

**ALGORITMO DE DETECCIÓN DE FALLAS
PARA MOTORES TRIFÁSICOS TIPO JAULA
DE ARDILLA BASADO EN EL ANÁLISIS DE
COMPONENTES PRINCIPALES**



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO
CARRERA DE ELECTRICIDAD

**ALGORITMO DE DETECCIÓN DE FALLAS
PARA MOTORES TRIFÁSICOS TIPO JAULA
DE ARDILLA BASADO EN EL ANÁLISIS DE
COMPONENTES PRINCIPALES**

Trabajo de titulación previo a la obtención del
Título de Ingeniero Eléctrico

AUTOR: CESAR HUMBERTO ORELLANA PINZÓN
TUTOR: LEONY ORTIZ MATOS

Quito -Ecuador
2024


Cesar Humberto Orellana Pinzón

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

Universidad Politécnica Salesiana, Quito – Ecuador 2024


Carrera de Electricidad

Breve reseña histórica e información de contacto.



Cesar Humberto Orellana Pinzón (Y'1998). Realizó sus estudios de nivel secundario en el Colegio Técnico “José de la Cuadra” de la ciudad de Quito. Actualmente se encuentra cursando el décimo semestre de la carrera de Electricidad de la Universidad Politécnica Salesiana. corellap3@est.ups.edu.ec

Dirigido por:



Leony Ortiz Matos (Y'1982). Recibió el título de Ms. e Ingeniería en Automática por el Instituto Superior Politécnico Julio Antonio Mella (ISPJAM) de la Universidad de Oriente, Cuba. El ingeniero Ortiz tiene un MSc. En ciencias y Doctor en Ingeniería de la Universidad Pontificia Bolivariana-Colombia-Medellín y es miembro del Grupo de Investigación en Redes Eléctricas Inteligentes (GIREI). Forma parte del equipo académico de la carrera de Ingeniería Eléctrica de Universidad Politécnica Salesiana Quito-Ecuador. Sus principales intereses de investigación Automatización y Control, Control robusto y Control Tolerante a Fallos, Micro-redes Eléctricas Inteligentes híbrida, CA/CC. lortiz@ups.edu.ec

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2024 Universidad Politécnica Salesiana
QUITO - ECUADOR


CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, Cesar Humberto Orellana Pinzón con documento de identificación N° 1728944966 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 15 de enero del año 2024

Atentamente,



Cesar Humberto Orellana Pinzón
1728944966

CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Yo, Cesar Humberto Orellana Pinzón con documento de identificación No. 1728944966, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo Académico: “Algoritmo de Detección de Fallas para Motores Trifásicos tipo Jaula de Ardilla Basado en el Análisis de Componente Principales ”, el cual ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 15 de enero del año 2024

Atentamente,



Cesar Humberto Orellana Pinzón


1728944966

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Leony Ortiz Matos con documento de identificación N° 1754230389, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN ANÁLISIS DE COMPONENTES PRINCIPALES, realizado por Cesar Humberto Orellana Pinzon con documento de identificación N° 1728944966, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 15 de enero del año 2024

Atentamente,



Ing. Leony Ortiz Matos, Ph. D
1754230389

ÍNDICE GENERAL

1	Introducción	2
2	Motores de Inducción.....	5
2.1	SCIM.....	6
2.1.1	Principio de funcionamiento.....	6
2.1.2	Modelo matemático.....	6
2.2	Tipos de Fallas en SCIM	8
2.2.1	Excentricidad.....	8
2.2.2	Armónicos del estator.....	9
2.2.3	Daño de Rodamiento	9
2.2.4	Deflexión de Eje.....	9
2.2.5	Barras del Rotor Rotas.....	10
3	Formulación del Problema	10
3.1	Metodología	10
4	Caso de Estudio.....	11
4.1	Modelo de SCIM con fallas	12
4.2	Índice de carga y Falla.....	12
4.3	Datos obtenidos de campo.....	12
4.4	Firmas de Corriente.....	13
5	Análisis de Resultados	14
5.1	Tratamiento de Datos.....	14
5.2	Detección de fallas	16
5.2.1	Escenario 2 - Excentricidad	16
5.2.2	Escenario 3 – Armónicos en el estator	17
5.2.3	Escenario 4 – Barra del rotor rota.....	17
5.3	Comportamiento de las fallas respecto al índice de fallo.....	18
5.4	Comportamiento con datos obtenidos de campo	19
6	Conclusiones.....	20
6.1	Trabajos futuros	20
7	Referencias.....	20
7.1	Matriz de Estado del Arte	28
7.2	Resumen de Indicadores.....	35

ÍNDICE DE FIGURAS

Figura 1. Sistema de Detección de Fallas Inteligente.....	2
Figura 2. Modelo ortogonal del SCIM.....	7
Figura 3. Señal de corriente trifásica del SCIM saludable.....	8
Figura 4. Señal con armónico N.º 7 y THDI del 50%.....	8
Figura 5. Señal de corriente trifásica del SCIM con desperfecto de EF.....	8
Figura 6. Bobinado cortocircuitado.....	9
Figura 7. Señal de corriente trifásica del SCIM con desperfecto SH.....	9
Figura 8. Señal de corriente trifásica del SCIM con desperfecto BF.....	9
Figura 9. Señal de corriente trifásica con desperfecto SD.....	10
Figura 10. Señal de corriente trifásica con defecto BRBF.....	10
Figura 11. Diagrama del modelo del SCIM con Fallas.....	12
Figura 12. Índice Porcentual de fallas en SCIM.....	14
Figura 13. Muestras de los escenarios delimitados por líneas.....	14
Figura 14. Varianza de Componentes Principales sin normalizar y normalizados.....	15
Figura 15. Umbral 3D elíptico con muestras de funcionamiento normal usando tres PC.....	16
Figura 16. Varianza de PCs de EF.....	16
Figura 17. de EF usando P1 y P2.....	17
Figura 18. Varianza de PCs de SH.....	17
Figura 19. Detección de falla SH 3D usando P1, P2 y P3.....	17
Figura 20. Varianza de PCs de BRBF.....	18
Figura 21. Detección de Falla de BRBF.....	18
Figura 22. Detección de fallas con tasa de fallo del 10%.....	18
Figura 23. Detección de falla con tasa de falla del 90%.....	19
Figura 24. Varianzas de PC de BF.....	19
Figura 25. Detección de falla BF con datos de campo.....	19
Figura 26. Muestreo de corriente del SCIM de campo.....	20
Figura 27. Resumen e indicador de la temática - Estado del arte.....	35
Figura 28. Indicador de formulación del problema - Estado del arte.....	35
Figura 29. Indicador de solución - Estado del arte.....	35

ÍNDICE DE TABLAS

Tabla 1. Modelos de detección de fallas.....	5
Tabla 2. Variables utilizadas en el Algoritmo de detección de fallas en SCIM.....	11
Tabla 3. Pseudocódigo.....	11
Tabla 4. Descripción de escenarios de prueba del modelo del SCIM.....	11
Tabla 5. Parámetros de SCIM trifásico de 3 HP.....	12
Tabla 6. Datos de placa del SCIM de campo.....	13
Tabla 7. Datos del SCIM de campo saludables y con rodamiento defectuoso.....	13
Tabla 8. Variables de firma de frecuencia de falla de corriente estáticas del SCIM.....	13
Tabla 9: Matriz de estado del arte.....	28

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

Resumen

En la presente investigación tiene como objetivo detectar fallas en motores trifásicos tipo jaula de ardilla, mediante el uso de un algoritmo de detección de fallos basado en Análisis de Componentes Principales en Matlab. El método se basa en el entrenamiento forzado a través de datos históricos normalizados de todas las variables medibles o registradas en un motor de inducción tipo jaula de ardilla. El estudio se realizó mediante co-simulación PLECS-Matlab, estableciendo límites de control por medio del cociente de las varianzas de los componentes principales y la distribución T^2 de Hotelling, proponiendo un umbral elipsoide que separa el régimen de funcionamiento normal del régimen de falla. Para el registro de datos en funcionamiento de falla se desarrolló un sistema de inyección de fallas en el esquema eléctrico del modelo del motor de inducción tipo jaula de ardilla, proponiendo tres fallas características: la excentricidad, los armónicos en el estator y la ruptura de la barra del rotor. El algoritmo se validó con el índice de falla al 10% y 90%, logrando detectar el 100% de fallas desde sus primeros índices. Además, se obtuvo los mismos resultados con datos medidos en campo.

Palabras Clave: Falsos negativos, ventana cimbreada, convertidor electromecánico, excentricidad, ambigüedad de señales, no estacionariedad.

Abstract

This research aims to detect faults in three-phase squirrel cage motors using a fault detection algorithm based on Principal Component Analysis in Matlab. The method is based on forced training through normalized historical data of all measurable or recorded variables in a squirrel cage induction motor. The study was performed by PLECS-Matlab co-simulation, establishing control limits through the ratio of the variances of the principal components and Hotelling's T^2 distribution, proposing an ellipsoid threshold separating the normal operating regime from the fault regime. For data logging in fault operation, a fault injection system was developed on the electrical diagram of the squirrel cage induction motor model, proposing three characteristic faults: eccentricity, stator harmonics, and rotor bar breakage. The algorithm was validated with a 10% and 90% failure rate, managing to detect 100% of failures from its first rates. Furthermore, the same results were obtained with measured in the field.

Keywords: False negatives, swaying window, electromechanical converter, eccentricity, signal ambiguity, non-stationarity.

1 Introducción

El motor de inducción tipo jaula de ardilla (SCIM), está presente en casi todas las industrias como lo registra en [1], enfrentándose a una alta gama de condiciones operativas de suministro, escenarios de servicio como $s_1, s_2 \dots s_{10}$, según la IEC 60034-1 y atmósferas explosivas como Zona I, Grupo IIA, Grupo IIB, T4, según la IEC 60079 para más información se recomienda revisar [2].

Estos motores tienen la flexibilidad de ser diseñados afines a la necesidad industrial, proporcionando una operación eficiente, segura, controlable y confiable; además de ser accesibles económicamente. Sin embargo, el SCIM a pesar de su constitución simple presenta graves fallas ya sea por variables internas o externas que perturban el correcto funcionamiento y disminuyen la eficiencia convirtiéndose en considerables pérdidas económicas para la industria, esto resultado de no monitorear y diagnosticar fallas en el SCIM.

La correcta detección de una falla antes que esta el SCIM permite realizar plan de contingencia para reducir pérdidas económicas al mínimo, evitar reprocesos y descartar accidentes por fallas mecánicas

graves, además, de determinar la capacidad del SCIM para cumplir su función [1], [3], [4].

En consecuencia, el sector industrial se innova continuamente en métodos de precisión, eficiencia y confiabilidad que consuman menos recursos computacionales capaces de realizar la detección oportuna de fallas y determinar el estado del SCIM. Esto implica que, para realizar un método de Detección de Fallos (FD) e incluso la predicción los programas computacionales se basan en la adquisición de datos por medio de sensores inalámbricos o alámbricos, de señales analógicas o digitales en funcionamiento dinámico tales como corrientes, par, vibraciones, velocidad, temperaturas, potencia, sonido y voltajes [5]–[13].

Estas señales son procesadas y analizadas por algoritmos diseñados para la detección de fallas únicas, simultáneas o combinadas sin sufrir ambigüedad en su respectivo dominio. Dado que en las últimas décadas los conceptos de eficiencia, la constante investigación y la industria 4.0; se ha migrado a equipos inteligentes como se muestra en la Figura 1, que aportan perturbaciones a la señal, convirtiéndose en la problemática y reto [14]–[32].




Figura 1. Sistema de Detección de Fallas Inteligente.

Con la invención de la tecnología IoT, se busca que los sensores de los métodos FD en SCIM con comunicación de cableado estructurado sean reemplazados por sensores inalámbricos. Especialmente por: su simplicidad de instalación, reducción de costos y eliminación de interrupción de comunicación por daños en el cable [33].

La red de sensores inalámbricos (WSN), ofrece flexibilidad de ajustarse a sistemas no estacionarios. Sin embargo, uno de los mayores retos para esta tecnología es la confiabilidad de comunicación, ya que la interrupción entre sensores significaría la pérdida de datos disminuyendo gravemente su confiabilidad. Para mitigar esta problemática en [34] se ha implementado una malla de nodos inalámbricos dotado con algoritmos de enrutamiento que definen la mejor ruta.

Además se busca la sostenibilidad energética de la WSN donde se investiga un sistema de administración de energía y generación eléctrica por medio de recursos renovables o reutilizables [35]. Sin embargo, los campos magnéticos producidos por el SCIM provocan interferencia y la pérdida de paquete de transmisión de datos. No obstante, en [36] exploran las posibilidades de usar WSN en SCIM, validando el método con una pérdida de paquete de datos inferior al 10% utilizando la red TinyOS. Las WSN no son tan fiables como los sensores cableados, por lo que se debe aumentar la potencia de transmisión para reducir la pérdida de paquetes, comprometiendo la eficiencia energética.

Asimismo, en [37] se usa WSN de corriente a una frecuencia de muestreo de 1.8 KHz en combinación con la transformada wavelet para obtener los coeficientes de quinto nivel. Posteriormente, se alimentan las entradas de una red neural artificial detectando fallas en las barras del rotor, dando como resultado una eficiencia promedio del 91.6%.

En [38], en cambio se usa los coeficientes de la transformada wavelet discreta (DWT) de octavo y noveno nivel en combinación con el método estadístico de desviación media absoluta, definiéndolo como índice de severidad de falla para las barras rotas del rotor tipo jaula de ardilla. En cambio, en [39] se valida el coeficiente de octavo nivel de la DWT como indicador de falla para evaluar parámetros de umbral y de energía; por medio de análisis probabilísticos de correlación y estimación del intervalo de confianza.

Los métodos que se encuentran en el dominio de frecuencia-tiempo abordan la problemática de los métodos FD con baja cargabilidad o en condiciones desequilibradas del suministro, por lo que abordan la solución desde la selección del nivel de la DWT; mejorando el tiempo de respuesta y diagnóstico[40].

Sin embargo, en [41] se propone un nuevo método FD en las barras del rotor; la transformada de paquetes wavelet (WPT) no diezmada recursiva (RUWPT) y máquina de vectores de soporte multicapa (MSVM) destacando como una técnica simple y siendo de 8 a 12 veces más rápida que los métodos mencionados en [37]–[39], [42]. Además suprime totalmente la componente fundamental dando cabida a una frecuencia de muestreo de 224 Hz y 1024 muestras, teniendo por resultado una efectividad del 99%.

La detección de fallos de excentricidad dinámica, estática o mixta en el SCIM por el método de análisis de firma de corriente del motor (MCSA) que se basa principalmente en la aplicación de la transformada de Fourier. En este sentido en [43] se demostró que presenta ambigüedad compleja al trabajar con altas frecuencias. De ahí que, en [44] se propone una combinación de la transformada rápida de Fourier (FFT) y aprendizaje automático. En este trabajo se aplica un método de pre-blanqueamiento de datos para suavizarlos.

Por consiguiente, el método utiliza los diez primeros segmentos de horarios pico del espectro, obtenidos de la FFT. Para ello se procede a normalizar por unidad a la resultante de la suma de las amplitudes de cada segmento para alimentar el modelo de aprendizaje automático de la máquina de soporte vectorial (SVM); logrando así una aparente eficiencia del 99.7%. Además, este modelo utilizó datos reales de la industria para un SCIM en operación. Uno de ellos en perfectas condiciones y otro con cojinetes y acoplamiento defectuoso a plena carga [44].

Puede deducirse que, la selección de un método de aprendizaje automático para detección de fallos en SCIM es una tarea fundamental y compleja dado problemáticas como: disponibilidad, costos de mantenimiento, intervalos de paro forzado, análisis de falsos negativos y positivos, características dominantes de muestreo, ventajas y desventajas del método seleccionado y la relación eficiencia-precisión.

Como se muestra en [45], para realizar una correcta selección y determinación de un método apropiado para detección, diagnóstico y monitoreo de fallas en SCIM, se debería evaluar la dimensionalidad y comportamiento ante escenarios peculiares de muestreo. Aparentemente, el método propuesto en [44] sería una opción excelente en términos de costo, precisión y consistencia para SCIM. Además, se concluye que seleccionar las características correctas para entrenar el algoritmo de aprendizaje automático tiene impacto positivo.

La detección en condiciones de operación condición normal y defectuosa de un SCIM con carga transitoria es una tarea no adecuada para métodos como MCSA, DWT, debido al escenario de servicio al que se acopla. Por ello, no son capaces de detectar la no estacionariedad por sí mismos al analizar las muestras que pasan de escenarios saludables a defectuosos. Por lo antes mencionado, en [46] se propone el

método de Análisis de Componentes Curvilíneos Crecientes (GCCA) para detectar fallas en las espiras del devanado del SCIM. Este método tiene la capacidad de procesar datos en línea y reducir la dimensionalidad en tiempo real, lo que fundamenta como requisito un flujo constante de datos de alimentación.

Adicionalmente, este método utiliza el espectro de corrientes del estator y realiza la detección de la falla en un mapa tridimensional logrado por la distribución de datos. Este método logró detectar cambios instantáneos con la capacidad de aislar clústeres defectuosos y monitorear la evolución de la falla, además de tomar la mejor decisión de detener o no la operación del SCIM.

La no estacionariedad es una de las mayores problemáticas para la detección de fallos en SCIM cuando se tiene variación abrupta de la carga o la velocidad. En [47] con el método Armónicos Residuales (NRHA), se logra mayor desempeño para situaciones de cargas fijas. Aunque para la presencia de cargas cimbreadas, el método presenta grandes limitaciones ya que no detecta la no estacionariedad.

Por lo tanto, los métodos FD en escenarios de cambio abrupto es una rama de investigación muy solicitada no solo para SCIM, sino también, en la industria química, mecánica de máquinas, tribología, aerogeneradores, entre otros campos [48]–[51]. Esto debido principalmente a la constante modernización de procesos industriales como el control numérico computarizado o resumidamente la industria 4.0 han dejado obsoletos algunos modelos de FD que trabajan en estado estable o con régimen de variables constantes.

Para mitigar esta problemática se han propuesto varias alternativas que trabajan con una señal como sonido, corrientes, voltaje, vibración y temperatura [46], [52]–[55], estos modelos, aunque detectan la no estacionariedad, están limitados por el

espectro de fallas que pueden detectar y en algunos de los casos el tiempo que utilizan para desarrollarlo. Por lo tanto, en [56] se propone un método basado en Análisis de Componentes Principales (PCA) y un árbol de decisiones. Para ello se toman todas las señales resultantes de diferentes sensores con la capacidad de reducir la dimensionalidad para realizar detección de fallas simultánea, combinada y únicas. El método es insensible a la variabilidad abrupta de carga, velocidad o frecuencia con la capacidad de detectar fallas en 0.5 segundos.

En este sentido es fundamental seleccionar correctamente los componentes principales (PC) en el uso de estrategias basadas en PCA que buscan la reducción de dimensionalidad. De no ser así, se toma el riesgo de cometer un error que podría llevar a perder información, o en su caso contrario tener demasiados datos innecesarios que contienen ruido. Para realizar una correcta selección es muy utilizado la regla K1, definiendo que un componente es útil si su magnitud es superior que uno.

Sin embargo, el PCA funciona bien para sistemas lineales, pero para sistemas dinámicos sus resultados son afectados disminuyendo drásticamente su eficiencia. Por este motivo se han realizado varias investigaciones de variantes de PCA, como PCA dinámico (DPCA) que se puede aplicar para datos autocorrelacionados, PCA multiescala (MSPCA) para datos no estacionarios variables en el tiempo y PCA de ventana móvil referenciada (RMWPCA) y RMWPCA asociado con el complemento de SCHUR (RMWPCA-SC) que buscan maximizar la tasa del método FD y minimizar la tasa de falsas alarmas [57], [58].

Tabla 1. Modelos de detección de fallas.

Modelo	Técnica	Ambigüedad	Detección
DWT	Corriente o voltaje del estator	Baja carga y no estacionariedad de suministro	Barras rotas
MCSA	Corriente o voltaje del estator y señal de vibración.	Alta frecuencia	Excentricidad
SVM - FFT	Corriente estatística y señal acústica.	Falsos negativos	Cojinetes y acoplamiento
GCCA	Corriente del estator	Plena carga	Espiras del bobinado estatórico Barra rota y cortocircuito entre espiras
NRHA	Corriente del estator	No estacionariedad	Multi-etiqueta
PCA	Multi-Variable	Falsos negativos	Multi-etiqueta
PCA y Árbol de decisión	Multi-Variable	Índice de severidad	Multi-etiqueta
RUWP T-MSVM	Corriente del estator	Tipo de operación	Barra rota

2 Motores de Inducción

El SCIM es una de las máquinas rotativas con mayor protagonismo en las industrias como fuente de energía mecánica. Además, debido a su simplicidad de partes mecánicas y gracias a su producción en serie estos son accesibles a todo público económicamente, lo que conlleva, al SCIM a un constante desarrollo de aplicación y eficiencia. Extendiendo su campo aplicativo y de control con unidades de velocidad variable con diferentes tipos de control. Asimismo, mejorando su eficiencia amplificando los campos magnéticos con aceros eléctricos [59].

2.1 SCIM.

El motor de inducción o asíncrono con rotor en jaula de ardilla o cortocircuito es un convertidor electromecánico gracias al efecto de la inducción que funciona con alimentación trifásica o monofásica de corriente alterna y cuenta con una estructura magnética (MG) y una eléctrica (ES). La MG está constituida por una parte estatórica y otra rotativa; está conformado por un conjunto de láminas de acero eléctrico, dimensionado de acuerdo con el análisis de saturación magnética, además de estar la ES está conformada por bobinado inductor trifásico y bobinado inducido.

El bobinado inductor trifásico está alojado en las ranuras estatóricas conectado de manera que forman tres bobinas iguales e independientes desfasadas 120 grados eléctricamente conectados en estrella, doble estrella, delta o doble delta. De igual forma, el bobinado inducido tipo jaula de ardilla tiene alojado barras en las ranuras del inducido, por consiguiente, entran en estado de cortocircuito gracias a los anillos de ambos lados del rotor, los mismos que permiten balancearlo.

El SCIM para cumplir su correcto funcionamiento está constituido mecánicamente de estator, rotor, tapa lado carga, tapa lado libre, anillo de precarga, contratapas, rodamientos, vinchas, caperuza, retenedores, ventilador, engrasadores y carcasa. En vista del hecho que, según su aplicación y mientras mayor sea la potencia del SCIM tendrá mayor cantidad de piezas que garanticen el correcto funcionamiento [60].

2.1.1 Principio de funcionamiento.

El SCIM al ser energizado con un suministro trifásico sus bobinados generan campos magnéticos (MF) giratorios que cambia de intensidad y polaridad conforme al cambio de dirección de los electrones en tiempos diferentes gracias al desfase de 120 grados de cada bobina. A su vez se induce

una corriente en las barras del rotor jaula de ardilla provocando un MF en cada barra.

Los MF del estator y del rotor interactúan continuamente, además, los MF del rotor giran en la misma dirección intentado alcanzar la velocidad sincrónica. En cambio, las barras del rotor evitan la alineación gracias a la inclinación que sirve para distribuir el MF entre varias barras, ya que si el rotor alcanzará la velocidad de sincronismo este se bloquearía.

La velocidad de sincronismo (n) está dada por la ecuación 1 y a la diferencia de la velocidad magnética y la velocidad del rotor (n') se la denomina deslizamiento (s), se expresa según la ecuación 2 [61].

$$n = \frac{\text{frecuencia} \times 60}{\text{N}^\circ \text{ de polos}} = \text{rpm} \quad (1)$$

$$s = \frac{n \times n'}{n} \quad (2)$$

2.1.2 Modelo matemático.

El modelo equivalente del SCIM tienen como fin exponer el comportamiento y flujos del SCIM por medio de un circuito equivalente de impedancias RL. Además, este modelo simplifica la parte convertidora y se lo expresa como inductancia mutua (Lm) como se lo muestra en la Figura 2. El circuito equivale a una fase, de dos mallas divididas por Lm . La primera malla equivale al estator y la segunda al rotor; lo que implica que la corriente estatórica se descompone en dos componentes; carga (I_r) y excitación (I_m). Puede deducirse que I_r es resultado de la fuerza magnetomotriz y I_m es la encargada de generar el flujo en el entrehierro.

El modelo está basado en sistema ortogonal, de la transformación de un sistema trifásico (a, b, c) a dos componentes en un marco estacionario ortogonal (d, q); donde las ecuaciones diferenciales no lineales del SCIM se transforman a ecuaciones lineales; de este modo se lo puede escribir como parte real y parte

imaginaria. Por otro lado, las señales d, q están desfasadas 90 grados eléctricos en estado estacionario, además, la señal d tiene 1.5 veces la amplitud de la fase a y está en fase con la misma [62].

La Figura 2 muestra el esquema de un motor, donde se tiene que R_s y L_{ls}

conforman el cuerpo inductor y el cuerpo inducido conformado por $L'lr$ y $R'r$, además, la acción convertidora se simplifica como Lm . La resistencia de carga va conectada en serie con el cuerpo inducido. El flujo en weber (Wb) del rotor (r) y estator (s) se calcula con la ecuación 3 [63].




Figura 2. Modelo ortogonal del SCIM

La Figura 2 muestra:

- R_s Resistencia del estator.
- L_{ls} Inductancia de fuga del estator.
- Lm Inductancia magnética.
- $L'lr$ Inductancia de fuga del rotor.
- $R'r$ Resistencia del rotor.
- Rc Resistencia de carga variable.

$$\Psi_{x,y} = L'lr \cdot i'_{r,y} + Lm(i_{s,y} + i'_{r,y}) \quad (3)$$

Donde

- x Rotor (r) o estator (s)
- y Eje directo (d) o eje en cuadratura (q).

El torque electromagnético se lo calcula según la ecuación 4 [63].

$$T_e = \frac{3}{2} p Lm (i_{s,q} i'_{r,d} + i_{s,d} i'_{r,q}) \quad (4)$$

La velocidad mecánica del rotor se la calcula con la ecuación 5 [63].

$$\omega_m = \frac{1}{J} (T_e + F \omega_m + T_m) \quad (5)$$

Las tensiones ortogonales se calculan con la ecuación 6 y 7 para el estator y ecuación 8 y 9 para el rotor [63].

$$V_{s,q} = R_s i_{s,q} + \frac{d\Psi_{s,q}}{dt} + \omega \Psi_{s,d} \quad (6)$$

$$V_{s,d} = R_s i_{s,d} + \frac{d\Psi_{s,d}}{dt} - \omega \Psi_{s,q} \quad (7)$$

$$V_{r,q} = R_r i'_{r,q} + \frac{d\Psi_{r,q}}{dt} + (\omega - \omega_r) \Psi_{r,d} \quad (8)$$

$$V_{r,d} = R_r i'_{r,d} + \frac{d\Psi_{r,d}}{dt} - (\omega - \omega_r) \Psi_{r,q} \quad (9)$$

Para transformar las corrientes estáticas de $a, b, c \leftrightarrow d, q$ se usa la ecuación 10 de matrices [63].

$$\begin{pmatrix} i_{s,a} \\ i_{s,b} \\ i_{s,c} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{pmatrix} \times \begin{pmatrix} i_d \\ i_q \end{pmatrix} \quad (10)$$

Asimismo, para las tensiones se usa la ecuación 11 de matrices [63].

$$\begin{pmatrix} V_{s,d} \\ V_{s,q} \end{pmatrix} = \begin{pmatrix} \frac{2}{3} & \frac{1}{3} \\ 0 & \frac{1}{\sqrt{3}} \end{pmatrix} \times \begin{pmatrix} V_{s,ab} \\ V_{s,bc} \end{pmatrix} \quad (11)$$

2.2 Tipos de Fallas en SCIM

La vida útil de los elementos que conforman el SCIM puede reducirse, si son expuestas a condiciones de estrés eléctrico, mecánico o ambiental. Por lo general un SCIM está diseñado para operar de manera óptima, de acuerdo con, tolerancias definidas por las normas de diseño NEMA o IEC [64].

Dado que, fuera de los rangos de tolerancia establecidos el SCIM reduce drásticamente su vida útil y entra en régimen de falla. Por otro lado, las fallas también son causadas por envejecimiento o desgaste natural; lo que implica mantenimientos para sustituir los elementos fallados. En vista del hecho de que los arrollamientos del SCIM pueden ser sustituidos, cabe mencionar que este mantenimiento debe valorarse en función de la eficiencia que mantenga la máquina [65].

Las fallas producen desperfectos que alteran el campo magnético y la acción convertidora que se refleja en las medidas eléctricas como armónicos. Lo ideal para la lectura de la corriente eléctrica del SCIM debería ser una sinusoidal pura como lo indica la Figura 3.




Figura 3. Señal de corriente trifásica del SCIM saludable.

Sin embargo, los armónicos que presenta la señal como lo ilustra la Figura 4,

detalla la existencia de una anomalía, por otro lado, esta también tiene la posibilidad de ser producto de perturbaciones ajenas. Lo que implica que debe procesarse dicha señal acorde al entorno de operación [66].

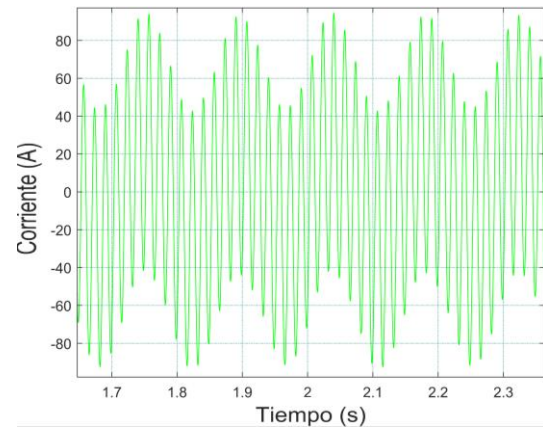


Figura 4. Señal con armónico N.º 7 y THDI del 50%

2.2.1 Excentricidad

La excentricidad (EF) consiste en la asimetría en el entrehierro, ya que, el entrehierro es un espacio circunferencial inamovible durante la rotación del cuerpo inducido. Además, la asimetría presente en el cuerpo inductor se lo conoce como EF estática y a la presente en el cuerpo inducido como EF dinámica, por lo tanto, la combinación puede inferirse EF mixta. Esta falla presenta un comportamiento característico vibratorio reflejado en la corriente estática como expresa la Figura 5 [67].




Figura 5. Señal de corriente trifásica del SCIM con desperfecto de EF

2.2.2 Armónicos del estator.

Los armónicos en el estator (SH) se produce por conmutaciones, fugas de corriente o puntos calientes en las chapas presentándose como armónicos en las medidas eléctricas y en el peor escenario éstas dan como resultados bobinados cortocircuitados. Además, las fallas en el estator también se dan por sobrecargas, cortocircuito entre espiras por desperfectos de aislamiento, cortocircuito entre fases causados por agentes contaminantes, abrasivos o bien por oscilaciones en la tensión de suministro. También se puede generar esta falla por arranque de marcha y contramarcha en periodos demasiado reducidos abusando de la tolerancia de fabricación como lo ilustra la Figura 6 [68].




Figura 6. Bobinado cortocircuitado.

A la presencia de esta anomalía la señal presenta sobre corrientes y armónicos como lo muestra la Figura 7. El incremento de la corriente puede ir desde fugas a la saturación y conllevando a un cortocircuito.




Figura 7. Señal de corriente trifásica del SCIM con desperfecto SH.

2.2.3 Daño de Rodamiento

La falla en rodamientos (BF) consta de picaduras, fisuras, rayones, agrietamientos, deformaciones entre otras más; en la pista superior o interior, externa o interna del rodamiento o deformaciones en las bolas producto de almacenamiento inadecuado, errores de manipulación, agentes contaminantes, deflexiones, holguras y principalmente por falta de lubricación o mal aplicación del concepto. Generalmente el síntoma de una BF es un sonido de fricción, zumbido o chasquidos, además de, generar ondas de vibración que son notorias en la señal de corriente como lo muestra la Figura 8 [69].




Figura 8. Señal de corriente trifásica del SCIM con desperfecto BF

2.2.4 Deflexión de Eje

La deflexión del eje (SD) se presenta como la desviación de la dirección del eje, está se produce por cinturones o acoples desalineados, también esta anomalía se presenta por golpes o fuerzas que exceden la tolerancia del material. Se puede inferir que esta anomalía genera no estacionariedad como lo ilustra la Figura 9 por el aumento de fricción que se tiene en los puntos más críticos de la deflexión [70].




Figura 9. Señal de corriente trifásica con desperfecto SD

2.2.5 Barras del Rotor Rotas.

La falla de barras rotas en el rotor (BRBF) es menos frecuente que fallas BF, SD y EF con un 10 % de posibilidad de fallo en SCIM. Está se presenta debido a sobrecalentamientos del cuerpo inducido, estrés de torsión y sobrecarga. El desperfecto se traduce en las corrientes estáticas como oscilaciones según lo ilustra la Figura 10, esto debido al par motor no estable en régimen estacionario [71].




Figura 10. Señal de corriente trifásica con defecto BRBF

3 Formulación del Problema

El SCIM tiene gran protagonismo en la industria desempeñando el trabajo de mover un sin fin de cargas, lo que implica que, la disponibilidad del SCIM representa parte fundamental del índice de productos terminados al día. En consecuencia, los

paros no programados por fallas en el SCIM resultan en grandes pérdidas económicas.

Esta adversidad hace necesario presentar un algoritmo de detección de fallas en SCIM basado en PCA, que permita dar solución a la situación problemática que responde a: ¿Es posible desarrollar un algoritmo que permita detectar los primeros índices de falla en SCIM?

El algoritmo propuesto y desarrollado en MATLAB se valida con datos registrados de simulaciones modeladas en PLECS interconectado con SIMULINK.

3.1 Metodología

El algoritmo basado en PCA requiere de una matriz de datos históricos de variables medibles tales como: corriente trifásica, voltaje trifásico, torque, temperatura, velocidad asíncrona y ángulo del rotor del SCIM en funcionamiento sin fallas. Las variables son normalizadas previamente para crear la matriz de covariación con el fin de minimizar falsos negativos.

Con la matriz de covariación se calcula los componentes principales (PC) con PCA en matriz de covariación (PCACOV), seleccionando las PC por el criterio del porcentaje de varianza superior o igual al 90%, que se obtiene de la suma de la varianza de cada componente seleccionada para establecer el umbral de detección de falla delimitado por la distribución T^2 Hotelling en marco tridimensional o bidimensional en forma de elipsoide o elíptica respectivamente.

Asimismo, los conjuntos de datos con fallas serán alimentados al algoritmo, calculando las PC para realizar la detección de falla de acuerdo con su comportamiento en referencia al umbral.

La Tabla 2 y Tabla 3 detallan las variables y la prefiguración del algoritmo de detección de fallas.

Tabla 2. Variables utilizadas en el Algoritmo de detección de fallas en SCIM.

Símbolo	Variable	Unidad
DM_{E_i}	Matriz 11 Variables x 26000 muestras de la simulación	[V, A, C°, Nm, °deg]
$xnSIGMA$	Matriz de covarianza	u
$xnMEAN$	Vector con promedios de las variables	u
V	Matriz con coeficientes de PC	u
D	Vector con varianza de los PC	u
E	Vector con la varianza total que contiene cada PC	%
nXn	Datos normalizados	pu
$t2Ht$	Umbral para la detección	u
a	Elección de cantidad de PC	u
n	Cantidad de muestras	u
xc, yc, zc	Coordenadas del centro del elipsoide	u
xr, yr, zr	Semiejes principales	u

Tabla 3. Pseudocódigo

Algoritmo de detección de fallas para SCIM basado en PCA en matriz de covariación	
Inicio	
Step 1:	Entradas: $\{DM_{E1}, DM_{E2}, \dots, DM_{E5}\}$
Step 2:	Salidas: $\{xnSIGMA, xnMEAN, V, D, E, aXn, AXf\}$
Step 3:	Inicialización: $xn \leftarrow [], xf \leftarrow [], Fm1 \leftarrow []$ Asignación de Datos Fm1
Step 4:	$= \{DM_{E1}(:, N), DM_{E2}(:, N), \dots, DM_{E4}(:, N)\}$ $xn = [Fm1(1:n, 1:x)],$ $xf = [Fm1(n+1:k, 1:x)]$
Step 5:	Normalización: $nXn \leftarrow ZScoreNormalization(xn)$
Step 6:	Creación de matriz de covariación y vectores promedio y desviación estándar $xnSIGMA \leftarrow cov(nXn)$ $MUn \leftarrow mean(xn)$ $xstd \leftarrow std(xn)$
Step 7:	Cálculo de Componentes Principales $[V, D, E] \leftarrow PCACOV(xnSIGMA)$ Umbral para FD utilizando T² Hotelling
Step 8:	$t2Ht = \frac{a(n-1)}{n-a} * F(0.95, a, n-a)$ $[x, y, z]$ $\leftarrow ellipsoided(xc, yc, zc, xr, yr, zr)$ Proyección de observaciones y media cero para estandarizar datos. $L \leftarrow (:, 1:a)$
Step 9:	Datos sin falla $aXn \leftarrow (nXn * L)$ $nXf \leftarrow \frac{(xf(i,:) - MUn)}{xstd}$ Datos con fallas $aXf \leftarrow (nXf * L)$
Step 10:	Cálculo de posición

$D_{SF} = subspace(aXn_{x,y}, aXn_{x+1,y+1})$ $D_{CF} = subspace(aXf_{x,y}, aXf_{x+1,y+1})$ $D_u = subspace(x, y)$
Detección de falla si $D_{CF} \leq D_u$ <i>Mostrar("Sin Falla")</i> $Falla = 0$ de lo contrario si $D_{CF} > D_u$ <i>Mostrar("Con Falla")</i> $Falla = 1$ Fin si Fin si
Step 11:
Step 12: Retorna: falla

4 Caso de Estudio

Como se explica anteriormente se desarrolla un sistema de inyección de fallas en el modelo del SCIM de PLECS, definiendo seis escenarios descritos en la Tabla 4.

Tabla 4. Descripción de escenarios de prueba del modelo del SCIM.

Escenario	Estados del SCIM
1	Sin falla
2	Falla de excentricidad
3	Falla de armónicos en el estator
4	Falla rodamiento dañado
5	Falla deflexión en el eje
6	Falla de barra rota del rotor

Inicialmente, se parametriza el modelo del SCIM y se modela un sistema de alimentación trifásico (220V-60Hz), además de colocar un sistema de carga modificable desde la ventana de parámetros del bloque; obteniendo el primer escenario denominado funcionamiento normal.

Con respecto a los cinco escenarios de fallas restantes se los creo por medio de firmas de frecuencia de corriente descritas en la Tabla 8, para lo cual, se implementó un sistema de medición de frecuencia del rotor para cumplir con los datos requeridos de ciertas ecuaciones de fallas. Para ilustrar cada escenario de falla puede ser seleccionado y simulado a través de un selector, reflejando las fallas en variables medibles como: corriente, torque, temperatura del bobinado estático, velocidad y posición del rotor.

4.1 Modelo de SCIM con fallas

El modelo de SCIM de PLECS consta de marco de referencia eléctrico y mecánico, ambos didácticos, donde se encuentra la transformación de componentes del dominio del tiempo (A, B, C) a componentes

ortogonales (d, q) con la novedosa versatilidad de poder registrar medidas de temperatura en los bobinados estáticos y cuerpo inducido. Además, este modelo tiene la posibilidad de ser modificable en su marco de referencia ortogonal.

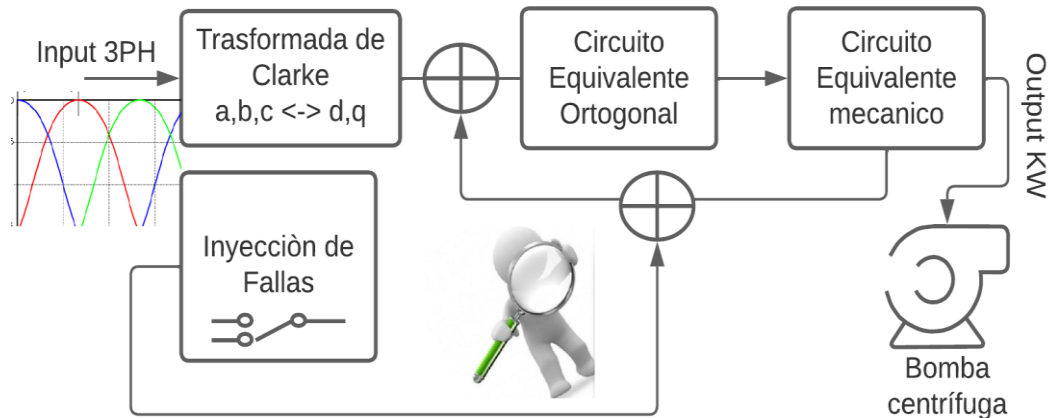


Figura 11. Diagrama del modelo del SCIM con Fallas

En vista del hecho que el modelo opera en funcionamiento ideal sin anomalías es necesario implantar un modelo de inyección de fallas específicas que trabajan por firmas de corriente ilustrado en la Figura 11; del mismo modo, se parametriza el modelo con los datos descritos en la Tabla 5.

Tabla 5. Parámetros de SCIM trifásico de 3 HP

Parámetro	Dato	Parámetro	Dato
Resistencia del estator	0.435 (Ω)	Velocidad inicial del rotor	0
Inductancia del estator	0.004 (H)	Posición Inicial del rotor	0
Resistencia del rotor	0.816 (Ω)	Corriente inicial del estator	0
Inductancia del rotor	0.002 (H)	Flujo inicial del estator	0
Inductancia de magnetización	0.00693 1 (H)	Índice de falla	0.1 (pu)
Inercia	0.089	Par de carga	11.9 (Nm)
Fricción	0	Corriente nominal	8 (A)
Pares de polos	2	RPM	1725
Voltaje	220 (v)	Frecuencia	60 (Hz)

En cuanto al registro de medidas de pruebas dinámicas en SCIM se obtuvo datos

de variables medibles tales como voltaje trifásico (V), corriente trifásica (A), temperatura en (°C), torque (Nm), velocidad del rotor (RPM), ángulo del rotor (°) las cuales están representadas en la Figura 13. Estas tienen una resolución de 0.0001. Cabe mencionar que los datos obtenidos de la simulación son analógicos.

4.2 Índice de carga y Falla

El índice de carga y falla implementado en el bloque del SCIM de PLECS determina el porcentaje de potencia exigido a la máquina y grado porcentual de la avería a simular. Brindado una gran versatilidad de escenarios de prueba. Cabe mencionar que, para esta investigación, se realizó las simulaciones con un 100% de carga y un índice del 10% y 90% para las fallas.

4.3 Datos obtenidos de campo

Los datos de campo se obtuvieron por medio de pruebas dinámicas en SCIM. El registro de datos se realizó con el controlador VFD-MS300 modelo VDF33AMS23ANSAA, cabe mencionar que este equipo nos entrega datos digitales. Para está investigación se utilizó un SCIM

de 7.5 HP. Primero, se registró un escenario saludable y segundo, se registró un escenario con rodamiento defectuoso. Los datos de placa del SCIM son descritos en la Tabla 6.

Tabla 6. Datos de placa del SCIM de campo.

Magnitud	Dato	Magnitud	Dato
V	220/380/440	IP	55
A	21.2/12.3/10.6	CL	F
PF	0.76	ΔT	80K
Hz	60	AMB.	40 °C
FRAME	112M	IE2	90
SF	1.15	min^{-1}	1750
DUTY	S1	HP	7.5

Las variables registradas son voltaje, corriente, torque, frecuencia, velocidad, potencia de salida y ángulo de factor de potencia. Los datos de escenario saludable se utilizan para entrenar el algoritmo y establecer el umbral de detección. Del mismo modo, se utiliza los datos de escenario con rodamiento defectuoso para realizar la detección. Los datos más relevantes se detallan en la Tabla 7.

Tabla 7. Datos del SCIM de campo saludables y con rodamiento defectuoso.

Hz	A	V	Nm	PF ϕ	RPM	W. 10 ⁴
Datos saludables						
60.52	8.37	219.9	58.3	24.8	3631	0.16
60.52	8.38	219.9	58.3	24.8	3631	0.16
60.52	8.37	219.9	58.3	24.8	3631	0.16
60.51	8.37	219.9	59	24.8	3630	0.16
60.51	8.38	219.9	59	24.7	3630	0.16
60.51	8.4	219.9	58.3	24.7	3630	0.16
60.51	8.4	219.9	58.3	24.7	3630	0.16
60.51	8.4	219.9	59	24.7	3630	0.16
60.51	8.39	219.9	59	24.6	3630	0.16
60.51	8.39	219.9	59	24.6	3630	0.16
60.51	8.39	219.9	59	24.6	3630	0.16
60.51	8.39	219.9	59	24.6	3630	0.16
60.51	8.4	219.9	59	24.6	3630	0.16
60.52	8.4	219.9	59	24.6	3631	0.16
60.51	8.39	219.9	59	24.6	3630	0.16
60.51	8.37	219.9	59	24.6	3630	0.16
60.5	8.36	219.9	59	24.5	3630	0.16
60.5	8.35	219.9	59	24.5	3630	0.16
60.51	8.34	219.9	59	24.4	3630	0.16
60.51	8.33	219.9	59	24.4	3630	0.16
60.51	8.31	219.9	58.3	24.4	3630	0.16
60.5	8.3	219.9	59	24.4	3630	0.16
60.5	8.29	219.9	58.3	24.4	3630	0.16
60.5	8.29	219.9	58.3	24.4	3630	0.16
Datos con rodamiento defectuoso						
62.78	33.26	189.6	24.4	144	3773	1
62.81	31.77	196.3	23.7	145.3	3768	0.96
62.84	32.09	188.7	23.7	144.5	3768	0.96
62.82	32.71	193.3	24.4	145.5	3770	0.99
62.63	29.62	192.4	23.7	139.7	3759	0.91

62.64	29.31	198.1	23.7	137.9	3757	0.9
62.62	29.13	192.6	23.7	136.6	3757	0.89
62.5	28.38	197.7	23.7	135.5	3755	0.87
62.41	26.98	198.9	24.4	133	3749	0.84
62.5	26.01	200	23.7	124	3743	0.8
62.72	28.78	193.6	23.7	125.4	3752	0.87
62.69	30.23	191.4	24.4	131.3	3760	0.92
62.55	28.88	198.9	24.4	134.8	3757	0.89
62.76	29.39	189.7	23.7	133.8	3756	0.89
62.95	35.77	190.6	25.2	150.7	3780	1.06
62.66	32.6	191.4	24.4	152.4	3773	0.99
62.59	29.78	198.4	24.4	147.2	3761	0.91
62.51	28.26	193.8	23.7	140.6	3754	0.87
62.75	28.99	195.1	23.7	135.6	3754	0.88
63.08	36.37	184.3	25.2	148.3	3781	1.07
63.05	36.51	192.7	25.2	153.4	3782	1.07
62.99	35.84	186	25.2	155.5	3781	1.06
63.07	36.23	189.3	25.2	155.4	3781	1.06
63.09	38.17	188.5	25.2	156.7	3782	1.1

Por último, el equipo utilizado registra datos con una precisión de 0.01.

4.4 Firmas de Corriente.

Las fallas más ocurrentes en SCIM pueden clasificarse según la Tabla 8. Sin embargo, para determinar su índice porcentual depende fielmente a las condiciones energéticas, mecánicas y ambientales a las que está expuesto el SCIM. Según el levantamiento de datos en [72] que se aprecia en la Figura 12 del SCIM. Por lo tanto, se puede inferir que la falla típica con mayor recurrencia en régimen de servicio S1, S4 y S5 son los rodamientos dado que estos están expuestos a fricción permanente.

Para este documento se trabaja con tres fallas de simulación: la excentricidad, los armónicos en el estator, la ruptura de la barra del rotor y una falla de campo: los fallos en rodamiento.

Tabla 8. Variables de firma de frecuencia de falla de corriente estáticas del SCIM.

Ref.	Variable	Firma	Sim
[73]	Excentricidad	$ f_s \pm f_r $	EF
[74]	Armónicos en el estator	$ f_s \pm (N_n/p) \times f_r $	SH
[75]	Falla en rodamientos	$ f_s \pm 0.4 \times n_b \times f_r $	BF
[76]	Deflexión de eje	$ f_s \pm (2 \times \pi \times R)/L \times f_r $	SD
[77]	Barras del rotor rotas	$ f_s \pm 2 \times (f_s - f_r) $	BRBF

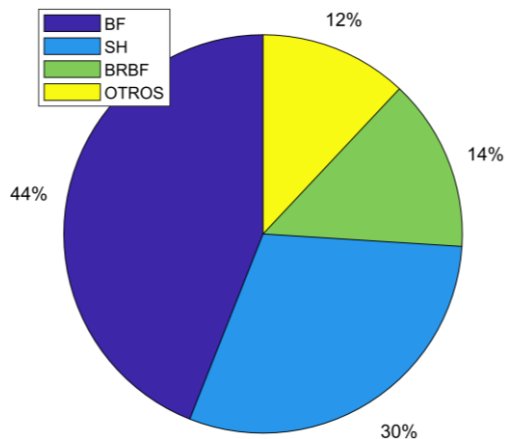


Figura 12. Índice Porcentual de fallas en SCIM

5 Análisis de Resultados

En este apartado se analiza el comportamiento de las fallas, paralelando las mismas con el umbral de funcionamiento normal. Además, se tienen 4 escenarios de prueba de simulación y un

quinto escenario de prueba de campo detallados a continuación:

- Escenario 1 – Funcionamiento normal denotada con celeste.
- Escenario 2 – Falla de excentricidad denotada con magenta.
- Escenario 3 – Falla de armónicos en el estator denotado con verde
- Escenario 4 – Falla de barra rota denotado con azul.
- Escenario 5 – Falla de rodamiento denotado con naranja

5.1 Tratamiento de Datos

Los datos obtenidos por cada escenario fueron alrededor de 26000 muestras de 7 segundos de simulación, para lo cual, se seleccionaron 500 muestras de cada escenario con 10 variables respectivamente, como lo ilustra la Figura 13.




Figura 13. Muestras de los escenarios delimitados por líneas.

En la Figura 13 se tiene 3 subtramas que explican el comportamiento de las variables registradas del SCIM en funcionamiento dinámico expresadas de esa manera debido a que distan de escalas considerablemente. En las tramas se encuentra 2000 muestras graficadas en intervalos de 500, delimitando cada escenario de prueba con líneas punteadas verticalmente.

Por otro lado, las variables manejan diferentes escalas, que reducen drásticamente la confiabilidad del algoritmo detallado en el primer segmento de la Figura 14, puesto que, la reducción de dimensionalidad con datos no normalizados es mayor con solo 3 PC debido a la presencia de valores atípicos anómalos, causado por el análisis de covariación, denotando erradas varianzas.

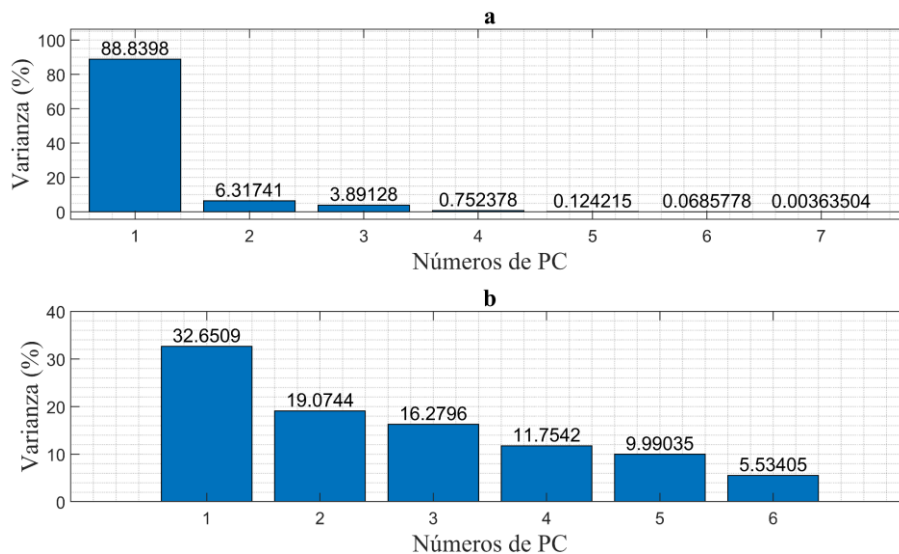


Figura 14. Varianza de Componentes Principales: a) sin normalizar y b) normalizados.

Lo cual representa que utilizando los tres primeros componentes se tiene una reducción de la dimensión del sistema real con 99.04% de coincidencia con los datos reales. Adicionalmente, esto permite lograr cierta separabilidad entre el escenario de funcionamiento normal y los otros escenarios de fallos. Sin embargo, como se puede observar en Figura 14, al utilizar los datos no normalizados para crear los tres primeros componentes principales no es posible garantizar que el modelo PCA tome a todas las variables con el mismo peso o importancia.

Debido a lo anteriormente expuesto se hace necesario normalizar todas las variables del modelo, garantizando así que el modelo PCA asuma la misma importancia o peso por igual a todas las variables registradas del SCIM. De esta manera, a pesar de que siendo

seleccionados solo los tres primeros PC el modelo PCA es capaz de representar en un 68.0049% del SCIM. Por esta razón para lograr una mejor representación del modelo PCA con respecto al SCIM lo recomendado sería tomar los 6 primeros PC con las variables normalizadas (95.2835%).

Aun usando los 6 primeros PC la dimensión del SCIM en función del número de variables registradas y cantidad de muestras es reducida considerablemente. Puesto que, para realizar un gráfico visual, solamente es posible en 2D o 3D, por ello en este trabajo se consideraron los dos o tres primeros PC.

Como se puede apreciar en las gráficas restantes, a pesar de que se utilizaron para el presente estudio los dos o tres primeros PC, cuya representación quizás sea un poco baja (Figura 14) es suficiente para lograr la separabilidad entre los escenarios, la

definición de un umbral y la detección de los fallos.

5.2 Detección de fallas

Con el registro de datos de funcionamiento normal se realizó un entrenamiento forzado al algoritmo de FD, estableciendo los límites de control en dos o tres dimensiones únicamente debido a los planos manejables hasta tres dimensiones; definiendo un umbral de tolerancia de forma elíptica; indicando que todas las muestras en su interior se establecen como régimen de funcionamiento normal como lo ilustra la Figura 15. Además, se puede inferir fácilmente gracias a la manipulación del plano 3D.

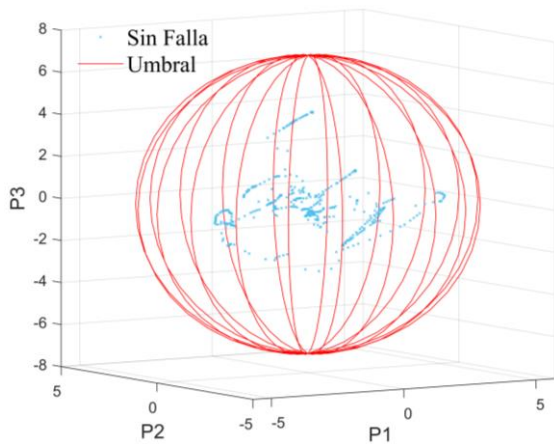


Figura 15. Umbral 3D elíptico con muestras de funcionamiento normal usando tres PC.

Como lo indica, el plano tridimensional se tiene que ninguna muestra en color celeste de funcionamiento normal excede las delimitaciones del umbral; conceptualizando el escenario de funcionamiento normal.

5.2.1 Escenario 2 - Excentricidad

Para este escenario se tiene la falla EF y se verifica su comportamiento en la Figura 17. Se observa que, la reducción de la dimensionalidad para los dos primeros PC (Figura 16) corresponde al 70.5058%. A pesar de que pudiese parecer bajo este porcentaje es suficiente para mostrar el comportamiento de las 10 variables

registradas. Independientemente de que tres o más PC representan con mayor exactitud al SCIM para esta sección se han seleccionado los dos primeros PC con el objetivo de validar el sistema de detección de fallo con una baja representación y un grado bajo del modelo PCA.

La Figura 17 muestra el plano entre los dos primeros PC. Como se observa se ha logrado una separabilidad suficiente de la clase de fallo EF con respecto a la clase de funcionamiento normal. La elipse representa el umbral de detección obtenido de la clase de funcionamiento normal. A pesar de que se selecciona dos PC existe una separabilidad suficiente entre las dos clases lo que permite la detección oportuna de la falla minimizando las falsas alarmas. Si bien visualmente aparece una mezcla entre ambas clases, este efecto no influye en la detección de falla ya que son estados que corresponden a los datos de la clase en fallo pero que coinciden con los estados de operación normal.

Una vez que los estados de operación salen de la elipse de umbral, el comportamiento dinámico del SCIM se degrada considerablemente y por ende se realiza la detección de falla. Consecuentemente las corrientes se elevan 1.35 veces respecto a la corriente nominal.

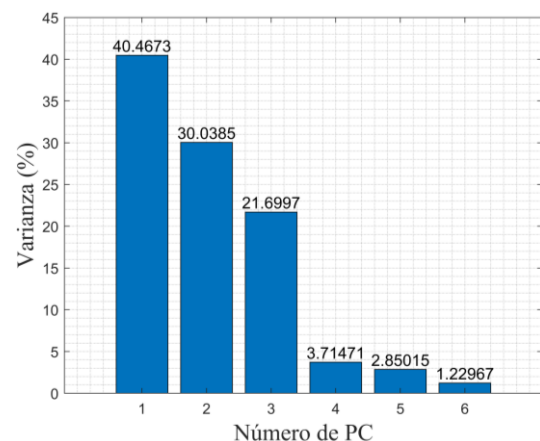


Figura 16. Varianza de PC de EF

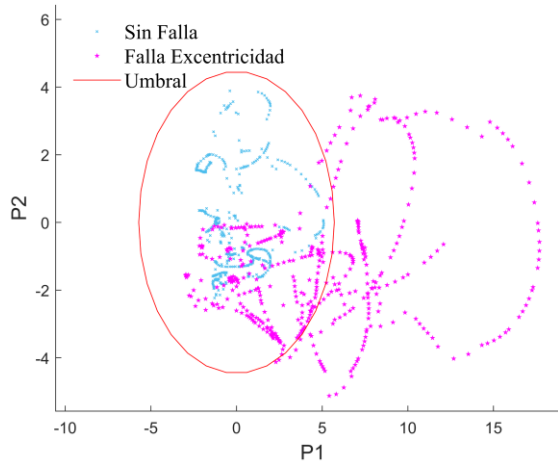


Figura 17. de EF usando P1 y P2.

5.2.2 Escenario 3 – Armónicos en el estator

Para este caso de estudio se tiene la falla SH obteniendo el comportamiento ilustrado en la Figura 19.

Como se muestra en la Figura 18, se observa una separabilidad suficiente de la clase de fallo SH con respecto a la clase de funcionamiento normal. En este caso para lograr mayor representación del modelo PCA (98.4719%) se han seleccionado los tres primeros PC. Como se puede observar en la Figura 19 al seleccionar los tres primeros PC se garantiza una separabilidad suficiente entre las clases, eliminando las falsas alarmas.

El elipsoide mostrado en la Figura 19 representa el umbral de detección de fallo tridimensional, resultando en una mejor apreciación de la separabilidad de los escenarios. Se puede deducir que ninguna muestra en color verde de SH invade el elipsoide de umbral, infiriendo así que, el SCIM se ve fatigado drásticamente alcanzado un factor de servicio de 2.2, comprometiendo sus bobinados por incremento abrupto de temperatura notable en los primeros minutos de operación.

Cabe mencionar que el incremento de temperatura no es muy notable en las muestras registradas debido al corto intervalo de muestreo, pero este si se encuentra presente siendo proporcional al tiempo de operación y la magnitud de

corrientes; ya que se registró lecturas específicamente en los devanados del cuerpo inductor.

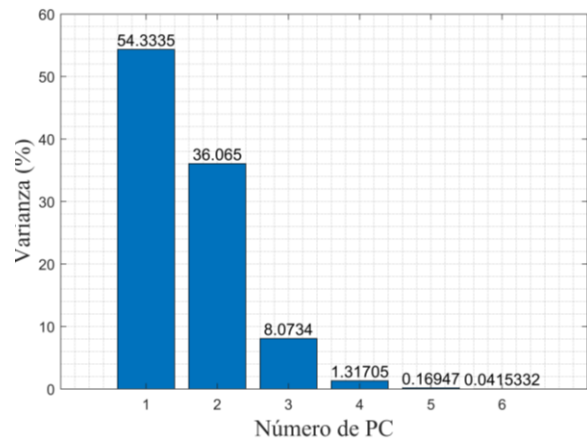


Figura 18. Varianza de PC de SH.

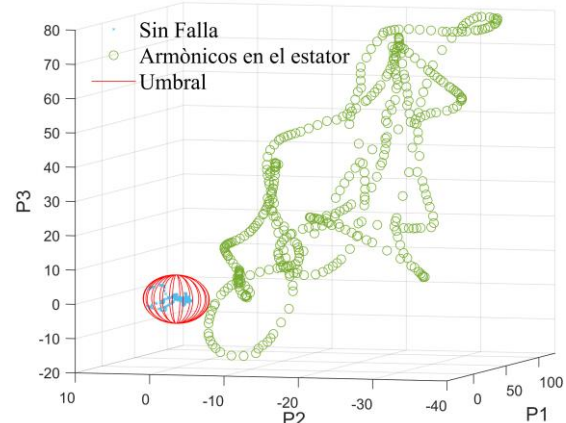


Figura 19. Detección de falla SH 3D usando P1, P2 y P3.

5.2.3 Escenario 4 – Barra del rotor rota.

El desperfecto de BRBF se presenta con gravedad desde sus primeros índices de falla incrementando su severidad en proporción a la carga. En la Figura 21 se observa el comportamiento de BRBF. Por otro lado, en la Figura 20 se tiene que tan solo con la primera PC (99.0452%) es suficiente para representar al SCIM, ya que esta contiene la suficiente información de las variables garantizando que el modelo toma la suficiente información de todas las variables.

Puesto que, con la primera PC es suficiente para representar el SCIM; en este documento se ha seleccionado los dos primeros PC (99.8017%) con el objetivo de validar una correcta representación visual.

De este modo, se obtiene en la Figura 21 un plano entre los dos primeros PC, siendo visualmente notoria la separabilidad de la clase de BRBF con respecto a la clase de funcionamiento normal.

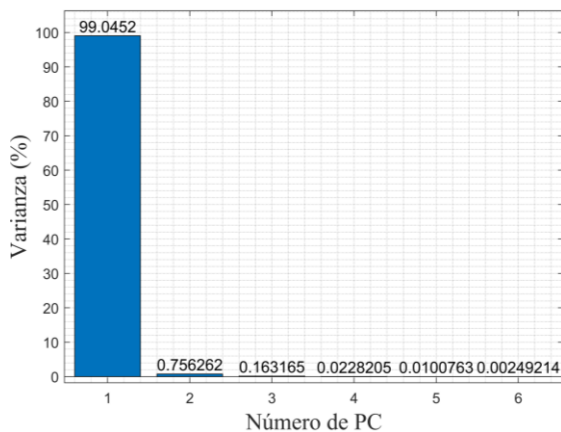


Figura 20. Varianza de PC de BRBF.

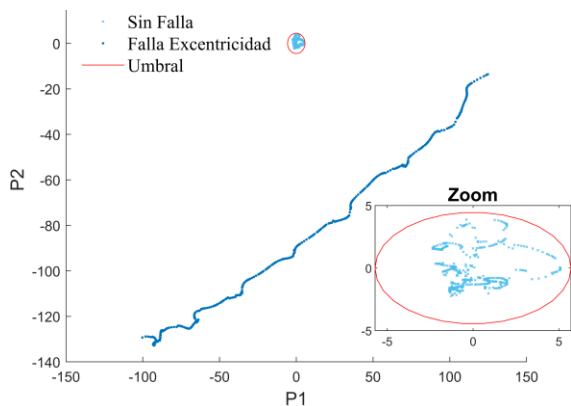


Figura 21. Detección de Falla de BRBF

En la elipse de umbral ilustrada en la subtrama aumentada de la Figura 21, se tiene que ninguna muestra en color azul invade la elipse, lo que permite inferir que el SCIM presencia un escenario de saturación magnética, conllevando a las corrientes de arranque de 5.5 veces respecto con la corriente nominal.

5.3 Comportamiento de las fallas respecto al índice de fallo.

El índice de fallo o tasa de falla corresponde a el grado de avería que presenta el SCIM este puede ir desde la insipencia o desde sus primeros síntomas que no repercuten en gran medida al SCIM y si no se realiza detección de fallas puede pasar desapercibido. Del mismo modo la tasa de

falla es capaz de alcanzar la saturación magnética o anómalas fricciones mecánicas, lo que permite deducir que el SCIM queda inutilizado.

En este documento con el fin de validar la capacidad del algoritmo para detectar fallos desde su insipencia hasta la saturación (10% - 90%); se ha propuesto dos escenarios, uno con tasa de falla del 10% ilustrada en la Figura 22 y otro con tasa de falla del 90% del mismo modo ilustrado en la Figura 23.

En la Figura 22 (A10) y Figura 23 (B90) se tiene una representación visual de todas las clases bidimensional, esto dado que se selecciona las dos primeras PC, siendo suficiente para explicar el comportamiento de las 10 variables registradas. Validado una separabilidad suficiente para detectar fallas con respecto a la elipse de umbral.

Al paralelar los escenarios A10 y B90 se puede notar que las clases distan en mayor manera en B90 con respecto a la elipse de umbral, por otro lado en A10 las clases distan 30 veces menos. Si bien para el escenario A10 es notoria una menor separabilidad, esto no influye en la detección de falla ya que solo es necesario que las observaciones salgan de las delimitaciones de la elipse de umbral para interpretarlas como fallos en el SCIM. Por último, se concluye que mientras mayor sea la tasa de falla mayor será la separabilidad de las clases de falla con respecto a la clase de funcionamiento normal.

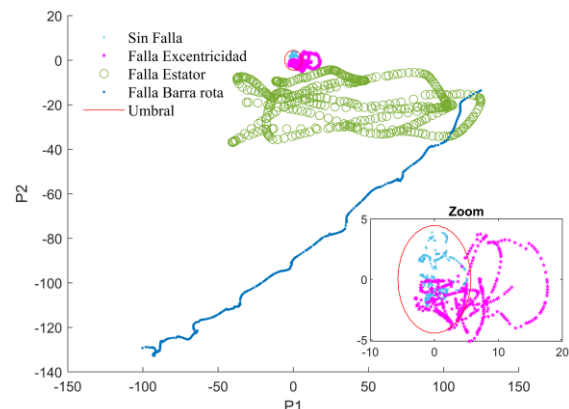


Figura 22. Detección de fallas con tasa de fallo del 10%

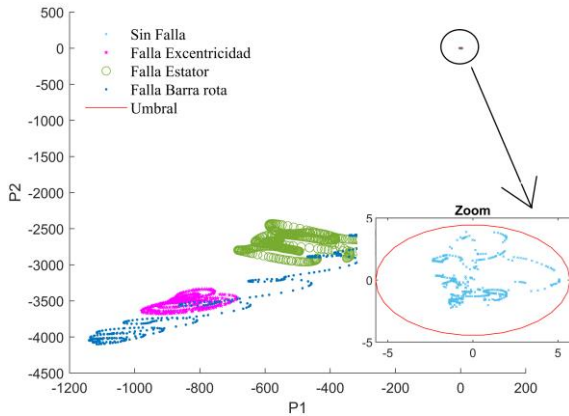


Figura 23. Detección de falla con tasa de falla del 90%

5.4 Comportamiento con datos obtenidos de campo

Para este caso de estudio se tiene la falla BF obteniendo el comportamiento ilustrado en la Figura 25.

Las muestras obtenidas de campo fueron 28000 en 48 minutos tanto en funcionamiento normal como en falla, de lo cual, se seleccionó 600 muestras que consisten en un ciclo de operación en campo. Se trabaja con ciclos de operación para entrenar el algoritmo, dado que, el régimen de operación del SCIM presenta no estacionariedad como lo ilustra la Figura 26 y la falta de datos del comportamiento de operación generaría falsas alarmas.

Como se muestra en la Figura 25, se tiene un marco bidimensional representando las dos primeras PC validando suficiente separabilidad. Puesto que, en la Figura 24 nos garantiza que con las dos primeras PC (99.2832%) el modelo PCA conserva la mayor información posible de las 7 variables estando bien representadas.

En la elipse de umbral ilustrada en la subtrama aumentada de la Figura 25, se tiene que ninguna muestra en color naranja invade la elipse, lo que permite deducir que el motor presenta fatiga por fricción en los rodamientos, reduciendo drásticamente la eficiencia y aumentando el consumo de energía para seguir con el cumplimiento de su función.

Por otro lado, paralelando la falla EF con BF podemos notar que las clases de funcionamiento normal tienen la peculiaridad de partir del punto (0,0) esto se debe a que se estandariza los datos de funcionamiento normal como umbral, sin embargo las dimensiones de la elipse varían de acuerdo con el espectro muestral de funcionamiento normal que se le dé.

La detección de fallos con muestras de campo requiere de la correcta selección del espacio muestral, ya que, este debe contener todas las peculiaridades que representan el comportamiento de la operación del SCIM, con él, fin de recrear el correcto umbral para la detección.

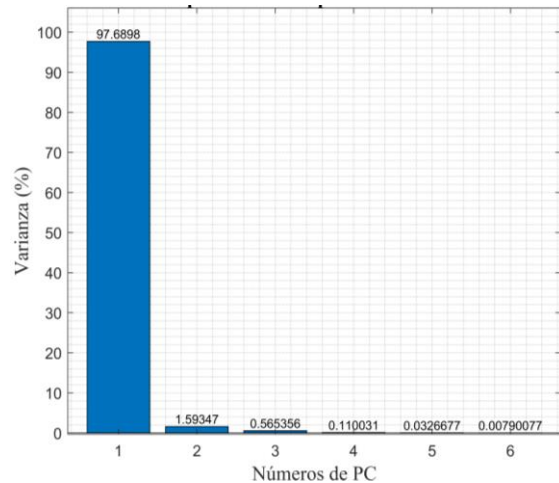


Figura 24. Varianzas de PC de BF.

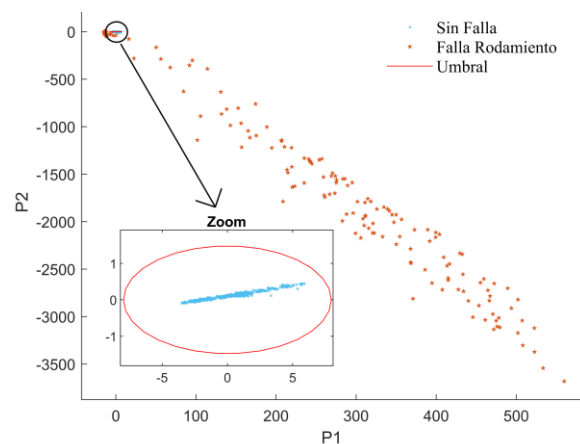


Figura 25. Detección de falla BF con datos de campo.

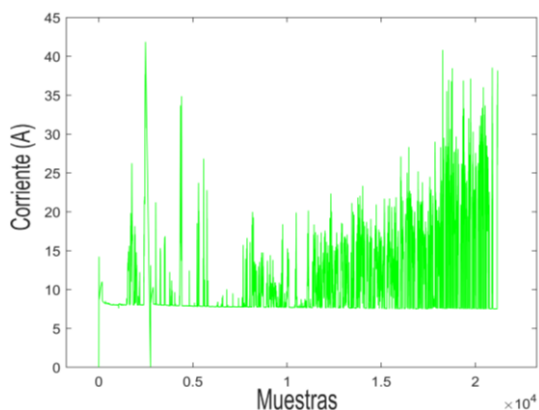


Figura 26. Muestreo de corriente del SCIM de campo.

6 Conclusiones

El algoritmo basado en PCA es capaz de detectar fallas puesto que la separabilidad de las clases es evidente y deducible como fallas con respecto a la elipse o el elipsoide de umbral según corresponda el plano 2D o 3D. Por consiguiente, la reducción de la dimensionalidad es eficiente dado que se trabajó con dos o tres PC validadas con respecto a las varianzas explicadas detalladas en los histogramas expuesto en el análisis de resultados, además de ser comprobadas con el aporte visual en marco tridimensional o bidimensional según la distribución de varianzas y detección de fallos.

La baja separabilidad de las clases respecto al umbral con una baja tasa de fallo no es una limitante para poder notar una falla dado que basta con tener unas pocas observaciones fuera del umbral para tener una alarma de los primeros síntomas de fallo.

La normalización de datos tiene impacto positivo en el análisis de covariación reduciendo notoriamente falsas alarmas y maximizando la precisión del modelo, además, de mejorar la capacidad de reducción de la dimensionalidad garantizando que en las dos o tres primeras PC está bien representadas las variables registradas.

El algoritmo no presenta ambigüedad a la no estacionariedad y es eficiente con

datos obtenidos en campo, sin embargo, se debe considerar los ciclos de operación del SCIM en campo para obtener las peculiaridades muestrales para entrenar el algoritmo garantizando la ausencia de falsas alarmas.

6.1 Trabajos futuros

Como posible línea de investigación en vista del hecho que la fase de registro de datos y detección de fallas en motores trifásicos tipo jaula de ardilla está completada, se propone, realizar la fase de diagnóstico de fallas y mantenimiento programado del SCIM.

Otra posibilidad de investigación es realizar un sistema robusto con entrenamiento del PCA que se lo puede realizar por medio de la reconstrucción de datos y calculando el error de reconstrucción, definiendo al algoritmo como robusto una vez que se alcance el objetivo.

7 Referencias

- [1] J. Faiz, V. Ghorbanian, and B. M. Ebrahimi, "A survey on condition monitoring and fault diagnosis in line-start and inverter-fed broken bar induction motors," in *2012 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, IEEE, Dec. 2012, pp. 1–5. doi: 10.1109/PEDES.2012.6484487.
- [2] R. McElveen, J. Korkeakoski, and J. Malinowski, "Electrical and mechanical differences between NEMA/IEEE and IEC ac low voltage random wound induction motors," in *2012 Petroleum and Chemical Industry Conference (PCIC)*, IEEE, Sep. 2012, pp. 1–10. doi: 10.1109/PCICON.2012.6549685.
- [3] C. G. Novoa, G. A. G. Berrios, and R. A. Soderberg, "Predictive maintenance for motors based on vibration analysis with compact rio," in *2017 IEEE Central America and*

- Panama Student Conference (CONESCAPAN)*, IEEE, Sep. 2017, pp. 1–6. doi: 10.1109/CONESCAPAN.2017.8277603.
- [4] B. Akin, S. B. Ozturk, H. A. Toliyat, and M. Rayner, “DSP-Based Sensorless Electric Motor Fault-Diagnosis Tools for Electric and Hybrid Electric Vehicle Powertrain Applications,” *IEEE Trans Veh Technol*, vol. 58, no. 6, pp. 2679–2688, Jul. 2009, doi: 10.1109/TVT.2009.2012430.
- [5] G. H. Bazan, A. Goedel, O. Duque-Perez, and D. Morinigo-Sotelo, “Multi-Fault Diagnosis in Three-Phase Induction Motors Using Data Optimization and Machine Learning Techniques,” *Electronics (Basel)*, vol. 10, no. 12, p. 1462, Jun. 2021, doi: 10.3390/electronics10121462.
- [6] L. Ortiz-Matos, L. B. G. Zea, and J. W. González-Sánchez, “A Methodology of Sensor Fault-Tolerant Control on a Hierarchical Control for Hybrid Microgrids,” *IEEE Access*, vol. 11, no. June, pp. 58078–58098, 2023, doi: 10.1109/ACCESS.2023.3279821.
- [7] L. Ortiz, J. W. González, L. B. Gutierrez, and O. Llanes-Santiago, “Impact of voltage sensor faults on two-level hierarchical control required for Grid-forming VSCs in isolated Microgrids,” *It is submitted for journal review.*, 2023.
- [8] J. Ramírez, L. Ortiz, and A. Aguila, “Passive Control Tolerant to Sensing Faults in dynamic compensation devices - SVC through a hybrid strategy Control Pasivo Tolerante a Fallos de sensado en dispositivos de compensación dinámicos - SVC mediante una estrategia híbrida,” *Ingenius*, no. 28, pp. 34–43, 2022, doi: <https://doi.org/10.17163/ings.n28.2022.03>.
- [9] F. Uguiles, L. Ortiz, and A. Aguila, “Estrategia de identificación no-lineal para Fuentes de Generación Distribuida acopladas electrónicamente a Micro-redes en CA / CC basada en NARX,” *RISTI – Revista Ibérica de Sistemas e Tecnologías de Informação*, no. E48, pp. 576–593, 2021, [Online]. Available: <http://www.risti.xyz/issues/ristie48.pdf>
- [10] J. C. Buestán, L. Ortiz Matos, and A. Aguila Telelz, “Control Tolerante a Fallos Multi-Objetivo para BESS acoplados a Micro-redes aisladas basado en IMC y H_{∞} ,” *Serie Científica de la Universidad de las Ciencias Informáticas*, vol. 15, no. 5, pp. 41–56, 2022, [Online]. Available: <https://publicaciones.uci.cu/index.php/serie/article/view/1046/912>
- [11] B. Ramírez, L. Ortiz, and W. Pavón, “Análisis Dinámico Comparativo de Métodos de Detección e identificación de Fallas de Sensado sobre el Control Local de Micro-redes,” *RISTI – Revista Ibérica de Sistemas e Tecnologías de Informação*, vol. E45, no. 44, pp. 1–17, 2021, [Online]. Available: <http://www.risti.xyz/issues/ristie45.pdf>
- [12] B. E. Ramírez Velasco and L. Ortiz Matos, “Estudio comparativo de métodos de detección e identificación de fallas (FDI) de sensado sobre el Control Local de micro redes Electricas Híbridas AC/DC,” Universidad Politécnica Salesiana, 2020. [Online]. Available: <https://dspace.ups.edu.ec/handle/123456789/19170>
- [13] L. Ortiz, J. W. Gonzalez, L. B. Gutierrez, and O. Llanes-santiago,

- “A review on control and fault-tolerant control systems of AC / DC microgrids,” *Heliyon*, vol. 6, no. June, 2020, doi: 10.1016/j.heliyon.2020.e04799.
- [14] B. Bengherbia, R. Kara, A. Toubal, M. O. Zmirli, S. Chadli, and P. Wira, “FPGA implementation of a wireless sensor node with a built-in ADALINE neural network coprocessor for vibration analysis and fault diagnosis in machine condition monitoring,” *Measurement*, vol. 163, p. 107960, Oct. 2020, doi: 10.1016/j.measurement.2020.107960.
- [15] A. M. G. Júnior, V. V. R. Silva, L. M. R. Baccarini, and L. F. S. Mendes, “The design of multiple linear regression models using a genetic algorithm to diagnose initial short-circuit faults in 3-phase induction motors,” *Appl Soft Comput*, vol. 63, pp. 50–58, Feb. 2018, doi: 10.1016/j.asoc.2017.11.015.
- [16] S. Dutta, B. Basu, and F. A. Talukdar, “Classification of motor faults based on transmission coefficient and reflection coefficient of omni-directional antenna using DCNN,” *Expert Syst Appl*, vol. 198, no. March, p. 116832, Jul. 2022, doi: 10.1016/j.eswa.2022.116832.
- [17] E. T. Esfahani, S. Wang, and V. Sundararajan, “Multisensor Wireless System for Eccentricity and Bearing Fault Detection in Induction Motors,” *IEEE/ASME Transactions on Mechatronics*, vol. 19, no. 3, pp. 818–826, Jun. 2014, doi: 10.1109/TMECH.2013.2260865.
- [18] L. Magadán, F. J. Suárez, J. C. Granda, and D. F. García, “Low-cost real-time monitoring of electric motors for the Industry 4.0,” *Procedia Manuf*, vol. 42, no. 2019, pp. 393–398, 2020, doi: 10.1016/j.promfg.2020.02.057.
- [19] M. Drakaki, Y. L. Karnavas, P. Tzionas, and I. D. Chasiotis, “Recent Developments Towards Industry 4.0 Oriented Predictive Maintenance in Induction Motors,” *Procedia Comput Sci*, vol. 180, pp. 943–949, 2021, doi: 10.1016/j.procs.2021.01.345.
- [20] S. Vadi, R. Bayindir, Y. Toplar, and I. Colak, “Induction motor control system with a Programmable Logic Controller (PLC) and Profibus communication for industrial plants — An experimental setup,” *ISA Trans*, vol. 122, pp. 459–471, Mar. 2022, doi: 10.1016/j.isatra.2021.04.019.
- [21] A. L. O. Vitor, A. Goedtel, S. Barbon, G. H. Bazan, M. F. Castoldi, and W. A. Souza, “Induction motor short circuit diagnosis and interpretation under voltage unbalance and load variation conditions,” *Expert Syst Appl*, vol. 224, no. January, p. 119998, Aug. 2023, doi: 10.1016/j.eswa.2023.119998.
- [22] R. Guerreiro Carvalho Cunha, E. T. da Silva, and C. Marques de Sá Medeiros, “Machine learning and multiresolution decomposition for embedded applications to detect short-circuit in induction motors,” *Comput Ind*, vol. 129, p. 103461, Aug. 2021, doi: 10.1016/j.compind.2021.103461.
- [23] P. Fu, J. Wang, X. Zhang, L. Zhang, and R. X. Gao, “Dynamic Routing-based Multimodal Neural Network for Multi-sensory Fault Diagnosis of Induction Motor,” *J Manuf Syst*, vol. 55, no. May, pp. 264–272, Apr. 2020, doi: 10.1016/j.jmsy.2020.04.009.
- [24] J. R. Collaguazo Solís and L. Ortiz Matos, “Control de voltaje óptimo

- para sistemas de almacenamiento de energía de batería (BESS) acoplados a microrredes de AC utilizando algoritmos LQG,” Universidad Politécnica Salesiana, 2020. [Online]. Available: <https://dspace.ups.edu.ec/handle/123456789/19171>
- [25] A. F. Falcón Ayala and L. Ortiz Matos, “Confiabilidad en microredes eléctricas AC/DC usando control robusto H_∞ y estrategias de tolerancia a fallas,” Universidad Politécnica Salesiana, 2019. [Online]. Available: <http://dspace.ups.edu.ec/handle/123456789/17685>
- [26] S. X. Garrido Jácome and L. Ortiz Matos, “Estrategia activa de tolerancia a fallas para el control Buck-Boost de micro-redes eléctricas en DC,” Universidad Politécnica Salesiana, 2019. [Online]. Available: <http://dspace.ups.edu.ec/handle/123456789/17621>
- [27] F. A. Urgiles Navarrete and L. Ortiz Matos, “Estrategia de identificación dinámica no lineal basada en NARX para fuentes de generación distribuida acopladas electrónicamente a micro – redes AC/DC,” Universidad Politécnica Salesiana, 2020. [Online]. Available: <https://dspace.ups.edu.ec/handle/123456789/18892>
- [28] L. Ortiz, L. B. Gutiérrez, J. W. González, and A. Águila, “A novel strategy for dynamic identification in AC/DC microgrids based on ARX and Petri Nets,” *Heliyon*, vol. 6, no. March, p. 18, 2020, doi: 10.1016/j.heliyon.2020.e03559.
- [29] L. Ortiz Matos, L. B. Gutierrez Zea, J. W. González Sanchez, and A. Aguila Tellez, “An ARX-Petri Nets algorithm for Active Identification of an AC / DC Microgrid Simulation,” in *2019 IEEE 4th Colombian Conference on Automatic Control (CCAC)*, Medellín, Colombia: IEEE, 2019, p. 6. doi: 10.1109/CCAC.2019.8921191.
- [30] J. L. M. Bastidas and L. O. Matos, “Localización de fallas en microredes eléctricas basado en un modelo Markoviano.,” Universidad Politécnica Salesiana, 2018. [Online]. Available: <http://dspace.ups.edu.ec/handle/123456789/15782>
- [31] G. K. Chinchuña Toledo and L. Ortiz Matos, “Mejoramiento de la fiabilidad en microredes mediante el control robusto de voltaje usando técnicas pasivas de tolerancia a fallos,” Universidad Politécnica Salesiana, 2018. [Online]. Available: <http://dspace.ups.edu.ec/handle/123456789/15342>
- [32] J. G. B. Sánchez and L. O. Matos, “Estrategia de tolerancia a fallas por condiciones ambientales para IEDS en subestaciones de distribución,” Universidad Politécnica Salesiana, 2016. [Online]. Available: <https://dspace.ups.edu.ec/handle/123456789/13260>
- [33] G.-J. Feng, J. Gu, D. Zhen, M. Aliwan, F.-S. Gu, and A. D. Ball, “Implementation of envelope analysis on a wireless condition monitoring system for bearing fault diagnosis,” *International Journal of Automation and Computing*, vol. 12, no. 1, pp. 14–24, Feb. 2015, doi: 10.1007/s11633-014-0862-x.
- [34] V. Musale and D. Chaudhari, “Challenges, protocols and case studies in design of reliable energy efficient wireless sensor networks,” in *2017 4th International Conference on Advanced Computing and Communication Systems (ICACCS)*, IEEE, Jan. 2017, pp. 1–7. doi: 10.1109/ICACCS.2017.8014583.

- [35] M. A. Rahmadhani, L. V. Yovita, and R. Mayasari, "Energy Consumption and Packet Loss Analysis of LEACH Routing Protocol on WSN Over DTN," in *2018 4th International Conference on Wireless and Telematics (ICWT)*, IEEE, Jul. 2018, pp. 1–5. doi: 10.1109/ICWT.2018.8527827.
- [36] Xin Xue, V. Sundararajan, and W. P. Brithinee, "The application of wireless sensor networks for condition monitoring in three-phase induction motors," in *2007 Electrical Insulation Conference and Electrical Manufacturing Expo*, IEEE, Oct. 2007, pp. 445–448. doi: 10.1109/EEIC.2007.4562657.
- [37] S. Sridhar, K. U. Rao, M. S. Nihaal, and A. K. Shetty Aashik, "Real time wireless condition monitoring of induction motor," in *2016 IEEE Industrial Electronics and Applications Conference (IEACon)*, IEEE, Nov. 2016, pp. 173–178. doi: 10.1109/IEACON.2016.8067375.
- [38] M. Singh and A. G. Shaik, "Broken Rotor Bar Fault Diagnosis of a Three-phase Induction Motor using Discrete Wavelet Transform," in *2019 IEEE PES GTD Grand International Conference and Exposition Asia (GTD Asia)*, IEEE, Mar. 2019, pp. 13–17. doi: 10.1109/GTDAsia.2019.8715925.
- [39] M. Z. Ali and X. Liang, "Threshold-Based Induction Motors Single- and Multifaults Diagnosis Using Discrete Wavelet Transform and Measured Stator Current Signal," *Canadian Journal of Electrical and Computer Engineering*, vol. 43, no. 3, pp. 136–145, Jun. 2020, doi: 10.1109/CJECE.2020.2966114.
- [40] Y. Liu and A. M. Bazzi, "A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art," *ISA Trans*, vol. 70, pp. 400–409, Sep. 2017, doi: 10.1016/j.isatra.2017.06.001.
- [41] H. Keskes and A. Braham, "Recursive Undecimated Wavelet Packet Transform and DAG SVM for Induction Motor Diagnosis," *IEEE Trans Industr Inform*, vol. 11, no. 5, pp. 1059–1066, Oct. 2015, doi: 10.1109/TII.2015.2462315.
- [42] A. Braham and H. Keskes, "DAG SVM and Pitch Synchronous Wavelet Transform for Induction Motor diagnosis," in *7th IET International Conference on Power Electronics, Machines and Drives (PEMD 2014)*, Institution of Engineering and Technology, 2014, pp. 0166–0166. doi: 10.1049/cp.2014.0321.
- [43] N. Bessous, S. E. Zouzou, S. Sbaa, and W. Bentrach, "A comparative study between the MCSA, DWT and the vibration analysis methods to diagnose the dynamic eccentricity fault in induction motors," in *2017 6th International Conference on Systems and Control (ICSC)*, IEEE, May 2017, pp. 414–421. doi: 10.1109/ICoSC.2017.7958655.
- [44] V. Duc Nguyen, E. Zwanenburg, S. Limmer, W. Luijben, T. Back, and M. Olhofer, "A Combination of Fourier Transform and Machine Learning for Fault Detection and Diagnosis of Induction Motors," in *2021 8th International Conference on Dependable Systems and Their Applications (DSA)*, IEEE, Aug. 2021, pp. 344–351. doi: 10.1109/DSA52907.2021.00053.
- [45] N. Rajapaksha, S. Jayasinghe, H. Enshaei, and N. Jayarathne, "Supervised Machine Learning Algorithm Selection for Condition Monitoring of Induction Motors," in *2021 IEEE Southern Power Electronics Conference (SPEC)*,

- IEEE, Dec. 2021, pp. 1–10. doi: 10.1109/SPEC52827.2021.9709436.
- [46] R. R. Kumar *et al.*, “Induction Machine Stator Fault Tracking Using the Growing Curvilinear Component Analysis,” *IEEE Access*, vol. 9, pp. 2201–2212, 2021, doi: 10.1109/ACCESS.2020.3047202.
- [47] A. Allal and A. Khechekhouché, “Diagnosis of induction motor faults using the motor current normalized residual harmonic analysis method,” *International Journal of Electrical Power & Energy Systems*, vol. 141, p. 108219, Oct. 2022, doi: 10.1016/j.ijepes.2022.108219.
- [48] J. Huang, X. Sun, X. Yang, and K. Peng, “Fault detection for chemical processes based on non-stationarity sensitive cointegration analysis,” *ISA Trans*, vol. 129, no. Pt B, pp. 321–333, Oct. 2022, doi: 10.1016/j.isatra.2022.02.010.
- [49] P. Zhou, Z. Peng, S. Chen, Z. Tian, and M. J. Zuo, “Sinusoidal FM patterns of fault-related vibration signals for planetary gearbox fault detection under non-stationary conditions,” *Mech Syst Signal Process*, vol. 155, p. 107623, Jun. 2021, doi: 10.1016/j.ymsp.2021.107623.
- [50] X. Wang, J. Zheng, Q. Ni, H. Pan, and J. Zhang, “Traversal index enhanced-gram (TIEgram): A novel optimal demodulation frequency band selection method for rolling bearing fault diagnosis under non-stationary operating conditions,” *Mech Syst Signal Process*, vol. 172, p. 109017, Jun. 2022, doi: 10.1016/j.ymsp.2022.109017.
- [51] Himani and R. Dahiya, “Condition monitoring of wind turbine for rotor fault detection under non stationary conditions,” *Ain Shams Engineering Journal*, vol. 9, no. 4, pp. 2441–2452, Dec. 2018, doi: 10.1016/j.asej.2017.04.002.
- [52] P. A. Delgado Arredondo, “Diagnóstico de motores eléctricos para la localización de fallas incipientes,” Universidad de Valladolid, 2017. doi: 10.35376/10324/27619.
- [53] L. Saidi, F. Fnaiech, H. Henao, G.-A. Capolino, and G. Cirrincione, “Diagnosis of broken-bars fault in induction machines using higher order spectral analysis,” *ISA Trans*, vol. 52, no. 1, pp. 140–148, Jan. 2013, doi: 10.1016/j.isatra.2012.08.003.
- [54] C. Ding, M. Zhao, J. Lin, K. Liang, and J. Jiao, “Kernel ridge regression-based chirplet transform for non-stationary signal analysis and its application in machine fault detection under varying speed conditions,” *Measurement*, vol. 192, p. 110871, Mar. 2022, doi: 10.1016/j.measurement.2022.110871.
- [55] S. P. Quishpe Guamantica and L. Ortiz Matos, “Detección de fallas de sensado en convertidores CA/CC para micro-redes híbridas usando análisis de componentes principales (PCA),” Universidad Politécnica Salesiana, 2021. [Online]. Available: <https://dspace.ups.edu.ec/handle/123456789/19791>
- [56] M. Juez-Gil, J. J. Saucedo-Dorantes, Á. Arnaiz-González, C. López-Nozal, C. García-Osorio, and D. Lowe, “Early and extremely early multi-label fault diagnosis in induction motors,” *ISA Trans*, vol. 106, pp. 367–381, Nov. 2020, doi: 10.1016/j.isatra.2020.07.002.
- [57] E. Kilic, O. Ozgonenel, and A. E. Ozdemir, “Fault Identification in Induction Motors with RBF Neural Network Based on Dynamical PCA,” in *2007 IEEE International Electric*

- Machines & Drives Conference*, IEEE, May 2007, pp. 830–835. doi: 10.1109/IEMDC.2007.382776.
- [58] M. A. de Carvalho Michalski and G. F. Martha de Souza, “Comparing PCA-based fault detection methods for dynamic processes with correlated and Non-Gaussian variables,” *Expert Syst Appl*, vol. 207, p. 117989, Nov. 2022, doi: 10.1016/j.eswa.2022.117989.
- [59] H. A. Weiss, N. Leuning, K. Hameyer, H. Hoffmann, and W. Volk, “Manufacturing efficient electrical motors with a predictive maintenance approach,” *CIRP Annals*, vol. 68, no. 1, pp. 253–256, 2019, doi: 10.1016/j.cirp.2019.04.044.
- [60] J. Fraile Mora, *Máquinas eléctricas*, 8^a ed. Madrid: Garceta, 2016.
- [61] J. M. Redondo Gallardo and M. Domínguez Herranz, *Electrotecnia*. Barcelona, SPAIN: Cano Pina, 2013.
- [62] “Reference-Frame Theory,” in *Analysis of Electric Machinery and Drive Systems*, IEEE, 2009. doi: 10.1109/9780470544167.ch3.
- [63] “Model dynamics of three-phase asynchronous machine, also known as induction machine, in SI or pu units - Simulink - MathWorks América Latina.” https://la.mathworks.com/help/sps/powersys/ref/asynchronousmachine.html?searchHighlight=AsynchronousMachine&s_tid=srchtitle_AsynchronousMachine_1 (accessed Jan. 18, 2023).
- [64] Ş. Bayraktar and Y. Turgut, “Experimental and statistical analysis of the effects of punching and laser cutting methods on induction motor efficiency and total magnetic losses in silicon lamination sheets,” *J Magn Magn Mater*, vol. 572, no. March, p. 170599, Apr. 2023, doi: 10.1016/j.jmmm.2023.170599.
- [65] S. Fan, D. Meng, and M. Ai, “Efficiency analytical of five-phase induction motors with different stator connections for fracturing pump drives,” *Energy Reports*, vol. 8, pp. 405–413, 2022, doi: 10.1016/j.egy.2021.11.240.
- [66] M. Jiang *et al.*, “Experimental study on the influence of high frequency PWM harmonics on the losses of induction motor,” *Energy Reports*, vol. 8, pp. 332–342, Nov. 2022, doi: 10.1016/j.egy.2022.09.158.
- [67] M. Tran *et al.*, “Robust fault recognition and correction scheme for induction motors using an effective IoT with deep learning approach,” *Measurement*, vol. 207, no. September 2022, p. 112398, Feb. 2023, doi: 10.1016/j.measurement.2022.112398.
- [68] T. Ghanbari, A. Mehraban, and E. Farjah, “Inter-turn fault detection of induction motors using a method based on spectrogram of motor currents,” *Measurement*, vol. 205, no. October, p. 112180, Dec. 2022, doi: 10.1016/j.measurement.2022.112180.
- [69] P. Kumar and A. S. Hati, “Dilated convolutional neural network based model for bearing faults and broken rotor bar detection in squirrel cage induction motors,” *Expert Syst Appl*, vol. 191, no. October 2021, p. 116290, Apr. 2022, doi: 10.1016/j.eswa.2021.116290.
- [70] S. K. Bharti, A. Sinha, A. K. Samantaray, and R. Bhattacharyya, “Dynamics of a rotor shaft driven by a non-ideal source through a universal joint,” *J Sound Vib*, vol. 499, p. 115992, May 2021, doi: 10.1016/j.jsv.2021.115992.

- [71] V. Fernandez-Cavero, J. Pons-Llinares, O. Duque-Perez, and D. Morinigo-Sotelo, "Detection and quantification of bar breakage harmonics evolutions in inverter-fed motors through the dragon transform," *ISA Trans*, vol. 109, pp. 352–367, Mar. 2021, doi: 10.1016/j.isatra.2020.10.020.
- [72] P. F. Albrecht, J. C. Appiarius, R. M. McCoy, E. L. Owen, and D. K. Sharma, "Assessment of the Reliability of Motors in Utility Applications - Updated," *IEEE Transactions on Energy Conversion*, vol. EC-1, no. 1, pp. 39–46, Mar. 1986, doi: 10.1109/TEC.1986.4765668.
- [73] N. Yassa, M. Rachek, and H. Houassine, "Motor Current Signature Analysis for the Air Gap Eccentricity Detection In the Squirrel Cage Induction Machines," *Energy Procedia*, vol. 162, pp. 251–262, Apr. 2019, doi: 10.1016/j.egypro.2019.04.027.
- [74] S. Sarkar, P. Purkait, and S. Das, "NI CompactRIO-based methodology for online detection of stator winding inter-turn insulation faults in 3-phase induction motors," *Measurement*, vol. 182, no. December 2020, p. 109682, Sep. 2021, doi: 10.1016/j.measurement.2021.109682.
- [75] J. A. Lucena-Junior *et al.*, "Chaos theory using density of maxima applied to the diagnosis of three-phase induction motor bearings failure by sound analysis," *Comput Ind*, vol. 123, p. 103304, Dec. 2020, doi: 10.1016/j.compind.2020.103304.
- [76] Chong Di, Xiaohua Bao, Hanfeng Wang, Qiang Lv, and Yigang He, "Modeling and Analysis of Unbalanced Magnetic Pull in Cage Induction Motors With Curved Dynamic Eccentricity," *IEEE Trans Magn*, vol. 51, no. 8, pp. 1–7, Aug. 2015, doi: 10.1109/TMAG.2015.2412911.
- [77] P. A. Panagiotou, I. Arvanitakis, N. Lophitis, J. A. Antonino-Daviu, and K. N. Gyftakis, "A New Approach for Broken Rotor Bar Detection in Induction Motors Using Frequency Extraction in Stray Flux Signals," *IEEE Trans Ind Appl*, vol. 55, no. 4, pp. 3501–3511, Jul. 2019, doi: 10.1109/TIA.2019.2905803.

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

7.1 Matriz de Estado del Arte

Tabla 9: Matriz de estado del arte.

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES																							
ITEM	DATOS			TEMÁTICA				FORMULACIÓN DEL PROBLEMA				RESTRICCIÓN DEL PROBLEMA			PROPUESTA PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTICULO	CITAS	Motor trifásico tipo Jaula de ardilla	Predicción y Detección de fallas	Modernización de la matriz productiva	Método de Análisis de Componentes Principales	Falla en Motores Eléctricos	Pérdidas económicas por interrupciones forzadas	Desgaste prematuro de Equipos y desempeño ineficiente	Mantenimientos no programados	Complejidad de las plantas industriales	Reducción de costos de mantenimiento	Daños en cableado estructurado	Detección temprana y extremadamente temprana de fallas	Datos brutos y diferenciados	Aprendizaje Automático	Red de sensores inalámbricos WSN	Espectro de Variables eléctricas	Red neural artificial	Análisis de vibraciones y temperatura	Corrientes Estatóricas	Métodos estadísticos
1	2012	A survey on condition monitoring and fault diagnosis in line-start and inverter-fed broken bar induction motors	8	☒	☒			☒	☒											☒	☒		
2	2012	Electrical and mechanical differences between NEMA/IEEE and IEC ac low voltage random wound induction motors	6	☒																			
3	2017	Predictive maintenance for motors based on vibration analysis with compact rio	3	☒	☒			☒	☒			☒					☒				☒		☒
4	2009	DSP-Based Senseless Electric Motor Fault-Diagnosis Tools for Electric and Hybrid Electric Vehicle Powertrain Applications	37		☒			☒															
5	2021	Multi-Fault Diagnosis in Three-Phase Induction Motors Using Data Optimization and Machine Learning Techniques	8					☒	☒														
6	2023	A Methodology of Sensor Fault-Tolerant Control on a Hierarchical Control for Hybrid Microgrids	0		☒													☒					☒
7	2023	Impact of voltage sensor faults on two-level hierarchical control required for Grid-forming VSCs in isolated Microgrids	0		☒													☒					☒
8	2022	Passive Control Tolerant to Sensing Faults in dynamic compensation devices - SVC through a hybrid strategy Control Pasivo Tolerante a Fallos de sensado en dispositivos de compensación dinámicos - SVC mediante una estrategia híbrida	3		☒													☒					☒
9	2021	Estrategia de identificación no-lineal para Fuentes de Generación Distribuida acopladas electrónicamente a Micro-redes en CA / CC basada en NARX	2		☒															☒			
10	2022	Control Tolerante a Fallos Multi-Objetivo para BESS acoplados a Micro-redes aisladas basado en IMC y H _∞	2		☒										☒								☒
11	2021	Análisis Dinámico Comparativo de Métodos de Detección e identificación de Fallas de Sensado sobre el Control Local de Micro-redes	3		☒													☒				☒	☒

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES																							
ITEM	DATOS			TEMÁTICA				FORMULACIÓN DEL PROBLEMA				RESTRICCIÓN DEL PROBLEMA			PROPUESTA PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA					
	AÑO	TÍTULO DEL ARTICULO	CITAS	Motor trifásico tipo Jaula de ardilla	Predicción y Detección de fallas	Modernización de la matriz productiva	Método de Análisis de Componentes Principales	Falla en Motores Eléctricos	Pérdidas económicas por interrupciones forzadas	Desgaste prematuro de Equipos y desempeño ineficiente	Mantenimientos no programados	Complejidad de las plantas industriales	Reducción de costos de mantenimiento	Daños en cableado estructurado	Detección temprana y extremadamente temprana de fallas	Datos brutos y diferenciados	Aprendizaje Automático	Red de sensores inalámbricos WSN	Espectro de Variables eléctricas	Red neural artificial	Análisis de vibraciones y temperatura	Corrientes Estatóricas	Métodos estadísticos
25	2019	Confiabilidad en microredes eléctricas AC/DC usando control robusto H _∞ y estrategias de tolerancia a fallas	12	☒	☒			☒	☒											☒	☒		
26	2019	Estrategia activa de tolerancia a fallas para el control Buck-Boost de micro-redes eléctricas en DC	12	☒																			
27	2020	Estrategia de identificación dinámica no lineal basada en NARX para fuentes de generación distribuida acopladas electrónicamente a micro – redes AC/DC	10	☒	☒			☒	☒			☒					☒				☒		☒
28	2020	A novel strategy for dynamic identification in AC/DC microgrids based on ARX and Petri Nets	32		☒			☒															
29	2019	An ARX-Petri Nets algorithm for Active Identification of an AC / DC Microgrid Simulation	18					☒	☒														
30	2018	Localización de fallas en microredes eléctricas basado en un modelo Markoviano	0		☒																		☒
31	2018	Mejoramiento de la fiabilidad en microredes mediante el control robusto de voltaje usando técnicas pasivas de tolerancia a fallos	2	☒	☒								☒		☒								
32	2016	Estrategia de tolerancia a fallas por condiciones ambientales para IEDS en subestaciones de distribución	14	☒	☒			☒	☒					☒									☒
33	2015	Implementation of envelope analysis on a wireless condition monitoring system for bearing fault diagnosis	20		☒	☒									☒	☒							
34	2017	Challenges, protocols and case studies in design of reliable energy efficient wireless sensor networks	4			☒		☒				☒	☒	☒			☒						
35	2017	Energy Consumption and Packet Loss Analysis of LEACH Routing Protocol on WSN Over DTN	9			☒						☒					☒						
36	2007	The application of wireless sensor networks for condition monitoring in three-phase induction motors	12	☒	☒	☒		☒					☒	☒			☒			☒			

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES																								
ITEM	DATOS				TEMÁTICA				FORMULACIÓN DEL PROBLEMA				RESTRICCIÓN DEL PROBLEMA				PROPUESTA PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA			
	AÑO	TÍTULO DEL ARTICULO	CITAS	Motor trifásico tipo jaula de ardilla	Predicción y Detección de fallas	Modernización de la matriz productiva	Método de Análisis de Componentes Principales	Falla en Motores Eléctricos	Pérdidas económicas por interrupciones forzadas	Desgaste prematuro de Equipos y desempeño ineficiente	Mantenimientos no programados	Complejidad de las plantas industriales	Reducción de costos de mantenimiento	Daños en cableado estructurado	Detección temprana y extremadamente temprana de fallas	Datos brutos y diferenciados	Aprendizaje Automático	Red de sensores inalámbricos WSN	Espectro de Variables eléctricas	Red neural artificial	Análisis de vibraciones y temperatura	Corrientes Estatóricas	Métodos estadísticos	
37	2016	Real time wireless condition monitoring of induction motor	1	☒	☒	☒		☒		☒	☒		☒	☒		☒	☒	☒	☒		☒	☒		
38	2019	Broken Rotor Bar Fault Diagnosis of a Three-phase Induction Motor using Discrete Wavelet Transform	8	☒				☒		☒			☒		☒			☒			☒			
39	2020	Threshold-Based Induction Motors Single- and Multifaults Diagnosis Using Discrete Wavelet Transform and Measured Stator Current Signal	7	☒	☒			☒						☒				☒			☒			
40	2017	A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art	95	☒	☒	☒	☒	☒	☒	☒	☒	☒		☒	☒	☒		☒	☒	☒	☒	☒		
41	2015	Recursive Undecimated Wavelet Packet Transform and DAG SVM for Induction Motor Diagnosis	84	☒	☒	☒		☒						☒				☒				☒		
42	2014	DAG SVM and Pitch Synchronous Wavelet Transform for Induction Motor diagnosis	6	☒	☒			☒				☒						☒			☒			
43	2017	A comparative study between the MCSA, DWT and the vibration analysis methods to diagnose the dynamic eccentricity fault in induction motors	19	☒	☒			☒			☒			☒						☒	☒	☒		
44	2021	A Combination of Fourier Transform and Machine Learning for Fault Detection and Diagnosis of Induction Motors	1	☒	☒	☒		☒		☒			☒			☒	☒		☒		☒	☒		
45	2021	Supervised Machine Learning Algorithm Selection for Condition Monitoring of Induction Motors	0	☒	☒			☒	☒		☒		☒		☒	☒	☒		☒			☒		
46	2021	Induction Machine Stator Fault Tracking Using the Growing Curvilinear Component Analysis	4	☒	☒		☒	☒			☒	☒		☒	☒			☒	☒		☒	☒		
47	2022	Diagnosis of induction motor faults using the motor current normalized residual harmonic analysis method	4	☒	☒					☒			☒					☒			☒	☒		
48	2022	Fault detection for chemical processes based on non-stationarity sensitive cointegration analysis	1		☒		☒						☒			☒								
49	2021	Sinusoidal FM patterns of fault-related vibration signals for planetary gearbox fault detection under non-stationary conditions	9		☒					☒			☒									☒		

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES																								
ITEM	DATOS				TEMÁTICA			FORMULACIÓN DEL PROBLEMA				RESTRICCIÓN DEL PROBLEMA			PROPUESTA PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA						
	AÑO	TÍTULO DEL ARTICULO	CTTAS	Motor trifásico tipo Jaula de ardilla	Predicción y Detección de fallas	Modernización de la matriz productiva	Método de Análisis de Componentes Principales	Falla en Motores Eléctricos	Pérdidas económicas por interrupciones forzadas	Desgaste prematuro de Equipos y desempeño ineficiente	Mantenimientos no programados	Complejidad de las plantas industriales	Reducción de costos de mantenimiento	Datos en cableado estructurado	Detección temprana y extremadamente temprana de fallas	Datos brutos y diferenciados	Aprendizaje Automático	Red de sensores inalámbricos WSN	Espectro de Variables eléctricas	Red neural artificial	Análisis de vibraciones y temperatura	Corrientes Estatóricas	Métodos estadísticos	
50	2022	Traversal index enhanced gram (TIEgram): A novel optimal demodulation frequency band selection method for rolling bearing fault diagnosis under non-stationary operating conditions	6		☒					☒	☒				☒									☒
51	2018	Condition monitoring of wind turbine for rotor fault detection under nonstationary conditions	12		☒	☒				☒	☒	☒						☒					☒	
52	2017	Diagnóstico de motores eléctricos para la localización de fallas incipientes	1	☒	☒			☒					☒								☒			
53	2013	Diagnosis of broken-bars fault in induction machines using higher order spectral analysis	72	☒	☒			☒		☒					☒			☒				☒	☒	
54	2022	Kernel ridge regression-based chirp let transform for non-stationary signal analysis and its application in machine fault detection under varying speed conditions	5		☒				☒	☒					☒						☒			
55	2021	Detección de fallas de sensado en convertidores CA/CC para micro-redes híbridas usando análisis de componentes principales (PCA)	7		☒		☒		☒		☒							☒						☒
56	2020	Early and extremely early multi-label fault diagnosis in induction motors.	15	☒	☒	☒	☒	☒	☒						☒	☒	☒	☒					☒	☒
57	2007	Fault Identification in Induction Motors with RBF Neural Network Based on Dynamical PCA	2	☒	☒		☒	☒		☒		☒			☒		☒			☒				
58	2022	Comparing PCA-based fault detection methods for dynamic processes with correlated and non-Gaussian variables	1		☒	☒	☒					☒				☒								☒
59	2019	Manufacturing efficient electrical motors with a predictive maintenance approach	2		☒	☒																		☒
60	2016	Máquinas eléctricas	35	☒																				
61	2013	Electrotecnia	3	☒																				

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES																							
ITEM	DATOS			TEMÁTICA			FORMULACIÓN DEL PROBLEMA			RESTRICCIÓN DEL PROBLEMA			PROPUESTA PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA							
	AÑO	TÍTULO DEL ARTICULO	CITAS	Motor trifásico tipo jaula de ardilla	Predicción y Detección de fallas	Modernización de la matriz productiva	Método de Análisis de Componentes Principales	Falla en Motores Eléctricos	Pérdidas económicas por interrupciones forzadas	Desgaste prematuro de Equipos y desempeño ineficiente	Mantenimientos no programados	Complejidad de las plantas industriales	Reducción de costos de mantenimiento	Daños en cableado estructurado	Detección temprana y extremadamente temprana de fallas	Datos brutos y diferenciados	Aprendizaje Automático	Red de sensores inalámbricos WSN	Espectro de Variables eléctricas	Red neural artificial	Análisis de vibraciones y temperatura	Corrientes Estatóricas	Métodos estadísticos
62	2009	Analysis of Electric Machinery and Drive Systems	1976	☒																			
63	2023	Model dynamics of three-phase asynchronous machine, also known as induction machine, in SI or pu units - Simulink – MathWorks América Latina.	1	☒																			
64	2023	Experimental and statistical analysis of the effects of punching and laser cutting methods on induction motor efficiency and total magnetic losses in silicon lamination sheets	1	☒					☒														☒
65	2022	Efficiency analytical of five-phase induction motors with different stator connections for fracturing pump drives	4	☒		☒			☒														
66	2022	Experimental study on the influence of high frequency PWM harmonics on the losses of induction motor	1	☒		☒			☒														
67	2022	Robust fault recognition and correction scheme for induction motors using an effective IoT with deep learning approach	10	☒	☒			☒			☒					☒	☒						
68	2022	Inter-turn fault detection of induction motors using a method based on spectrogram of motor currents	1	☒	☒			☒							☒	☒						☒	
69	2022	Dilated convolutional neural network-based model for bearing faults and broken rotor bar detection in squirrel cage induction motors	13	☒	☒			☒							☒		☒			☒			
70	2021	Dynamics of a rotor shaft driven by a non-ideal source through a universal joint	3		☒			☒															
71	2021	Detection and quantification of bar breakage harmonics evolutions in inverter-fed motors through the dragon transform	8		☒			☒								☒							☒
72	1986	Assessment of the Reliability of Motors in Utility Applications - Updated	219	☒				☒	☒	☒													
73	2019	Motor Current Signature Analysis for the Air Gap Eccentricity Detection in the Squirrel Cage Induction Machines	20	☒	☒			☒								☒		☒				☒	
74	2021	NI CompactRIO-based methodology for online detection of stator winding inter-turn insulation faults in 3-phase induction motors	6	☒	☒		☒	☒								☒						☒	

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES																								
ITEM	DATOS				TEMÁTICA				FORMULACIÓN DEL PROBLEMA				RESTRICCIÓN DEL PROBLEMA				PROPUESTA PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA			
			TÍTULO DEL ARTICULO	CITAS	Motor trifásico tipo Jaula de ardilla	Predicción y Detección de fallas	Modernización de la matriz productiva	Método de Análisis de Componentes Principales	Falla en Motores Eléctricos	Pérdidas económicas por interrupciones forzadas	Desgaste prematuro de Equipos y desempeño ineficiente	Mantenimientos no programados	Complejidad de las plantas industriales	Reducción de costos de mantenimiento	Daños en cableado estructurado	Detección temprana y extremadamente temprana de fallas	Datos brutos y diferenciados	Aprendizaje Automático	Red de sensores inalámbricos WSN	Espectro de Variables eléctricas	Red neural artificial	Análisis de vibraciones y temperatura	Corrientes Estatóricas	Métodos estadísticos
75	2020	Chaos theory using density of maxima applied to the diagnosis of three phase induction motor bearings failure by sound analysis		21	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>				<input checked="" type="checkbox"/>									<input checked="" type="checkbox"/>			
76	2015	Modeling and Analysis of Unbalanced Magnetic Pull in Cage Induction Motors with Curved Dynamic Eccentricity		12	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>						<input checked="" type="checkbox"/>								<input checked="" type="checkbox"/>
77	2019	A New Approach for Broken Rotor Bar Detection in Induction Motors Using Frequency Extraction in Stray Flux Signals		53	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>										<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>				
				CANTIDAD:	50	59	17	8	42	20	16	12	12	15	5	19	20	14	8	24	12	14	20	31

ALGORITMO DE DETECCIÓN DE FALLAS PARA MOTORES TRIFÁSICOS TIPO JAULA DE ARDILLA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

7.2 Resumen de Indicadores

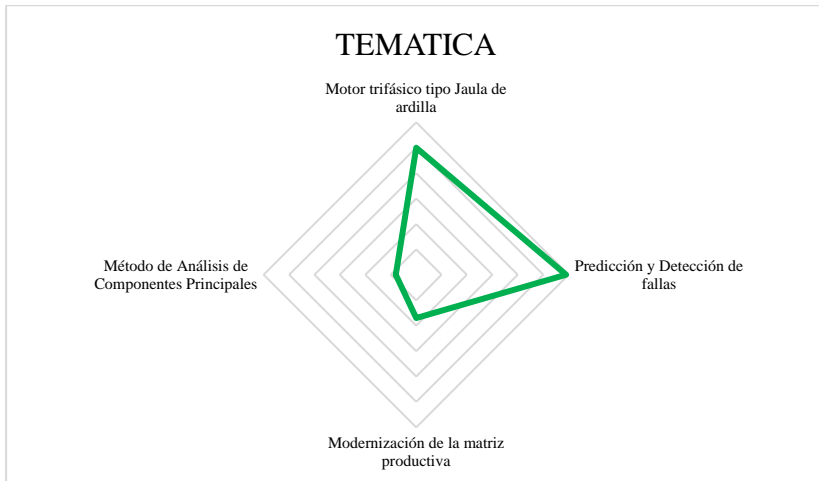


Figura 27. Resumen e indicador de la temática - Estado del arte.

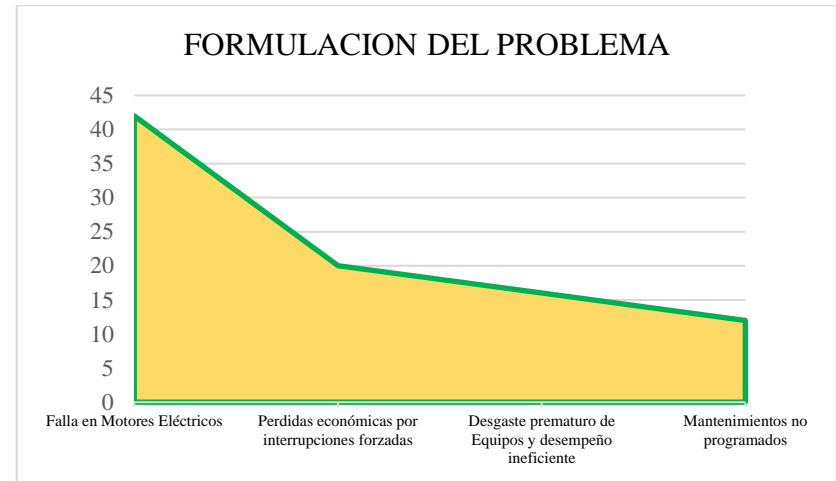


Figura 28. Indicador de formulación del problema - Estado del arte.




Figura 29. Indicador de solución - Estado del arte.