holgura) a medida que el valor de C aumenta.

4.2.3. Formulación dual y funciones núcleo (kernel)

Con el fin de manejar el alto número de atributos de las muestras, el problema anterior con restricciones complejas puede simplificarse enormemente convirtiéndolo, mediante la condición de Kuhn–Tucker, a su problema dual Lagrangiano equivalente dado por[27]:

$$\begin{aligned} \max_{\alpha} \quad & L(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) \\ \text{sueto a:} \quad & \alpha_i \geq 0, \quad i = 1, \dots, m, \\ & \sum_{i=1}^m \alpha_i y_i = 0, \quad i = 1, \dots, m. \end{aligned} \quad (4.5)$$

Aquí $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$, es una función núcleo que, para conjuntos de datos linealmente separables, es equivalente al producto punto entre los vectores $\mathbf{x}_i$ y $\mathbf{x}_j$. Por otro lado, cuando los datos no son linealmente separables en su espacio de entrada original, las SVM mapean implícitamente los datos a un espacio de características de mayor dimensión. En este nuevo espacio, los datos pueden volverse linealmente separables, y el hiperplano óptimo se construye allí. De esta manera, el mapeo de ϕ se realiza de manera eficiente a través de la función kernel presentada, calculando la similitud entre dos observaciones sin la necesidad de trabajar explícitamente en el espacio de alta dimensión[27]. Asimismo, las funciones núcleo también transforman la función de decisión (que antes era lineal en el espacio de características) en una función de decisión no lineal en el espacio de entrada original. Luego la función de decisión estará dada por[32]:

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i,j=1}^m \alpha_i y_i \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) + b \right) \quad (4.6)$$

Cabe mencionar que la selección de una función núcleo adecuada es muy importante, ya que el núcleo define el espacio de características en el cual se clasificarán los ejemplos del conjunto de entrenamiento[27]. Existen diferentes funciones núcleo para SVM, donde algunas de las más utilizadas son la función lineal, función polinomial, función de base radial (RBF, por sus siglas en inglés) y función sigmoide. Las formulaciones matemáticas para estas se muestran a continuación[29]:

1. Lineal: $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^\top \mathbf{x}_j$.
2. Polinomial: $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^\top \mathbf{x}_j + r)^d$, $\gamma > 0$.
3. Sigmoide: $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^\top \mathbf{x}_j + r)$.
4. Función de base radial (RBF): $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2)$, $\gamma > 0$.

Donde γ corresponde al parámetro de ancho de banda, r corresponde al coeficiente de sesgo y d corresponde al grado polinomial.

En general, el núcleo RBF es el núcleo más utilizado de todos, dado su capacidad de generar fronteras de decisión no lineales complejas y por requerir un único parámetro

ajustable. Asimismo, en estudios aplicados a sistemas reales de diagnóstico de fallas, como rodamientos y devanados de motores, este kernel ha mostrado consistentemente mejor desempeño que otros modelos [30].




Figura 4.3: Efecto del tipo de núcleo sobre la forma del hiperplano generado en un clasificador SVM binario con $C = 1$.

En la Figura 4.3 se observa el efecto del tipo de núcleo sobre la frontera de decisión y el hiperplano generado en un clasificador SVM binario con hiperparámetros fijos. La comparación muestra que la elección del núcleo determina la forma y complejidad de la frontera que el modelo puede representar, y que su conveniencia depende de la distribución de los datos sobre el espacio representado.

Por otro lado, respecto al parámetro de ancho de banda γ , este es un hiperparámetro clave en ciertos núcleos, como el núcleo RBF, el núcleo sigmoide y el núcleo polinomial. En RBF, γ determina la influencia de cada vector de soporte sobre la clasificación de nuevos puntos. Geométricamente, un valor pequeño de γ produce una función núcleo más ancha, donde cada vector de soporte tiene una mayor área de influencia, lo que genera fronteras de decisión más suaves y generalizadas. Por el contrario, un valor grande de γ produce una función núcleo más estrecha, donde cada vector de soporte tiene influencia localizada sobre los puntos muy cercanos, generando una frontera de decisión más ajustada, compleja y con

mayor riesgo de sobreajuste. De esta manera, su correcta selección es crucial para lograr un buen equilibrio entre el *underfitting* y el *overfitting* del modelo.




Figura 4.4: Efecto del parámetro de ancho de banda γ en la frontera de decisión del SVM para un núcleo tipo RBF con $C = 1$.

En la Figura 4.4 se ejemplifica, para un SVM binario con núcleo RBF y $C = 1$, el efecto del parámetro de ancho de banda sobre la frontera de decisión. Se aprecia claramente como este parámetro controla la escala o nivel de influencia de cada muestra, por lo que para un valor pequeño de γ la frontera es amplia y suave, capturando variaciones de gran escala. Por el contrario, para un valor alto de γ la frontera se vuelve altamente local, incrementando la sensibilidad pero aumentando el riesgo de sobreajuste.

4.2.4. Extensión a problemas multiclase (SVM Multiclase)

El algoritmo básico para el modelo SVM, descrito anteriormente, se basa específicamente en la clasificación binaria, donde las etiquetas de clase solo pueden tomar valores 1 y -1. Sin embargo, en aplicaciones reales, frecuentemente se encuentran muestras con más de dos clases. Por ejemplo, en el diagnóstico de fallas en máquinas rotatorias existen múltiples tipos de fallas como desequilibrio mecánico, desalineación, fallas en rodamientos, etc., donde cada tipo de falla puede representar una clase del conjunto de datos[27]. Resulta

que el concepto de hiperplanos separadores, en los cuales se basa el SVM, no se adapta naturalmente a más de dos clases, por lo que se han propuesto múltiples métodos para extender los SVM al caso de k clases. Dentro de estos métodos destacan el método uno-contra-todos (OVA, por sus siglas en inglés), el método de uno-contra-uno (OVO, por sus siglas en inglés) y el método de grafo acíclico dirigido (DAG, por sus siglas en inglés). Cabe mencionar que de los tres métodos, el OVA y el OVO son los enfoques más populares debido a su simplicidad conceptual, su eficiencia y robustez empírica, y su simplicidad en la implementación dado al soporte nativo en librerías comúnmente utilizadas para el aprendizaje automático. [32, 33].

4.2.4.a. Clasificación uno-contra-todos

El enfoque uno-contra-todos (también conocido como uno-contra-el-resto) es la implementación más antigua para clasificación multiclase con SVM. En este caso, se construyen k clasificadores SVM (donde k es el número total de clases), cada uno comparando una de las clases frente al conjunto de las otras $k - 1$ clases. De esta manera, el i -ésimo modelo SVM se entrena con todos los ejemplos de la clase i etiquetados como positivos, mientras que todos los demás ejemplos se etiquetan como negativos[32].

Dado un conjunto de entrenamiento con l muestras tal que $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)$, donde $\mathbf{x}_i \in \mathbb{R}^n$ e $y_i \in \{1, \dots, k\}$ es la clase de x_i , el i -ésimo modelo SVM resuelve el siguiente problema de optimización[27]:

$$\begin{aligned} \min_{\mathbf{w}^i, b^i, \xi^i} \quad & \frac{1}{2} \|\mathbf{w}^i\|^2 + C \sum_{j=1}^l \xi_j^i (\mathbf{w}^i)^T \\ \text{sujeto a:} \quad & (\mathbf{w}^i)^\top \phi(\mathbf{x}_j) + b^i \geq 1 - \xi_j^i, \quad \text{si } y = i, \\ & (\mathbf{w}^i)^\top \phi(\mathbf{x}_j) + b^i \leq -1 + \xi_j^i, \quad \text{si } y \neq i, \\ & \xi_j^i \geq 0, \quad j = 1, \dots, l. \end{aligned} \tag{4.7}$$

donde la muestra de entrenamiento $\mathbf{x}_t$ se transforma a un espacio de mayor dimensión mediante la función de mapeo ϕ , y C es el parámetro de penalización.

Cabe destacar que minimizar (4.7) equivale a maximizar la relación $2/\|\mathbf{w}^i\|$, el cual corresponde al margen entre los dos grupos de datos. De esta manera, cuando los datos no son separables, se penaliza el término $\sum \xi_t^i$, permitiendo reducir el número de errores de entrenamiento [27].

4.2.4.b. Clasificación Uno-Contra-Uno

Otro método importante es el método uno-contra-uno. Este método construye $\frac{k(k-1)}{2}$ clasificadores SVM (donde k es el número total de clases), cada uno de los cuales compara un par de clases. Por ejemplo, un SVM de tipo OVO podría comparar la clase i (etiquetada como $+1$) con la clase j (etiquetada como -1), para posteriormente realizar una clasificación de las muestras [32].

Dado un conjunto de entrenamiento con l muestras tal que $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)$, donde $\mathbf{x}_t \in \mathbb{R}^n$ e $y_t \in \{1, \dots, k\}$ es la clase de x_t , para los datos de entrenamiento pertenecientes a la clase i y clase j , se resuelve el siguiente problema de clasificación binaria [27]:

$$\begin{aligned}
\min_{\mathbf{w}^{ij}, b^{ij}, \xi^{ij}} (\mathbf{w}^{ij})^T \phi(\mathbf{x}_t) + b^{ij} &= \frac{1}{2} \|\mathbf{w}^{ij}\|^2 + C \sum_{t=1}^l \xi_t^{ij} (\mathbf{w}^{ij})^T \phi(\mathbf{x}_t) \\
\text{sueto a: } (\mathbf{w}^{ij})^T \phi(\mathbf{x}_t) + b^{ij} &\geq 1 - \xi_t^{ij}, & \text{si } y_t = i, \\
(\mathbf{w}^{ij})^T \phi(\mathbf{x}_t) + b^{ij} &\leq -1 + \xi_t^{ij}, & \text{si } y_t = j, \\
\xi_t^{ij} &\geq 0, & t = 1, \dots, l.
\end{aligned} \tag{4.8}$$

Una vez contruidos los $\frac{k(k-1)}{2}$ clasificadores, existen diferentes métodos para realizar la clasificación con nuevas muestras. En algunas pruebas, se utiliza la siguiente relación como estrategia de votación:

$$f(\mathbf{x}) = \text{sign} \left((\mathbf{w}^{ij})^T \phi(\mathbf{x}) + b^{ij} \right) \tag{4.9}$$

Esta indica que si $f(\mathbf{x}) = +1$, entonces se añade un voto a la clase i , mientras que si $f(\mathbf{x}) = -1$, se suma un voto a la clase j . Finalmente, la clasificación se realiza asignando la muestra a la clase que haya recibido más votos en el total de comparaciones. Este método de votación también se conoce como la estrategia de *mayoría de votos* o *Max Wins* [27].

4.2.5. Clasificación de grafo acíclico dirigido (DAG)

En este método, el entrenamiento es similar a la estrategia OVO, resolviendo $\frac{k(k-1)}{2}$ clasificadores SVM binarios. Sin embargo, en la fase de prueba se utiliza un grafo binario acíclico en forma de árbol con $\frac{k(k-1)}{2}$ nodos internos y k hojas, donde cada nodo es un clasificador binario entrenado entre dos clases i y j . Luego, a partir de la raíz del DAG (inicio del modelo), se evalúa una función de decisión binaria con una muestra de prueba $\mathbf{x}$. Dependiendo del resultado, se avanza hacia la izquierda o la derecha del árbol, repitiendo el proceso hasta llegar a una hoja, que corresponde a la clase final predicha[27].

Debido a que este método resulta ser el menos popular de los tres, no se aboradará su profundidad teórica, sin embargo, una explicación más detallada del método puede ser encontrada en [34, 35].

4.3. Métricas de evaluación aplicadas a SVM

Aun cuando las SVM producen directamente clases (o “scores” continuos mediante la función de desición escogida, su desempeño se valora a partir de métrica que derivan de la matriz de confusión, utilizada en cualquier clasificador. A continuación se resumen las métricas principales para evaluar el desempeño del modelo, siendo estas: precisión global (accuracy en inglés), precisión (precision en inglés), sensibilidad (recall en inglés) y F1-score, indicando la formulación matemática y su interpretación particular para las SVM [33].

Para la evaluación de la matriz de confusión (y por ende de las métricas) en un problema de clasificación, ya sea binario o multiclase, existen cuatro términos clave a tener en cuenta:

1. Verdaderos Positivos: Los Verdaderos Positivos (TP, por sus siglas en inglés) son los casos que pertenecen a la clase k y que el modelo predice correctamente como perteneciente a la clase k .

2. Verdaderos Negativos: Los Verdaderos Negativos (TN, por sus siglas en inglés) son los casos que no pertenecen realmente a la clase k y que el modelo predice correctamente que no pertenecen a la clase k .
3. Falsos Positivos: Los Falsos Positivos (FP, por sus siglas en inglés) son los casos que no pertenecen a la clase k pero que el modelo predice incorrectamente como pertenecientes a la clase k .
4. Falsos Negativos: Los Falsos Negativos (FN, por sus siglas en inglés), son los casos que pertenecen a la clase k pero que el modelo predice que no pertenecen a la clase k .

4.3.1. Precisión global (Accuracy)

Esta métrica cuantifica la proporción total de observaciones clasificadas de forma correcta, por lo que refleja la tasa global de acierto del modelo. Resulta adecuada cuando las clases presentan una distribución balanceada y el impacto asociado a los dos tipos de error, tanto falsos positivos (FP) como falsos negativos (FN), es comparable. La formulación matemática para esta métrica está dada por la siguiente relación:

$$\text{Acc} = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.10)$$

4.3.2. Precisión (Precision)

Esta métrica corresponde al porcentaje de predicciones positivas que el modelo clasifica correctamente, es decir, refleja el *valor predictivo positivo* (precision) del clasificador. Resulta útil cuando los falsos positivos (FP) implican un costo considerable, por ejemplo en diagnósticos médicos, detección de fraude o filtrado de spam, y por tanto, resulta prioritario minimizar su ocurrencia. La formulación matemática para esta métrica está dada por la siguiente relación:

$$\text{Prec} = \frac{TP}{TP + FP} \quad (4.11)$$

4.3.3. Sensibilidad (Recall)

Esta métrica corresponde al porcentaje de observaciones positivas que el modelo identifica correctamente. En otras palabras, representa la *tasa de verdaderos positivos* del clasificador. Esta métrica es especialmente útil cuando el costo de pasar por alto un caso positivo (FN) es mucho mayor que el de generar un falso positivo (FP), como sucede en detecciones de fallas de seguridad o esquemas de mantenimiento predictivo. La formulación matemática para esta métrica está dada por la siguiente relación:

$$\text{Rec} = \frac{TP}{TP + FN} \quad (4.12)$$

4.3.4. F1-score

Esta métrica corresponde a la media armónica entre la métrica de Precisión y de Sensibilidad, es decir, el F1-score resume el rendimiento del modelo en un único valor que pondera por igual la proporción de falsos positivos (FP) y falsos negativos (FN). Resulta especialmente útil cuando el conjunto de datos está desbalanceado o cuando la clase de interés

es minoritaria, pues obliga al modelo a mantener un compromiso equilibrado entre ambos tipos de error. La formulación matemática para esta métrica está dada por la siguiente relación:

$$F_1 = 2 \frac{\text{Prec} \cdot \text{Rec}}{\text{Prec} + \text{Rec}} \quad (4.13)$$

4.3.5. Modos de agregación global

En el contexto de evaluación de clasificadores multiclase, los modos de agregación global indican cómo se combinan las métricas calculadas para cada clase individual (precisión, sensibilidad, F1, etc.) en un único valor global. Los cuatro modos más habituales que se citan en la literatura son [33]:

4.3.5.a. Promedio-micro (Micro-average)

Esta sub-métrica mide el rendimiento global del clasificador combinando primero todos los verdaderos positivos, falsos positivos y falsos negativos de las k clases, y aplicando después la fórmula binaria correspondiente. De ese modo, las clases con mayor número de muestras influyen más en el resultado final.

Su formulación matemática sigue la siguiente relación:

$$\text{Prec}_{\text{micro}} = \frac{\sum_{k=1}^K TP_k}{\sum_{k=1}^K (TP_k + FP_k)} \quad (4.14)$$

Es apropiada cuando interesa el rendimiento agregado (por ejemplo número total de errores) y las clases mayoritarias tienen un peso operativo considerablemente superior.

4.3.5.b. Promedio-macro (Macro-average)

El promedio macro calcula la media aritmética de la métrica M_k obtenida para cada clase, otorgando el mismo peso a todas ellas. Esto la hace especialmente sensible a deficiencias en clases minoritarias.

Su formulación matemática sigue la siguiente relación:

$$M_{\text{macro}} = \frac{1}{K} \sum_{k=1}^K M_k \quad (4.15)$$

Esta sub-métrica resulta útil cuando se desea que cada clase contribuya por igual a la evaluación global, independientemente de la cantidad de muestras.

4.3.5.c. Promedio ponderado (Weighted-average)

A diferencia del promedio-macro, esta variante pondera la contribución de cada clase por su soporte n_k (número de observaciones reales en la clase k en el conjunto de datos). Así se obtiene un único valor global que refleja el rendimiento general sin penalizar en exceso las clases pequeñas.

Su formulación matemática sigue la siguiente relación:

$$M_{\text{ponderado}} = \frac{\sum_{k=1}^K n_k M_k}{\sum_{k=1}^K n_k} \quad (4.16)$$

Es especialmente útil cuando se necesita un único indicador que refleje el rendimiento general del modelo sin distorsionar la influencia proporcional de cada clase en el conjunto de datos.

4.3.5.d. Precisión balanceada (Balanced Accuracy)

Esta métrica extiende la precisión clásica promediando las sensibilidades de cada clase, de modo que corrige el sesgo hacia las clases mayoritarias.

$$\text{BAcc} = \frac{1}{K} \sum_{k=1}^K \text{Rec}_k, \quad (4.17)$$

donde se tiene que $\text{Rec}_k = \frac{TP_k}{TP_k + FN_k}$.

En problemas binarios ($k = 2$) esta sub-métrica se reduce a la media entre la sensibilidad de la clase positiva y la especificidad (o tasa de verdaderos negativos) de la clase negativa, obteniendo la siguiente relación:

$$\text{BAcc} = \frac{1}{2} (\text{Rec} + \text{Especificidad}), \quad (4.18)$$

donde se tiene que $\text{Especificidad} = \frac{TN}{TN + FN}$.

4.4. Consideraciones para el ajuste del modelo SVM

4.4.1. Descripción de los datos y estructura del conjunto

El conjunto de datos utilizado en este trabajo corresponde a señales extraídas a partir de ensayos en un motor de inducción bajo diversas condiciones de operación. Se consideran en total 32 características, de las cuales cinco se obtienen mediante la transformada wavelet discreta, y el resto corresponden a características estadísticas en el dominio del tiempo, calculadas para dos señales de vibración y tres señales de corriente registradas.

Las etiquetas representan las clases de falla, incluyendo estados saludables, fallas mecánicas, fallas eléctricas y fallas mixtas (combinación simultánea de fallas mecánicas y eléctricas) en distintos grados de severidad. El conjunto final se construye mediante la concatenación horizontal de todas las características.

4.4.2. Preprocesamiento

El conjunto de datos se divide en subconjuntos de entrenamiento y prueba siguiendo una proporción de 70/30, preservando la distribución original de las clases mediante estratificación. Con el fin de garantizar la reproducibilidad y facilitar comparaciones entre modelos, se utiliza un valor fijo de semilla aleatoria para la partición de los datos.

Posteriormente, todas las características se estandarizan mediante el método *StandardScaler*, de forma que cada una presente media cero y varianza unitaria. Este procedimiento previene que las diferencias de escala entre características influyan de manera indebida en el ajuste del modelo.

4.4.3. Configuración del modelo SVC

Se emplea el modelo *SVC* de la librería *scikit-learn*. Dado que el problema es de tipo multiclase, se utiliza el esquema *One-vs-Rest* (OvR), implementado por defecto en la librería.

4.4.4. Validación cruzada y selección de hiperparámetros

Para la selección de los hiperparámetros óptimos se aplica una búsqueda por rejilla (*Grid Search*) combinada con *validación cruzada estratificada de cinco particiones*¹. Esta metodología evalúa todas las combinaciones posibles de la rejilla, estimando su desempeño mediante validación cruzada en la que cada partición conserva la proporción de clases del conjunto original. De esta forma, se obtiene una evaluación más estable y representativa, minimizando la dependencia de un único corte de los datos.

La rejilla de búsqueda se define como sigue: el parámetro de penalización C toma los valores [0.01, 0.1, 1, 10, 100, 1000, 10000]; el tipo de núcleo (*kernel*) se evalúa en las opciones *linear*, *poly*, *rbf* y *sigmoid*; el parámetro de ancho de banda γ se configura como *scale* o *auto*; y, en el caso del núcleo polinómico, el grado se prueba con los valores [2, 3, 4, 5]. Además, se aplica la opción *balanced* en *class_weight* para compensar posibles desbalances en las clases.

La métrica de optimización utilizada es *F1_macro*, con el fin de otorgar igual importancia a todas las clases en la evaluación. Esta estrategia sigue las recomendaciones metodológicas de [29], quienes proponen el uso combinado de validación cruzada y búsqueda logarítmica en C y γ para mejorar la robustez del modelo.

4.4.5. Ajuste final e interpretación del parámetro γ

Una vez identificada la combinación óptima de hiperparámetros mediante *Grid Search*, el modelo definitivo se entrena utilizando la totalidad del conjunto de entrenamiento y los valores seleccionados. Como parte del análisis posterior, se calcula el valor numérico efectivo del parámetro γ , dado que sus configuraciones predefinidas en *scikit-learn* (*scale* y *auto*) se expresan de forma relativa:

- Si *gamma* = *scale*, entonces: $\gamma = \frac{1}{n_{\text{features}} \cdot \text{Var}(X)}$.
- Si *gamma* = *auto*, entonces: $\gamma = \frac{1}{n_{\text{features}}}$.

Este cálculo explícito, basado en [33], permite interpretar de manera cuantitativa el alcance de cada punto de soporte en el espacio transformado, favoreciendo una mejor comprensión de la capacidad del modelo para separar las clases.

¹Traducción del autor para *StratifiedKFold* con $K = 5$.

Capítulo 5

Implementación del banco de pruebas

En este capítulo se presenta el desarrollo del banco de pruebas implementado, diseñado para la adquisición de señales de vibración y corriente al someter un motor de inducción a diversas condiciones de operación y fallas (en su mayoría) incipientes controladas. Estas señales son posteriormente procesadas y clasificadas mediante el modelo de Inteligencia Artificial propuesto. Además, se realiza una descripción detallada de las características constructivas del banco de pruebas, del motor de pruebas y de la máquina de inducción empleada como generador (en adelante referida como generador de inducción o simplemente generador) para aplicar carga al sistema mecánico.

5.1. Diseño y estructura del nuevo banco de pruebas

Para cumplir con los objetivos propuestos en este trabajo, fue necesario rediseñar el banco de pruebas original desarrollado por Mella en [36]. En la Figura 5.1 se presenta el banco de pruebas original, el cual tiene como base una plancha de acero soportada por perfiles cuadrados de madera para aislar el sistema del suelo, un perfil en “C” dispuesto para soportar el eje y los rodamientos, cuatro barras de metal que sostienen y dan altura al motor instalado y, a modo de carga mecánica, un freno tipo zapata anclado a la placa y unido mediante una correa al eje. Una descripción más detallada de los aspectos constructivos del banco original pueden revisarse en [36].






Figura 5.1: Vista lateral del banco de pruebas original.[36]

El nuevo diseño para el banco de pruebas tiene como objetivo aplicar distintos niveles de carga mecánica al motor de pruebas, minimizar el ruido en las mediciones provocado por vibraciones externas no relacionadas con las fallas inducidas y facilitar el reemplazo sistemático de los rodamientos utilizados para las pruebas. Dicho esto, una de las principales modificaciones realizadas consiste en la reutilización del banco de pruebas original para la construcción de una nueva estructura. La estructura tiene como función soportar las máquinas y el eje que las conecta, por lo que debe contar con la rigidez suficiente para garantizar una operación estable y libre de interferencias por vibraciones mecánicas externas, tanto en condiciones normales (sin fallas) como anormales (con fallas). Asimismo, debe proporcionar los grados de libertad adecuados que permitan el correcto alineamiento del sistema motor-eje-generator, además de facilitar el reemplazo sistemático de los rodamientos de prueba.



(a)



(b)

Figura 5.2: Vista (a) lateral y (b) superior del nuevo banco de pruebas instalado.

En las Figuras 5.2a y 5.2b se muestra la vista superior y lateral, respectivamente, del nuevo banco de pruebas terminado e instalado. En estas se observa que la plancha de acero que constituye la base del sistema original se extiende de forma axial, con el fin de proporcionar espacio suficiente para alinear las dos máquinas junto con el eje. Además, se reemplazan los antiguos perfiles de madera por perfiles cuadrados de acero estructural de $150 \times 150 \times 40\text{mm}$. Estos perfiles fueron soldados entre sí, y a su vez, soldados a la plancha de acero para aumentar la rigidez del conjunto. Se conservan los soportes originales para el

generador y el perfil tipo “C” destinado a soportar el eje. Asimismo, se incorpora un soporte en altura, destinado a la instalación del motor de pruebas. Este soporte se elabora a partir de una placa de acero A36 de $300 \times 300 \times 20\text{mm}$, a la cual se le realizan orificios tipo “ojos chinos” con el fin de facilitar el alineamiento preciso del motor. Complementariamente, se fabrican cuatro apoyos utilizando perfiles cuadrados de acero estructural de $40 \times 40 \times 3\text{mm}$, los cuales dan la elevación y rigidez necesarias a dicho soporte.

5.2. Generador de inducción y carga eléctrica

Con el objetivo de aplicar distintos niveles de carga mecánica al motor de pruebas, se emplea, como generador de inducción autoexcitado, una máquina de inducción trifásica marca Siemens modelo 1LE0102-1AC4, la cual se encuentra a disposición en el diseño original del banco de pruebas. Este tipo de generador permite la generación de energía eléctrica a partir de una máquina de inducción trifásica mediante el uso de capacitores en conexión shunt en sus terminales. De este modo, mientras el motor de pruebas acciona el generador, este último puede ser cargado eléctricamente mediante un banco trifásico de cargas resistivas, lo que permite regular el par de carga transmitido al motor.

Una descripción detallada sobre el principio de funcionamiento y operación del generador de inducción autoexcitado y los criterios de dimensionamiento de los capacitores shunt se presenta en el Apéndice A. Asimismo, en la Tabla 5.1 se muestran los valores de placa correspondientes a dicha máquina.

Tabla 5.1: Datos de placa para el generador de inducción autoexcitado.

Parámetro	Valor	Unidad de medida
Frecuencia nominal	50	Hz
Tensión nominal (Δ/Y)	230/400	V
Corriente nominal (Δ/Y)	6,6/3,80	A
Potencia nominal	1,5	kW
FP nominal	0,76	[-]
Velocidad nominal	940	rpm
Eficiencia	75,2	%
Clase de Eficiencia	IE1	No aplica

Asimismo, la Figura 5.3 muestra la vista exterior e interior, respectivamente, del banco trifásico de capacitores empleado para la autoexcitación de la máquina de inducción, el cual permite lograr valores de $50\mu F$, $100\mu F$ y $200\mu F$ por fase. Se aprecia que el banco de capacitores posee un sistema de ventilación forzada, el cual resulta necesario instalar para evitar riesgos de explosión o ruptura debido al calentamiento excesivo que sufren los capacitores durante los ensayos con carga, permitiendo extender su vida útil. Sin embargo, el sistema de ventilación no logra ser suficiente, por lo que una alternativa factible para sustituir el sistema generador-carga eléctrica es la instalación de un freno electromagnético. Este dispositivo ofrece una solución más robusta y segura, permitiendo también lograr diferentes niveles de carga mecánica sobre el motor, sin incrementar significativamente el costo de implementación.

Por otro lado, la Figura 5.4 muestra el banco trifásico de cargas resistivas utilizado como carga eléctrica. Este equipo cuenta con nueve niveles de resistencias conmutables, contando su resistencia interna cuya magnitud alcanza los $127,7\Omega$. Cabe mencionar que durante la




Figura 5.3: Vista (a) exterior e (b) interior del banco de capacitores utilizado.

implementación únicamente se utilizan dos niveles de resistivos, siendo estos de $127,7\Omega$ y de $90,69\Omega$.



Figura 5.4: Banco de cargas resistivas utilizado.

5.3. Motor de pruebas

5.3.1. Características de fábrica

Para la selección del motor de pruebas se consideran los equipos previamente instalados en el banco de pruebas original. En función de ello, se opta por utilizar un motor trifásico Siemens modelo 1LE0021-1AC4, el cual posee características similares a la máquina usada como generador.

Tabla 5.2: Datos de placa para máquina de pruebas.

Parámetro	Valor	Unidad de medida
Frecuencia nominal	50	Hz
Tensión nominal (Δ/Y)	230/400	V
Corriente nominal (Δ/Y)	6,4/3,65	A
Potencia nominal	1,5	kW
FP nominal	0,74	[-]
Velocidad nominal	945	rpm
Eficiencia	79,8	%
Clase de Eficiencia	IE2	No aplica

Asimismo, con el propósito de comparar las características iniciales del motor de pruebas con las obtenidas tras el rebobinado de este, se debe conocer los parámetros originales que lo modelan. Ello permite evaluar la factibilidad del método propuesto para inducir fallas por cortocircuito y verificar si el procedimiento resulta aplicable para emular condiciones de operación anómalas en una máquina comercial real.

De esta manera, se emplea el método de estimación de parámetros para máquinas de inducción propuesto en [37, 38]. Dicho método se basa en la medición de tensiones y corrientes instantáneas durante el arranque del motor. A partir de los datos, y mediante la minimización de una función de costo que compara los valores medidos con los obtenidos del modelo dinámico de la máquina de inducción, es posible estimar los parámetros eléctricos del equipo.

Con el valor de resistencia de estator ($R_s = 4,1532 \Omega$ o 0,0387 pu en base propia del motor), calculado como el promedio de las mediciones por fase realizadas con un puente de Wheatstone-Kelvin modelo QJ31E, se obtienen los parámetros eléctricos de fábrica del motor de inducción, los cuales se muestran la Tabla 5.3.

Tabla 5.3: Parámetros de fábrica estimados para el motor de pruebas, en por unidad base propia.

Parámetro	Por Unidad (<i>pu</i>)
Resistencia de estator (R_s)	0,0387
Resistencia de rotor (R_r)	0,0379
Inductancia de dispersión estator ($L_{\sigma s}$)	0,0402
Impedancia de dispersión rotor ($L_{\sigma r}$)	0,0485
Impedancia mutua (M)	0,6602

Por otro lado, para lograr un rebobinado satisfactorio del motor, resulta necesario conocer la composición de fábrica de su devanado estatórico, por lo que se realiza un análisis del interior del estator. La Figura 5.5 muestra el interior del estator del motor, junto con su devanado estatórico original. Este cuenta con un total de 36 ranuras; por tanto, al tratarse de un motor trifásico con devanado de capa simple y tres pares de polos, se conforman 18 bobinas (seis por cada fase), distribuidas en dos ranuras consecutivas. Esta disposición se puede apreciar con mayor claridad en el diagrama del bobinado correspondiente a la fase A (Figura 5.6a) y en el esquema completo del devanado del estator que incluye las tres fases (Figura 5.6b).




Figura 5.5: Interior del estator y devanado estático original del motor de pruebas.




Figura 5.6: Diagrama del bobinado para la (a) fase A y del (b) bobinado completo del motor de pruebas.

5.3.2. Características del motor modificado

Para contar con una configuración que permita ensayar el motor en condiciones normales y en condiciones de fallas inducidas, se propone modificar el devanado del estator de la máquina de inducción. Esta modificación consiste en rebobinar el estator de la máquina con el objetivo de incorporar derivaciones (taps) cada cierta cantidad de vueltas de bobina, en cada una de sus fases. De este modo, al conectar entre sí los terminales de dichas derivaciones, es posible emular distintos grados de severidad de cortocircuito entre espiras,

tal como muestran [39] o [40] en su configuración experimental.

Al rebobinar el motor, la principal dificultad radica en evitar alteraciones significativas en los parámetros eléctricos que modelan la máquina. Por este motivo, resulta fundamental conocer la cantidad de vueltas de cada bobina por fase y el diámetro del conductor para la construcción del nuevo devanado.

Respecto al número de vueltas, inicialmente se realiza una estimación utilizando el método propuesto en [41] para el diseño de máquinas de inducción de potencia inferior a $100kW$. A partir de los parámetros constructivos y los valores nominales de la máquina, se obtiene una estimación inicial de 51 vueltas por bobina. Posteriormente, este valor fue ajustado mediante el conteo directo de los conductores en cada bobina, obteniendo la cantidad de 52 vueltas por bobina, para un total de 312 vueltas por cada fase. Así, la estimación inicial resulta ser suficientemente precisa para definir con antelación el grado de severidad adecuado para la separación de las derivaciones. Por otro lado, el diámetro del conductor se determina mediante su medición directa utilizando un pie de metro, obteniendo un valor de $0,81mm$.




Figura 5.7: Esquema referencial del rebobinado para el devanado de estator de la fase U en el motor de pruebas.

La Figura 5.7 presenta un esquema referencial del rebobinado final para la fase U del motor, en el cual cada conjunto de espiras conforma una bobina completa, para un total de 6 bobinas por fase. Del esquema, se muestran las derivaciones numeradas, indicando la cantidad de vueltas a la que se ubican respecto del inicio del devanado (terminal U1). Cabe señalar que todas las derivaciones fueron implementadas en la primera bobina de cada una de las fases (U, V y W). Además, las fases U y V poseen la misma cantidad de derivaciones, ubicadas a igual número de vueltas, mientras que en la fase W, debido a limitaciones de espacio, solo se realizaron derivaciones a las 2, 5, 8 y 18 vueltas.

Asimismo, la Figura 5.8 muestra el motor de pruebas ya rebobinado, con la adición de una caja para sus terminales principales y sus derivaciones.

Notar que la configuración del nuevo devanado permite emular diversas combinaciones de cortocircuito entre vueltas, conectando entre sí, los terminales de las derivaciones realizadas. Dicho esto, las configuraciones de cortocircuito específicas que se emplearon durante los ensayos y la toma de muestras se describen con detalle en el Capítulo 6.




Figura 5.8: Vista (a) lateral y (b) superior del MI rebobinado con caja para terminales y derivaciones.

Por otro lado, siguiendo el procedimiento utilizado para la estimación de los parámetros originales del motor de inducción, se lleva a cabo la estimación de los nuevos parámetros correspondientes al motor rebobinado. Mediante el nuevo valor de resistencia de estator ($R_s^* = 4,590\Omega$ o $0,0428pu$), calculado como el promedio de las mediciones por fase obtenidas mediante un puente de Wheatstone-Kelvin modelo QJ31E, se determinan los parámetros eléctricos del motor rebobinado, presentados en la Tabla 5.4.

Tabla 5.4: Parámetros estimados para el motor de pruebas rebobinado, en por unidad base propia.

Parámetro	Por Unidad (pu)
Resistencia de estator nueva (R_s^*)	0,0425
Resistencia de rotor nueva (R_r^*)	0,0214
Inductancia de dispersión estator nueva ($L_{\sigma s}^*$)	0,0100
Impedancia de dispersión rotor nueva ($L_{\sigma r}^*$)	0,0105
Impedancia mutua nueva (M^*)	0,8414

5.4. Acoplamiento y alineación del sistema motor-eje-generator

El acoplamiento es un componente utilizado para conectar el motor de inducción con el eje del sistema. La elección de este elemento resulta bastante relevante, ya que debe proporcionar el grado de libertad necesario para permitir el desacople y retiro del eje sin necesidad de desplazar las máquinas de su posición original. De este modo, un acoplamiento adecuado facilita el reemplazo sistemático de los rodamientos, evitando la necesidad de realizar un nuevo proceso de alineación tras cada intervención.

Para este propósito, se emplea un acoplamiento flexible con espaciador Rexnord Omega modelo ES10-R. Cabe destacar que las propiedades mecánicas del acoplamiento son determinantes para asegurar una correcta alineación entre el motor de inducción, el eje y el generador del banco de pruebas. Estas características definen el desalineamiento ad-


misible y permiten mitigar el riesgo de generar vibraciones no deseadas producto de una instalación deficiente, lo cual resulta esencial para evitar interferencias en las mediciones y preservar la integridad de las condiciones de falla controlada. Las características de este componente se presentan en la Tabla 5.5, mientras que en las Figuras 5.9a y 5.9b se muestran imágenes del acoplamiento completo, junto con su juego de masas mecanizadas las dimensiones de los ejes.

Tabla 5.5: Características del acoplamiento para el motor de pruebas.[42]

Diámetro de Salida	6,38 in
Tipo de Cierre	Tornillo de Fijación
Valor Nominal del Par	164 Nm
Desalineamiento - Angular	4°
Desalineamiento - Paralelo	0,063 in
Desalineamiento - Axial	0,25 in
Material	Poliuretano



(a)



(b)

Figura 5.9: (a) Acoplamiento Rexnord Omega modelo ES10-R junto con su (b) juego de masas.

Por otro lado, para asegurar una correcta alineación entre el motor de inducción, el eje y el generador del banco de pruebas, se utiliza el “método de los comparadores alternados” [43]. Este procedimiento fue seleccionado por su fiabilidad y simplicidad, ya que permite detectar desviaciones angulares y paralelas entre los ejes con alta exactitud. El método consiste en la instalación de dos relojes comparadores dispuestos en forma alternada sobre los acoplamientos, uno fijado a la parte móvil y otro a la parte fija. De forma tal que, a partir

de las mediciones obtenidas en distintos puntos de rotación, se determina el grado de desalineamiento presente en el sistema, permitiendo realizar los ajustes necesarios mediante el desplazamiento controlado de las bases de apoyo. En el Apéndice B se presenta una descripción detallada del procedimiento de alineación realizado.

Cabe destacar que la alineación se realiza desde el generador hacia el motor, considerando que el generador presenta una menor cantidad de grados de libertad y, por tanto, una menor capacidad de ajuste respecto al resto de los componentes del sistema.

5.5. Rodamientos de prueba

Por último, uno de los elementos más relevantes del sistema (y también objeto de estudio en este trabajo) son los rodamientos utilizados. Estos componentes mecánicos cumplen una función esencial en sistemas rotativos, al permitir el movimiento relativo entre elementos giratorios y estacionarios, reduciendo la fricción y soportando cargas tanto radiales como axiales. Para la implementación del banco de pruebas se utilizan rodamientos de bolas autoalineables Craft, modelo 1207 EF-J31. En la Figura 5.10a se muestra una imagen del rodamiento empleado, mientras que la Figura 5.10b presenta un esquema con sus dimensiones principales, las cuales se recopilan en la Tabla 5.6.

A partir de dichas dimensiones, y utilizando las ecuaciones (2.1), (2.2), (2.3) y (2.4) presentadas en el Capítulo 2, se calculan las frecuencias características del rodamiento a una velocidad de rotación de 999 RPM (velocidad de vacío para el motor). Los resultados obtenidos se resumen en la Tabla 5.7.




Figura 5.10: (a) Rodamiento Craft 1207 EF-J31 y su (b) esquema referencial de dimensiones.

Tabla 5.6: Dimensiones de rodamiento de bola autoalineable Craft modelo 1207 EF-J31.

Diámetro del agujero (d)	35 mm
Diámetro exterior (D)	72 mm
Ancho (B)	17 mm
Diámetro de elemento rodante (b)	7,9 mm
Número de bolas (N_b)	2×16 bolas

Tabla 5.7: Frecuencias naturales para el rodamiento de bola autoalineable Craft modelo 1207 EF-J31 a una velocidad de giro de 999 RPM.

Frecuencia de pista externa (f_o)	227,06 Hz
Frecuencia de pista interna (f_i)	305,74 Hz
Frecuencia de elemento rodante (f_b)	55,15 Hz
Frecuencia de jaula de contención (f_c)	7,10 Hz

Capítulo 6

Base de datos experimental

En este capítulo se detalla la elaboración y características principales de la base de datos experimental desarrollada. Se describen de manera específica el montaje experimental realizado, la instrumentación utilizada para la adquisición de muestras y para la generación de las condiciones operativas de la máquina, y detalles técnicos sobre cada una de las condiciones registradas, incluyendo niveles de carga mecánica, tipos de alimentación y defectos estudiados. Asimismo, se ilustran ejemplos representativos de las señales recogidas en diferentes escenarios operativos y de fallo. Con ello se busca proporcionar una visión completa y autosuficiente del conjunto de datos que sustenta los análisis posteriores.

6.1. Montaje experimental

Tal como se presentó en el Capítulo 5, el sistema experimental principal consta de 4 equipos fundamentales: un motor de inducción trifásico de 1,5 kW (2 Hp) modificado para ser utilizado como máquinas de pruebas, una máquina de inducción trifásica (de características similares al motor) utilizada como generador de inducción autoexcitado acoplada al motor de pruebas mediante un sistema de eje rígido y acoples flexibles, un banco trifásico de capacitores (con valores de 50 μF , 100 μF y 200 μF por fase) dispuestos en conexión shunt al generador con el fin de autoexcitar la máquina, y banco trifásico de resistencias conmutables que permite, mediante la variación de carga eléctrica sobre el generador, modificar el par en el motor de pruebas. Este conjunto de equipos conforman por tanto el sistema básico que permite operar el banco de pruebas. Adicionalmente, se consideran sensores específicos para medir las señales de vibración y corriente a estudiar, equipos de adquisición y visualización de señales, un medidor de velocidad y distintas fuentes de alimentación para el motor.

A continuación, se presenta una lista con los equipos, sensores e instrumentos utilizados durante la toma de muestras realizada, los que a su vez se muestran en la Figura 6.1, correspondiente al montaje experimental:

1. Motor de pruebas.
2. Generador de inducción autoexcitado.
3. Acoplamiento Rexnord Omega ES10-R.
4. Acelerómetros piezoeléctricos CTC AC102-1A.

osciloscopio mediante las sondas diferenciales.

Por otro lado, las corrientes de estator se miden utilizando las sondas de corriente AC/DC AEMC SL261. Dada la limitación de canales en el osciloscopio, solo es posible registrar las señales de corriente para las fases A y B (canales 3 y 4, respectivamente). De esta forma, la corriente de la fase C se calcula considerando que la relación:

$$i_C = -(i_A + i_B), \quad (6.1)$$

siempre se cumple para motores de inducción trifásicos.

6.3. Definición de escenarios de pruebas

Con el objetivo de construir una base de datos amplia y representativa, capaz de reflejar distintos grados de falla en motores de inducción, se definen múltiples escenarios de operación para la toma de muestras. Estos escenarios varían en el tipo de alimentación eléctrica, el nivel de carga del motor y la condición operativa del sistema, considerando tanto la presencia como la severidad de fallas eléctricas y mecánicas. Como resultado, se generan un total de 900 muestras (cada una correspondiente a un estado de operación específico) compuestas por los registros de vibración y corriente trifásica adquiridos de forma simultánea, de las cuales 20 corresponden a la clase *Saludable*, 40 corresponden a la clase *Mecánica*, 280 pertenecen a la clase *Eléctrica* y 560 pertenecen a la clase *Mixta*.

6.3.1. Niveles de carga mecánica

Los distintos niveles de carga para el motor de pruebas se obtienen variando el valor de resistencia conmutable del banco trifásico de resistencias, junto con la conexión/desconexión en shunt del banco capacitivo (dispuesto en un valor fijo de $50\mu\text{F}$ por fase) a la máquina generadora. La configuración implementada permite obtener, de manera estable, cuatro niveles de carga para el motor de prueba, los que se describen a continuación:

1. El primer nivel de carga (T0) corresponde al funcionamiento “en vacío” del motor de pruebas, es decir, sin la conexión de los capacitores para la autoexcitación del generador. Con esta configuración se logra un nivel de carga para la máquina motriz del 4,78 % (0,68 Nm) respecto al valor de carga nominal (par nominal) del motor de pruebas original. Notar que el grado de carga para este punto de operación corresponde únicamente a las pérdidas intrínsecas del sistema motor-eje-generador (considerando las pérdidas propias del motor).
2. El segundo nivel de carga (T1) corresponde al funcionamiento “en vacío” del generador de inducción. Dicho de otra forma, en esta condición de operación existe autoexcitación del generador, sin embargo, este se encuentra girando en vacío, sin carga eléctrica acoplada. Notar que el generador de inducción se encuentra operando con un FP muy cercano a 0. Con esta configuración se logra un nivel de carga para la máquina motriz del 45,95 % (6,56 Nm) respecto al valor de carga nominal (par nominal) del motor de pruebas original.
3. El tercer nivel de carga (T2) corresponde a una operación “con carga” del generador, donde se alimenta una carga resistiva de $90,69\Omega$ por fase. Con esta configuración se obtiene un nivel de carga para la máquina motriz del 102,76 % (14,62 Nm) respecto al valor de carga nominal (par nominal) del motor de pruebas original.

4. El cuarto y último nivel de carga (T3) corresponde a otra operación “con carga” del generador de inducción, donde se alimenta una carga resistiva de $127,7\Omega$ por fase. Con esta configuración se obtiene un nivel de carga para la máquina motriz del 110,25 % (15,69 Nm) respecto al valor de carga nominal (par nominal) del motor de pruebas original.

Cabe destacar que todos los niveles de carga indicados son referenciados al valor de par nominal del motor de pruebas antes de ser modificado, por lo que, el nivel o grado de carga real visto por la nueva de la máquina será ligeramente diferente a lo indicado para cada punto de operación. A pesar de ello, dada la similitud de las máquinas, estos valores resultan ser un buen indicador para el grado de carga.

6.3.2. Tipos de alimentación para el motor de pruebas

Respecto a la alimentación eléctrica utilizada para impulsar el motor de pruebas, esta incluyó tres regímenes principales: alimentación trifásica balanceada, alimentación trifásica desbalanceada, y alimentación trifásica mediante un inversor de dos niveles.

La alimentación trifásica balanceada, por motivos de simplicidad en la implementación, se genera utilizando el simulador de red regenerativo. En general, y a diferencia de tensiones balanceadas generadas por este tipo de equipos, las tensiones de la red nunca son perfectamente balanceadas. Dicho esto, al utilizar el simulador de red para imponer tensiones balanceadas, se esconden los desbalances naturales que contiene la red. Si bien, dichos desbalances existen, cabe mencionar que son mínimos (menores incluso que los desbalances generados para la base de datos), por lo que resulta completamente válido sacrificar este comportamiento en pro de mejorar y simplificar la implementación y el método de toma de datos.

Por otro lado, con el uso del simulador de red regenerativo, fue posible implementar una alimentación trifásica desbalanceada, con desbalances de tensión del 1 %, 2 % y 3 %. Detalles específicos sobre el cálculo para los desbalances de tensión utilizados (magnitud y fase) se presentan en el Apéndice C.

Por último, la alimentación mediante inversor trifásico se realiza con tres módulos Imperix PEN8018 (uno por fase). Aunque este hardware permite operar como un convertidor NPC de tres niveles, en este trabajo se utiliza como un inversor de dos niveles, mediante el ajuste las señales portadoras en la modulación. Para el arranque del motor se implementa un control escalar en lazo abierto, orientado a limitar la corriente “inrush” en cada perna del convertidor. Además, se utiliza una estrategia de modulación por vector espacial (SVPWM), lo que optimiza el perfil armónico de la tensión de salida.

6.3.3. Defectos inducidos en el motor de pruebas

Para conseguir una base de datos completa y robusta, se inducen, en el motor, cuatro tipos de condiciones de salud distintas: condición sana o saludable, condición con falla de tipo eléctrica (cortocircuito entre vueltas en el devanado de estator), condición con falla de tipo mecánica (muesca en elemento rodante de un rodamiento) y condición con falla mixta, la cual corresponde a una combinación de las fallas ya mencionadas.

6.3.3.a. Defectos en los rodamientos de prueba

En cuanto a los defectos de tipo mecánico, en este trabajo se busca evaluar defectos catalogados como incipientes. Se indica en [23] que un defecto en un elemento rodante del rodamiento es catalogado como incipiente cuando el componente de degradación es menor al 12,5 % (razón entre el diámetro del defecto y el diámetro de la bola). En este sentido, la toma de muestras se lleva a cabo considerando 3 rodamientos distintos: un rodamiento saludable o sin fallas (*R00*); un segundo rodamiento con un orificio de 0,3mm (*R03*) de diámetro en uno de sus elementos rodantes, equivalente a un 3,80 % en su componente de degradación; y un tercer rodamiento con un orificio de 0,5mm (*R05*) de diámetro en uno de sus elementos rodantes, equivalente a un 6,33 % en su componente de degradación. Así, se logra emular distintos niveles de severidad para fallas mecánicas incipientes, permitiendo evaluar el comportamiento del sistema y la capacidad del modelo de diagnóstico propuesto.




Figura 6.2: Rodamientos con (a) orificio de 0,3mm de diámetro y con (b) orificio de 0,5mm de diámetro en un elemento rodante.

En la Figura 6.2 se aprecian los orificios realizados a los rodamientos ensayados, los cuales fueron elaborados a partir de brocas especiales. En [36] se describe con mayor detalle el procedimiento de elaboración de los orificios y la posterior evaluación de las firmas espectrales para los rodamientos en estudio.

6.3.3.b. Defectos en el devanado de estator del motor de pruebas

Como se menciona en el Capítulo 5, las fallas eléctricas se inducen a partir de la conexión de las derivaciones instaladas en el nuevo motor de pruebas. Según se menciona en [23], una falla en el devanado del estator es considerada incipiente si el cortocircuito involucra una componente de degradación del 3 % o menos del total de las vueltas por fase. Así, las fallas de cortocircuito entre vueltas son inducidas mediante la conexión del terminal inicial del devanado (*U1*, *V1* o *W1*) con cualquiera de las derivaciones disponibles de su misma fase. De esta forma, se obtiene la Tabla 6.1 donde se muestra el resumen de los cortocircuitos inducidos para cada uno de los devanados, en función de la derivación conectada o en función de la componente de degradación.

Tabla 6.1: Cortocircuitos inducidos en cada fase del devanado de estator.

Fase	Número de derivación conectada	Valor en componente de degradación
U	2 - 5 - 8 - 11 - 18	0,64 % - 1,60 % - 2,56 % - 3,53 % - 5,76 %
V	2 - 5 - 8 - 11 - 18	0,64 % - 1,60 % - 2,56 % - 3,53 % - 5,76 %
W	2 - 5 - 8 - 18	0,64 % - 1,60 % - 2,56 % - 5,76 %

Se verifica que las fallas eléctricas inducidas corresponden, en su mayoría, a fallas de tipo incipiente, teniendo solo cuatro fallas de tipo avanzadas (dos para la fase U y dos para la fase V) con valores del 3,53 % y 5,76 % en su componente de degradación.

Cabe mencionar que, para evitar daños permanentes en el motor y asegurar una operación segura durante los ensayos, se incluye un reostato de resistencia variable a modo de resistencia de falla. Con el uso del reostato, es posible regular la magnitud de la corriente de falla, minimizando el riesgo de sobrecalentamientos localizados y garantizando un régimen de operación controlado. Así, se reproducen condiciones de falla de manera realista, sin comprometer la vida útil del motor ni la estabilidad de las mediciones realizadas en el banco de pruebas.


6.4. Forma de onda de las señales registradas

Tal como se indicó en capítulos previos, una correcta clasificación y detección de fallas en motores de inducción requiere del registro preciso de las señales temporales asociadas al sistema en estudio. La información contenida en dichas formas de onda constituye la base para la extracción de características relevantes, las que permiten un diagnóstico confiable de la condición del motor.


Con el propósito de visualizar adecuadamente las señales adquiridas durante la elaboración de este trabajo, en las Figuras 6.3, 6.4, 6.5 y 6.6 se presentan formas de onda temporales representativas de señales de vibración y corriente. Las condiciones ilustradas fueron escogidas para abarcar la totalidad de los grupos de carga mecánica, los distintos tipos de alimentación eléctrica utilizados, las principales configuraciones de fallas mecánicas en elementos rodantes y los diferentes niveles de severidad en fallas de cortocircuito entre vueltas, en un número reducido de gráficas. Esta selección permite evidenciar las variaciones que presentan las señales bajo distintos escenarios operativos.

Del análisis visual de las gráficas, se observa que tanto la amplitud de las señales de vibración como de corriente presentan variaciones significativas entre las distintas condiciones de operación, lo cual resulta coherente considerando que cada grupo de señales corresponde a un escenario de operación diferente.

En el caso de las señales de vibración, estas se presentan en dos escalas de medida. La primera corresponde a voltaje (V), puesto que todas las señales de vibración fueron adquiridas mediante puntas de tensión y almacenadas con el uso de un osciloscopio. La segunda corresponde a unidades de aceleración relativa g , donde $1g$ representa la aceleración gravitacional estándar en la superficie terrestre, con un valor aproximado de $9,80665m/s^2$. Esto debido a que el acelerómetro utilizado proporciona una relación directa entre la señal de salida en mV y la aceleración en g . Dicho esto, se aprecia que los niveles de aceleración registrados rondan el orden de los $0,4g$ a $0,6g$ peak para las vibraciones del soporte, y de los $0,1g$ a $0,3g$ peak para las vibraciones del motor.



(a) Vibraciones de soporte y motor.




(b) Corrientes de las fases A, B y C.

Figura 6.3: Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación balanceada, falla eléctrica severa en la fase A y carga del 45,95 % del par nominal del motor.


Por otro lado, las señales de corriente fueron medidas directamente en amperios (A), mediante el uso de puntas de corriente conectadas al osciloscopio. Los registros obtenidos muestran valores máximos comprendidos entre 3,0A y 5,0A peak, dependiendo de la condición de operación correspondiente.

En términos generales, las mediciones realizadas en los soportes presentan una mayor amplitud en comparación con aquellas obtenidas directamente en el motor. Este comportamiento se atribuye a que los soportes concentran una mayor proporción de las vibraciones mecánicas generadas en el conjunto de ensayo. Esta situación está directamente relacionada con la metodología implementada para facilitar el reemplazo sistemático de los rodamientos, la cual requiere la existencia de una leve holgura entre el eje y el rodamiento de prueba. Si bien dicha holgura puede incrementar la magnitud de las vibraciones registradas, su incorporación resulta indispensable, dado que permite realizar los cambios de rodamiento con los instrumentos disponibles en el laboratorio para el desarrollo del trabajo experimental.

Asimismo, la menor amplitud observada en las señales de vibración en el motor, se explica por las modificaciones estructurales realizadas al banco de pruebas y a la incorporación de una plataforma mecanizada destinada a dar soporte y altura al motor de pruebas. Esta intervención contribuye de manera efectiva a mitigar la generación y propagación de



(a) Vibraciones de soporte y motor.




(b) Corrientes de las fases A, B y C.

Figura 6.4: Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación desbalanceada del 3 %, sin fallas y carga del 4,78 % del par nominal del motor.


vibraciones indeseadas en el sistema.

Adicionalmente, al comparar las señales de vibración en las Figuras 6.3a, 6.4a, 6.5a y 6.6a, se advierte que las amplitudes en las dos últimas son considerablemente mayores que en las dos primeras. Esta diferencia es particularmente notoria en el sensor ubicado en el soporte. La razón de este comportamiento radica, principalmente, en la ausencia de lubricación en los rodamientos con fallas (rodamientos *R03* y *R05*). Si bien un rodamiento en operación debe contar con una adecuada lubricación, se optó por omitirla en los casos con defectos mecánicos incipientes, ya que el uso de lubricantes podría atenuar o enmascarar las firmas vibracionales asociadas al defecto. A pesar de que esta práctica introduce en las señales ruido armónico proveniente de otros elementos del rodamiento, se considera una opción válida, teniendo en cuenta que las señales serán posteriormente procesadas antes de su uso en el diagnóstico.

Respecto a las señales de corriente, cabe destacar que, con el fin de facilitar su visualización, las figuras muestran únicamente una ventana de tiempo de 0,2 segundos para cada señal, a pesar de que la duración total de cada registro es de 1 segundo. Por otro lado, se observa que, a medida que aumenta la carga mecánica, también se incrementa la magnitud de las corrientes, lo cual concuerda con el comportamiento esperado del motor. En relación con el tipo de alimentación utilizada, las diferencias entre las condiciones con fuentes balanceadas y desbalanceadas no resultan evidentes a simple vista, debido al bajo grado de desbalance



(a) Vibraciones de soporte y motor.



(b) Corrientes de las fases A, B y C.


Figura 6.5: Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación desbalanceada del 1 %, falla incipiente en la fase C, muesca de 5mm en el elemento rodante del rodamiento, y carga del 102,76 % del par nominal del motor.

aplicado (máximo de 3 %). No obstante, en la Figura 6.6b, correspondiente a una condición de operación con alimentación mediante inversor (VSI), se aprecia levemente la presencia de pequeños armónicos superpuestos a las señales de corriente, los cuales son característicos de este tipo de fuente.


6.5. Observaciones y limitaciones de la base de datos

Durante la recolección de datos se detectaron varias fuentes de variabilidad que conviene considerar. La holgura necesaria para el reemplazo rápido de rodamientos aumentó el nivel de ruido en las señales de vibración. Además, el número de muestras para las condición saludable y para las fallas mecánicas es mucho menor que las muestras para fallas eléctricas o fallas mixtas, pudiendo limitar el correcto análisis de las condiciones.

Como comentario adicional, se sugiere incrementar el número de repeticiones por condición, considerar sensores adicionales de sonido, temperatura o flujo magnético, de modo de enriquecer la caracterización de las fallas. Asimismo, la inclusión de un equipo más robusto para lograr más niveles de carga mecánica, y mejorar la cantidad de muestras registradas.



(a) Vibraciones de soporte y motor.



(b) Corrientes de las fases A, B y C.

Figura 6.6: Formas de onda de (a) vibraciones y (b) corrientes, bajo operación con alimentación mediante inversor, falla incipiente en la fase B, muesca de 3mm en el elemento rodante del rodamiento, y carga del 110,25 % del par nominal del motor.

Capítulo 7

Resultados y análisis

El presente capítulo expone y analiza de manera sistemática los resultados obtenidos tras entrenar y evaluar los clasificadores SVM diseñados para diagnosticar fallas en motores de inducción trifásicos. Su propósito central es cuantificar el aporte relativo de cada fuente de información (corrientes de estator y señales de vibración) y determinar una configuración que permita clasificar las fallas de forma eficaz teniendo en cuenta aspectos como el desempeño, cantidad de instrumentación utilizada y tiempo de cómputo. Para ello, se presentan cinco variantes de modelo que difieren únicamente en el vector de características suministrado, manteniéndose invariables la estrategia de preprocesamiento, entrenamiento y prueba.

Además se detalla parte del preprocesamiento de las señales medidas, desde la inclusión de una estrategia de aumento de datos mediante la inyección controlada de ruido gaussiano de baja amplitud, hasta la extracción y representación visual de las características extraídas, tanto en el dominio del tiempo como en el dominio tiempo-frecuencia, evaluando su aporte a los modelos de clasificación.

7.1. Señales con ruido sintético de tipo Gaussiano

Durante la elaboración de la base de datos, se identifica una clara desproporción en la cantidad de registros entre clases. Esta desproporción representa una limitación importante al momento de utilizar modelos de clasificación, puesto que dificulta la representación adecuada, dentro del conjunto de datos, de configuraciones de fallas experimentales con frecuencia de aparición significativamente menor respecto de otras. Para mitigar este defecto, se opta por implementar una estrategia de aumento de datos mediante la incorporación de ruido sintético en las señales medidas.


En particular, se generan versiones modificadas de las señales originales mediante la adición de ruido gaussiano blanco de media cero y desviación estándar controlada, correspondiente al 1 %, 2 % y 3 % de la desviación estándar de cada señal individual. Este procedimiento se aplica de manera independiente a cada una de las señales registradas, generando muestras nuevas que siguen la relación:

$$\tilde{x}(t) = x(t) + \epsilon(t), \quad \text{con } \epsilon(t) \sim \mathcal{N}\left(0, \left(\frac{p}{100} \cdot \sigma_x\right)^2\right) \quad (7.1)$$


Donde:

- $\tilde{x}(t)$: Señal con ruido.
- $x(t)$: Señal original.
- $\epsilon(t)$: Ruido gaussiano.
- $\mathcal{N}(0, (\cdot)^2)$: Distribución normal con media 0 y varianza indicada.
- p : Porcentaje de ruido (1, 2 o 3).
- σ_x : Desviación estándar de la señal original.

Esta técnica permite introducir perturbaciones controladas que preservan la estructura principal de la forma de onda, simulando condiciones de interferencia similares a las que se pueden observar en entornos reales. Así, con la incorporación de las señales ruidosas se amplía la base de datos original sin modificar las etiquetas de clase, se incrementa el número de muestras pertenecientes a las clases minoritarias y se consolida un conjunto de datos más robusto para las etapas posteriores de procesamiento. Además, la inclusión de ruido sintético refuerza la capacidad de generalización del modelo, pues lo obliga a identificar patrones distintivos de cada condición de operación y a diferenciar entre clases incluso cuando las señales presentan perturbaciones reales, reduciendo así la tendencia al sobreajuste y mejorando su rendimiento frente a datos no observados.



(a) Vibraciones de soporte y motor.



(b) Corrientes de las fases A, B y C.

Figura 7.1: Formas de onda de (a) vibraciones y (b) corrientes, con ruido gaussiano del 3 % de su desviación estándar, bajo operación con alimentación balanceada, falla eléctrica severa en la fase A, y carga del 45,95 % del par nominal del motor.

Cabe destacar que la generación de señales con ruido sintético a partir de los registros existentes no altera la proporción relativa entre clases; sin embargo, incrementa de forma absoluta la cantidad de muestras disponibles para las clases minoritarias, tanto en los conjuntos de entrenamiento como en los conjuntos de prueba, otorgándoles una mayor representatividad. A modo de ejemplo, si la clase *Saludable* (clase con menor cantidad de muestras) contaba con 14 instancias para entrenamiento (70 %) y 6 para prueba (30 %), tras aplicar la estrategia de aumento de datos se dispone de 56 y 24 muestras, respectivamente, lo que permite al modelo capturar la variabilidad de dicha clase.

Con el fin de visualizar la diferencia entre las señales originales y aquellas con ruido, la Figura 7.1 muestra las formas de onda resultantes tras la adición de ruido Gaussiano del 3 % de la desviación estándar de cada señal, para la condición de operación mostrada en la Figura 6.3. En las gráficas se aprecia claramente la distorsión introducida por efecto del ruido, especialmente en las señales de corriente.

En particular, al comparar la forma de onda de las señales originales (Figura 6.3) con las señales con ruido, se observa que su comportamiento general se mantiene. Asimismo, se destaca que el rango de amplitudes para cada señal también se conserva, alcanzando un valor aproximado de $\pm 0,6 g$ peak para las vibraciones en el soporte, un valor de $\pm 0,2 g$ peak para las vibraciones en el motor, y un valor de $\pm 3,1 A$ peak para las corrientes, de ambos grupos. Esto confirma la eficacia del enfoque adoptado para enriquecer la base de datos sin comprometer la integridad de las señales ni alterar significativamente sus propiedades.

7.2. Visualización y validación de las características seleccionadas

Una adecuada elección de características representativas permite obtener diagnósticos precisos y acertados sobre el estado de la máquina. De esta forma, resulta de interés visualizar cómo las características seleccionadas en este trabajo se relacionan con las clases del conjunto de datos y con los modelos de clasificación. Así, es posible mostrar dicha relación de forma gráfica, obteniendo el comportamiento de la distribución de clases en función de todas las características calculadas, tanto en el dominio del tiempo como en el dominio del tiempo-frecuencia.

Para esto, se recurre a una técnica estadística de descomposición lineal de datos conocida como Análisis de Componentes Principales (PCA, por sus siglas en inglés). El PCA es comúnmente aplicado en aprendizaje automático, análisis exploratorio de datos y comprensión de información. Se utiliza para reducción de dimensionalidad y permite transformar un conjunto de variables posiblemente correlacionadas en un nuevo conjunto de variables ortogonales llamadas componentes principales. Estas componentes están ordenadas según la cantidad de varianza que explican los datos originales, permitiendo representar la información más relevante del conjunto de datos en un espacio de menor dimensión, sin perder las características esenciales para su análisis.

Cabe destacar, que para los análisis presentados en esta sección, solo se toman en cuenta las características extraídas de las señales originales, es decir, no se toman en cuenta las características extraídas a partir de las señales con ruido Gaussiano incluido. Esto para no saturar con información redundante las gráficas y conseguir apreciar la distribución de clases de forma clara.

7.2.1. Características en el dominio del tiempo

Dada la cantidad de características en el dominio del tiempo utilizadas durante este trabajo (nueve características en total) resulta imposible visualizar la distribución y agrupación de clases sin aplicar la técnica antes mencionada, puesto que su representación real sería en nueve dimensiones (una por cada característica). Así, mediante PCA se puede representar esta distribución de clases en mapas de dos y tres dimensiones, tal como se observa en la Figura 7.2. Cabe destacar que dichas características fueron extraídas de las dos señales de vibración (en soporte y en motor) y de la magnitud del fasor espacial de corriente, el cual fue calculado a partir de las señales de corriente registradas durante los ensayos.




Figura 7.2: Descomposición PCA en (a) dos dimensiones y (b) tres dimensiones para las características en el dominio del tiempo utilizadas.

Del análisis visual de la Figura 7.2a, correspondiente a la proyección de las características en el dominio del tiempo en un espacio bidimensional definido por los primeros dos componentes principales (PC1 y PC2), se aprecia cierta separabilidad entre las clases *Eléctrica* y *Mixta*, las cuales tienden a ocupar regiones diferenciadas del espacio proyectado, entrecruzándose en la zona central del gráfico. En cuanto a las clases *Mecánica* y *Saludable*, estas presentan un mayor grado de superposición con el resto de las categorías, observándose pequeñas agrupaciones de entre 6 y 8 muestras distribuidas en distintas zonas del plano. Este comportamiento dificulta una distinción clara entre estas dos últimas clases en el espacio bidimensional. Si bien, este gráfico evidencia que las características temporales contienen información útil para fines de clasificación, su capacidad discriminante puede resultar limitada para ciertas categorías si se considera únicamente esta representación en dos dimensiones.

Por otro lado, la representación tridimensional mostrada en la Figura 7.2b, que incorpora el tercer componente principal (PC3), permite observar una separación espacial más clara entre las clases. Al compararla con la proyección bidimensional, se mantiene el patrón previamente descrito: una relativa separabilidad entre las clases *Eléctrica* y *Mixta*, con una tendencia al entrecruzamiento en la región central del gráfico. Sin embargo, en cuanto

a las clases *Mecánica* y *Saludable* exhiben una separación particular respecto a las otras dos clases. Además, en la representación tridimensional se observa que todas las clases tienden a formar agrupaciones con una disposición tipo líneas diagonales que atraviesan el espacio desde la esquina superior izquierda hacia la inferior derecha. Aunque estas formaciones no permiten identificar una separación completamente nítida entre las clases a simple vista, el patrón observado sugiere que la combinación de información temporal con características provenientes de otros dominios podría contribuir significativamente a mejorar la capacidad de separación entre condiciones de operación.

7.2.2. Características en el dominio tiempo-frecuencia

Además de las características en el dominio del tiempo, también se seleccionan cinco características en el dominio tiempo-frecuencia como parte de los indicadores de entrada para los modelos de clasificación. En específico, se utilizan características tipo wavelet, obtenidas a partir de la Transformada Wavelet Discreta (DWT, por sus siglas en inglés). En este contexto, la selección de dichas características implica el cálculo de los niveles de descomposición de cada señal registrada, el cálculo de la energía asociada a cada nivel de descomposición y finalmente, la identificación de aquel nivel que concentra la mayor proporción de energía de la señal, esto con el fin de extraer los indicadores más representativos del conjunto de datos.

7.2.2.a. Cálculo de niveles de descomposición

En primer lugar, para realizar la DWT, se debe calcular la cantidad de niveles de descomposición. Así, mediante la relación definida en la Ecuación (3.12), considerando una frecuencia de muestreo de $f_s = 7680\text{Hz}$ y una frecuencia de alimentación de $f_1 = 50\text{Hz}$, se obtiene:

$$\text{int} \left(\frac{\log \left(\frac{7680}{50} \right)}{\log(2)} \right) + 2 = 9$$

De esta manera, y siguiendo con el criterio de selección óptima para la cantidad de niveles, se utiliza una descomposición de 9 niveles. Además, se selecciona la función wavelet Daubechies de orden 8 (Daubechies-8) como wavelet madre, debido a su adecuada capacidad de localización temporal y frecuencial.

Tabla 7.1: Descomposición en frecuencia para DWT de nueve niveles.

Nivel de Detalle	Rango de Frecuencia (Hz)
1	1920 - 3840
2	960 - 1920
3	480 - 960
4	240 - 480
5	120 - 240
6	60 - 120
7	30 - 60
8	15 - 30
9	7,5 - 15

A partir de los parámetros indicados, se aplica la DWT a cada una de las señales de la

base de datos, obteniendo su representación por niveles según los rangos de frecuencia asociados a cada nivel de detalle, presentados en la Tabla 7.1.

7.2.2.b. Elección de niveles de mayor energía

La elección de los niveles de mayor energía no es un proceso trivial, puesto que esta influye directamente sobre el rendimiento del clasificador. Dicha elección se fundamenta en la premisa de que una señal (o porción de señal) con más energía aporta una mayor cantidad de información, ya sea en los dominios temporal y frecuencial. De esta forma, al escoger el nivel con mayor energía, se garantiza que las características extraídas capturen la información más relevante para la detección de fallas, reforzando así la robustez y el rendimiento del modelo de clasificación.




Figura 7.3: Reconstrucción de los niveles de detalle de la DWT para las señales de (a) vibración de soporte y (b) corriente de fase A, bajo operación con alimentación balanceada, falla incipiente en la fase A, muesca de 3mm en el elemento rodante del rodamiento, y carga del 4,78 % del par nominal del motor.

A partir de lo anterior, para identificar el nivel de mayor energía de cada señal se emplea la reconstrucción de los niveles de detalle de la DWT. A modo de ejemplo, en la Figura 7.3 se presenta dicha reconstrucción aplicada a la señal de vibración en el soporte y a la señal de corriente de la fase A, correspondientes a una condición de operación con alimentación balanceada, falla incipiente en la fase A, muesca de 3mm en el elemento rodante del rodamiento, y carga del 4,78 % del par nominal del motor. Mediante la inspección de los diferentes niveles de detalle reconstruidos, se observa que para la señal de vibración el nivel de mayor energía corresponde al detalle 1 (D1), dado que su reconstrucción al-

canza amplitudes del orden de $\pm 0,08$. Por otro lado, en la señal de corriente, el nivel más energético se identifica en el detalle 7 (D7), cuya reconstrucción alcanza amplitudes que superan los ± 3 .

Dicho esto, la selección de los niveles *D1* para vibraciones y *D7* para corrientes se justifica si se considera el espectro de frecuencias característico de cada tipo de señal. En efecto, el nivel *D7* abarca el rango de $30Hz$ a $60Hz$, precisamente la banda donde se sitúa la componente fundamental de la corriente ($50Hz$) para todas las mediciones. Por ende, resulta natural que en dicho nivel se concentre la mayor parte de la energía eléctrica registrada y, en consecuencia, que la reconstrucción del nivel *D7* presente la amplitud predominante.

Por otro lado, la totalidad de las fallas analizadas en este trabajo corresponden a fallas incipientes cuyas firmas espectrales de vibración se manifiestan, según la literatura, en regiones de alta frecuencia (cercano a los $2kHz$). De esta manera, se destaca que el nivel *D1* de la descomposición cubre el rango de $1920Hz$ a $3840Hz$, rango donde se espera que aparezcan estos componentes de alta frecuencia. Ratificando de esta manera, la elección del nivel *D1* como nivel de detalle con mayor energía en la descomposición de las señales de vibración.

Para complementar el análisis anterior, se verifica el nivel de mayor energía para cada una de las señales disponibles en la base de datos, agrupándolos en histogramas que muestran la frecuencia de aparición de cada nivel de detalle más energético. Así, si los niveles propuestos anteriormente tienen una frecuencia de aparición mucho mayor que cualquier otro, es posible validar, paralelamente, el uso generalizado de los niveles *D1* (en vibraciones) y *D7* (en corrientes) para la extracción de características wavelet.




Figura 7.4: Frecuencia de aparición de los niveles más energéticos para las señales de vibración (a) en el soporte y (b) en el motor.

En la Figura 7.4 se presentan los histogramas correspondientes a las señales de vibración registradas tanto en el soporte como en el motor. Para las vibraciones medidas en el soporte (Figura 7.4a), el nivel de detalle 1 (*D1*) exhibe la mayor frecuencia de aparición como nivel de mayor energía. En cambio, el histograma para las vibraciones captadas sobre el motor (Figura 7.4b) muestra una disminución notable en la frecuencia de aparición de los niveles de mayor energía, a pesar que *D1* sigue siendo el nivel de detalle predominante. Esta atenuación se debe, principalmente al acoplamiento sobredimensionado utilizado en el banco de pruebas, que actúa como un filtro pasa-bajos mecánico, amortiguando las vibraciones de alta frecuencia generadas por los defectos incipientes en el rodamiento antes




Figura 7.5: Frecuencia de aparición de los niveles más energéticos para las señales de corriente (a) en fase A, (b) en fase B y (c) en fase C.

de ser captadas por el sensor. Este fenómeno constituye un aspecto relevante e interesante de análisis en trabajos futuros, ya sea mediante la reubicación de los sensores para mejorar la sensibilidad a dichas excitaciones o la optimización de la rigidez del acople.

Por otro lado, la Figura 7.5 muestra los histogramas correspondientes a las señales de corriente para las tres fases (A, B y C). En este caso, se aprecia de manera consistente que el nivel de detalle 7 (*D7*) corresponde al de mayor frecuencia de aparición, y por lo tanto, el de mayor energía.

Cabe destacar que el análisis anterior omite deliberadamente el nivel de aproximación 9 (*A9*), puesto que este se encuentra alejado de las bandas de interés para el diagnóstico de fallas analizadas. Dicho nivel cubre el rango de frecuencias entre $0Hz$ y $7,5Hz$, por lo que capta únicamente componentes de muy baja frecuencia cuya aporte al proceso de clasificación resulta limitada. A pesar de esto, la presencia recurrente del nivel *A9* en los histogramas de todas las señales sugiere la existencia de un contenido continuo o de muy baja frecuencia durante las mediciones, posiblemente causado por componentes continuas en las señales o por el ajuste de los sensores al momento de las mediciones. Si bien, la existencia de esta componente en los histogramas no implica necesariamente un error durante el registro de muestras, este nivel es poco relevante para el diagnóstico de las fallas en estudio, por lo que sería de interés evaluar la inclusión un filtrado que elimine componentes de baja frecuencia para concentrar el análisis en las bandas que realmente aportan información.

En general, los histogramas obtenidos permiten corroborar mediante un enfoque estadístico

y práctico la validez del uso generalizado de los niveles $D1$ para vibraciones y $D7$ para corrientes, como referencia para la extracción de características tipo wavelet a lo largo de todas las condiciones de operación registradas en la base de datos.

7.2.2.c. Visualización de características en el dominio tiempo-frecuencia

A partir del procedimiento mencionado, se logra identificar el nivel más energético para cada grupo de señales. Este permite calcular las características wavelet, anteriormente descritas en el Capítulo 3.

Así, de manera homóloga a lo descrito para las características estadísticas, se tiene que la cantidad de características wavelet utilizadas en este trabajo (cinco en total) imposibilitan la visualización de las clases sin aplicar PCA. En este caso la visualización real sería solo de cinco dimensiones (una por cada característica), sin embargo, siguen siendo más dimensiones que las máximas que se pueden visualizar. De esta manera, aplicando PCA se logra representar la distribución de clases con características wavelet en mapas de dos y tres dimensiones, tal como se muestra en la Figura 7.6. Cabe destacar estas características, a diferencia de las características en el dominio del tiempo, fueron extraídas a partir de la DWT aplicada directamente a las señales medidas.




Figura 7.6: Descomposición PCA en (a) dos dimensiones y (b) tres dimensiones para las características en el dominio del tiempo-frecuencia utilizadas.

En la Figura 7.6a, correspondiente a la proyección bidimensional de las características wavelet utilizando los dos primeros componentes principales (PC1 y PC2), se observa una distribución más estructurada y compacta de las clases en comparación con la obtenida a partir de las características estadísticas. En particular, las clases *Eléctrica* y *Mixta* presentan una notable separabilidad, ubicándose en regiones opuestas del plano, con una clara delimitación espacial y una leve tendencia a converger hacia la zona central del gráfico. En contraste, las clases *Mecánica* y *Saludable* manifiestan una mayor superposición respecto de las demás, lo que dificulta identificar agrupaciones globales definidas que permitan se-

pararlas de manera evidente. No obstante, es posible distinguir agrupamientos parciales para estas dos clases, lo que sugiere cierto grado de organización interna. En conjunto, el comportamiento observado en esta figura indica que las características wavelet, a pesar de ser menos numerosas, capturan patrones relevantes que permiten lograr una discriminación efectiva entre ciertas categorías, en particular aquellas asociadas a fallas combinadas o de origen eléctrico.

Al incorporar el tercer componente principal en la representación tridimensional mostrada en la Figura 7.6b, se refuerzan parcialmente las observaciones previas, evidenciándose una mayor diferenciación entre clases. Las clases *Eléctrica* y *Mixta* mantienen agrupaciones bien definidas, separadas del resto de las categorías. Por su parte, las clases *Mecánica* y *Saludable* continúan mostrando un grado significativo de solapamiento, sin que se observe una mejora sustantiva respecto a la representación bidimensional. A diferencia de lo observado en la proyección tridimensional de las características del dominio temporal, esta visualización no revela patrones geométricos distintivos entre las clases. En definitiva, la representación 3D permite confirmar que algunas clases presentan una capacidad representacional sólida, lo que sugiere que la combinación de este conjunto de características con otros dominios (como los ya analizados) podría enriquecer de manera sustancial los modelos de clasificación multiclase de fallas en motores eléctricos. Cabe destacar, además, que la proyección mediante PCA no representa con exactitud el comportamiento completo del espacio de características original, por lo que los resultados visuales deben ser considerados como una aproximación cualitativa del grado de separabilidad entre clases.

7.3. Resultados de los clasificadores entrenados

Para evaluar el desempeño de las características extraídas, se entrenaron cinco clasificadores SVM, cada uno utilizando una combinación distinta de señales medidas. En todos los casos se consideran todas las condiciones de operación disponibles en la base de datos, incluyendo las señales con ruido artificialmente incorporado. Si bien cada condición incluye cinco señales por defecto (vibraciones en soporte y motor, y corrientes en las tres fases), cada clasificador fue entrenado utilizando un subconjunto específico de estas. Esta estrategia permite analizar de manera comparativa el aporte de cada tipo de señal al rendimiento general del sistema.

Cabe mencionar que todos los modelos son entrenados siguiendo un procedimiento común. Los datos son divididos de forma estratificada en proporción 70/30 entre entrenamiento y prueba, y posteriormente estandarizados para evitar que el modelo de más peso a las características que tienen valores numéricamente más grandes. El ajuste de hiperparámetros se realiza mediante búsqueda por rejilla con validación cruzada estratificada de cinco pliegues, incorporando balanceo automático de clases para compensar el desbalance en la distribución de etiquetas. Asimismo, se utiliza la métrica F1-score macro como criterio de optimización (métrica objetivo), puesto que esta garantiza un equilibrio efectivo entre la reducción de falsos positivos y falsos negativos, evaluando por igual todas las clases, incluso en presencia de clases desbalanceadas. Además, en todos los modelos se establece un criterio tipo *arg max* para la asignación de la clase sobre el conjunto de prueba, es decir, cada muestra se asigna con la clase cuya probabilidad es la más alta, lo que resulta equivalente a utilizar un umbral de 0,5 para asignar una clase en un clasificador binario o en un esquema de Uno contra Todos (OvA, por sus siglas en inglés). Por último, se procura utilizar la misma semilla aleatoria durante la partición de los datos y la validación cruzada,

esto con el fin de garantizar la reproducibilidad de los resultados y asegurar condiciones comparables entre los distintos clasificadores entrenados.

7.3.1. Clasificador 1: todas las señales medidas

El primer clasificador se entrena utilizando la totalidad de las señales medidas para cada condición de operación: vibraciones en el soporte y el motor, junto con las corrientes de las tres fases. Este enfoque establece un punto de comparación, al considerar el máximo de información posible contenida en la base de datos.

Los resultado del ajuste de hiperparámetros para el modelo entrenado se resumen en la Tabla 7.2. Este modelo utiliza como núcleo una Función de Base Radial (RBF, por sus siglas en inglés), un parámetro de penalización $C = 1000$, un parámetro de ancho de banda $\gamma = 0.03125$ y un ajuste balanceado de pesos para compensar el desbalance entre clases. El proceso de ajuste alcanza una puntuación de 0.9506 para la métrica objetivo (F1-score macro) en un tiempo total de entrenamiento de 3274 segundos (55 minutos aproximadamente).

Tabla 7.2: Resumen de hiperparámetros y resultados del entrenamiento del clasificador 1 (todas las señales).

Parámetro	Valor
C	1000
Peso de clases ('class_weight')	balanceado
γ	'escalado': 0.03125
Tipo de núcleo ('kernel')	rbf
Métrica objetivo	F1-score macro
Mejor puntuación obtenida	0.950615
Tiempo de entrenamiento (segundos)	3274.32

La matriz de confusión obtenida a partir del conjunto de prueba se muestra en la Figura 7.7, la cual refleja un comportamiento altamente satisfactorio para el modelo 1. En la clase *Eléctrica* no se comete ningún error de predicción. En las clases *Mecánica* y *Mixta* el modelo comete ligeros errores, confundiendo muestras de ambas clases entre sí. Por último, en la clase *Saludable* se observan tres muestras clasificadas erróneamente como *Eléctrica*.

Los resultados muestran un alto nivel de generalización del modelo entrenado, donde el error más significativo ocurre en la clase *Saludable*, cuya baja representatividad en el conjunto de prueba incrementa la probabilidad de fallo. Asimismo, la ligera tendencia a confundir las clases *Mecánica* y *Mixta* sugiere la conveniencia de ajustar la frontera de decisión entre ellas, ya sea mediante un reajuste de hiperparámetros o mediante la inclusión de características que acentúen sus diferencias.

Junto a lo anterior, en la Tabla 7.3, se muestra el reporte de clasificación para el mismo conjunto de prueba. En este se indica que las clases *Eléctrica*, *Mixta* y *Saludable* alcanzan una precisión perfecta, indicando que no existen falsos positivos para dichas clases, mientras que la clase *Mecánica* registra un valor de 0.90, señalando la asignación de bastantes falsos positivos, a comparación de las demás. Por otro lado, la sensibilidad de las clases *Eléctrica*, *Mecánica* y *Mixta* es bastante alta (valores de 1.00, 0.98 y 0.99 respectivamente), mientras que la clase *Saludable* tiene un valor de 0.88, lo que indica que una parte significativa de sus muestras reales se clasifica incorrectamente.




Figura 7.7: Matriz de confusión obtenida para el clasificador 1 (todas las señales).

Respecto al F1-score, el valor de 1.00 para las clases *Eléctrica* y *Mixta* evidencia un desempeño casi ideal para estas, en contraste con los 0.94 de *Mecánica* y 0.93 de *Saludable*. Esto sugiere que es posible refinar la frontera de decisión para mejorar la detección de dichas clases, sin sacrificar precisión. Cabe destacar que, el elevado soporte de clases como *Mixta* (672) y *Eléctrica* (341) aporta estabilidad a sus métricas, mientras que un bajo soporte respecto al total, como en *Saludable* (24) y en *Mecánica* (48), puede aumentar la variabilidad de sus resultados.

En general, el promedio macro de 0.97 para F1-score confirma un rendimiento uniforme y balanceado en cuanto a la tasa de falsos positivos y falsos negativos para todas las clases, mientras que el promedio ponderado de 0.99 (en esta misma métrica) demuestra la robustez de los resultados para las clases mayoritarias. Finalmente, la precisión global de 0.99 y la precisión global balanceada de 0.96 reafirman la solidez del modelo, demostrando que el sesgo generado por las clases con mayor soporte respecto a las con menor soporte, tiene poca influencia en el comportamiento general del modelo.

Tabla 7.3: Reporte de clasificación en el conjunto de prueba para el clasificador 1 (todas las señales).

Clase	Precisión	Sensibilidad	F1-score	Soporte
Eléctrica	0.99	1.00	1.00	341
Mecánica	0.90	0.98	0.94	48
Mixta	1.00	0.99	1.00	672
Saludable	1.00	0.88	0.93	24
promedio macro	0.97	0.96	0.97	1085
promedio ponderado	0.99	0.99	0.99	1085
Precisión global				0.99
Precisión global balanceada				0.96

Complementariamente, la Figura 7.8 ilustra las curvas ROC para cada clase cuando se emplean todas las señales disponibles. En los cuatro casos el área bajo la curva (AUC)

alcanza el valor máximo de 1.00, lo que indica que el clasificador separa con precisión perfecta los verdaderos positivos de los falsos positivos a lo largo de todo el rango de umbral de decisión. La traza vertical presente en el tramo inicial demuestra que, incluso con tasas de falsos positivos cercanas a cero, se obtiene una sensibilidad próxima al 100 %. Asimismo, la superposición casi exacta de las curvas revela un rendimiento uniforme entre clases, donde ninguna presenta degradación en su capacidad discriminativa ni sufre el efecto de umbrales de clasificación desalineados. Cabe destacar que la línea diagonal punteada representa a un clasificador aleatorio, por lo que cualquier sistema que se ubique sobre esa recta ofrece un poder predictivo superior al azar.




Figura 7.8: Curvas ROC para el clasificador 1 (todas las señales).

En conjunto, estos resultados evidencian que el clasificador entrenado con la totalidad de las señales disponibles ofrece un rendimiento sobresaliente, sirviendo como modelo de referencia frente a las demás configuraciones.

7.3.2. Clasificador 2: solo vibraciones

Este segundo modelo se entrena únicamente a partir de las señales de vibración registradas, tanto en el soporte como en el motor.

Los resultado del ajuste de hiperparámetros se presentan en la Tabla 7.4. El proceso de búsqueda y ajuste por rejilla utilizando como núcleo una RBF, arroja como combinación óptima un parámetro de penalización $C = 1000$ y un parámetro de ancho de banda $\gamma = 0.05$, manteniendo el ajuste balanceado de pesos para compensar el desbalance de clases. El ajuste alcanza una puntuación de 0.97 para la métrica objetivo (F1-score macro) con un tiempo de entrenamiento aproximado de 1892 segundos (32 minutos aproximadamente), evidenciando un recorte de tiempo significativo respecto al clasificador 1, gracias a la menor dimensionalidad de entrada.

Tabla 7.4: Resumen de hiperparámetros y resultados del entrenamiento del clasificador 2 (solo señales de vibración).

Parámetro	Valor
C	1000
Peso de clases ('class_weight')	balanceado
γ	'escalado': 0.05
Tipo de núcleo ('kernel')	rbf
Métrica objetivo	F1-score macro
Mejor puntuación obtenida	0.967897
Tiempo de entrenamiento (segundos)	1891.76

En cuanto al rendimiento sobre el conjunto de prueba, ilustrado en la Figura 7.9, este revela un comportamiento casi ideal del modelo. Sobre la clase *Eléctrica* se clasifican 337 de 341 instancias correctamente, donde los cuatro errores obtenidos se etiquetan como *Saludable*, a pesar de que esta última clase se logra identificar sin errores. De esta forma, se mantiene la leve tendencia mostrada por el clasificador 1 a confundir estas dos clases, más aun, si se tiene en cuenta que el valor de C y de γ , en ambos ajustes, son similares. Cabe mencionar que, en la práctica, algunos defectos eléctricos incipientes producen niveles de vibración comparables a un funcionamiento saludable, siendo esta una posible causa de la confusión del modelo.

Por otro lado, las clases *Mecánica* y *Mixta* se logran clasificar sin un solo error, confirmando que la mezcla de características extraídas de las señales de vibración y el ajuste de hiperparámetros utilizado mantiene un patrón distintivo para ambas clases.




Figura 7.9: Matriz de confusión obtenida para el clasificador 2 (solo señales de vibración).

Estas observaciones se cuantifican en la Tabla 7.5, que presenta el reporte de clasificación para el conjunto de pruebas con el clasificador 2. Este reporte confirma el elevado desempeño del clasificador basado sólo en vibraciones. La precisión global se redondea a un valor de 1.00, mientras que el F1-macro alcanza un valor de 0.98, superando al modelo con todas las señales. Las clases *Eléctrica*, *Mecánica* y *Mixta* presentan valores de F1-score entre 0.99 y 1.00, indicando que las firmas vibracionales son suficientes para distinguirlas.

Por el contrario, el punto débil del clasificador se concentra en la clase *Saludable*, si bien esta mantiene una sensibilidad de 1.00, indicando que el modelo es capaz de identificar todas las instancias de la clase, su precisión baja a 0.86 por la confusión del modelo para asignar dicha etiqueta a muestras que corresponden a la clase *Eléctrica*, reduciendo el F1-score a 0.92.

A pesar de lo anterior, el promedio macro para F1-score es de 0.98, indicando que dichos errores son estadísticamente marginales frente al gran número de observaciones correctamente clasificadas.

Tabla 7.5: Reporte de clasificación en el conjunto de prueba para el clasificador 2 (solo señales de vibración).

Clase	Precisión	Sensibilidad	F1-score	Soporte
Eléctrica	1.00	0.99	0.99	341
Mecánica	1.00	1.00	1.00	48
Mixta	1.00	1.00	1.00	672
Saludable	0.86	1.00	0.92	24
promedio macro	0.96	1.00	0.98	1085
promedio ponderado	1.00	1.00	1.00	1085
Precisión global				1.00
Precisión global balanceada				1.00

Por último, la Figura 7.10 muestra las curvas ROC de las cuatro clases, donde todas exhiben un AUC igual a la unidad y presentan la forma vertical en el tramo inicial característica de una buena separación de clases. Esto demuestra que, al igual que en el clasificador 1, se obtiene una sensibilidad próxima al 100 % con una tasa de FPR igual a cero. Además, la superposición de las curvas revela que el clasificador mantiene un rendimiento uniforme entre todas las clases, donde ninguna presenta degradación en su capacidad discriminativa ni sufre el efecto de umbrales de clasificación desalineados.




Figura 7.10: Curvas ROC para el clasificador 2 (solo señales de vibración).

En resumen, las características presentadas evidencian que el clasificador 2, basado única-

mente en señales de vibraciones, logra un rendimiento excepcional, clasificando de manera sobresaliente todas las clases y mejorando el rendimiento obtenido por el clasificador 1, en un menor tiempo de entrenamiento.

7.3.3. Clasificador 3: solo corrientes

El tercer clasificador se entrena únicamente a partir características extraídas de las corrientes medidas, prescindiendo completamente de las señales de vibración. Este enfoque permite identificar si las características utilizadas para corriente son sensibles a los defectos incipientes de cortocircuitos y de rodamientos utilizados.

Los resultado para el ajuste de hiperparámetros del modelo se resumen en la Tabla 7.2. Se utiliza como núcleo una RBF, obteniendo un parámetro de penalización $C = 10000$, un parámetro de ancho de banda $\gamma = 0.08333$, con un ajuste balanceado de pesos para compensar el desbalance entre clases. El entrenamiento muestra una puntuación de 0.539483 para F1-score macro (métrica objetivo) en un tiempo total de entrenamiento de 1933 segundos (32 minutos aproximadamente), similar al tiempo requerido para el ajuste del clasificador 2. Cabe destacar que el valor tan alto de C y γ dan cuenta de la rigidez necesaria para ajustar el modelo con curvas de decisión más complejas al disponer solo de información eléctrica.

Tabla 7.6: Resumen de hiperparámetros y resultados del entrenamiento del clasificador 3 (solo señales de corriente).

Parámetro	Valor
C	10000
Peso de clases ('class_weight')	balanceado
γ	'escalado': 0.08333
Tipo de núcleo ('kernel')	rbf
Métrica objetivo	F1-score macro
Mejor puntuación obtenida	0.539483
Tiempo de entrenamiento (segundos)	1933.06

Respecto a la matriz de confusión, mostrada en la Figura 7.11, se observa que el clasificador 3 muestra un patrón de errores muy distinto a los dos modelos anteriores. La clase *Eléctrica* concentra la mayoría de los aciertos (con 314 de 341 instancias), pero 27 registros son mal clasificados, distribuyéndose sobre todo hacia las clases *Mixta* y *Saludable*. Por otro lado, la clase *Mecánica* es la peor clasificada, con menos de la mitad de sus muestras (21 de 48 instancias) detectadas correctamente, en la que 22 se clasifican como *Mixta*. En cuanto a la clase *Mixta*, se alcanzan 560 aciertos sobre un total de 672 muestras, pero persiste un error significativo hacia las clases *Mecánica* y *Eléctrica*. Finalmente, para la clase *Saludable* solo se reconocen 8 de 24 instancias, donde las 16 muestras restantes se etiquetan, en su mayoría, como *Eléctrica*.

Lo anterior puede ser un indicio de que el modelo tiende a sobredimensionar defectos eléctricos cuando opera sin información de tipo mecánica (señales de vibración). Bajo esta misma línea, se observa que la falta de este tipo de información produce que la ambigüedad intrínseca de las fallas mixtas, dificulten la obtención de una clasificación precisa. Así, este clasificador da indicios de que el desbalance de par que se genera por defectos incipientes en los rodamientos, apenas logra perturbar la corriente de estator.




Figura 7.11: Matriz de confusión obtenida para el clasificador 3 (solo señales de corriente).

En cuanto a las métricas mostradas en el reporte de clasificación (Tabla 7.7), estas respaldan cuantitativamente las observaciones. La clase *Eléctrica* mantiene un equilibrio relativamente razonable entre precisión (0.85) y sensibilidad (0.92), alcanzando un valor de F1-score aceptable (0.88). La clase *Mixta* exhibe alta precisión (0.94) pero una sensibilidad moderadamente baja (0.83), dado los falsos negativos que se etiquetan como otra categoría de falla. En tanto la clase *Mecánica* sufre un F1-score de 0.29, lo que confirma la dificultad que tienen las señales de corriente para identificar defectos puramente mecánicos. Finalmente, la clase *Saludable* presenta un F1-score de apenas 0.33, lo que refleja la elevada tasa de falsos positivos. De forma general, el promedio macro de F1-score para este clasificador desciende a 0.60, valor muy por debajo de los 0.97 y 0.98 obtenidos con los clasificadores 1 y 2, mientras que la precisión global balanceada desciende a un valor de 0.63.

Tabla 7.7: Reporte de clasificación en el conjunto de prueba para el clasificador 3 (solo señales de corriente).

Clase	Precisión	Sensibilidad	F1-score	Soporte
Eléctrica	0.85	0.92	0.88	341
Mecánica	0.22	0.44	0.29	48
Mixta	0.94	0.83	0.88	672
Saludable	0.33	0.33	0.33	24
promedio macro	0.59	0.63	0.60	1085
promedio ponderado	0.87	0.83	0.86	1085
Precisión global				0.83
Precisión global balanceada				0.63

Asimismo, las curvas ROC mostradas en la Figura 7.12 confirman que la separación de clases es menor y resulta deficiente cuando el diagnóstico depende solo de las corrientes. Al contrario del valor 1.00 de AUC obtenido con los clasificadores 1 y 2, los valores AUC de 0.97, 0.95, 0.82 y 0.83 obtenidos con el clasificador 3 para las clases *Eléctrica*, *Mixta*, *Mecánica* y *Saludable*, respectivamente, indican que el método de “arg max” para la

asignación de clases sobre el conjunto de prueba es poco estricto con las clases menos representativas del conjunto.

De lo anterior, se extiende que un ajuste de costos asimétricos en la función de pérdida del clasificador permitiría mejorar la sensibilidad de estas, aumentando ligeramente la tasa de falsos positivos, pero sin deteriorar de forma significativa la precisión global. Esta necesidad se manifiesta, principalmente, en el Clasificador 3 porque la información de las corrientes, por sí sola, no separa claramente las condiciones de falla mecánicas, falla mixtas y saludable, mientras que en los clasificadores 1 y 2, la inclusión de firmas vibracionales aportan con información que incrementa la separabilidad entre clases.




Figura 7.12: Curvas ROC para el clasificador 3 (solo señales de corriente).

De esta manera se entiende que el modelo es competente para identificar fallas eléctricas y, en menor medida, las mixtas, pero muestra una clara debilidad para identificar defectos de tipo mecánico y condiciones sanas, resaltando la necesidad de incluir información vibracional.

7.3.4. Clasificador 4: vibración de soporte y corrientes

En esta configuración se entrena un modelo SVM empleando todas las señales de corriente, junto con las señales de vibración registradas sobre el soporte del rodamiento, por lo que se excluye la vibración medida sobre la carcasa del motor. El motivo es comprobar si el aporte de las vibraciones donde se concentra la mayor energía de las excitaciones mecánicas, combinado con la información eléctrica, puede igualar el desempeño alcanzado por el clasificador 1 o 2.

La búsqueda por rejilla establece como configuración óptima un modelo SVM con núcleo RBF, un parámetro de penalización $C = 1000$ y ancho de banda $\gamma = 0.04545$, manteniendo el ajuste de pesos balanceado para mitigar el desbalance de clases. Bajo estas condiciones, el entrenamiento alcanza una puntuación de 0.896913 para F1-score macro, en un tiempo de entrenamiento de 1782 segundos (30 minutos aproximadamente). A diferencia del clasificador 3, este ajuste mantiene valores menos rígidos para los parámetros C y γ , disminuyendo el tiempo de ajuste en un 8 % aproximadamente. La información mencionada sobre el ajuste del modelo 4 se resumen en la Tabla 7.8.

Tabla 7.8: Resumen de hiperparámetros y resultados del entrenamiento del clasificador 4 (vibración de soporte y corrientes).

Parámetro	Valor
C	1000
Peso de clases ('class_weight')	balanceado
γ	'auto': 0.04545
Tipo de núcleo ('kernel')	rbf
Métrica objetivo	F1-score macro
Mejor puntuación obtenida	0.896913
Tiempo de entrenamiento (segundos)	1781.98

La Figura 7.13 muestra la matriz de confusión obtenida sobre el conjunto de prueba, la cual revela un desempeño global aceptable para el clasificador. La clase *Eléctrica* se predice con un único error (340 aciertos de 341), mientras que las clases *Mecánica* y *Mixta* presentan confusiones marginales entre sí (seis muestras *Mecánica* clasificadas como *Mixta* y diez muestras *Mixta* etiquetadas como *Mecánica*), manteniendo la tendencia de confusión vista en los clasificadores 1 y 3 para estas dos clases, sugiriendo que la frontera de decisión puede ser ajustada para mejorar la separabilidad de estas. Por último, la clase *Saludable* registra cinco instancias identificadas erróneamente como *Eléctrica*, fenómeno atribuible a la similitud existente entre la firma de corriente de un motor saludable y un motor con fallas eléctricas incipientes.

En términos generales, la matriz confirma que la combinación de vibraciones de soporte y corrientes permite discriminar de forma aceptable las fallas en estudio, mejorando la separación de clases frente al clasificador 3 (solo corrientes), pero sin alcanzar los resultados obtenidos por el clasificador 1 y 2.




Figura 7.13: Matriz de confusión obtenida para el clasificador 4 (vibración de soporte y corrientes).

En la Tabla 7.9 se resume cuantitativamente el desempeño del clasificador 4 en el conjunto de prueba. El modelo muestra una precisión global del 98 % y una precisión global balanceada del 91 %, valores que confirman la obtención de un modelo útil y robusto,

pero ligeramente sesgado debido al desbalance de clases en la base de datos. El promedio ponderado de las métricas (0.98 para precisión y sensibilidad) indican que el modelo se comporta de forma sólida al considerar principalmente las clases con alto soporte, mientras que los valores de promedio macro (0.93 en precisión y 0.91 en sensibilidad) evidencian un comportamiento equilibrado cuando cada clase recibe el mismo peso.

Tabla 7.9: Reporte de clasificación en el conjunto de prueba para el clasificador 4 (vibración de soporte y corrientes).

Clase	Precisión	Sensibilidad	F1-score	Soporte
Eléctrica	0.98	1.00	0.99	341
Mecánica	0.81	0.88	0.84	48
mixta	0.99	0.98	0.99	672
Saludable	0.95	0.79	0.86	24
promedio macro	0.93	0.91	0.92	1085
promedio ponderado	0.98	0.98	0.98	1085
Precisión global				0.98
Precisión global balanceada				0.91

Respecto a la clase *Mecánica*, esta registra la precisión más baja (0.81) y un F1-score de 0.84, consecuencia de la gran confusión con la clase *Mixta*. Este resultado indica que el modelo tiende a sobrediagnosticar fallas mecánicas cuando las firmas vibracionales se solapan entre sí.

Asimismo, la clase *Saludable* muestra el menor valor de sensibilidad (0.79), por lo que el 21% de las muestras saludables se etiquetan incorrectamente (en su mayoría como *Eléctrica*). Esto se atribuye su bajo soporte (24 muestras) y a la similitud espectral con los defectos eléctricos incipientes.

Por otro lado, las clases *Eléctrica* y *Mixta* muestran métricas casi perfectas (precisión, sensibilidad y F1-score mayor al 98%), respaldadas por la gran cantidad de muestras (341 y 672 registros, respectivamente), evidenciando la eficacia del modelo para distinguir estas condiciones.




Figura 7.14: Curvas ROC para el clasificador 4 (vibración de soporte y corrientes).

Las curvas ROC para el clasificador 4 (Figura 7.14) muestran $AUC = 1.00$ para las clases *Eléctrica*, *Mecánica* y *Mixta*, y $AUC = 0.98$ para *Saludable*. La forma vertical en el tramo inicial de las curvas revela una alta separabilidad entre verdaderos y falsos positivos, con un desempeño homogéneo para todas las clases.

En general, el clasificador ofrece un desempeño global aceptable, en particular para las clases mayoritarias. Sin embargo, los valores atípicos mencionados para las clases *Mecánica* y *Saludable* sugieren que las métricas pueden mejorar mediante el aumento de muestras en dichas clases y/o la incorporación de características más representativas para las señales de corriente, con el fin de que defectos en los rodamientos sean representadas mediante estas características. Por último cabe destacar que se logra un desempeño aceptable con el clasificador, pero que no iguala al obtenido por los modelos 1 y 2.

7.3.5. Clasificador 5: vibración de motor y corrientes

En esta última configuración se entrena un modelo SVM empleando las señales de corriente y las señales de vibración registradas sobre el motor de prueba, excluyendo la vibración medida sobre el soporte del rodamiento de ensayos. De esta forma, es posible comprobar si la combinación entre las señales de vibración en zonas que igualmente resultan críticas para el estudio, pero que se encuentran más alejadas del elemento mecánico en falla, y los registros de corriente eléctrica, puede igualar el desempeño alcanzado por los clasificadores anteriores.

La información sobre el ajuste de los hiperparámetros para el modelo 5 se resume en la Tabla 7.10. La búsqueda por rejilla determina como configuración óptima una SVM con núcleo RBF, un factor de penalización $C = 10000$, un parámetro de ancho de banda $\gamma = 0.04545$ con ajuste balanceado de pesos para compensar el desbalance entre clases. Con estos parámetros el entrenamiento alcanza un F1-score macro de 0.907331 en 3939 segundos (66 minutos aproximadamente).

Tabla 7.10: Resumen de hiperparámetros y resultados del entrenamiento del clasificador 5 (vibración de motor y corrientes).

Parámetro	Valor
C	10000
Peso de clases ('class_weight')	balanceado
γ	'escalado': 0.04545
Tipo de núcleo ('kernel')	rbf
Métrica objetivo	F1-score macro
Mejor puntuación obtenida	0.907331
Tiempo de entrenamiento (segundos)	3939.57

Cabe destacar que el tiempo de entrenamiento para este modelo duplica al tiempo empleado por el clasificador 2, 3 y 4, y tarda aproximadamente un 20 % más que el clasificador 1, lo que se explica por el gran valor de C (el cual endurece la búsqueda del margen óptimo) y al uso de la mayoría de registros (exceptuando las vibraciones de soporte) para su entrenamiento. A pesar de esto, el valor obtenido en la métrica objetivo confirma que el clasificador ajusta de manera aceptable, considerando que la energía para las señales de vibración del motor disminuye en comparación a las vibraciones registradas en el soporte del rodamiento con fallas, utilizadas en el clasificador 4.

Por otro lado, la Figura 7.15 presenta la matriz de confusión obtenida sobre el conjunto de prueba, la cual revela un desempeño global sólido para el clasificador 5, aunque ligeramente peor que para el clasificador 4. En la matriz, la clase *Eléctrica* presenta sólo cinco errores, donde cuatro muestras son confundidas como *Mixta* y una como *Saludable*. Por otro lado, la clase *Mecánica* concentra la mayor cantidad de errores, donde 9 de sus 48 instancias totales se clasifican como *Mixta* y 1 como *Eléctrica*, conservando la dificultad mostrada en los modelos anteriores para separar fallas puramente mecánicas de las fallas mixtas. Asimismo, la clase *Mixta* obtiene 666 aciertos de 672 muestras totales, con apenas seis falsos positivos distribuidos entre las clases *Eléctrica* y *Mecánica*, indicador de que la clase en cuestión resulta fácilmente identificable al incluir señales de vibración. Por último, la condición *Saludable* registra 18 aciertos y 6 falsos negativos clasificados como *Eléctrica*, evidenciando la complejidad para distinguir motores saludables de defectos eléctricos incipientes. En conjunto, la matriz confirma que la principal confusión persiste entre las categorías *Mecánica* y *Mixta*, y la confusión de las muestras de la clase *Saludable* con la clase *Eléctrica*.

Vibración motor y corrientes

Valor real	Eléctrica	336	0	4	1
	Mecánica	1	38	9	0
	Mixta	2	4	666	0
	Saludable	6	0	0	18
		Eléctrica	Mecánica	Mixta	Saludable
		Predicción			

Figura 7.15: Matriz de confusión obtenida para el clasificador 5 (vibración de motor y corrientes).

La Tabla 7.11 confirma el aceptable desempeño general del clasificador 5. En esta se muestra que dicho modelo alcanza una precisión global de 0.98 y una precisión global balanceada de 0.88, acompañadas por un valor promedio de F1-macro igual 0.91 y un promedio de F1-ponderado igual 0.97. Estos valores evidencian que el modelo mantiene total robustez frente al desbalance de clases, pero que presenta problemas de consideración en las clases con menor cantidad de muestras.

De manera individual, se destacan los excelentes valores obtenidos en las métricas para las clases *Eléctrica* (precisión igual a 0.97; sensibilidad igual a 0.99; F1-score igual a 0.98) y *Mixta* (precisión igual a 0.98; sensibilidad igual a 0.99; F1-score igual a 0.99), cuyo elevado soporte de 341 y 672 instancias, respectivamente, garantiza una detección casi perfecta de estas clases. Por el contrario, un punto débil del clasificador se encuentra en la clase *Mecánica* (con precisión de 0.90, sensibilidad de 0.79 y F1-score de 0.84), donde la mayoría de sus errores proviene de la confusión con fallas mixtas. Asimismo, la

clase *Saludable* presenta la sensibilidad más baja (0.75), explicable por su bajo soporte (24 muestras) y por la similitud espectral con defectos eléctricos incipientes, a pesar de mantener una precisión elevada (0.95).

Tabla 7.11: Reporte de clasificación en el conjunto de prueba para el clasificador 5 (vibración de motor y corrientes).

Clase	Precisión	Sensibilidad	F1-score	Soporte
Eléctrica	0.97	0.99	0.98	341
Mecánica	0.90	0.79	0.84	48
Mixta	0.98	0.99	0.99	672
Saludable	0.95	0.75	0.84	24
promedio macro	0.95	0.88	0.91	1085
promedio ponderado	0.97	0.98	0.97	1085
Precisión global				0.98
Precisión global balanceada				0.88

Los resultados presentados en la tabla sugieren que el clasificador mantiene una detección aceptable, permitiendo identificar con un alto porcentaje de precisión si una máquina posee algún tipo de falla. Asimismo, se sugiere que el modelo puede mejorar al fortalecer la representación de las clases minoritarias, en especial las clases *Mecánica* y *Saludable* o utilizando características que permitan aumentar la frontera entre las clases con fallas (sobretudo entre las de tipo mixta y mecánica).




Figura 7.16: Curvas ROC para el clasificador 5 (vibración de motor y corrientes).

Adicionalmente, las curvas ROC, mostradas en la Figura 7.16, exhiben un AUC igual a 1.00 para la clase *Eléctrica* y *Mixta*, 0.99 para la clase *Mecánica* y 0.95 para la clase *Saludable*. Nuevamente, la traza casi vertical de las clases para fallas indica que el modelo alcanza sensibilidades cercanas al 100% con tasas de falsos positivos (FPR) próximas a cero, mostrando una separabilidad aceptable entre estas. Por otro lado, la curva de la clase *Saludable*, confirma la menor discriminación de dicha condición, a pesar de que su AUC sigue siendo alto.

En general, el clasificador 5 logra un desempeño global comparable al del clasificador 4, con mejoras marginales pero en un mayor tiempo de entrenamiento. La mezcla entre las vibraciones de motor con las corrientes refuerza la detección de fallas de tipo eléctricas y mixtas, pero empeora en la identificación de fallas mecánicas y en la condición saludable.

Capítulo 8

Conclusiones y recomendaciones para trabajos futuros

El presente capítulo sintetiza los hallazgos más relevantes del estudio realizado, verifica el cumplimiento de los objetivos establecidos y sugiere rutas de investigaciones futuras para fortalecer el diagnóstico de fallas en motores de inducción mediante el uso de inteligencia artificial.

Conclusiones generales sobre el procesamiento y los clasificadores

Respecto al procesamiento y caracterización de las señales registradas, se constató una atenuación energética en las vibraciones medidas directamente en el motor, atribuible al acoplamiento sobredimensionado empleado en el banco de pruebas. Este elemento actúa como un filtro pasabajos mecánico, amortiguando las componentes de alta frecuencia asociadas a fallas incipientes en los rodamientos, lo cual podría limitar la sensibilidad diagnóstica del sistema. En términos prácticos, la atenuación disminuye el efecto que genera el par oscilante en las vibraciones de la máquina, lo que repercute en la información aportada por las características extraídas de las corrientes. Esta situación sugiere la necesidad de relocalizar el acelerómetro que registra las vibraciones en el motor, con el fin de mejorar la captación de señales relevantes. Por otro lado, el análisis estadístico de los histogramas de energía permitió identificar que los niveles $D1$ para señales de vibración y $D7$ para señales de corriente constituyen las referencias más adecuadas para la extracción de características wavelet bajo diversas condiciones operativas, respaldando la consistencia de los criterios empleados. Adicionalmente, se implementó una estrategia de aumento de datos basada en la inyección de ruido gaussiano acotado (entre un 1 % y 3 % de la desviación estándar de cada señal), con el objetivo de aumentar la representatividad de las clases menos frecuentes sin comprometer la integridad de la información original. Esta técnica contribuyó a mejorar la generalización y robustez de los modelos de clasificación entrenados.

Al evaluar los clasificadores entrenados, se observa que, en términos generales, todos ellos (con excepción del clasificador 3) alcanzaron desempeños adecuados. El clasificador 2, que utiliza únicamente las señales de vibración, obtuvo los mejores resultados tanto en precisión como en tiempos de entrenamiento, posicionándose como el más eficiente del conjunto. En contraste, el clasificador 3, basado únicamente en señales de corriente, presentó

un rendimiento considerablemente inferior, sin alcanzar los niveles mínimos esperados. El clasificador 1, que considera tanto vibraciones como corrientes, también mostró un buen desempeño, aunque levemente inferior al del clasificador 2, debido posiblemente a la inclusión de características poco relevantes. Esta tendencia se replica en los clasificadores 4 y 5, los cuales, si bien logran una correcta separación entre clases, presentan resultados notablemente más bajos que los dos primeros. Lo anterior sugiere que las características derivadas de las señales de corriente no contribuyen de manera significativa al proceso de clasificación, especialmente en la detección de fallas mecánicas, dado que los modelos tienden a confundir dichas fallas con fallas mixtas. Esto se atribuye a la limitada sensibilidad de estas características para reflejar los efectos mecánicos que los rodamientos defectuosos inducen sobre el par generado. No obstante, cabe destacar que las señales de corriente sí permiten identificar fallas eléctricas con precisión, como se evidencia en el clasificador 1. En este contexto, se sugiere explorar nuevas características que capten de forma más efectiva la influencia de los daños mecánicos en las corrientes. Adicionalmente, se detectó que las clases con menor cantidad de muestras fueron sistemáticamente las peor clasificadas, lo cual resalta la importancia de mejorar el equilibrio de clases en la base de datos, o al menos, durante el entrenamiento de clasificadores mediante técnicas específicas para el entrenamiento de clasificadores. Por otro lado, los resultados de los clasificadores 4 y 5 también respaldan la hipótesis de que una reubicación estratégica de los acelerómetros podría mitigar la atenuación vibracional y, con ello, mejorar la precisión de los modelos. Finalmente, si bien los tiempos de entrenamiento de los clasificadores 1 y 2 no fueron excesivos, se identificó que una reducción del vector de características puede reducir significativamente los tiempos computacionales. Este efecto fue particularmente notorio en el clasificador 2, cuyo tiempo de entrenamiento se redujo casi a la mitad respecto del clasificador 1 al omitir las señales de corriente, lo que implica una reducción aproximada del 33 % en las dimensiones del vector de entrada. En consecuencia, se recomienda aplicar técnicas de selección u optimización de características para reducir la dimensionalidad sin comprometer el rendimiento de clasificación, independientemente de si se utilizan señales de vibración, corriente o ambas.

Recomendaciones para trabajos futuros

Finalmente, a partir de los resultados obtenidos, se proponen una serie de recomendaciones orientadas a fortalecer futuras investigaciones y desarrollos en esta línea de trabajo. En primer lugar, se sugiere reubicar los acelerómetros con el fin de incrementar la sensibilidad a componentes de alta frecuencia, las cuales son claves para la detección temprana de fallas incipientes. Asimismo, se recomienda aumentar el número de muestras correspondientes a las clases menos representadas, particularmente las clases *Mecánica* y *Saludable*, e incluir fallas progresivas bajo distintas condiciones de carga para enriquecer la variabilidad de la base de datos. En esa misma línea, podría resultar conveniente incorporar nuevos tipos de fallas o condiciones más severas de las ya consideradas, así como explorar la integración o el uso de sensores adicionales (como sensores acústicos, de temperatura o de flujo magnético) que puedan complementar la información para el diagnóstico.

Además, se plantea la necesidad de perfeccionar el banco de pruebas y la metodología empleada para el registro de señales. En particular, la automatización del proceso de adquisición mediante el uso de tarjetas de adquisición permitiría reducir de forma significativa los tiempos asociados a la recolección de datos, aumentando así la eficiencia del procedimiento experimental. Junto a lo anterior, la inclusión de este tipo de dispositivos

permite lograr frecuencias de muestreo superiores y una mejor resolución temporal, lo que mejora el análisis de firmas asociadas a fallas que se manifiestan en bandas de alta frecuencia. Del mismo modo, la implementación de sistemas de carga más controlados (como la incorporación de un freno electromagnético) permitiría aplicar cargas de manera precisa y repetible, lo que contribuiría directamente a la calidad, consistencia y robustez de los registros recopilados. En cuanto a las señales de corriente, se sugiere investigar nuevos indicadores más sensibles a la influencia de fallas mecánicas, como aquellos definidos en el dominio de Park o los basados en secuencia negativa.

Por otro lado, sería pertinente evaluar el desempeño de modelos más avanzados, como aquellos basados en aprendizaje profundo o estrategias híbridas que combinen diferentes clasificadores para mejorar la capacidad de generalización. Finalmente, como paso hacia una aplicación práctica, se propone el desarrollo e implementación de un prototipo de monitoreo en tiempo real, cuya validación debe contemplar condiciones más cercanas al entorno industrial, por ejemplo, la presencia de ruido u otro tipo de variaciones ambientales.

Apéndice A

Generador de inducción autoexcitado

Un generador de inducción autoexcitado (SEIG, por sus siglas en inglés) es una máquina de inducción (típicamente de jaula de ardilla) que, al acoplar un banco de condensadores en sus terminales, puede generar tensión en modo isla sin conexión a red, aprovechando el magnetismo residual y el intercambio de potencia reactiva con los condensadores para establecer el flujo magnético requerido [44, 45]. Sus principales ventajas frente a un generador síncrono incluyen: bajo costo y tamaño, construcción robusta y sin escobillas (en jaula), ausencia de fuente de CD separada para alimentar el campo, mantenimiento sencillo y protección intrínseca ante sobrecargas severas y cortocircuitos [45].

A.1. Clasificación de generadores de inducción según esquema de operación

Dependiendo de los motores primarios utilizados (velocidad constante o velocidad variable) y de su ubicación (cerca de la red eléctrica o en lugares aislados), los esquemas de generación se pueden clasificar ampliamente de la siguiente manera[45]:

1. **Velocidad y frecuencia constantes (CSCF)**: En este esquema, la velocidad del motor primario se mantiene constante mediante el ajuste continuo de las características del generador. De esta manera, un generador de inducción puede operar en una barra colectora infinita con un deslizamiento del 1 % al 5 % por encima de la velocidad síncrona. La máquina solo puede actuar como generador con en isla si se provee de reactivos localmente.
2. **Velocidad variable y frecuencia constante (VSCF)**: Son esquemas populares para obtener una salida de frecuencia constante, que alimenta directamente a la red, a partir de una velocidad de eje variable. Se utilizan principalmente en la generación de energía eléctrica mediante sistemas eólicos debido a las velocidades de viento variable. Existen dos esquemas comunmente utilizados para este tipo de generador:
 - Los esquemas mediante enlaces AC-DC-AC, donde la salida del generador trifásico se rectifica mediante un puente DC y luego se convierte de nuevo a corriente alterna usando inversores.
 - Los esquemas mediante Generador de Inducción de Doble Salida (DOIG, por sus siglas en inglés), que consiste en una máquina de inducción de rotor bobinado trifásica que se acopla mecánicamente a una turbina (eólica o hidráulica)

y cuyos terminales de estator se conectan a una red de tensión y frecuencia constante. Por otro lado, la salida de frecuencia variable se inyecta a la red mediante un convertidor AC-DC-AC. Este esquema es de poco uso en comparación dada sus desventajas operacionales como requerimientos elevados de mantenimiento, factor de potencia bajo y confiabilidad pobre por los contactos mecánicos deslizantes en el rotor.

3. **Velocidad y frecuencia variables (VSVF):** Este esquema es apropiado para cargas poco sensibles a las variaciones de frecuencia (como cargas resistivas) o para aplicaciones en isla pequeñas.

A.2. Fenómeno de auto-excitación y formación de tensión

Cuando el eje se hace girar a velocidad superior a la síncrona (deslizamiento $s < 0$), la máquina de inducción entrega potencia activa al circuito. En isla, la potencia reactiva necesaria para magnetizarse la suministra mediante un banco de condensadores conectado en bornes. El magnetismo residual induce una pequeña tensión inicial, alimentado los condensadores y provocando la circulación de corriente capacitiva. De esta forma, aumenta el flujo y la tensión, y el proceso se realimenta hasta alcanzar el punto de equilibrio establecido por la curva de magnetización de la máquina y la reactancia capacitiva efectiva de los condensadores [44, 45].




Figura A.1: Curva de magnetización y fenómeno de autoexcitación y formación de tensión [46].

Gráficamente, el punto de operación en vacío se obtiene por la intersección entre la curva de magnetización de la máquina y la recta capacitiva del banco. De esta forma, es posible obtener el valor de reactancia capacitiva máxima para que ocurra la autoexcitación en vacío, correspondiente a la razón entre la tensión de vacío y la corriente magnetizante [44]:

$$X_{C_{\max}} = \frac{V_o}{I_{mo}} \quad (\text{A.1})$$

donde $X_{C_{max}}$ corresponde al valor de reactancia capacitiva máxima, V_o corresponde al valor de tensión de vacío de la máquina e I_{mo} corresponde a su valor de corriente magnetizante. Finalmente, el valor de capacitancia mínima requerida para la operación del generador queda limitado por la siguiente expresión [44]:

$$C_{min} > \frac{1}{2\pi f X_{C_{max}}} \quad (A.2)$$

donde C_{min} es la capacitancia mínima por fase, $X_{C_{max}}$ corresponde al valor de reactancia capacitiva máxima calculada con (A.1) y f es la frecuencia de las corrientes de estator.

La Figura A.1 representa de forma ilustrativa el fenómeno de autoexcitación y formación de tensión, junto con la relación entre la curva de vacío de la máquina y el valor de reactancia capacitiva.

A.3. Selección de capacitancia para operación del SEIG

En este trabajo se propone un esquema de operación tipo isla, donde el SEIG estará funcionando en régimen VSVF. Dada la condición de velocidad y frecuencia variables que presenta el sistema, se requiere una formulación mucho más precisa para estimar el valor de capacitancia mínima requerida al momento de cargar el generador. Para cumplir con estos requerimientos, a partir de los parámetros y curvas estudiadas de la máquina generadora, se realiza una aproximación inicial para la capacitancia máxima, la que posteriormente se contrasta mediante el método propuesto en [47], el cual permite calcular un requisito de capacitancia para un generador de inducción autoexcitado operando en isla.

A.3.1. Curva de magnetización y capacitancia máxima

Como criterio inicial de estimación se toma como referencia la recta generada por de impedancia capacitiva generada a a partir de la curva de magnetización de la máquina, tal como se observa en la Figura A.2.




Figura A.2: Curva de magnetización y recta de impedancia capacitiva para el SEIG.

De esta manera, y siguiendo con el procedimiento presentado anteriormente, se obtiene que:

$$X_{C_{\max}} = \frac{V_o}{I_{mo}} = \frac{230,71}{2,51} = 90,80 \, \Omega \quad (\text{A.3})$$

Luego, suponiendo que la frecuencia de las corrientes generadas tiene un valor de 50Hz , la capacitancia mínima requerida debe respetar la siguiente desigualdad:

$$C_{\min} > \frac{1}{2\pi \cdot 50 \cdot 90,80} = 34,63 \mu F \quad (\text{A.4})$$

A.3.2. Requerimientos de capacitancia y para un SEIG

De forma preliminar, mediante la curva de magnetización de la máquina, se determinan que los requerimientos de capacitancia mínima para que ocurra el proceso de autoexcitación cuando el generador se encuentra en vacío. Dicho esto, se implementa el método propuesto por Al Jabri [47] para la estimación de la capacitancia mínima requerida. El método en cuestión se basa en el circuito equivalente para un SEIG, tal como se muestra en la Figura A.3, donde los parámetros requeridos para el modelo han sido estimados mediante el método de estimación de parámetros para máquinas de inducción propuesto en [37, 38], y se presentan en la Tabla A.1.




Figura A.3: Circuito equivalente en estado estacionario por fase en pu de un SEIG con carga RL.

Cabe destacar que en el circuito equivalente se han ignorado las pérdidas del núcleo de la máquina. De hecho, para cumplir con el requisito de capacitancia mínima, la máquina debe operar en el umbral de saturación, por lo que, ignorar tales pérdidas no resultará en errores en serie al momento de estimar $C_{\min}$. Además, se asume que todos los parámetros del circuito, excepto las inductancias, son constantes y no se ven afectados por la saturación.

Tabla A.1: Parámetros estimados para la máquina generadora, en por unidad base propia.

Parámetro	Por Unidad (<i>pu</i>)
Resistencia de estator ($R_{s,gen}$)	0,0488
Resistencia de rotor ($R_{r,gen}$)	0,0313
Inductancia de dispersión estator ($L_{\sigma s,gen}$)	0,0326
Impedancia de dispersión rotor ($L_{\sigma r,gen}$)	0,0417
Impedancia mutua (M_{gen})	0,6213

De esta manera, considerando que el valor mínimo de resistencia de carga a utilizar es de aproximadamente 90Ω , para un deslizamiento estimado del 5 %, se obtiene que el valor de capacitancia mínimo requerido para la autoexcitación de $C_{min} = 52,6\mu F$.

Apéndice B

Alineación del sistema motor-eje-generator

La correcta alineación del sistema en el banco de pruebas es un requisito previo para cualquier medición fiable. Un desalineamiento, aunque sea pequeño, introduce esfuerzos en los rodamientos y el acoplamiento, elevando la vibración de fondo y puede enmascarar o imitar síntomas de falla. De esta manera, antes de la adquisición de las señales a estudiar, se ejecuta un procedimiento alineación comúnmente utilizado en el mantenimiento de máquinas llamado “*método de los comparadores alternados*” [43].

B.1. Método de los comparadores alternados

Este método se basa en la utilización de dos relojes comparadores, donde cada uno está fijo a una de las partes de la máquina que quedan a ambos lados del acoplamiento, tal como se muestra en la Figura B.1. Así, existirá un comparador que se moverá solidariamente con el eje de la parte fija de la máquina (llamado comparador F) y el otro con el eje de la parte móvil (llamado comparador M). Luego, para la toma de medidas se giran simultáneamente los dos ejes. Por último, se determinan los desplazamientos de los apoyos cercano (DAC) y lejano (DAL) de la parte móvil, a partir de las medidas tomadas. Cabe destacar que la alineación se realiza de forma independiente en los dos planos horizontal y vertical.




Figura B.1: Montaje del método de comparadores alternados para la alineación de los elementos (a) generador-eje y (b) eje-motor.

En este método se toman dos medidas por cada plano de alineación, una en el lado positivo (P) y otra en el lado negativo (N), rigiéndose por el convenio de sentidos positivos y negativos mostrado en la Figura B.2. Así se llega a las lecturas FP (comparador Fijo, lado Positivo) y FN (comparador Fijo, lado Negativo) proporcionadas por el comparador de la parte fija y a las lecturas MP (comparador Móvil, lado Positivo) y MN (comparador Móvil, lado Negativo) proporcionadas por el comparador de la parte móvil.




Figura B.2: Convenio de sentidos positivos en los planos horizontal y vertical.

La diferencia entre ambas medidas es la distancia recorrida por el comparador y equivale a la desalineación diametral en el punto medido:

$$F = FP - FN \quad (B.1)$$

$$M = MP - MN \quad (B.2)$$

La Figura B.3 representa la vista superior del esquema general para el método de los comparadores alternados. En este se observan las partes fija y móvil del sistema, junto con el par de relojes comparadores alternados. Además, el esquema indica las relaciones geométricas y principales distancias para el sistema mencionado.

Una vez que se han obtenido las medidas de la desalineación, F y M , se pueden determinar los desplazamientos necesarios en la parte móvil para conseguir la alineación perfecta. Esta alineación se realiza de forma analítica en los dos planos, horizontal y vertical, a partir de relaciones trigonométricas que se extraen de la Figura B.3.

De esta manera, se determina la magnitud del ángulo de desalineación (α) en el plano considerado mediante la expresión:

$$\operatorname{tg} \alpha = \frac{1}{C} \left(\frac{F}{2} + \frac{M}{2 \cos \alpha} \right) \quad (B.3)$$

En esta relación se asume que el ángulo α es positivo en sentido contrario a las agujas del reloj y medido desde el eje de la parte fija hasta el eje de la parte móvil. Además, teniendo en cuenta que el ángulo α es habitualmente muy pequeño, el coseno del mismo es prácticamente 1 y la ecuación anterior se puede expresar, con una buena aproximación,




Figura B.3: Esquema de alineación y relaciones geométricas en el método de comparadores alternados.

como sigue:

$$\operatorname{tg} \alpha \approx \frac{F + M}{2C} \quad (\text{B.4})$$

Luego, la relación para el ángulo de desalineación α , queda de la forma:

$$\alpha = \operatorname{arctg} \left(\frac{F + M}{2C} \right) \approx \frac{F + M}{2C} \text{ (rad)} \quad (\text{B.5})$$

Cabe mencionar que la aproximación para esta expresión es aceptable siempre que se cumpla el criterio:

$$\left| \frac{F + M}{2C} \right| < 0,25 \quad (\text{B.6})$$

Por otro lado, la desalineación paralela DP en el centro del acoplamiento se calcula mediante la relación:

$$DP = -\frac{F}{2} + \frac{C}{2} \tan \alpha = -\frac{F}{2} + \frac{C}{2} \frac{F + M}{2C} = \frac{M - F}{4} \quad (\text{B.7})$$

donde M y F corresponden a las medida de desalineación calculadas, y pueden ser positivas o negativas. Mientras que C es una cota o dimensión sin signo.

Una vez conocidos los valores de desalineación paralela DP y de desalineación angular α , para ambos planos, se verificar en la hoja de datos del acople, que conecta las partes fija y móvil, si el estado de alineación está dentro de los límites aceptables. En caso de no estarlo, se debe desplazar la parte móvil para lograr una mejor alineación.

De esta forma, a partir del ángulo de desalineación α se obtienen los desplazamientos necesario en los apoyos cercano (DAC) y lejano (DAL) al acoplamiento, mostrados en el esquema de la Figura B.3:

$$DAC = -\frac{F}{2} - D \operatorname{tg} \alpha \quad (\text{B.8})$$

$$DAL = -\frac{F}{2} - (D + E) \operatorname{tg} \alpha \quad (\text{B.9})$$

sustituyendo “ $\operatorname{tg} \alpha$ ” por su valor obtenido de la ecuación (B.4) se obtiene que:

$$DAC = -\frac{F}{2} - D \frac{F + M}{2C} \quad (\text{B.10})$$

$$DAL = -\frac{F}{2} - (D + E) \frac{F + M}{2C} \quad (\text{B.11})$$

donde M y F corresponden a las medida de desalineación calculadas, pudiendo ser positivas o negativas. Mientras que C , D y E son cotas o dimensiones sin signo.

Los valores obtenidos son las distancias que se han de desplazar los apoyos del eje de la parte móvil para una correcta alineación en el plano vertical, teniendo como referencia el convenio de signos mostrado en la Figura B.2. De esta forma, un signo positivo en los desplazamientos obtenidos indica la necesidad de desplazamiento en el sentido positivo del apoyo, mientras que un signo negativo en los desplazamientos obtenidos indica la necesidad de desplazamiento en el sentido negativo, para el apoyo correspondiente.

B.2. Ventajas y desventajas del método de los comparadores alternados

Dentro de los métodos manuales, el método de los comparadores alternados cuenta con gran aceptación entre los ingenieros de mantenimiento porque presenta ciertas ventajas que son expuestas a continuación [43]:

- Proporciona una muy buena precisión cuando los diámetros de los platos del acoplamiento son pequeños (mejor que la de otros métodos).
- Las medidas se pueden tomar con los ejes acoplados, por lo que no requiere el desmontaje del acoplamiento.
- Generalmente, ambos ejes son girados conjuntamente y, de esta forma, la posible excentricidad de las caras laterales del acoplamiento no afecta la medida.
- La holgura axial de los ejes (imprescindible en algunas máquinas) no afecta significativamente las medidas.
- Los desplazamientos necesarios están relacionados con las lecturas de los comparadores de forma intuitiva, lo que proporciona seguridad en los cálculos.

En oposición a estas ventajas, el método cuenta con una serie de inconvenientes que hacen poco indicado su uso en ciertas aplicaciones:

- Se requiere la rotación de ambos rotores. Si un rotor de una máquina no se puede mover, el método no es aplicable.
- Proporciona una precisión menor en máquinas axialmente muy próximas con acoplamientos de gran diámetro.
- No puede ser utilizado en pequeñas máquinas con espacio insuficiente para instalar dos brazos soporte y los correspondientes relojes comparadores.
- En máquinas con acoplamiento de gran diámetro y distancias axiales grandes, los brazos de los comparadores hacen difícil la toma de datos consistentes y sin error.

Apéndice C

Tensiones desbalanceadas

C.1. Desequilibrio de tensión

El desequilibrio de tensión es un problema frecuente en sistemas eléctricos a nivel industrial. La existencia de cargas monofásicas, alimentadores no transpuestos, u otro tipo de razones, influye directamente en la presencia de niveles de desequilibrios en los sistemas de potencia, lo que ha sido motivo de estudio durante muchos años. Hoy en día existen diversas propuestas para medir el nivel de desequilibrio en las tensiones de una red eléctrica, entre las más relevantes se encuentran indicadores que se calculan a partir de las tensiones línea como el porcentaje de Desequilibrio de Tensión de Línea (LVU, por sus siglas en inglés–Line Voltage Unbalance) o una definición similar, pero a partir de tensiones de fase conocida como Porcentaje de Desequilibrio de Tensión de Fase (PVU, por sus siglas en inglés–Phase Voltage Unbalance), y otros indicadores que se calculan a partir de las componentes de secuencia positiva y negativa como el Factor de Desequilibrio de Tensiones (VUF, por sus siglas en inglés), o un indicador similar, denominado Factor de Desequilibrio Complejo de Tensiones (CVUF, por sus siglas en inglés Complex Voltage Unbalance Factor)[48].

C.2. Factor de Desequilibrio Complejo de Tensiones

Tradicionalmente, el nivel de desequilibrio se cuantifica mediante índices reales, tales como el Porcentaje de Desequilibrio de Tensión de Fase (PVU) propuesto por la NEMA y el Factor de Desequilibrio de Tensiones (VUF) definido por la IEC. Sin embargo, estos índices consideran únicamente la magnitud del desequilibrio, omitiendo la información de fase entre las componentes simétricas.

Para superar esta limitación, se introduce en [49] el Factor de Desequilibrio Complejo de Tensiones (CVUF), una extensión del VUF que incorpora tanto la magnitud como el ángulo de la relación entre las componentes de secuencia negativa y positiva del sistema de tensiones. De esta manera, el CVUF se define como el cociente entre ambas componentes de secuencia [50]:

$$CVUF = \frac{V_2}{V_1} = \frac{|V_2|\angle\theta_2}{|V_1|\angle\theta_1} = VUF\angle(\theta_2 - \theta_1) = VUF\angle\theta \quad (C.1)$$

Donde:

- V_1 : componente de secuencia positiva de la tensión,
- V_2 : componente de secuencia negativa de la tensión,
- $VUF = |V_2|/|V_1|$: magnitud del desequilibrio (según IEC),
- θ : ángulo que representa el desfase entre las tensiones de secuencia positiva y negativa.

Si se tiene en cuenta que las tensiones de secuencia positiva, negativa y cero se pueden expresar a partir de las tensiones de línea, mediante la transformada de Fortescue, como:

$$\begin{bmatrix} V_0 \\ V_1 \\ V_2 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & a & a^2 \\ 1 & a^2 & a \end{bmatrix} \begin{bmatrix} V_{ab} \\ V_{bc} \\ V_{ca} \end{bmatrix} \quad (C.2)$$

donde $a = e^{j\frac{2\pi}{3}}$ es el operador de rotación o de desfase. El VUF se expresa como:

$$VUF = \frac{|V_2|}{|V_1|} \quad (C.3)$$

Se observa entonces que el CVUF conserva la misma magnitud pero añade la información angular de θ , lo cual permite representar simultáneamente el nivel y la orientación del desequilibrio.

De esta manera, este parámetro complejo entrega una caracterización más completa del desequilibrio, puesto que la magnitud $|CVUF|$ cuantifica el nivel global de asimetría, mientras que el ángulo θ describe la disposición geométrica de los fasores de línea y, por tanto, el modo específico en que las tensiones están desequilibradas.

C.3. Cálculo de tensiones desequilibradas

Sea un conjunto desequilibrado de tensiones de línea V_{ab} , V_{bc} y V_{ca} con neutro aislado. Las relaciones entre las tensiones de línea y las componentes de tensión de secuencia positiva V_1 y negativa V_2 , para dicho conjunto, se pueden expresar de la siguiente manera:

$$\begin{bmatrix} V_{ab} \\ V_{bc} \\ V_{ca} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & a^2 & a \\ 1 & a & a^2 \end{bmatrix} \begin{bmatrix} 0 \\ V_1 \\ V_2 \end{bmatrix} \quad (C.4)$$

donde $a = e^{j\frac{2\pi}{3}}$ es el operador de rotación. La relación (C.4) muestra que los tres fasores de tensión de línea quedan definidos completamente por las tensiones de secuencia positiva y negativa.

Al considerar la ecuación presentada en (C.1), la relación anterior se puede expresar a partir del $CVUF$, como sigue [50]:

$$\begin{bmatrix} V_{ab} \\ V_{bc} \\ V_{ca} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & a^2 & a \\ 1 & a & a^2 \end{bmatrix} \begin{bmatrix} 0 \\ V_1 \\ V_1 \cdot CVUF \end{bmatrix} \quad (C.5)$$

$$\begin{bmatrix} V_{ab} \\ V_{bc} \\ V_{ca} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & a^2 & a \\ 1 & a & a^2 \end{bmatrix} \cdot V_1 \cdot \begin{bmatrix} 0 \\ 1 \\ VUF \angle \theta \end{bmatrix} \quad (C.6)$$

Las relaciones (C.5) y (C.6) muestran que, dada la tensión de secuencia positiva V_1 y el CVUF, se pueden definir completamente las tensiones de línea V_{ab}, V_{bc}, V_{ca} del sistema.

Así, el desequilibrio de tensiones puede caracterizarse a partir de tres parámetros fundamentales:

- $|V_1|$: magnitud de la componente de secuencia positiva, que determina el nivel de tensión del sistema;
- VUF : grado de desequilibrio de tensiones, es decir, la proporción entre las componentes de secuencia negativa y positiva;
- θ : ángulo del CVUF, que indica cómo se encuentran desfasadas ambas componentes y define la forma geométrica del triángulo de tensiones de línea.

Si se mantiene constante el módulo VUF , el ángulo θ determina el lugar geométrico de los fasores de tensión, tal como se presenta en la Figura C.1.




Figura C.1: Variación de la forma del triángulo de tensiones para un mismo VUF y distinto ángulo θ . [50]

En esta representación, se observa como el ángulo θ modifica la orientación del fasor de secuencia negativa respecto del positivo, alterando las magnitudes aparentes de las tensiones de línea, para un mismo valor de VUF .

Luego, si para la ecuación (C.6) se considera un VUF constante, los fasores de tensiones de línea V_{ab}, V_{bc} y V_{ca} se expresan como:

$$V_{ab} = V_1(1 + VUF \angle \theta) \quad (C.7)$$

$$V_{bc} = V_1(a^2 + a VUF \angle \theta) \quad (C.8)$$

$$V_{ca} = V_1(a + a^2 VUF \angle \theta) \quad (C.9)$$

Para obtener las magnitudes de las tensiones de línea, se considera que $\theta_1 = 0^\circ$, por lo que se cumple que $V_1 = |V_1| \angle 0^\circ$. Así, mediante la consideración anterior y el uso de identidades trigonométricas, las relaciones (C.7), (C.8) y (C.9) toman la forma de:

$$|V_{ab}| = |V_1| \cdot \sqrt{1 + 2 \cdot VUF \cdot \cos(\theta) + VUF^2} \quad (C.10)$$

$$|V_{bc}| = |V_1| \cdot \sqrt{1 + 2 \cdot VUF \cdot \cos(\theta - 120^\circ) + VUF^2} \quad (C.11)$$

$$|V_{ca}| = |V_1| \cdot \sqrt{1 + 2 \cdot VUF \cdot \cos(\theta + 120^\circ) + VUF^2} \quad (C.12)$$

Finalmente, las tensiones de fase pueden calcularse a partir de las tensiones de línea calculadas, utilizando el Teorema de Apolonio. Este teorema permite determinar el centro geométrico de cualquier triángulo formado por los fasores de tensiones de línea desequilibradas.




Figura C.2: Triángulo formado por tensiones trifásicas desequilibradas [51].

A partir del triángulo presentado en la Figura C.2 se calculan las magnitudes y los ángulos de las tensiones de fase siguiendo el método propuesto en [51]. De esta manera, las magnitudes de las tensiones de fase se determinan mediante las siguientes expresiones:

$$V_a = \frac{1}{3} \sqrt{2(V_{ab}^2 + V_{ca}^2) - V_{bc}^2} \quad (C.13)$$

$$V_b = \frac{1}{3} \sqrt{2(V_{bc}^2 + V_{ab}^2) - V_{ca}^2} \quad (C.14)$$

$$V_c = \frac{1}{3} \sqrt{2(V_{ca}^2 + V_{bc}^2) - V_{ab}^2} \quad (C.15)$$

donde V_{ab} , V_{bc} y V_{ca} corresponden a las magnitudes de las tensiones de línea calculadas a partir de las relaciones (C.10), (C.10) y (C.10), respectivamente.

De forma complementaria, los ángulos de desfase entre las tensiones de fase también pueden obtenerse a partir de las relaciones trigonométricas del triángulo, considerando los teoremas del seno y del coseno. Si se considera que el fasor línea-neutro para la tensión de la fase a V_a se alinea con el eje real, es decir, tiene ángulo 0° , entonces los ángulos θ_a , θ_b y θ_c (en grados) se calculan como:

$$\theta_a = 0^\circ \quad (\text{C.16})$$

$$\theta_b = 360 - \cos^{-1} \left(\frac{V_{ab}^2 - V_a^2 - V_b^2}{-2V_a V_b} \right) \quad (\text{C.17})$$

$$\theta_c = \cos^{-1} \left(\frac{V_{ca}^2 - V_a^2 - V_c^2}{-2V_c V_a} \right) \quad (\text{C.18})$$

donde V_a , V_b y V_c corresponden a las magnitudes de las tensiones de línea-neutro calculadas en las relaciones (C.13), (C.14) y (C.15), respectivamente.

Bibliografía

- [1] S. Nandi, H. Toliyat y X. Li, “Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review,” *IEEE Transactions on Energy Conversion*, vol. 20, n.º 4, págs. 719-729, 2005. DOI: [10.1109/TEC.2005.847955](https://doi.org/10.1109/TEC.2005.847955).
- [2] A. Allal y A. Khechekhouche, “Diagnosis of induction motor faults using the motor current normalized residual harmonic analysis method,” *International Journal of Electrical Power Energy Systems*, vol. 141, pág. 108 219, 2022, ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2022.108219>. dirección: <https://www.sciencedirect.com/science/article/pii/S0142061522002496>.
- [3] A. Almounajjed, A. K. Sahoo y M. K. Kumar, “Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis,” *Measurement*, vol. 182, pág. 109 780, 2021, ISSN: 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2021.109780>. dirección: <https://www.sciencedirect.com/science/article/pii/S026322412100734X>.
- [4] M. El Hachemi Benbouzid, “A review of induction motors signature analysis as a medium for faults detection,” *IEEE Transactions on Industrial Electronics*, vol. 47, n.º 5, págs. 984-993, 2000. DOI: [10.1109/41.873206](https://doi.org/10.1109/41.873206).
- [5] P. Gangsar y R. Tiwari, “Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review,” *Mechanical Systems and Signal Processing*, vol. 144, pág. 106 908, 2020, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymssp.2020.106908>. dirección: <https://www.sciencedirect.com/science/article/pii/S0888327020302946>.
- [6] A. Bonnett y G. Soukup, “Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors,” *IEEE Transactions on Industry Applications*, vol. 28, n.º 4, págs. 921-937, 1992. DOI: [10.1109/28.148460](https://doi.org/10.1109/28.148460).
- [7] R. Liu, B. Yang, E. Zio y X. Chen, “Artificial intelligence for fault diagnosis of rotating machinery: A review,” *Mechanical Systems and Signal Processing*, vol. 108, págs. 33-47, 2018, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymssp.2018.02.016>. dirección: <https://www.sciencedirect.com/science/article/pii/S0888327018300748>.
- [8] A. K. Jardine, D. Lin y D. Banjevic, “A review on machinery diagnostics and prognostics implementing condition-based maintenance,” *Mechanical Systems and Signal Processing*, vol. 20, n.º 7, págs. 1483-1510, 2006, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymssp.2006.07.001>.

- [org/10.1016/j.ymssp.2005.09.012](https://doi.org/10.1016/j.ymssp.2005.09.012). dirección: <https://www.sciencedirect.com/science/article/pii/S0888327005001512>.
- [9] S. Kumar et al., “A comprehensive review of condition based prognostic maintenance (CBPM) for induction motor,” *Ieee Access*, vol. 7, págs. 90 690-90 704, 2019.
 - [10] M. A. Sheikh, S. T. Bakhsh, M. Irfan, N. b. M. Nor y G. Nowakowski, “A review to diagnose faults related to three-phase industrial induction motors,” *Journal of Failure Analysis and prevention*, vol. 22, n.º 4, págs. 1546-1557, 2022.
 - [11] R. García, “Diseño de una herramienta para detectar fallas mecánicas en motores de inducción utilizando IA,” *Coordinación de tecnología e ingeniería eléctrica, U. Simón Bolívar*, 2024.
 - [12] 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,” *ISA transactions*, vol. 70, págs. 400-409, 2017.
 - [13] A. Bellini, F. Filippetti, C. Tassoni y G.-A. Capolino, “Advances in diagnostic techniques for induction machines,” *IEEE Transactions on industrial electronics*, vol. 55, n.º 12, págs. 4109-4126, 2008.
 - [14] J.-H. Jung, J.-J. Lee y B.-H. Kwon, “Online diagnosis of induction motors using MCSA,” *IEEE Transactions on Industrial Electronics*, vol. 53, n.º 6, págs. 1842-1852, 2006.
 - [15] W. Rohouma, A. Zaitouny, M. F. Wahid, H. Ali y S. S. Refaat, “A machine learning framework for bearing fault detection in three-phase induction motors,” en *2024 4th International Conference on Smart Grid and Renewable Energy (SGRE)*, IEEE, 2024, págs. 1-5.
 - [16] S. Ahmed, M. Hasan, M. Islam y J. M. Kim, “A review of early fault diagnosis approaches and their applications in rotating machinery,” *IEEE Access*, vol. 7, págs. 86 584-86 600, 2019. DOI: [10.1109/ACCESS.2019.2925911](https://doi.org/10.1109/ACCESS.2019.2925911).
 - [17] R. Jigyasu, A. Varshney y D. K. Prasad, “Deep optimal feature extraction and selection-based motor fault diagnosis using vibration,” *Electrical Engineering*, 2024. DOI: [10.1007/s00202-024-01856-6](https://doi.org/10.1007/s00202-024-01856-6).
 - [18] J. Rengifo, J. Moreira, F. Vaca-Urbano y M. S. Alvarez-Alvarado, “Detection of Inter-Turn Short Circuits in Induction Motors Using the Current Space Vector and Machine Learning Classifiers,” *Energies*, vol. 17, n.º 10, pág. 2241, 2024.
 - [19] P. Singh y M. Shaik, “Incipient fault detection in stator windings of an induction motor using Stockwell transform and SVM,” *IEEE Sensors Journal*, vol. 20, n.º 22, págs. 13 523-13 530, 2020. DOI: [10.1109/JSEN.2020.3009542](https://doi.org/10.1109/JSEN.2020.3009542).
 - [20] A. Sharma, A. Kumar y A. Verma, “Condition Monitoring and Diagnosis of Outer Raceway Bearing Fault using Support Vector Machine,” *Journal of Vibroengineering*, vol. 26, n.º 1, págs. 202-213, 2024.
 - [21] P. Gangsar y R. Tiwari, “Comparative investigation of vibration and current monitoring for prediction of mechanical and electrical faults in induction motor based

- on multiclass-support vector machine algorithms,” *Mechanical Systems and Signal Processing*, vol. 94, págs. 464-481, 2017.
- [22] Z. Xu et al., “Data-driven inter-turn short circuit fault detection in induction machines,” *IEEE Access*, vol. 5, págs. 25 055-25 068, 2017.
- [23] T. Garcia-Calva, D. Morinigo-Sotelo, V. Fernandez-Cavero y R. Romero-Troncoso, “Early detection of faults in induction motors—A review,” *Energies*, vol. 15, n.º 21, pág. 7855, 2022.
- [24] W. Li y C. K. Mechefske, “Detection of induction motor faults: a comparison of stator current, vibration and acoustic methods,” *Journal of vibration and Control*, vol. 12, n.º 2, págs. 165-188, 2006.
- [25] J. T. Olkkonen, *Discrete Wavelet Transforms: Theory and Applications*. BoD—Books on Demand, 2011.
- [26] P. Kumar y A. S. Hati, “Review on machine learning algorithm based fault detection in induction motors.,” *Archives of Computational Methods in Engineering*, vol. 28, n.º 3, 2021.
- [27] A. Widodo y B.-S. Yang, “Support vector machine in machine condition monitoring and fault diagnosis,” *Mechanical systems and signal processing*, vol. 21, n.º 6, págs. 2560-2574, 2007.
- [28] M. Singh y A. G. Shaik, “Faulty bearing detection, classification and location in a three-phase induction motor based on Stockwell transform and support vector machine,” *Measurement*, vol. 131, págs. 524-533, 2019.
- [29] C.-W. Hsu, C.-C. Chang, C.-J. Lin et al., “A practical guide to support vector classification,” 2003.
- [30] P. G. R. Tiwari, “Mechanical and Electrical Fault Diagnosis of Induction Motor based on Continuous Wavelet Transform and Support Vector Machine,” 2017.
- [31] C. Cortes y V. Vapnik, “Support-vector networks,” *Machine learning*, vol. 20, n.º 3, págs. 273-297, 1995.
- [32] G. G. M. James, D. Witten, T. Hastie, R. Tibshirani y J. E. Taylor, “An introduction to statistical learning: with applications in Python,” 2023.
- [33] F. Pedregosa et al., “Scikit-learn: Machine learning in Python,” *the Journal of machine Learning research*, vol. 12, págs. 2825-2830, 2011.
- [34] J. C. Platt, “12 fast training of support vector machines using sequential minimal optimization,” *Advances in kernel methods*, págs. 185-208, 1999.
- [35] C.-W. Hsu y C.-J. Lin, “A comparison of methods for multiclass support vector machines,” *IEEE transactions on Neural Networks*, vol. 13, n.º 2, págs. 415-425, 2002.
- [36] L. Mella, D. Estay y J. Ardila, “Diseño e implementación de un banco de pruebas para medir vibraciones en rodamientos,” *Departamento de Ingeniería Mecánica, UTFSM*, 2022.

- [37] J. W. Rengifo-Santana, J. Benzaquen-Suñe, J. M. Aller-Castro, A. A. Bueno-Montilla y J. A. Restrepo-Zambrano, "Parameter estimation method for induction machines using instantaneous voltage and current measurements," *Revista Facultad de Ingeniería Universidad de Antioquia*, n.º 75, págs. 57-66, 2015.
- [38] J. Rengifo, J. M. Aller, A. Bueno, J. Viola y J. Restrepo, "Parameter estimation method for induction machines using the instantaneous impedance during a dynamic start-up," en *2012 VI Andean Region International Conference*, IEEE, 2012, págs. 11-14.
- [39] S. Das, P. Purkait, D. Dey y S. Chakravorti, "Monitoring of inter-turn insulation failure in induction motor using advanced signal and data processing tools," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 18, n.º 5, págs. 1599-1608, 2011.
- [40] M. Mohamed, E. Mohamed, A.-A. Mohamed, M. Abdel-Nasser y M. M. Hassan, "Detection of Inter Turn Short Circuit Faults in Induction Motor using Artificial Neural Network," en *2020 26th Conference of Open Innovations Association (FRUCT)*, 2020, págs. 297-304. DOI: [10.23919/FRUCT48808.2020.9087535](https://doi.org/10.23919/FRUCT48808.2020.9087535).
- [41] B. Ion y A. N. Syed, "The Induction Machines Design Handbook," *Electric Power Engineering Series, 2nd ed., by Taylor and Francis Group, LLC, Boca Raton London New York*, 2010.
- [42] *EQUISUM SPA: Compra y venta de productos industriales*, Último acceso 14 de Agosto, 2025, 2021. dirección: <https://www.equisum.cl/producto/es-10-elemento-flexible-rexnord-omega-con-espaciador/>.
- [43] A. P. González, P. J. R. Cervantes y J. L. S. Brú, *Mantenimiento mecánico de máquinas*. Publicacions de la Universitat Jaume I, 2007, vol. 25.
- [44] J. A. B. Rodrigo, *El generador de inducción autoexcitado*. Marcombo, 2010.
- [45] R. Bansal, "Three-phase self-excited induction generators: an overview," *IEEE transactions on energy conversion*, vol. 20, n.º 2, págs. 292-299, 2005.
- [46] H. T. Sánchez y Á. A. A. Alarcón, "Generador de inducción auto-excitado," *Ingeniería e Investigación*, n.º 6, págs. 67-72, 1983.
- [47] A. Al Jabri y A. Alolah, "Capacitance requirement for isolated self-excited induction generator," en *IEE Proceedings B (Electric Power Applications)*, IET, vol. 137, 1990, págs. 154-159.
- [48] J. W. Rengifo Santana, "Estimación de Eficiencia de Máquinas de Inducción en Ambientes Industriales," Tesis Doctoral en Ciencias de la Ingeniería, Universidad Central de Venezuela, Facultad de Ingeniería, Escuela de Ingeniería Eléctrica, 2020.
- [49] Y.-J. Wang, "Analysis of effects of three-phase voltage unbalance on induction motors with emphasis on the angle of the complex voltage unbalance factor," *IEEE Transactions on energy conversion*, vol. 16, n.º 3, págs. 270-275, 2001.

-
- [50] E. C. Quispe Oqueña et al., “Efectos del desequilibrio de tensiones sobre la operación del motor de inducción trifásico. Énfasis en la caracterización del desequilibrio de tensiones y el efecto sobre la potencia nominal,” 2015.
 - [51] J. Aller, A. Bueno, G. Machado, L. Salazar y T. de Energía, “Evaluación Energética de Motores de Inducción Sub Cargados, en Presencia de Armónicas y Desequilibrios de Tensión,” 2012.