

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

**Facultad de Ingeniería en Electricidad y Computación**

DESARROLLO DE ALGORITMO PARA  
DETECCION DE FALLAS EN MAQUINAS DE  
INDUCCION APARTIR DE MEDICIONES DE  
VARIABLES ELECTRICAS

ARTICULO PROFESIONAL DE ALTO NIVEL

Previo la obtención del Título de:

MAGÍSTER EN ELECTRICIDAD, MENCIÓN SISTEMAS  
ELÉCTRICOS DE POTENCIA

Presentado por:

Ing. Freddy Fernando Rubio Zambrano

GUAYAQUIL - ECUADOR

Año: 2024

# DEDICATORIA

Dedico este proyecto de titulación a la comunidad de ingenieros, tecnólogos, técnicos y estudiantes que se dedican a las tareas de reconstrucción y mantenimiento de máquinas eléctricas rotativas, bien sea en la industria o actividades académicas dándole un carácter eminentemente práctico e investigativo a las soluciones.

# AGRADECIMIENTOS

Agradezco a Dios por ser pilar vital y darme las fuerzas necesarias para escalar cada peldaño en mí vida, que sin él nada en mi vida fuera posible.

Agradezco a mi amada esposa, por su apoyo y ánimo que me brinda día con día para alcanzar nuevas metas, tanto profesionales como personales.

A mi adorable hijo Freddy Fernando Rubio Vallejo por su maravillosa llegada este año y que tenga por seguro que siempre lo protegeré para que sea una persona capaz y que pueda valerse por sí mismo.

A mí madre por ser mi consejera, amiga incondicional y darme su amor infinito en todo momento.

A mí padre por ser amigo y mentor e impartirme sus conocimientos y experiencias en el ámbito de las máquinas eléctricas, siendo parte clave en la ejecución de este proyecto.

A mi hermana por su ánimo y apoyo en momentos difíciles.

A mis dos amigos por su sinceridad y lealtad.

A las Empresas Tecnolec e Itelsa por facilitarnos sus instalaciones para el desmontaje y análisis de las máquinas eléctricas, por compartir datos y experiencias adquiridas en el transcurrir del tiempo.

A mí tutor del proyecto Johnny Rengifo Santana PhD por brindar su conocimiento, experiencia y apoyo.

# DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, me corresponde conforme al reglamento de propiedad intelectual de la institución; Freddy Fernando Rubio Zambrano y doy mi consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”



---

Ing. Freddy Fernando Rubio Zambrano

# EVALUADORES

.....  
**Johnny Rengifo Santana PhD**

TUTOR

.....  
**Fernando Vaca Urbano Msc**

REVISOR

# DESARROLLO DE ALGORITMO PARA DETECCIÓN DE FALLAS EN MÁQUINAS DE INDUCCIÓN APARTIR DE MEDICIONES DE VARIABLES ELÉCTRICAS

Freddy Fernando Rubio Zambrano

1Facultad de Ingeniería en Electricidad y Computación, Escuela Superior Politécnica del Litoral (ESPOL),  
Guayaquil, Ecuador, Email: frubio@espol.edu.ec

**Abstract**—La detección de fallas eléctricas o mecánicas en motores de inducción ha sido un desafío persistente para el personal de mantenimiento durante décadas, ya que es crucial para asegurar la seguridad y la eficiencia económica de los procesos industriales. Abordar este desafío requiere disponer de herramientas y técnicas avanzadas para la identificación y diagnóstico de fallos en máquinas eléctricas, así como sistemas de alerta temprana que permitan una toma de decisiones ágil y efectiva, este documento analiza los datos de corriente del estator obtenidos de motores de inducción, tanto sanos como defectuosos, con el objetivo de desarrollar un método de detección de fallas basado en técnicas de aprendizaje automático. El propósito es facilitar la detección temprana de fallas en el motor, incluyendo problemas en el estator, el rotor y los rodamientos. Este estudio propone indicadores basados en la magnitud de la corriente del estator del vector espacial para detectar y diagnosticar fallas en motores de inducción. La efectividad de estos indicadores se evaluó utilizando dos métodos de aprendizaje supervisado. A través de estudios de casos, este documento demostró la alta precisión, simplicidad y solidez del esquema de detección de fallas propuesto para la detección de fallas en motores de inducción. Además, con la integración de la base de datos de conocimiento de características, no se requiere conocimiento previo de los parámetros del motor.

## I. INTRODUCCIÓN

Los motores de inducción tienen un uso extenso en diversas aplicaciones industriales debido a su mantenimiento y robustez comparativamente bajos. La detección temprana de anomalías eléctricas o mecánicas en motores de inducción es importante para garantizar un funcionamiento seguro y económico de los procesos industriales, ya que las fallas normalmente resultan en pérdidas económicas más significativas que los costos asociados con la reparación o el reemplazo del motor. En particular, las fallas de los motores de inducción se pueden clasificar en cuatro grupos principales: fallas del estator, fallas de la jaula del rotor, irregularidades del entre-hierro y fallas de los cojinetes [1][2].

Las averías en los rodamientos representan el 41% de todos los problemas. El 37% de todos los defectos del motor son causados por fallas de cortocircuito entre espiras en los devanados del estator. Las barras del rotor dañadas representan el 10% de todos los defectos. Los voltajes desequilibrados del estator [3], la corriente, el par, la reducción de la eficiencia, las

oscilaciones, la vibración excesiva, el sobrecalentamiento y la reducción del par son todas repercusiones de estos problemas en los motores de inducción [1], [2].

Las fallas producen uno o más síntomas que pueden llegar a ser: tensiones de entre-hierro y corrientes de línea desequilibradas, incremento de la componente oscilatoria, disminución del par promedio, aumento de pérdidas y reducción de la eficiencia, calentamiento excesivo. Para detectar señales relacionadas con fallas, hasta ahora se han desarrollado numerosos métodos de diagnóstico, estos para identificar las fallas anteriores pueden involucrar diferentes campos de la ciencia y la tecnología [4].

Se pueden describir de la siguiente manera:

- Vigilancia de campos electromagnéticos, bobinas alrededor de ejes de motores (detección relacionada con el flujo axial);
- Mediciones de temperatura;
- Reconocimiento por infrarrojos;
- Monitoreo de emisiones de radiofrecuencia;
- Monitoreo de ruidos y vibraciones;
- Análisis químico;
- Mediciones de ruido acústico;
- Análisis de forma de corriente del motor;

En la actualidad, existen dos enfoques principales para resolver el problema de la detección y diagnóstico de fallas [2], [3]. El primero se basa en desarrollar modelos detallados que describen el comportamiento físico del sistema. El segundo enfoque emplea herramientas de inteligencia artificial que permiten analizar datos operativos y descubrir patrones relacionados con fallas [5], [6]. Los modelos basados en principios físicos suelen enfrentar dificultades para representar con precisión sistemas complejos, lo que puede limitar su rendimiento. Por otro lado, los métodos impulsados por datos filtran la información más relevante y utilizan algoritmos de aprendizaje automático para diagnosticar y detectar fallas de manera más eficaz.

Ha habido una cantidad significativa de investigaciones en esta área, incluyendo análisis de vibración y análisis de corriente del motor o análisis de firma de corriente del motor [7], [6]. Aunque los métodos de monitoreo térmico y de

vibración se han empleado durante décadas, la mayoría las investigaciones previas sobre monitoreo en línea o inspecciones periódicas de motores de inducción se basan en análisis de corriente del estator, que son bien conocidos por proporcionar un monitoreo continuo no intrusivo [5], [6].

Los algoritmos de aprendizaje automático supervisados se utilizan ampliamente en métodos de diagnóstico y detección de fallas basadas en datos para la clasificación. Algunos de los algoritmos más populares utilizados para el aprendizaje automático supervisado incluye árboles de decisión, bosques aleatorios, máquinas de vectores de soporte y redes neuronales [6]. El rendimiento de los modelos de aprendizaje automático supervisados se evalúa utilizando un conjunto de datos de prueba independiente del conjunto de datos de entrenamiento. Las métricas de evaluación más comunes para problemas de clasificación son la exactitud, la precisión y la recuperación. Estas métricas se pueden utilizar para comparar diferentes modelos y ajustar sus parámetros. La discusión sobre el diagnóstico de fallas utilizando datos se ha centrado principalmente en tratar distintas categorías de fallas mediante la utilización de indicadores, junto con una descripción detallada [6], [7], [8].

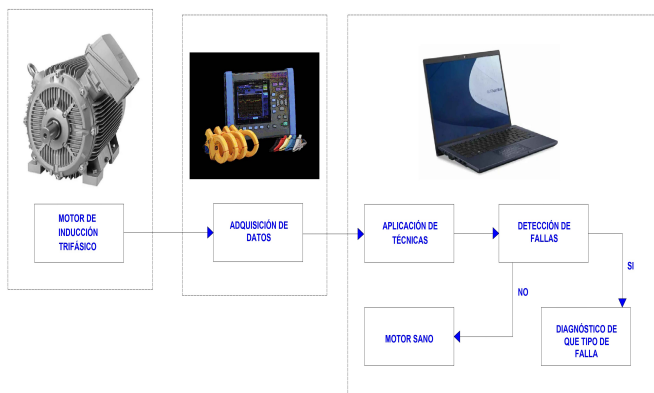


Fig. 1. Flujo de detección y diagnóstico de fallas en máquinas de inducción.

En el transcurso del tiempo se ha hecho revisiones exhaustivas del estado del arte en la detección y diagnóstico de fallas en máquinas eléctricas utilizando inteligencia artificial [4]. Estas compilaciones destacaron elementos significativos, como el uso de indicadores basados en análisis en el dominio de la frecuencia a través de la transformada rápida de Fourier o transformada wavelet para diagnosticar diversos tipos de fallas en máquinas eléctricas. Este estudio propone la utilización de indicadores basados en el análisis de la corriente utilizando la transformada de Park para detectar distintos tipos de fallas en motores de inducción, aplicando el algoritmo K-NN de aprendizaje automático supervisado. Se emplean datos experimentales que abarcan una variedad de condiciones de operación, incluyendo diferentes niveles de potencia, velocidad, voltaje y carga en el eje, con el objetivo de evaluar la eficacia de estos indicadores en la identificación precisa de fallas.

Las principales contribuciones de este trabajo son las siguientes:

**Desarrollo de indicadores estadísticos:** Se introducen indicadores basados en la magnitud de la corriente fasorial espacial para la detección temprana de fallas en motores de inducción.

**Evaluación del rendimiento:** Se examina la eficacia de los indicadores propuestos utilizando el algoritmo de clasificación K-NN, combinando y evaluando su rendimiento en diferentes escenarios.

**Comparación con métodos existentes:** Se compara la efectividad de los indicadores desarrollados con los resultados obtenidos mediante la transformada wavelet discreta, destacando las ventajas y limitaciones de cada enfoque.

Este artículo se ha dividido en diferentes secciones. La sección 2 enumera las fallas y sus causas en los motores de inducción. La sección 3 se presenta la técnica mediante algoritmos de aprendizaje para los motores de inducción. La sección 4 incluye el monitoreo de condición y el diagnóstico de fallas basados en algoritmos de aprendizaje automático la corroboración aplicando a motores en fallos y en buen estado. La Sección 5 presenta la discusión, las limitaciones y los alcances futuros de los algoritmos de detección de fallas basados en aprendizaje automático. Finalmente, la Secta. 6 concluye el trabajo.

## II. FALLAS Y CAUSAS

Las fallas en motores de inducción se dividen en mecánicas (como problemas en rodamientos y excentricidad) y eléctricas (defectos en devanados del estator y rotor). Los síntomas incluyen desequilibrio magnético, sobrecalentamiento, aumento de pérdidas, reducción de eficiencia y disminución del par promedio. Las causas comunes son sobrecarga, exceso de velocidad, defectos de fabricación, suciedad, fallos en componentes, sobrecalentamiento y estrés dieléctrico [2], [9], [3].

### A. Fallo en Rodamientos

El rodamiento es uno de los componentes fundamentales en los motores de inducción, ya que permite la separación entre la parte estacionaria y la parte móvil. Los fallos en el rodamiento pueden ocurrir por diversas razones, como el desgaste natural, el envejecimiento, cargas de choque, sobrecalentamiento, desequilibrios o una lubricación inadecuada. Estos fallos pueden manifestarse como defectos en la pista de rodadura exterior, la pista de rodadura interior, las bolas o la pista interna [2][10].

### B. Ruptura de la barra del rotor

El diseño del rotor en máquinas de inducción tipo jaula de ardilla ha permanecido sin cambios significativos, gracias a que es un diseño robusto [11]. Las fallas en el rotor representan entre el 5% y el 10% de las fallas totales en los motores de inducción [1], [2]. Estas fallas son más comunes en motores de potencia media o alta que en los de potencia baja, debido a las elevadas demandas de par de arranque y al estrés térmico. La presencia de una o varias barras rotas genera un campo magnético intensificado en las cercanías de la zona defectuosa del motor de inducción. Esto ocurre por la desmagnetización

local causada por la frecuencia de deslizamiento y la corriente inducida en las ranuras dañadas del rotor. La densidad de flujo magnético es mayor cerca del área afectada. A continuación, se detallan algunas posibles causas del daño en una barra rota :

1. Estrés como el estrés magnético y el estrés térmico causados por fuerzas electromagnéticas, atracción magnética desequilibrada, ruidos, sobrecarga térmica, pérdidas excesivas, chispas;
2. Tensiones dinámicas;
3. Tensiones mecánicas;

Si se presenta una falla en el rotor de un motor de inducción de tipo jaula de ardilla, el flujo de corriente en la barra afectada se verá bloqueado. Como consecuencia, no habrá un campo magnético disponible cerca de la barra dañada en el rotor.

### C. Fallas Estatóricas

Estos problemas están principalmente relacionados con fallas en los devanados y en el aislamiento. Pueden manifestarse como fallas de línea a tierra o de línea a línea, y representan entre el 30% y el 40% de las fallas reportadas en motores de inducción [4]. Los factores que contribuyen a las fallas en el aislamiento del estator incluyen:

- 1) Descargas eléctricas;
- 2) Sobrecalentamiento en el devanado, que provoca temperaturas elevadas;
- 3) Refuerzo inadecuado en el devanado [4].

### D. Excentricidad

La distribución desigual del entre-hierro entre el estator y el rotor puede causar excentricidad [4][11]. Aunque una excentricidad pequeña no suele tener un gran impacto, cuando es significativa, puede provocar una distribución irregular del flujo magnético. Esto puede resultar en una atracción magnética desequilibrada, que podría llevar al contacto entre el estator y el rotor. Además, la excentricidad provoca diferencias en las inductancias, generando un flujo magnético desigual en el entre-hierro y creando frecuencias de falla en la corriente de línea. La excentricidad en el entre-hierro se clasifica principalmente en tres tipos: estática, dinámica y excentricidad mixta.

## III. TEORÍA DE LOS ALGORITMOS DE APRENDIZAJE AUTOMÁTICO

La implementación de estos algoritmos ha contribuido al desarrollo de sistemas eficientes que no requieren conocimientos previos para operar. Entre los algoritmos comúnmente utilizados en la predicción y diagnóstico de fallas se encuentran las máquinas de vectores de soporte, el método de k-vecinos más cercanos, las redes neuronales artificiales, los árboles de decisión, el clasificador bayesiano, el bosque aleatorio y las redes neuronales convolucionales [4].

### A. El algoritmo de los k-vecinos más cercanos

El método de k-Vecinos más cercanos (k-NN) se encuentra entre las técnicas de aprendizaje automático más sencillas empleadas para problemas de clasificación. k-NN es un enfoque no paramétrico y basado en instancias que agrupa elementos similares. Se clasifica dentro del aprendizaje supervisado y se usa ampliamente en el reconocimiento de patrones y la minería de datos. En este algoritmo, las muestras dentro de una clase tienden a estar cerca de otras con características similares [4]. Todas las muestras se representan como puntos en un espacio N-dimensional  $\mathfrak{R}^n$ . La distancia euclidiana se utiliza para determinar las muestras con similitudes. Sea una muestra aleatoria  $x$  dada por el vector de características  $a_1(x), a_2(x), \dots, a_n(x)$  muestra la distribución de la muestra  $x$ . La distancia entre dos muestras  $x_i$  y  $x_j$  se define como  $d(x_i, x_j)$ , donde:

$$d(x_i, x_j) = \sqrt{\sum \ln(a_r(x_i) - a_r(x_j))^2} \quad (1)$$

La función objetivo en k-NN puede ser de valor real o de valor discreto. Para cada ejemplo de entrenamiento  $(x, f(x))$ , se agrega a la lista de ejemplos de entrenamiento. Para que se clasifique una instancia de consulta  $x_q$ . Sea  $x_1, x_2, \dots, x_k$  las  $k$  instancias de muestras de entrenamiento que están más cercanas a  $x_q$ , entonces [4]:

$$\hat{f}(x_q) \leftarrow \underset{v \in V}{\operatorname{argmax}} \sum_{i=1}^k \delta(v, f(x_i)) \quad (2)$$

donde  $\delta(a, b) = 1$  si  $a = b$  y donde  $(a, b) = 0$  en caso contrario.

## IV. MONITOREO DE LA CONDICIÓN BASADO EN ALGORITMOS DE APRENDIZAJE AUTOMÁTICO DEL MOTOR DE INDUCCIÓN

### A. Preprocesamiento de datos

La aplicación de algoritmos de aprendizaje automático en la supervisión de motores de inducción requiere el procesamiento de datos en bruto. La implementación de técnicas de inteligencia artificial en aplicaciones reales implica la extracción de características y la creación de un vector de características como entrada [4]. Para desarrollar patrones de reconocimiento de fallas, se realizan análisis con diferentes indicadores y relacionarlos entre sí y escoger la mejor relación para la separación de datos según el tipo de falla.

1) *Análisis estadístico de señales:* Las fallas eléctricas y mecánicas produce anomalías en la corrientes de línea desequilibradas o deformadas lo que es importante analizar estas formas de onda. Debido a la naturaleza de esta forma de onda desequilibrada o deformada, las corrientes de línea solo tienen componentes de secuencia positiva y negativa[6]; Por lo tanto, el vector espacial de corriente, representado por  $\vec{i}_s = \sqrt{2}I_1 e^{j\omega_s t} + \sqrt{2}I_2 e^{-j\omega_s t}$ , se describe a través de la transformación a vectores espaciales. Esta transformación permite analizar las corrientes en términos de componentes en un espacio tridimensional. En presencia de anomalías, el



lugar geométrico del vector espacial de corriente del estator toma la forma de una elipse. Esta elipse refleja las variaciones en la magnitud y fase de las corrientes, proporcionando información sobre el estado operativo del motor de inducción; estos componentes se deforman en direcciones opuestas en el plano complejo, como se muestra en la Figura 2. Los componentes de secuencia positiva y negativa giran en sentidos contrarios pero a la misma velocidad. En caso de un desequilibrio, como una falla por cortocircuito entre espiras, la forma elíptica se intensifica. La trayectoria de la amplitud del vector espacial de la corriente,  $|i_{s}|$ , a lo largo del tiempo, sigue un patrón significativo [6].




Fig. 2. Ubicación del vector espacial de la corriente del estator: (a) interacción entre las componentes positivas y negativas del vector espacial; (b) medición de un motor de inducción sano; y (c) medición de un motor de inducción defectuoso con fallo entre espiras.[6]

La forma de onda del vector espacial de la corriente del estator ofrece una información crucial para la identificación de fallas tanto en el estator como en el rotor, así como para la detección de problemas mecánicos y eléctricos, mediante la aplicación de algoritmos de aprendizaje supervisado. Los índices descriptivos que sintetizan las principales características de la señal son especialmente adecuados para entrenar estos algoritmos, ya que permiten una clara diferenciación entre condiciones operativas normales y aquellas que presentan defectos. Además, estos índices pueden ser fundamentales para extender la aplicación de los resultados obtenidos a otras máquinas similares. En este estudio, se emplean los siguientes indicadores estadísticos como características para el análisis [6]:

- 1) El factor de forma: la raíz cuadrada media (RMS) dividida por la media del valor absoluto de la señal.

$$X_{SF} = \frac{\sqrt{\frac{1}{N} \sum_{k=1}^N x_k^2}}{\frac{1}{N} \sum_{k=1}^N ||x_k||} \quad (3)$$

- 1) El factor de impulso compara el pico del valor absoluto ( $x_p$ ) con el nivel medio de la señal.

$$X_{IF} = \frac{x_p}{\frac{1}{N} \sum_{k=1}^N ||x_k||} \quad (4)$$

- 2) Factor de aclaramiento: el valor pico dividido por el valor medio al cuadrado de las raíces cuadradas de las amplitudes absolutas.

$$X_{clear} = \frac{x_p}{\left(\frac{1}{N} \sum_{k=1}^N \sqrt{||x_k||}\right)^2} \quad (5)$$

- 1) El factor de cresta: el valor pico dividido por el RMS.

$$X_{crest} = \frac{x_p}{\sqrt{\frac{1}{N} \sum_{k=1}^N ||x_k||^2}} \quad (6)$$

Estas características resultan ser altamente apropiadas y eficaces para entrenar algoritmos de aprendizaje automático, ya que facilitan la capacidad de estos sistemas para identificar y diferenciar entre el buen funcionamiento y aquellas que presentan fallos o problemas. Gracias a estas características, los algoritmos pueden aprender a reconocer patrones específicos que indican el buen estado o el mal funcionamiento del motor de inducción, mejorando así su capacidad para realizar clasificaciones precisas y tomar decisiones informadas.

2) *Transformada Wavelet Discreta*: La transformada Wavelet es una técnica avanzada de procesamiento de señales que permite descomponer una señal en sus componentes de frecuencia y tiempo de manera simultánea. Esta herramienta es ampliamente utilizada en diversas aplicaciones para analizar tanto señales estacionarias como transitorias. Existen dos enfoques principales para analizar una señal mediante la transformada Wavelet: el dominio continuo y el dominio discreto.

En el dominio del tiempo, la transformada Wavelet genera coeficientes que reflejan la similitud entre la señal original y la función wavelet, lo que permite extraer información significativa de las señales. No obstante, su uso requiere mayor potencia computacional debido a la complejidad del análisis continuo a diferentes niveles de escala

Por otro lado, en el dominio de la frecuencia la transformada Wavelet se basa en la descomposición multiescala, donde la señal se divide en diferentes escalas y ubicaciones utilizando funciones wavelet discretas. Esta técnica permite reducir la señal original en una serie de aproximaciones y detalles a distintas resoluciones. Esta emplea filtros de paso bajo y paso alto para extraer los coeficientes de señal detallados y aproximados. Este proceso de descomposición se repite de manera recursiva según sea necesario para alcanzar la resolución deseada. El número de niveles de descomposición ( $n_{ls}$ ) se determina en función de la relación entre la frecuencia de muestreo ( $f_s$ ) y la frecuencia fundamental ( $f_1$ ), calculándose de la siguiente manera[12]:

$$n_{ls} > \text{int}\left(\frac{\log\left(\frac{f_s}{f_1}\right)}{\log(2)}\right) + 1. \quad (7)$$

La energía de la señal asociada a cada nivel de descomposición en la transformada Wavelet Discreta se calcula de la siguiente manera:

- 1) Obtener los Coeficientes de Descomposición: Primero, se deben extraer los coeficientes de detalle (D) y los coeficientes de aproximación (A) para cada nivel de descomposición. Estos coeficientes resultan de aplicar los filtros de paso bajo y paso alto a la señal original.
- 2) Calcular la Energía de los Coeficientes: Para cada conjunto de coeficientes obtenidos en un nivel específico, se calcula la energía sumando el cuadrado de cada coeficiente. Matemáticamente, si  $c_i$  representa un coeficiente

de descomposición en un nivel dado, la energía  $E_i$  de ese nivel se calcula como:

$$E_i = \sum_k |c_{i,k}|^2 \quad (8)$$

donde  $c_{i,k}$  son los coeficientes en el nivel  $i$  y  $k$  denota los diferentes puntos en ese nivel.

- 3) Repetir para Cada Nivel: Este cálculo se repite para cada nivel de descomposición, tanto para los coeficientes de detalle como para los coeficientes de aproximación. Así, se obtiene una representación de la energía distribuida a través de las diferentes escalas y resoluciones.
- 4) Interpretación de la Energía: La energía calculada en cada nivel proporciona información sobre la cantidad de información contenida en ese nivel específico de resolución. Esto es útil para analizar la estructura y los patrones de la señal en diferentes escalas, así como para identificar características relevantes o detectar anomalías.

Este procedimiento permite obtener una comprensión detallada de cómo se distribuye la energía de la señal en función de las diferentes escalas de la descomposición wavelet, facilitando el análisis y la interpretación de la señal en contextos de procesamiento y detección de fallas.

Estudios previos han demostrado con éxito la utilización de indicadores para la detección de fallas estatísticas, fallas en rodamientos y fallas en el rotor en motores de inducción, empleando la energía calculada en el nivel más energético de la descomposición de la señal para cada línea de corriente, como se detalla en [12]. Estos indicadores, denominados  $S_1$ ,  $S_2$  y  $S_3$ , se definen en función de la energía obtenida a partir de la descomposición de la señal mediante la Transformada Wavelet Discreta en el nivel más energético para cada línea de corriente. A continuación, se presentan las definiciones y descripciones de estos indicadores [12], [6]:

$$S_1 = \frac{E_{dia}}{E_{dib}} \quad (9)$$

$$S_2 = \frac{E_{dib}}{E_{dic}} \quad (10)$$

$$S_3 = \frac{E_{dic}}{E_{dia}} \quad (11)$$

Cada uno de estos indicadores está diseñado para capturar la energía en el nivel de descomposición que mejor refleja el estado de la máquina en relación con los tipos de fallas específicas mencionadas. La implementación y análisis de estos indicadores permiten una monitorización más precisa y efectiva del estado de los motores de inducción, facilitando la identificación temprana de fallas y la implementación de estrategias de mantenimiento preventivo.

### B. Detección de fallas basada en $k$ -vecinos más cercanos

El algoritmo  $k$ -Nearest Neighbors ( $k$ -NN) es un método de aprendizaje basado en instancias que ha demostrado ser altamente efectivo en la clasificación de fallas. A continuación,

se explican las razones por las cuales  $k$ -NN es una herramienta valiosa en este contexto:

- 1) Principio de Funcionamiento:  $k$ -NN clasifica una nueva instancia basándose en la mayoría de las etiquetas de sus vecinos más cercanos en el espacio de características. Es decir, cuando se le presenta una nueva muestra,  $k$ -NN busca las  $k$  instancias más cercanas a esta muestra en el conjunto de datos de entrenamiento y asigna la etiqueta más frecuente entre estos vecinos. Esto permite que el algoritmo haga predicciones basadas en la similitud con ejemplos previos.
- 2) Simplicidad y Eficiencia: Una de las grandes ventajas de  $k$ -NN es su simplicidad. No requiere un proceso de entrenamiento explícito, ya que simplemente almacena todas las instancias de entrenamiento y realiza cálculos de similitud durante la clasificación. Esta característica lo hace especialmente útil en aplicaciones de clasificación de fallas, donde la rapidez en la evaluación de nuevas muestras es crucial.
- 3) Adaptabilidad a Datos Complejos:  $k$ -NN puede manejar datos complejos y no lineales sin requerir un modelo paramétrico explícito. Esto es ventajoso en el análisis de fallas, donde las características de las señales pueden variar significativamente y pueden no seguir distribuciones simples.
- 4) Eficiencia en Clasificación de Fallas: En problemas de clasificación de fallas,  $k$ -NN puede identificar patrones en las características extraídas de las señales de manera efectiva. Por ejemplo, en la detección de fallas en motores de inducción,  $k$ -NN puede clasificar distintos tipos de fallas basándose en características extraídas mediante transformaciones como la Transformada Wavelet Discreta o índices descriptivos de la energía. Su capacidad para considerar los vecinos más cercanos asegura que las predicciones se basen en instancias similares, lo que resulta en una clasificación precisa.
- 5) Configuración de Parámetros: La eficacia de  $k$ -NN depende en gran medida de la selección adecuada del número de vecinos ( $k$ ) y de la métrica de distancia utilizada (como Euclidiana, Manhattan, etc.). Una adecuada elección de estos parámetros puede mejorar significativamente la precisión de la clasificación de fallas.

En resumen,  $k$ -NN es un método robusto y flexible para la clasificación de fallas debido a su simplicidad, capacidad para manejar datos no lineales y eficacia en la clasificación basada en la similitud con instancias conocidas. Esto lo convierte en una herramienta valiosa en el análisis y diagnóstico de fallas en sistemas complejos.

## V. RESULTADO EXPERIMENTALES, DISCUSIÓN, LIMITACIONES Y ALCANCES FUTUROS

### A. Análisis experimental

Se emplearon motores de inducción trifásicos que presentaban diversos tipos de fallos, incluyendo fallos entre espiras,

problemas en los rodamientos, defectos en las barras del rotor, excentricidad y recalentamiento de los bobinados del estator. Estos motores variaban en potencia, pares de polos, voltaje y niveles de carga. Para evaluar el comportamiento de los motores en estas condiciones, se midieron las corrientes de línea utilizando un analizador de red MEATROL AO-Mi550. En la Figura 3 se ilustra una de las mediciones realizadas en un motor de inducción con una potencia de 250 HP, operando a un voltaje de 460V y conectado a una carga de molino de bolas. En la Tabla 1 los datos nominales de uno de los motores registrados. Se recopilaron un total de 15 puntos de operación en los que el motor presentaba defectos en los rodamientos, y también se registraron los puntos de operación con el motor en condiciones normales. Para cada punto de operación, se documentó la forma de onda de las corrientes de fase del motor con una frecuencia de muestreo de 8000 puntos por ciclo.

TABLE I  
DETALLES DE PLACA DEL MOTOR DE INDUCCIÓN.

Características del Motor de Inducción	Detalles
Serie	1LE0001-3BD5
Fabricante	Siemens
Potencia	250 HP
Voltaje de Operación	220/440 V
Conexión	$\Delta\Delta/\Delta$
Frecuencia	60 Hz
Numero de Fases	3
Corriente Nominal	285 A




Fig. 3. Pruebas experimentales en campo: (a) Molino de bolas que lo impulsa un Motor de inducción de 250 Hp a 460V; y (b) Captura de formas de Onda Corriente.

Se tomó registro de 37 motores de inducción con potencias nominales van entre 3 y 400 Hp. Para cada caso se tomó registro de 3 a 7 muestras, considerando mediciones con el motor con falla y sano. En total 9 motores presentaban falla tipo I, 17 tipo II, 9 tipo III y 2 tipo IV. La Tabla 2 presenta la información nominal de todos los motores utilizados para construir la base de datos y su respectivo tipo de falla utilizando cuatro grupos de características, a saber, I, II, III y IV. El conjunto de datos I comprende indicadores asociados

con los motores en buen estado. El conjunto de datos II incluye motores con fallos en los rodamientos. El conjunto de datos III comprende fallos de tipo estáticos como un cortocircuito entre espiras y el conjunto IV son los fallos rotóricos en un motor de inducción.

TABLE II  
REGISTRO Y CARACTERÍSTICAS NOMINALES DE LOS MOTORES ELÉCTRICOS QUE SE REALIZO LAS MEDICIONES ANTES Y DESPUÉS DE LA FALLA CON SU RESPECTIVA REPARACIÓN.

HP	EST	VF	APL	PP	V	Co.	A
200	III	No	Molino	4	460	$\Delta$	235
250	I	Si	Molino	4	460	$\Delta$	295
5	III	No	Bomba Sum	2	220/440	$\Delta/Y$	7.5
175	II	No	Trituradora	4	220/440	$\Delta\Delta/\Delta$	225
7.5	II	No	Banda Trans	2	220/440	$\Delta\Delta/\Delta$	11
7.5	II	No	Banda Trans	2	220/440	$\Delta/Y$	12
15	II	No	Banda Trans	2	220/440	$\Delta/Y$	22
3	II	No	Banda Trans	2	220/440	$\Delta/Y$	4.5
40	II	No	Banda Trans	2	220/440	$\Delta/Y$	55
125	II	No	Mandíbula	2	220/440	$\Delta\Delta/\Delta$	158
230	III	No	Molino	3	460	$\Delta$	253
175	IV	No	Molino	3	220/440	$\Delta\Delta/\Delta$	235
250	I	Si	Bomba	2	460	$\Delta$	285
10	III	Si	Maquina Vibra	4	220/440	$\Delta/Y$	12.5
400	II	No	Compresor	3	460	$\Delta$	492
10	III	Si	Maquina Vibra	4	220/440	$\Delta/Y$	12.5
200	I	No	Compresor	1	460	$\Delta$	245.3
100	III	Si	Mandíbula	4	220/440	$\Delta/Y$	124.3
20	I	No	Bomba	1	220/440	$\Delta\Delta/\Delta$	24.5
15	II	No	Maquina Vibra	2	220/440	$\Delta\Delta/\Delta$	18.3
10	II	Si	Bomba	2	220/440	$\Delta\Delta/\Delta$	13.2
25	II	No	Bomba	1	220/440	$\Delta\Delta/\Delta$	30.3
10	II	No	Bomba	2	220/440	$\Delta\Delta/\Delta$	12.5
30	III	No	Bomba	1	220/440	$\Delta\Delta/\Delta$	42.32
200	II	Si	Mandíbula	4	460	$\Delta$	235
300	I	No	Compresor	2	460	$\Delta$	385.6
30	III	No	Bomba	1	220/440	$\Delta\Delta/\Delta$	43.2
25	IV	No	Molino	2	220/440	$\Delta\Delta/\Delta$	29.3
150	II	Si	Compresor	2	220/440	$\Delta\Delta/\Delta$	195.7
50	I	No	Molino	2	220/440	$\Delta/Y$	68.3
3	III	No	Banda Trans	2	220/440	$\Delta/Y$	4.8
10	I	Si	Bomba	1	220/440	$\Delta\Delta/\Delta$	12.7
30	II	No	Bomba	1	220/440	$\Delta\Delta/\Delta$	42.5
3	I	No	Banda Trans	2	220/440	$\Delta\Delta/\Delta$	4.1
15	I	Si	Bomba	1	220/440	$\Delta\Delta/\Delta$	18.3
10	II	No	Bomba	2	220/440	$\Delta\Delta/\Delta$	12.2
25	II	Si	Molino	2	220/440	$\Delta\Delta/\Delta$	29.6

## B. Resultados y Discusiones

Se utilizaron ciento ochenta y cinco mediciones para el entrenamiento y la evaluación de los métodos de clasificación obteniendo un conjunto de datos que deben clasificarse en cuatro grupos (I, II, III y IV), a continuación se presenta en la Figura 4 uno de los motores que se analizaron con fallo en los rodamientos, tomando las formas de onda de corriente antes después de su reparación.

Para este conjunto de datos, se calculó los indicadores estadísticos y la transformada de Wavelet Discreta con los datos de las formas de onda de corriente de los motores de inducción a prueba, en la Figura 5 podemos ver la forma de onda correspondiente al motor de inducción que tiene un fallo estático.



Fig. 4. Motor del Fabricante Wolong 10 HP, 4 pares de polos con fallo en los rodamientos producido por un falta de mantenimiento preventivo.

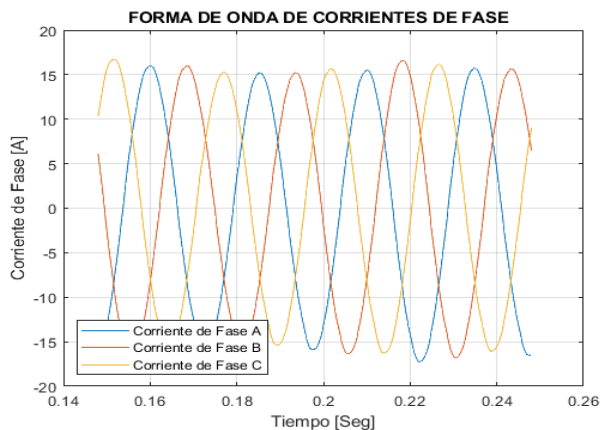


Fig. 5. Forma de onda de las corrientes de fase del Motor del Fabricante Wolong 10 HP, 4 pares de polos con fallo en los rodamientos.

El siguiente paso implicó el entrenamiento del algoritmo de clasificación k-NN con el objetivo de detectar de manera anticipada fallas que puedan surgir en el futuro. Este proceso de entrenamiento del método k-NN es fundamental para mejorar la capacidad del sistema de identificar problemas potenciales antes de que se conviertan en fallas graves. Al ajustar y optimizar el algoritmo, se busca asegurar que el sistema pueda reconocer patrones indicativos de problemas incipientes con la mayor precisión posible, permitiendo así una intervención proactiva y oportuna, en la Figura 6 se presenta los respectivos gráficos de dispersión para diferentes combinaciones de indicadores calculados.

Durante el proceso de entrenamiento, se enfocó en maximizar la precisión del modelo en cada caso, el entrenamiento y la validación se la realizo en MATLAB en el cual se dividió los datos de manera correcta con la función *cvpartition* para crear conjuntos de entrenamiento y validación, luego se entrenó un modelo de análisis discriminante lineal usando *fitcdiscr* y por último se evaluó su rendimiento en el conjunto de prueba.

Aplicando este algoritmo nos permite detectar fallas de manera temprana, antes de que sea necesario realizar un mantenimiento correctivo. Así, al ingresar un nuevo dato en

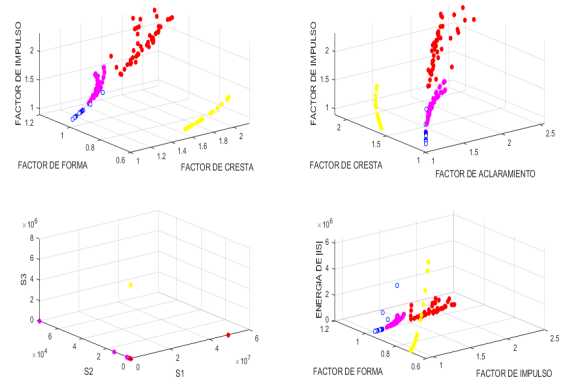


Fig. 6. Gráficos de dispersión para diferentes combinaciones de características. (a) Factor de impulso, factor de forma y factor de cresta, (b) Factor de impulso, factor de inclinación y relación (c) S1, S2 y S3, y (d) Energía de la magnitud del vector espacial ( $\|is\|$ ), factor de forma y factor de impulso.

el sistema, es posible determinar su pertenencia a un sector particular y prever posibles fallas, facilitando una intervención temprana y evitando problemas más graves en el futuro.

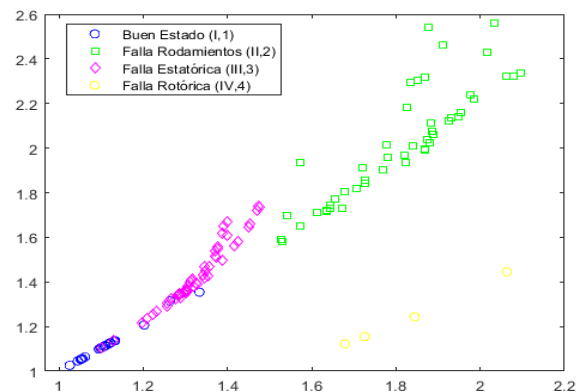


Fig. 7. Grafica de dispersión por grupo correspondiente del factor de impulso y factor de cresta.

Se calcula la matriz de confusión que es una herramienta utilizada en clasificación para evaluar el rendimiento de un modelo. Contiene la comparación entre las etiquetas verdaderas (conocidas) y las predichas por el modelo. Cada elemento en la posición  $(i, j)$  indica cuántas muestras que pertenecen a la clase  $i$  fueron clasificadas como la clase  $j$ . Los elementos en la diagonal corresponden a las observaciones clasificadas correctamente, en la Figura 7, se presenta los resultados de la matriz de confusión calculada.

De las 285 observaciones de entrenamiento, el 7 % o 13 observaciones están mal clasificadas por la función de clasificación discriminante lineal, esta clasificación representan las siguientes categorías de motores:

- 1) Motores en buen estado : Este grupo incluye motores que no presentan fallas detectables según los indicadores

1	60		3	
2		44	3	
3	3		68	
4				4
	1	2	3	4

Fig. 8. Matriz de confusión del conjunto de entrenamiento de motores de inducción en buen estado y falla.

utilizados.

- 2) Motores con fallos en los rodamientos: Este grupo agrupa los motores que muestran signos de problemas en los rodamientos, identificados a través de los indicadores calculados.
- 3) Motores con fallos en el estator: Los motores clasificados en este grupo tienen fallos en el estator, como lo indican los valores de los factores de impulso y cresta.
- 4) Motores con fallos en el rotor: Este grupo incluye motores con fallos detectados en el rotor, de acuerdo con los cálculos de los indicadores.

Según los datos de entrenamiento, la precisión que se determina es el 95.14, que proporciona una buena referencia para identificar el estado específico de los motores, facilitando la detección precisa de problemas y la intervención adecuada.

## VI. CONCLUSIÓN

Este documento expone un enfoque novedoso para detectar fallas en máquinas de inducción mediante un algoritmo de aprendizaje supervisado. La metodología se basa en indicadores derivados de la magnitud del vector de corriente del estator. Los resultados obtenidos en los experimentos evidencian la efectividad de los métodos de clasificación evaluados por kNN para detectar fallas en los motores de inducción, independientemente de su porcentaje de carga a la cual es sometido el motor.

El enfoque propuesto se validó experimentalmente utilizando motores inducción con cortocircuitos en todas las fases de la máquina y con varias resistencias de falla, diferentes estado de fallas en los rodamientos y con motores con fallas en una de las barras del rotor, además de diferentes potencias nominales, estados de carga y también impulsados por variadores de frecuencia.

## REFERENCES

[1] P. Zhang, Y. Du, T. G. Habetler, and B. Lu, "A survey of condition monitoring and protection methods for medium-voltage induction motors," vol. 47, no. 1, pp. 34–46. [Online]. Available: <http://ieeexplore.ieee.org/document/5620974/>

[2] M. A. Sheikh, S. T. Bakhsh, M. Irfan, N. B. M. Nor, and G. Nowakowski, "A review to diagnose faults related to three-phase industrial induction motors," vol. 22, no. 4, pp. 1546–1557. [Online]. Available: <https://link.springer.com/10.1007/s11668-022-01445-2>

[3] M. Irfan, N. Saad, R. Ibrahim, and V. S. Asirvadam, "An on-line condition monitoring system for induction motors via instantaneous power analysis," vol. 29, no. 4, pp. 1483–1492. [Online]. Available: <http://link.springer.com/10.1007/s12206-015-0321-9>

[4] P. Kumar and A. S. Hati, "Review on machine learning algorithm based fault detection in induction motors," vol. 28, no. 3, pp. 1929–1940. [Online]. Available: <https://link.springer.com/10.1007/s11831-020-09446-w>

[5] S. Nandi, H. Toliyat, and X. Li, "Condition monitoring and fault diagnosis of electrical motors—a review," vol. 20, no. 4, pp. 719–729. [Online]. Available: <http://ieeexplore.ieee.org/document/1546063/>

[6] J. Rengifo, J. Moreira, F. Vaca-Urbano, and M. S. Alvarez-Alvarado, "Detection of inter-turn short circuits in induction motors using the current space vector and machine learning classifiers," vol. 17, no. 10, p. 2241. [Online]. Available: <https://www.mdpi.com/1996-1073/17/10/2241>

[7] T. Yang, H. Pen, Z. Wang, and C. S. Chang, "Feature knowledge based fault detection of induction motors through the analysis of stator current data," vol. 65, no. 3, pp. 549–558. [Online]. Available: <https://ieeexplore.ieee.org/document/7372442/>

[8] S. Das, P. Purkait, D. Dey, and S. Chakravorti, "Monitoring of inter-turn insulation failure in induction motor using advanced signal and data processing tools," vol. 18, no. 5, pp. 1599–1608. [Online]. Available: <https://ieeexplore.ieee.org/document/6032830/>

[9] A. Siddique, G. Yadava, and B. Singh, "A review of stator fault monitoring techniques of induction motors," vol. 20, no. 1, pp. 106–114. [Online]. Available: <http://ieeexplore.ieee.org/document/1396088/>

[10] D. Ramya, R. Basha, and M. Bharathi, "FAULT DIAGNOSIS OF INDUCTION MOTOR DRIVE USING MOTOR CURRENT SIGNATURE ANALYSIS," in *Proceedings of the First International Conference on Advanced Scientific Innovation in Science, Engineering and Technology, ICASSET 2020, 16-17 May 2020, Chennai, India*. EAI. [Online]. Available: <http://eudl.eu/doi/10.4108/eai.16-5-2020.2304102>

[11] F. F. R. Zambrano, "ESQUEMAS, CA ´ LCULO y MANTENIMIENTO DE BOBINADOS DE MA ´ QUINAS ELE ´ CTRICAS TRIFA ´ SICAS y MONOFA ´ SICAS."

[12] H. Cherif, A. Benakcha, I. Laib, S. E. Chehaidia, A. Menacer, B. Soudan, and A. Olabi, "Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor," vol. 212, p. 118684. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0360544220317928>