

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación



“Sistema de Monitoreo en Nube Para el Diagnóstico Predictivo de Fallos de Motores Eléctricos”

PROYECTO DE TITULACIÓN

Previo a la obtención del Título de:

Magister en Automatización y Control

Presentado por:

Ing. Ronald Manolo Chicaiza Oña

Ing. Humberto González Jiménez

GUAYAQUIL – ECUADOR

Año: 2021

DEDICATORIA

Este proyecto va dedicado a:

Primero a Dios por darme la fuerza para llegar a este momento muy importante de mi carrera profesional y mi familia por ser quienes me acompañaron en todo momento.

Una mención especial a mis profesores y compañeros de estudio por brindarme todo su apoyo durante este periodo de aprendizaje, darles mi total agradecimiento y consideración.

Ing. Humberto González

DEDICATORIA

Este proyecto va dedicado a:

A Dios quien me ha guiado todos los días de mi vida y me ha bendecido con su gracia hasta el día de hoy.

A mis padres Eduardo y Dorita quienes con su amor, paciencia y esfuerzo me pudieron dar el estudio y me han permitido llegar a cumplir hoy un sueño más

A mis hermanos Henry y Melissa quienes con su apoyo incondicional y palabras de aliento hicieron de mi mejor persona

A mis profesores y amigos de estudio quiero dedicarles y agradecerles por apoyarme y alentarme constantemente.

Ing. Ronald Chicaiza

AGRADECIMIENTO

Quiero expresar mi gratitud a Dios y a toda mi familia por estar siempre presente conmigo.

Mi profundo agradecimiento a las autoridades y personal de la Escuela Superior Politécnica del Litoral por confiar en mí, abrirme las puertas y permitirme realizar todo el proceso investigativo

Finalmente quiero expresar mi más grande y sincero agradecimiento al PhD. Dennys Paillacho y MSc. Ronald Solís, principales colaboradores durante este proceso, quienes, con sus conocimientos, permitieron el desarrollo de este trabajo

Ing. Ronald Chicaiza

AGRADECIMIENTO

Primero Dios y mi familia por caminar siempre a mi lado.

Mi total agradecimiento a las autoridades de la FIEC de la Escuela Superior Politécnica del Litoral por darme la oportunidad de crecer primero como persona y después profesionalmente con el único objetivo de alcanzar la excelencia académica aplicándola en el mundo laboral.

Ing. Humberto González

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; Ing. Ronald Manolo Chicaiza Oña y Humberto González Jiménez, damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”



**Ing. Ronald Manolo
Chicaiza Oña**



**Ing. Humberto
González Jiménez**

COMITÉ EVALUADOR



Firmado electrónicamente por:
**DENNYS FABIAN
PAILLACHO
CHILUIZA**

Ph.D. Denny Fabian Paillacho C.

PROFESOR TUTOR



Firmado electrónicamente por:
**RONALD
DAVID SOLÍS**

MSc. Ronald David Solís M

PROFESOR EVALUADOR

RESUMEN

En este trabajo de tesis se presenta el diseño de un sistema de mantenimiento predictivo de motores eléctricos para establecer las condiciones de operación y acciones recomendadas de mantenimiento basado en la predicción de datos mediante aprendizaje automático supervisado.

El sistema es diseñado e implementado en un servidor en la nube del cual se podrá acceder desde diferentes dispositivos que se encuentren conectados a internet y que pertenezcan a la misma red del servidor.

La parte principal de este trabajo consiste en el desarrollo de un sistema de clasificación de indicadores de estados de condición de motores eléctricos de inducción basado en el entrenamiento de un modelo predictivo, el cual se puede acceder mediante una interfaz de monitoreo para realizar una revisión de los datos históricos, análisis de tendencias, diagnóstico y reporte de mantenimiento de los motores.

Los resultados demuestran que el sistema de monitoreo de mantenimiento predictivo cumple con los objetivos planteados resaltando su accesibilidad remota y su intuitiva navegación por las diferentes interfaces.

Palabras claves: *Monitoreo en nube, Aprendizaje Supervisado, Mantenimiento Predictivo*

ABSTRACT

In this thesis work, the design of a predictive maintenance system for electric motors is presented to establish the operating conditions and recommended maintenance actions based on the prediction of data through supervised machine learning.

The system is designed and implemented on a cloud server that can be accessed from different devices that are connected to the internet and that belong to the same server network.

The main part of this work consists of the development of a classification system of condition indicators of electric induction motors based on the training of a predictive model, which can be accessed through a monitoring interface to carry out a review of historical data, trend analysis, diagnosis and maintenance report of the engines.

The results show that the predictive maintenance monitoring system meets the stated objectives, highlighting its remote accessibility and its intuitive navigation through the different interfaces.

Keywords: *Cloud Monitoring, Supervised Learning, Predictive Maintenance*

ÍNDICE GENERAL

1.	Introducción	2
1.1	Identificación del problema	4
1.2	Justificación	4
1.3	Solución Propuesta	5
1.4	Objetivo de la Tesis	6
1.4.1	Objetivo General	6
1.4.2	Objetivos Específicos	6
1.5	Metodología	6
1.6	Alcance	7
2.	Estado del arte	8
2.1	Mantenimiento Predictivo de Motores.	8
2.2	Método de Análisis de la Corriente del Motor (MCSA).	9
2.2.1	Prueba de resistencia de aislamiento	9
2.2.2	Prueba de índice de polarización	10
2.3	Evaluador de Circuitos Industriales MCE	11
2.3.1	Prueba Estándar MCE	12
2.3.2	Prueba de influencia del rotor (RIC)	12
2.3.3	Prueba de influencia de polarización	13
2.3.4	Prueba de voltaje a pasos	14
2.4	Criterios y Diagnostico de Motores	15
2.4.1	Resistencia a Tierra (RTG)	15
2.4.2	Resistencia de Fase a Fase	16
2.4.3	Inductancia de Fase a Fase	18
2.4.4	Índice de polarización y absorción dieléctrica	19
2.5	Aprendizaje basado en Máquina	20

2.5.1	Aprendizaje Supervisado	20
2.5.2	Aprendizaje no Supervisado	21
2.5.3	Selección del Algoritmo	21
2.6	Monitoreo en la nube	21
2.6.1	Clasificación de monitoreo en la nube	21
2.6.2	Tipos de nube	22
2.6.3	Arquitectura de Monitoreo	22
3.	Diseño de categorización de estado de los motores	24
3.1	Propuesta inicial del diseño	24
3.1.1	Representación del sistema	25
3.1.2	Funcionamiento del sistema	27
3.2	Procesamiento de la información	27
3.2.1	Recolección de datos	27
3.2.2	Condiciones de categorización	29
3.2.3	Almacenamiento de los datos	30
3.3	Desarrollo del modelo de predicción	32
3.3.1	Selección del modelo de aprendizaje	32
3.3.2	Generación de función de predicción	36
3.3.3	Entrenamiento del modelo con nuevos datos	37
3.4	Diseño y desarrollo de la interfaz de monitoreo	37
3.4.1	Históricos y Base de Datos	38
3.4.2	Análisis y Tendencias	39
3.4.3	Diagnóstico y Reporte	40
4.	Diseño de pruebas y análisis de resultados	42
4.1	Pruebas de funcionamiento	42
4.1.1	Prueba de histórico de datos	42

4.1.2	Prueba del sistema de predicción del estado del motor	44
4.2	Análisis de Resultados	50
4.2.1	Análisis de las pruebas de mantenimiento	50
4.2.2	Análisis de la prueba de histórico de datos	51
4.2.3	Análisis de la prueba del sistema de categorización	51
5.	Conclusiones y recomendaciones	53
5.1	Conclusiones	53
5.2	Recomendaciones	54

ABREVIATURAS

PdM. Mantenimiento Predictivo

CA. Corriente Alterna

CC. Corriente Continua

ML. Aprendizaje Automático

P-I. Índice de Polarización

EASA. Asociación de Servicios y Aparatos Eléctricos

MO. Mega-óhmetro

RTG. Resistencia de aislamiento a tierra

MOHM. Resistencia de aislamiento expresada en megaohmios

COHM. Resistencia de aislamiento corregida por temperatura expresada en megaohmios

RIMB. Porcentaje de desbalance resistivo

IIMB, Porcentaje de desbalance inductivo

PI. Índice de polaridad

RIC. Verificación de influencia del rotor

AD. Absorción Dieléctrica

ÍNDICE DE FIGURAS

Figura 2.1 Resumen de fallas de motor según el manual del equipo MCE. [16].....	11
Figura 2.2 Prueba Estándar [16].....	12
Figura 2.3 Prueba de RIC. [16]	13
Figura 2.4 Prueba de índice de polaridad. [16]	14
Figura 2.5 Prueba de voltaje a pasos. [16]	15
Figura 2.6 Diagrama de flujo de entrenamiento de modelos. [14].....	20
Figura 2.7 Clasificación de soluciones de monitoreo en la nube. [12]	22
Figura 3.1 Diagrama de flujo del proceso	25
Figura 3.2 Diagrama esquemático del sistema de categorización de motores en la nube	26
Figura 3.3 Base de datos DatosMotor.db y sus tablas PARAMETROS e INDICADORES	31
Figura 3.4 Diagrama sistemático de aprendizaje automático	32
Figura 3.5 Carga de los datos.....	33
Figura 3.6 Dispersión de los datos, RIMB vs COHM	34
Figura 3.7 Modelos sintonizados con su porcentaje de validación	35
Figura 3.8 Exportación el mejor modelo al espacio de trabajo	36
Figura 3.9 Función de predicción.....	36
Figura 3.10 Flujo de nodos de histórico de datos	39
Figura 3.11 Flujo de nodos para los análisis de tendencias	40
Figura 3.12 Flujo de nodos de Diagnóstico y Reporte	41
Figura 4.1 Interfaz de Histórico de Datos.....	43
Figura 4.2 Interfaz de Histórico de Datos actualizada.....	43
Figura 4.3 Tabla de datos PARAMETROS en SQL_studio	44
Figura 4.4 Conformación de matriz de datos “totree” para el predictor de estado	45
Figura 4.5 Arreglo “yfit” con los indicadores de estado para cada registro	46
Figura 4.6 Conformación de la tabla de datos INDICADORES con la columna de predicción	46
Figura 4.7 Diagnostico del estado del motor, Eventos de Precaución	47
Figura 4.8 Diagnostico del estado del motor, Eventos de Alerta	48

Figura 4.9 Interfaz para el análisis de tendencias.....	48
Figura 4.10 Tendencia de Temperatura.....	49
Figura 4.11 Tendencia de Desbalance Resistivo.....	49
Figura 4.12 Tendencia de Desbalance Inductivo	49
Figura 4.13 Tendencia de Índice de Polarización	50
Figura 4.14 Medición con el equipo PdMA	51

ÍNDICE DE TABLAS

Tabla 1 Categorización de operación de los motores.....	7
Tabla 2 Condiciones y Acciones según los valores de COHM.....	16
Tabla 3 Condiciones y Acciones según los valores de RIMB.....	17
Tabla 4 Condiciones y Acciones según los valores de IIMB.....	18
Tabla 5 Índice de Polarización.....	19
Tabla 6 Datos obtenidos de la prueba estándar.....	28
Tabla 7 Datos recolectados de la prueba de PI.....	29
Tabla 8 Tabla de datos inicial, incluye área de trabajo, datos placa del motor y resultados prueba estándar MCE.	29
Tabla 9 Tabla de datos final con el indicador de estados de cada motor	30

CAPÍTULO 1

1. Introducción

La cantidad de datos extraídos de los procesos de producción ha aumentado exponencialmente debido a la proliferación de tecnologías de detección. Cuando se procesan y analizan, los datos pueden aportar información y conocimientos valiosos del proceso de fabricación, el sistema de producción y el equipo. En las industrias, el mantenimiento de equipos es una clave importante y afecta el tiempo de operación de los equipos y su eficiencia. Por lo tanto, es necesario identificar y solucionar las fallas de los equipos, evitando paradas en los procesos de producción. Los métodos de aprendizaje automático (ML, por sus siglas en inglés) han surgido como una herramienta prometedora en las aplicaciones de mantenimiento predictivo (PdM) para evitar fallas en los equipos que componen las líneas de producción en la fábrica. Sin embargo, el rendimiento de las aplicaciones PdM depende de la elección adecuada del método ML [1].

La Industria 4.0 está colaborando directamente para la revolución tecnológica. Tanto las máquinas como los gerentes se enfrentan diariamente a la toma de decisiones que implican una entrada masiva de datos y personalización en el proceso de fabricación. Poder predecir eventualidades en la parte eléctrica es la necesidad del departamento de mantenimiento y es uno de los principales desafíos en este ámbito. El predictivo eléctrico nos permite reducir el tiempo de fallo de equipos, costos y mantener la calidad de la producción.

Observamos que las encuestas y tutoriales sobre Industria 4.0 se enfocan principalmente en abordar el análisis de datos y los métodos de aprendizaje automático para cambiar los procedimientos de producción, por lo que no comprenden los métodos de mantenimiento predictivo y su organización. En este contexto, este artículo presenta una revisión bibliográfica sistemática de iniciativas de mantenimiento predictivo en la Industria 4.0, identificando y catalogando métodos, estándares y aplicaciones [2].

El desarrollo del presente tiene como objetivo diseñar e implementar un sistema de monitoreo en nube que permitan realizar el diagnóstico predictivo de fallos de motores eléctricos basado en el aprendizaje automático supervisado de datos históricos de la planta de cemento de Guayaquil obtenidos del equipo de medición de la corporación PdMA, para lo cual se utiliza la herramienta virtual de Matlab Classification Learner para obtener el modelo de predicción y el desarrollo de una interfaz levantada en la nube mediante Node Red.

La hipótesis planteada da lugar a generar un diagnóstico y reporte de mantenimiento basado en el clasificador de aprendizaje supervisado que permita reaccionar con tiempo prudencial con las acciones recomendadas de mantenimiento según la norma IEEE Std. 43-2000.

En el primer capítulo se *plantea los motivos para diseñar el sistema de mantenimiento predictivo en nube*, la importancia del proyecto para la gestión de mantenimiento de motores y porque es necesario una estrategia de aprendizaje automático supervisado que puede predecir de manera acertada la condición de operación del motor

En el segundo capítulo se realiza una revisión del marco teórico del mantenimiento predictivo de motores, los métodos de análisis de corriente de motores eléctricos, el equipo de medición que se utiliza en las pruebas de mantenimiento, los criterios utilizados para el diagnóstico de motores, los algoritmos de aprendizaje supervisados y monitoreo en nube.

En el tercer capítulo se describe la metodología utilizada, la descripción del sistema, las herramientas y plataformas de programación desarrolladas y la estrategia de clasificación para el desarrollo y entrenamiento del modelo de aprendizaje supervisado.

En el cuarto capítulo se presentan los resultados del diseño de la interfaz de monitoreo, las pantallas de históricos y base de datos, los análisis de tendencia y el diagnóstico y reporte de mantenimiento.

1.1 Identificación del problema

Los programas y proyectos como la creación de escuelas, viviendas, puentes de acceso e infraestructura para beneficio de la comunidad son importantes para el desarrollo de la región costa, por consiguiente, el abastecimiento de cemento para estas obras es importante y esencial para su concesión, pero la escasez de este producto puede estancar y retrasar este proceso por ende ocasionar pérdidas importantes en la empresa. Uno de los inconvenientes que se pueden presentar es el fallo de algún motor que ocasione el paro de la planta.

El problema planteado se debe a eventos ocurridos en motores de una planta de cemento en Guayaquil, las fallas tales como cortos entre espiras y cortos a tierra de los motores son evaluadas y analizadas por un especialista mediante mediciones realizadas por un equipo experto. El especialista se basa en las mediciones actuales para categorizar la condición de falla del motor sin tomar en cuenta las mediciones históricas, lo que provoca diagnósticos de estados no tan precisos. Debido a esto es necesario contar con un sistema de diagnóstico predictivo de fallos de motor que procese y evalúe los datos históricos y genere un estado de la condición del motor más preciso.

1.2 Justificación

Los avances recientes en la tecnología como lo son el internet de las cosas y el aprendizaje de maquina aplicado a grandes datos en la nube han permitido un crecimiento en el análisis de datos y la predicción de comportamientos basado en tendencias y modelos computacionales. Según [3] la industria 4.0 se basa en mejorar los modelos de negocios y la eficiencia en los procesos de producción, mantenimiento, servicios generales, entre otras áreas y unidades que conforma una empresa o industria. Desarrollar un mantenimiento predictivo que este enfocado en el análisis de datos históricos de los parámetros fundamentales de un equipo permiten establecer el estado o condición de operación. A diferencia de los sistemas tradicionales de mantenimiento predictivo el análisis de datos históricos basado en el aprendizaje de maquina resulta en un diagnóstico más preciso del

estado operacional del equipo y como consecuencia favorece la optimización de los recursos económicos y tiempos de producción [4].

Según el problema planteado debido a la frecuencia de fallas en los motores de Planta de cemento Guayaquil es necesario un diagnóstico basado en datos históricos de mediciones estáticas y dinámicas de mencionados motores para la detección o anticiparse a las posibles fallas antes que estas sucedan y las consecuencias que estas generan como equipos sin producir y la falta de abastecimiento de 8 TON de cemento diarias al consumidor que son las distribuidoras de cemento la cual implicaría pérdidas económicas considerables.

1.3 Solución Propuesta

A través del presente trabajo se plantea diseñar un sistema que pueda predecir las condiciones de operación de motores eléctricos basados en la estrategia de aprendizaje automático supervisado. Se espera poder observar los datos a través de un sistema de monitoreo en la nube el cual permitirá realizar análisis de tendencia, diagnóstico y generar reportes de mantenimiento.

1.4 Objetivo de la Tesis

1.4.1 Objetivo General

Diagnosticar el estado de motores basados en datos históricos para la predicción de fallas en una planta de cemento en Guayaquil.

1.4.2 Objetivos Específicos

- Adquirir los archivos históricos de los diferentes motores eléctricos (inducción, síncronos y dc) mediante las pruebas realizadas con el equipo de PdMA.
- Procesar los datos recolectados mediante un software de mantenimiento predictivo para la clasificación del estado y condición del motor.
- Diseñar un sistema de monitoreo en la nube que permita la categorización del estado o condición de los motores para la detección temprana de fallas y generación de reporte de mantenimiento.

1.5 Metodología

En el presente proyecto se utilizará la información de alrededor de los 900 motores de la Planta de Cemento Guayaquil con un histórico aproximado de dos años.

El presente proyecto se desarrollará en las siguientes etapas:

1. Adquisición de archivos históricos: Los archivos con los datos técnicos son obtenidos del equipo de la marca PdMA (medición de motores de 480, 600 y 4160 VAC) de la planta de cemento Guayaquil, las mediciones se realizan desde la caja de conexiones del motor cuando este está en mantenimiento, para lo cual se aplicará el muestreo de variables digitales y analógicas revisado en la materia "Sistemas SCADA"

2. Diagnóstico: En esta parte se utilizará un software de mantenimiento predictivo donde se ejecutarán técnicas basadas en datos para el análisis estadístico, espectral y en series de tiempo revisados en la materia de “control predictivo” para estimar el tiempo de falla de los motores de la planta de Cemento.
3. Diseño y monitoreo en nube de la categorización del estado de los motores, como se muestra en la Tabla 1: Se categoriza los motores de acuerdo con el diagnóstico de la falla que puede dividirse en los diferentes niveles:

Tabla 1 Categorización de operación de los Motores

Categoría (estado del motor)	PROPUESTA DE ACCION
NORMAL	SIN ACCIÓN
LEVE	SEGUIMIENTO
PELIGRO	INTERVENCIÓN PROGRAMADA
GRAVE	INTERVENCIÓN INMEDIATA

Se diseñará una interfaz para el monitoreo en nube de los datos recopilados y la clasificación del estado o condición del motor. Se generará un reporte de mantenimiento y envío de correos que notifiquen la condición del motor analizado.

1.6 Alcance

En el presente proyecto de tesis se espera diseñar un sistema de mantenimiento predictivo en la nube basado en la estrategia de clasificación de aprendizaje supervisado. Se espera poder acceder remotamente al sistema mediante conexión a internet y generar análisis de históricos, tendencias diagnóstico y reportes de mantenimiento.

CAPÍTULO 2

2. Estado del arte

En esta sección se presenta una revisión literaria de los conceptos, técnicas, métodos y algoritmos que serán aplicados en el desarrollo del proyecto. Los indicadores por revisar corresponden al mantenimiento predictivo de motores, análisis de la corriente de motores, procesamiento de datos, aprendizaje automático y monitoreo en la nube.

2.1 Mantenimiento Predictivo de Motores.

En las industrias, el mantenimiento de equipos es una clave importante y afecta el tiempo de operación de los procesos y su eficiencia [1], puesto que el impacto del mantenimiento representa un total del 15 al 60% de los costos totales de operación de toda la fabricación [2]. Por lo tanto, las fallas de los equipos deben ser identificadas y resueltas, evitando paradas en los procesos de producción. En mantenimiento, existen tres categorías de ocurrencia: correctiva, preventiva y predictiva [1].

El mantenimiento correctivo se produce cuando se detecta la falla o hay indicios, ocurre solo cuando un equipo deja de funcionar. Esta es la estrategia de mantenimiento más simple, ya que es necesario tanto la parada de la producción como la reparación de las piezas a reemplazar, agregando un costo directo al proceso [5]. El preventivo, es una técnica de mantenimiento que se realiza periódicamente con un cronograma planificado en el tiempo o iteraciones del proceso para anticipar fallas en el proceso / equipo. Generalmente es un enfoque eficaz para evitar fallas. Sin embargo, se toman acciones correctivas innecesarias, lo que lleva a un aumento en los costos operativos [6].

Por su parte, el PdM utiliza herramientas predictivas para determinar cuándo son necesarias las acciones de mantenimiento. Se basa en el monitoreo continuo de una

máquina o de la integridad de un proceso, lo que permite realizar el mantenimiento solo cuando es necesario. Además, permite la detección temprana de fallas gracias a herramientas predictivas basadas en datos históricos (por ejemplo, técnicas de aprendizaje automático), factores de integridad (por ejemplo, aspectos visuales, desgaste, coloración diferente al original, entre otros), métodos de inferencia estadística y enfoques de ingeniería [1].

2.2 Método de Análisis de la Corriente del Motor (MCSA).

El MCSA es una técnica que se utiliza para determinar la condición de funcionamiento de los motores de inducción de CA sin interrumpir la producción. Este análisis mide una señal eléctrica que contiene componentes de corriente, permitiendo detectar de forma precisa fallas de estado temprano, lo que evita el daño y fallas completas del motor [7].

Por lo general, se utiliza un espectro de decibelios (dB) frente a la frecuencia para proporcionar un rango dinámico amplio y para detectar los patrones de corriente exclusivos que son característicos de diferentes fallas y como se basa en el monitoreo de la corriente de los motores de inducción, no es un proceso costoso.

El MCSA utiliza el espectro actual de la máquina para localizar las frecuencias de falla, puesto que el espectro de frecuencia de la corriente de línea difiere del motor sin fallas. Los métodos basados en el análisis de firma de corriente del motor (MCSA) se utilizan para diagnosticar las fallas comunes del motor de inducción, como falla de barra rota, falla de bobinado corto, falla de cojinete y falla de carga [7]. Para predecir la falla del motor de forma exitosa se utiliza la resistencia de aislamiento, a continuación, se detallan las dos pruebas utilizadas para este proyecto.

2.2.1 Prueba de resistencia de aislamiento

Una prueba de gran utilidad para determinar el momento de la reparación o reemplazo del motor es la prueba de resistencia del aislamiento y se la debe realizar

a intervalos regulares. La técnica que se utiliza en esta prueba es conectar un **mega-óhmetro** (MO) a un motor cuyos devanados estén a temperatura ambiente. El MO mide la resistencia de aislamiento entre los devanados y el bastidor del motor.

Se debe utilizar un MO de 500 voltios para motores con tensiones nominales de 2.400 voltios o menos y se debe utilizar uno de 1000 voltios si la tensión nominal es superior a 2.400 voltios. Una vez que las lecturas se tabulan y se grafican, estas permiten el desarrollo de un patrón para identificar cualquier tendencia en los datos. Si los datos permanecen constantes una y otra vez, el sistema de aislamiento está en óptimas condiciones. Cuando la resistencia cae después de dos o tres pruebas sucesivas se debe retirar el motor de servicio [7], [8].

2.2.2 Prueba de índice de polarización

El índice de polarización (P-I) es un método que se utiliza para determinar si alguna sustancia ha contaminado el motor lo suficiente como para causar daños graves a los devanados que acortarán la vida útil del motor. Al probar el P-I, generalmente un MO de 500 voltios proporciona un voltaje de CC constante entre los devanados del motor y el bastidor durante 10 minutos. La resistencia de aislamiento se mide después del primer minuto y después del décimo minuto.

Se toma una relación para comparar la resistencia en el décimo minuto con la resistencia en el primer minuto. Siempre que esta relación sea superior a 2, los devanados funcionan correctamente. Si la relación es inferior a 2, la Asociación de Servicios y Aparatos Eléctricos (EASA) recomienda limpiar, hornear y volver a probar los devanados del motor. Si la lectura aún cae por debajo de 2, es posible que sea necesario rebobinar el motor.

La prueba P-I también se puede utilizar para determinar la tendencia del deterioro gradual en los devanados. Al igual que en la prueba de resistencia de aislamiento, los datos se pueden registrar a intervalos regulares y las nuevas pruebas se pueden

comparar con pruebas anteriores para observar cualquier diferencia en los datos [7], [8].

2.3 Evaluador de Circuitos Industriales MCE

El analizador de circuito de motor (MCE) analiza cinco de las seis zonas de falla del motor y su circuito, este ha sido diseñado para pruebas estáticas (motor desenergizado) y provee datos utilizados en la evaluación del circuito de potencia, aislamiento, rotor, estator y entrehierro (como se muestra en la Figura 2.1)

El equipo permite detectar zonas de fallas eléctricas las cuales están directamente relacionadas con la mayoría de las fallas de motores eléctricos. Supervisando y evaluando los parámetros y relacionándolos con las zonas de fallas se obtiene una información valiosa permitiendo que se mantengan los motores eléctricos de una planta en el mejor estado de operación posible [16].

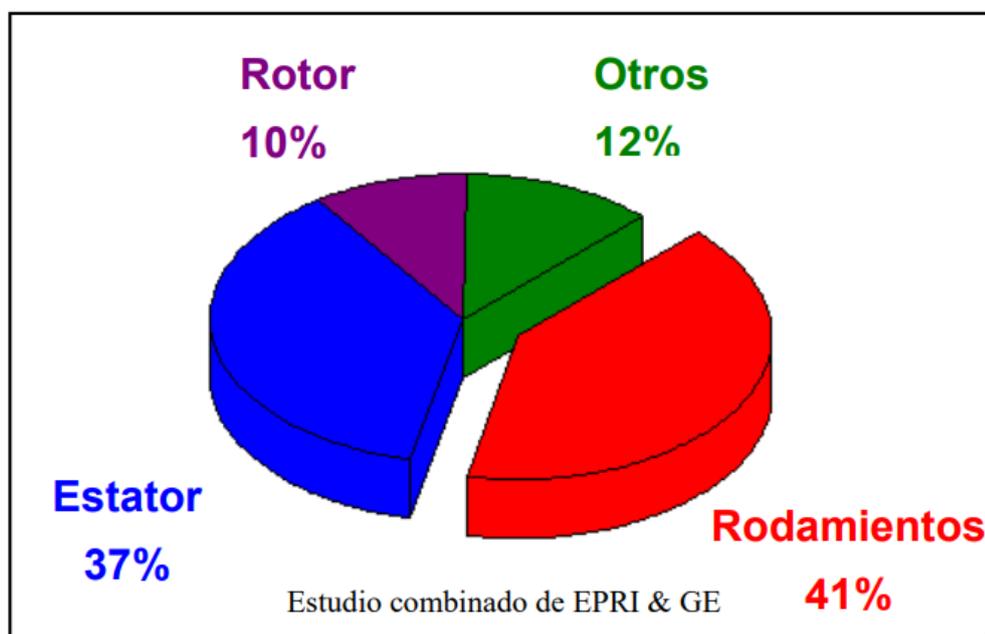


Figura 2.1 Resumen de fallas de motor según el manual del equipo MCE. [16]

El equipo permite realizar las siguientes pruebas: I) Prueba Estándar, II) Prueba de Influencia del Rotor, III) Índice de Polarización y IV) Voltaje a Pasos.

2.3.1 Prueba Estándar MCE

La prueba estándar es una prueba comprensiva del circuito del motor, esta provee datos que permiten la evaluación de cinco de las seis zonas de falla, con esta prueba se miden los siguientes parámetros: Resistencia a tierra, resistencia fase a fase, desequilibrio resistivo, desequilibrio inductivo, promedio inductivo

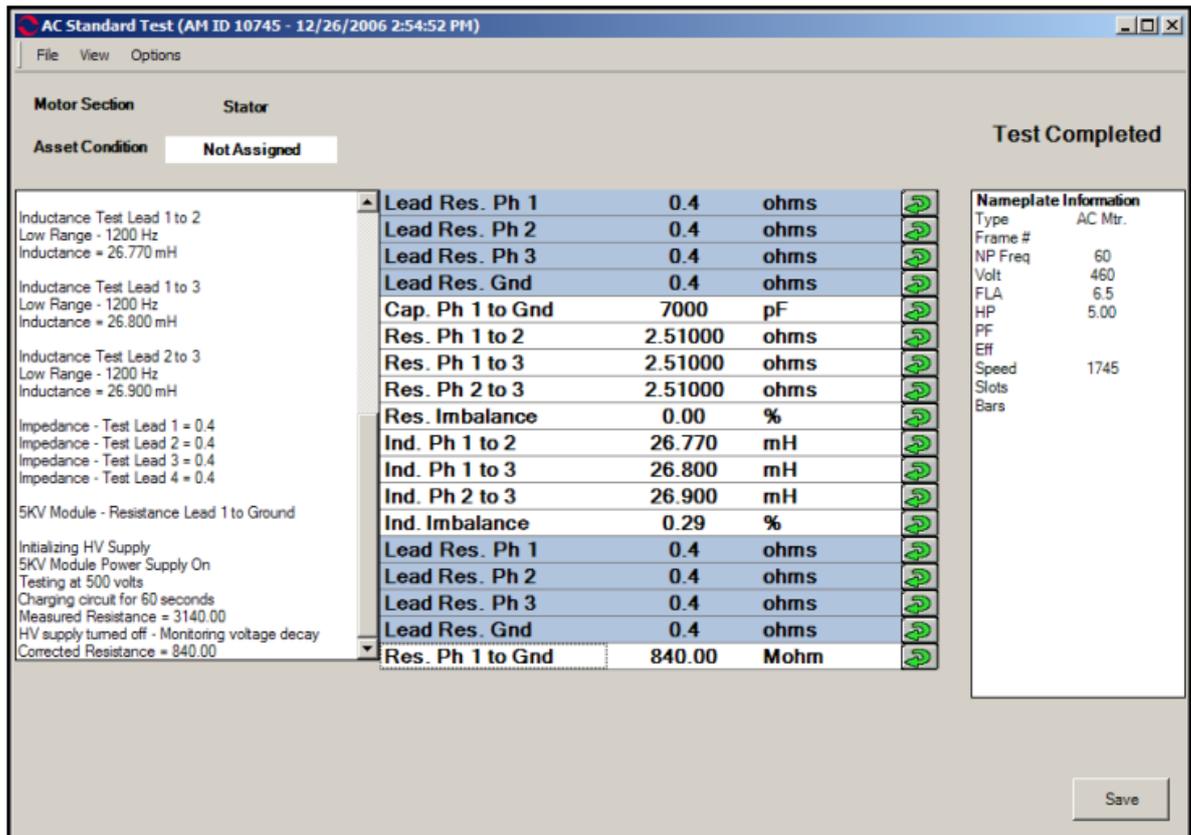


Figura 2.2 Prueba Estándar [16]

2.3.2 Prueba de influencia del rotor (RIC)

Es una prueba gráfica de la relación entre el rotor y el estator. El magnetismo residual que existe en el rotor afecta a la inductancia fase a fase mientras es rotado por una fase de polo. Se debe posicionar el rotor entre cada medida de inductancia fase a fase. La grafica que resulta por estos cambios en inductancia puede ser utilizada para evaluar las zonas de fallas del estator, rotor y entrehierro.

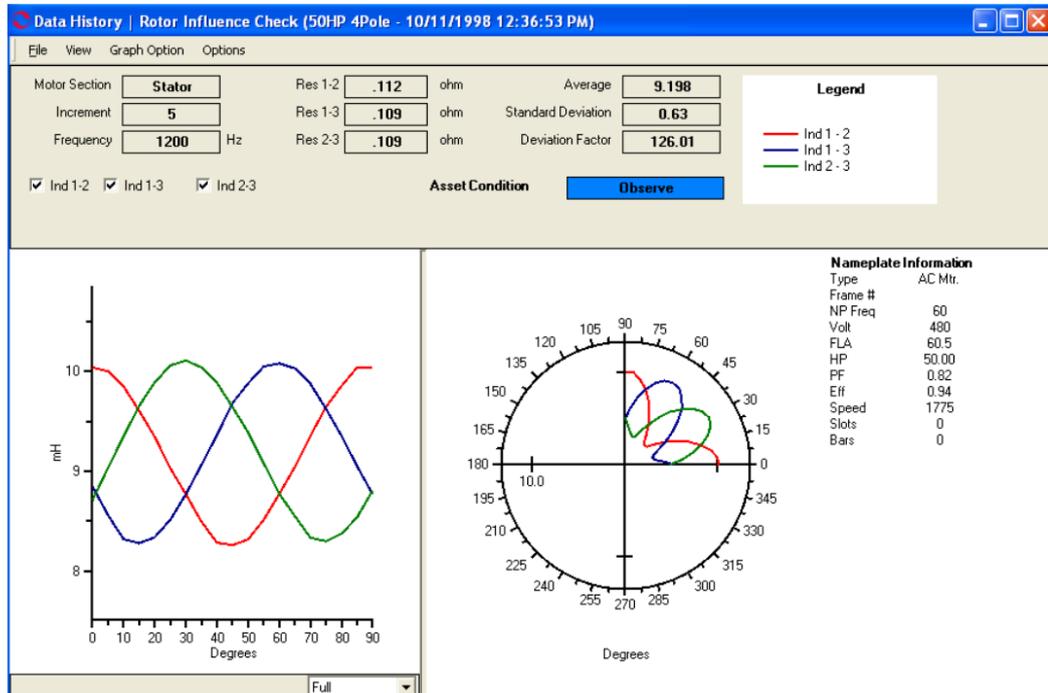


Figura 2.3 Prueba de RIC [16]

2.3.3 Prueba de influencia de polarización

Es una prueba en la cual se aplica un voltaje continuo a través del aislamiento a tierra. Un aislamiento en condiciones normales exhibe un aumento constante de los valores de resistencia a tierra llegando a un valor de nivelado de 10 minutos. Esta prueba es realizada para obtener datos detallados para evaluar la zona de falla de asilamiento. Cada vez que se realiza esta prueba también se realiza una prueba de absorción dieléctrica (AD).

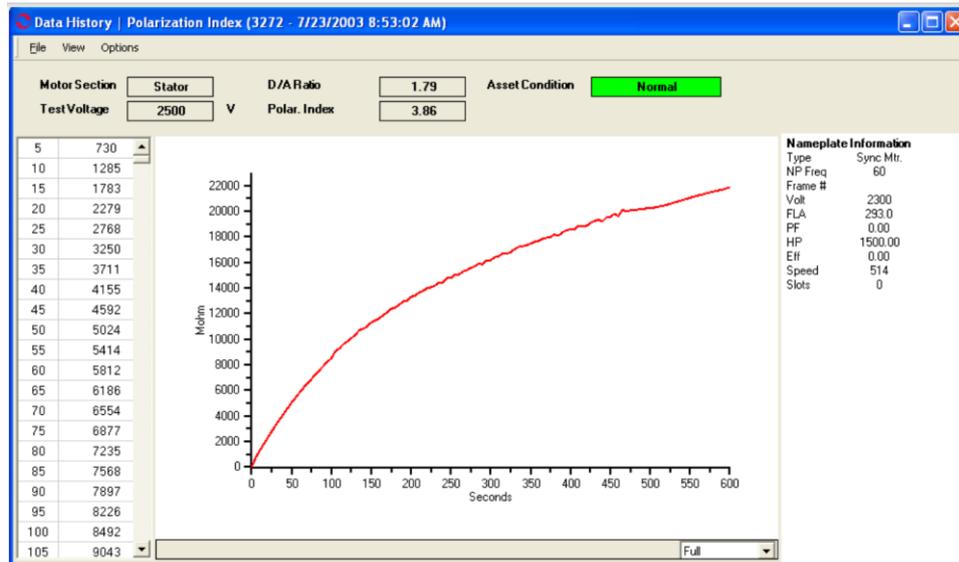


Figura 2.4 Prueba de índice de polaridad. [16]

2.3.4 Prueba de voltaje a pasos

En esta prueba se toma las medidas del pico y la decaída de la corriente mientras cada aumento (paso) es el voltaje DC es aplicado al aislamiento. La prueba permite observar como el sistema de aislamiento responde a un voltaje excesivo, se aumenta el voltaje en incrementos de un minuto. La corriente de fuga es comparada gráficamente con el voltaje aplicado.

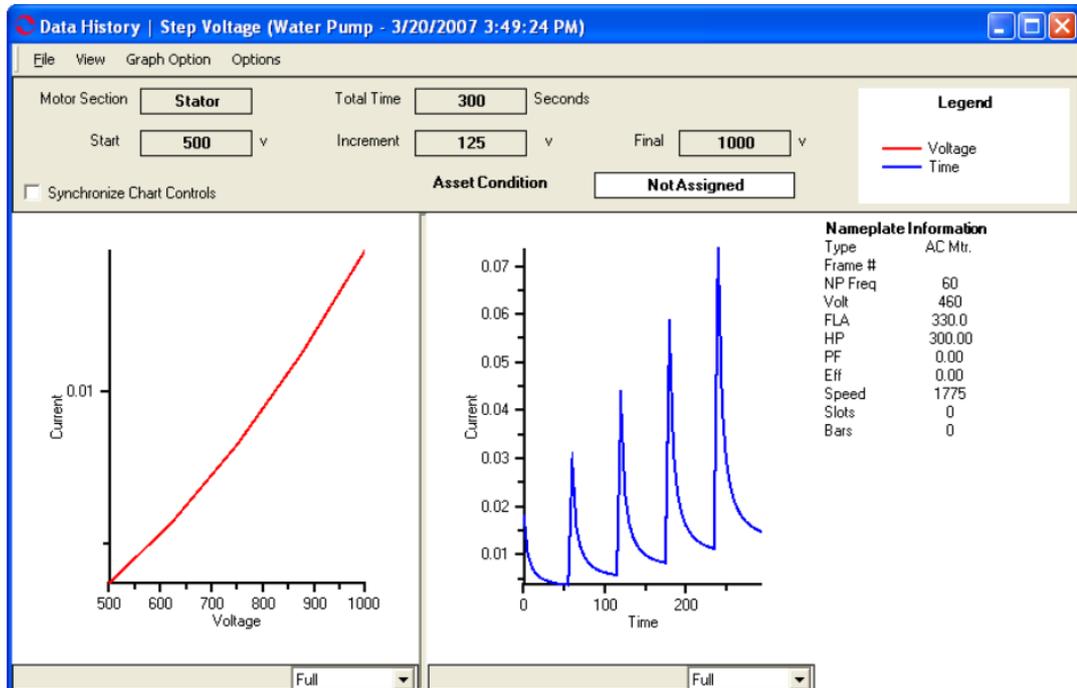


Figura 2.5 Prueba de voltaje a pasos. [16]

2.4 Criterios y Diagnostico de Motores

Para realizar un análisis de mantenimiento predictivo de motores es necesario considerar ciertos parámetros eléctricos que permitan conocer el estado del motor y en base a eso realizar ciertas acciones recomendadas según la norma IEEE Std. 43-200; para lo cual se describen los siguientes parámetros con su respectiva importancia y acciones a seguir según la condición del motor [9].

2.4.1 Resistencia a Tierra (RTG)

El valor de la resistencia a tierra del motor permite conocer la limpieza y el estado del aislamiento. Un valor bajo de RTG indica que el aislamiento necesita ser limpiado, ser sumergido o calentado al horno, si el RTG no se corrige, los devanados del motor podrían ser dañados y podría requerir de un bobinado completo del estator.

Existen tres factores que afectan el valor medido de RTG, temperatura, voltaje de prueba y duración del voltaje aplicado. Para analizar la tendencia de las mediciones se deben mantener estos factores constantes, el voltaje aplicado y la duración de la prueba se pueden controlar sin embargo la temperatura cambia según el estado

de medición del motor, por lo tanto, se debe realizar un ajuste por temperatura en la medición de la RTG.

El equipo PdMA entrega tres valores a tener en cuenta, **MOHM**, **COHM** y **temperatura**; MOHM hace referencia a la medición del aislamiento en megaohmios, COHM al valor corregido en megaohmios del aislamiento, y temperatura el valor de la temperatura actual del motor.

En base a la norma IEEE Std. 43-2000 se muestra la siguiente tabla de interpretación de los valores de COHM con las condiciones y acciones recomendadas

Tabla 2 Condiciones y Acciones según los valores de COHM

COHM (Para motores de 4KV en adelante)	Condición	Acciones
Tendencia estable: COHM mayor a 300 [Mohm]	Normal Margen recomendado contra corriente de fuga	Supervisar el motor bajo la planificación actual
Tendencia a la baja: COHM entre 100 y 300 [Mohm]	Precaución: La trayectoria para la corriente fuga a tierra se está desarrollando	Posible acumulación de humedad o suciedad en el aislamiento del motor. Inspeccionar aislamiento y programar limpieza del motor y cable de alimentación. Monitorear con mayor frecuencia el valor de COHM
Tendencia a la baja: COHM menor a 100 [Mohm]	Alerta: La trayectoria para la corriente de fuga existe.	Falla de tierra asilada. Inspeccionar y localizar posibles daños y reparar antes del servicio

2.4.2 Resistencia de Fase a Fase

La resistencia fase a fase es la resistencia de C.C. medida entre las fases del estator en un motor de CA. Los valores de la resistencia varían con la temperatura,

construcción del motor y materiales usados. Se mide el valor de la resistencia de las tres combinaciones fase a fase en el motor, luego estos valores se procesan en un algoritmo matemático que el calcula el porcentaje de desbalance resistivo (RIMB).

Un valor alto de RIMB indica conexiones de alta resistencia en el circuito o el motor, esto provoca desbalance de voltaje en el motor lo que implica altas temperaturas y potencial reducción de la vida del motor. El caso más extremo es cuando un motor pierde una fase, esto ocasiona un daño inmediato ya que las otras fases compensan aumentando la corriente en un 200% a 300% provocando que el aislamiento que los rodea se destruya.

Según la norma IEEE Std. 43-2000 se establece las condiciones y acciones recomendadas según el valor de la RIMB

Tabla 3 Condiciones y Acciones según los valores de RIMB

Desbalance resistivo (RIMB)	Condición	Acciones
Tendencia estable: RIMB menor a 2%	Normal	Supervisar el motor bajo la planificación actual
Tendencia ascendente: RIMB entre 2% y 3%	Precaución: desbalance moderado, satisfactorio para continuar en servicio	Supervisar el motor mensualmente para analizar tendencias. Inspeccionar y localizar defectos y reparar en la primera oportunidad. Defectos posibles: Conexiones flojas, contaminadas, corroídas; conexiones de alta resistencia; interruptores o conectores incorrectamente seleccionados.
Tendencia ascendente: RIMB mayor a 3%	Alerta: Desbalance severo, corrija antes de arranque del motor	Compruebe las conexiones, localice los daños y repárelos antes de arrancar el motor

2.4.3 Inductancia de Fase a Fase

La inductancia fase a fase prueba el circuito, las bobinas del estator, el hierro y los componentes del rotor para determinar los desbalances inductivos e indica cuando estos no son satisfactorios. Durante la medición una señal de baja tensión y alta frecuencia sea aplica a cada una de las tres combinaciones de fase a fase en el motor, se mide la impedancia y se calcula la inductancia del circuito, estos tres valores se insertan en una fórmula que determina el porcentaje de desbalance de inductancia (IIMB).

Un valor alto de IIMB provoca vibraciones inducidas por el par a dos veces la frecuencia de línea, esta vibración se puede asociar a la degradación mecánica o eléctrica. El IIMB también puede contribuir a daños en los cojinetes y acoplamiento, aflojamiento de barrar del rotor y la falla de aislamiento en cabezales o en la salida de la ranura del estator.

A continuación, se muestra en la siguiente tabla los rangos a considerar del IIMB, condiciones de estado del motor y acciones recomendadas según la norma IEEE Std. 43-2000.

Tabla 4 Condiciones y Acciones según los valores de IIMB

Desbalance inductivo (IIMB)	Condición	Acciones
Tendencia estable: IIMB menor a 5%	Normal	Supervisar el motor bajo la planificación actual
Tendencia ascendente: IIMB entre 5% y 7%	Precaución: desbalance moderado, satisfactorio para continuar en servicio	Supervisar el motor con mayor frecuencia. Realice una verificación de influencia del rotor (RIC), identificar las causas y reparar si el tiempo lo permite. Defectos posibles: Problema del estator o rotor, excentricidad. Busque problemas mecánicos, verifique la

		vibración para los defectos eléctricos en el rango de 7200 CPM
Tendencia ascendente: IIMB mayor a 7%	Alerta: Desbalance severo, corrija antes de arranque del motor	Realizar RIC. Correlacione diversas tecnologías, localice los posibles defectos y repárelos antes de arrancar el motor.

2.4.4 Índice de polarización y absorción dieléctrica

El índice de polarización (PI) resulta del promedio de varias mediciones realizadas durante un intervalo de 10 minutos en el cual se aplica un potencial de C.C. entre la fase 1 y los terminales a tierra del motor. Mediante el PI se identifica las características dieléctricas de asilamiento mientras se aplica un potencial constante de C.C.

Un valor bajo de PI puede indicar que el aislamiento necesita ser limpiado. Si el PI bajo es acompañado de un COHM bajo la condición es más severa. Si la condición que causa que el PI sea bajo no se corrige y el COHM continúa disminuyendo, el asilamiento podría fallar totalmente y los devanados podrían ser dañados.

En la siguiente se muestra las condiciones y acciones recomendadas según los valores de PI medidos basados en la norma IEEE 43-2000.

Tabla 5 Índice de Polarización

Índice de Polarización (PI)	Condición	Acciones
Tendencia estable: PI mayor a 2	Normal	Supervisar el motor bajo la planificación actual
Tendencia descendente: PI menor a 1	Alerta	Los niveles de advertencia son tentativos y relativos. Aísle el motor o cables. Corrija la falla a tierra antes de arrancar.

2.5 Aprendizaje basado en Máquina

El aprendizaje basado en máquina es una técnica computacional que permite a las computadoras ejecutar acciones en base al entrenamiento de datos. Los algoritmos de aprendizaje utilizan métodos computacionales para aprender directamente de los datos sin depender de una ecuación o modelo [13]. Al aumentar el número de muestras o datos de mediciones recientes permitirá una predicción cercana o parecida a la real.

Se utiliza dos tipos de técnicas: aprendizaje supervisado, que entrena un modelo con datos de entrada y salida conocidos, para que pueda predecir salidas futuras, y aprendizaje no supervisado, que encuentra patrones ocultos o estructuras intrínsecas en los datos de entrada.

2.5.1 Aprendizaje Supervisado

La finalidad de esta técnica es construir un modelo que realice predicciones basadas en evidencia en presencia de incertidumbre. Cualquiera de los algoritmos de aprendizaje supervisado tomo un conjunto conocido de datos de entrada y respuestas conocidas (salida) y entrena un modelo para generar predicciones razonables. Las aplicaciones de clasificación incluyen, entre otras: clasificación de documentos, filtrado de spam, clasificación de imágenes, detecciones de fraudes, análisis de contactos, análisis de riesgos [14].

El aprendizaje supervisado utiliza técnicas de clasificación y regresión para desarrollar modelos predictivos.

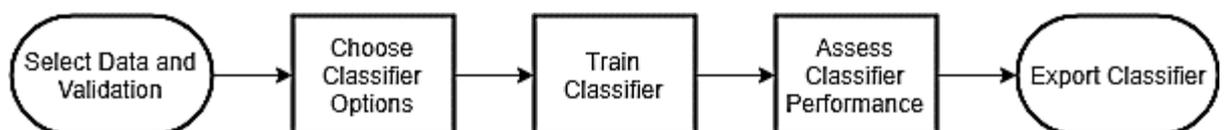


Figura 2.6 Diagrama de flujo de entrenamiento de modelos. [14]

2.5.2 Aprendizaje no Supervisado

Esta técnica encuentra patrones ocultos o estructuras intrínsecas en los datos, es utilizada para sacar inferencias de conjuntos de datos que consisten en datos de entrada sin respuestas etiquetadas. El agrupamiento es la técnica de aprendizaje no supervisado más común. Generalmente esta técnica se utiliza para el análisis exploratorio de datos y encontrar patrones ocultos o agrupaciones en los datos. Las aplicaciones para el agrupamiento incluyen análisis de secuencia de genes, investigación de mercado y reconocimiento de objetos [15].

2.5.3 Selección del Algoritmo

Existen varios algoritmos de aprendizaje automático supervisado y no supervisado y cada uno adopta un enfoque diferente para el aprendizaje. Seleccionar el algoritmo correcto radica en cierta medida en la prueba y error de los mismos, incluso los expertos en manejo de datos no pueden asegurar si un algoritmo funcionara sin probarlo. Los modelos más flexibles tienden a sobre ajustar los datos al modelar variaciones menores que podrían ser ruido. Los modelos simples son más fáciles de interpretar, pero pueden tener menor precisión, por consiguiente, seleccionar el algoritmo requiere compensar un beneficio con otro, velocidad, precisión y complejidad del modelo [13].

2.6 Monitoreo en la nube

La nube es un sistema grande y distribuido que considera la tecnología de la virtualización para administrar los recursos [10]. En este enorme sistema distribuido y virtualizado, el monitoreo se ha convertido en una necesidad para cumplir con los requisitos del usuario, es necesario el monitoreo preciso, detallado, adaptable y seguro para la gestión de la planificación y la utilización eficiente de los recursos [11]. Además, el monitoreo ayuda a mejorar la eficiencia de la nube en términos de la utilización eficiente de los recursos, la asignación de los recursos, la mejorar del rendimiento y la facturación por el uso de los recursos de la nube.

2.6.1 Clasificación de monitoreo en la nube

La solución de monitoreo en la nube se la puede clasificar en función de un conjunto de parámetros comunes que se resumen en la gráfica que se presenta a

continuación. El propósito del monitoreo establece el deseo principal del monitoreo en la nube, generar facturas, uso eficiente de los recursos, monitoreo de los índices de producción de manera efectiva.

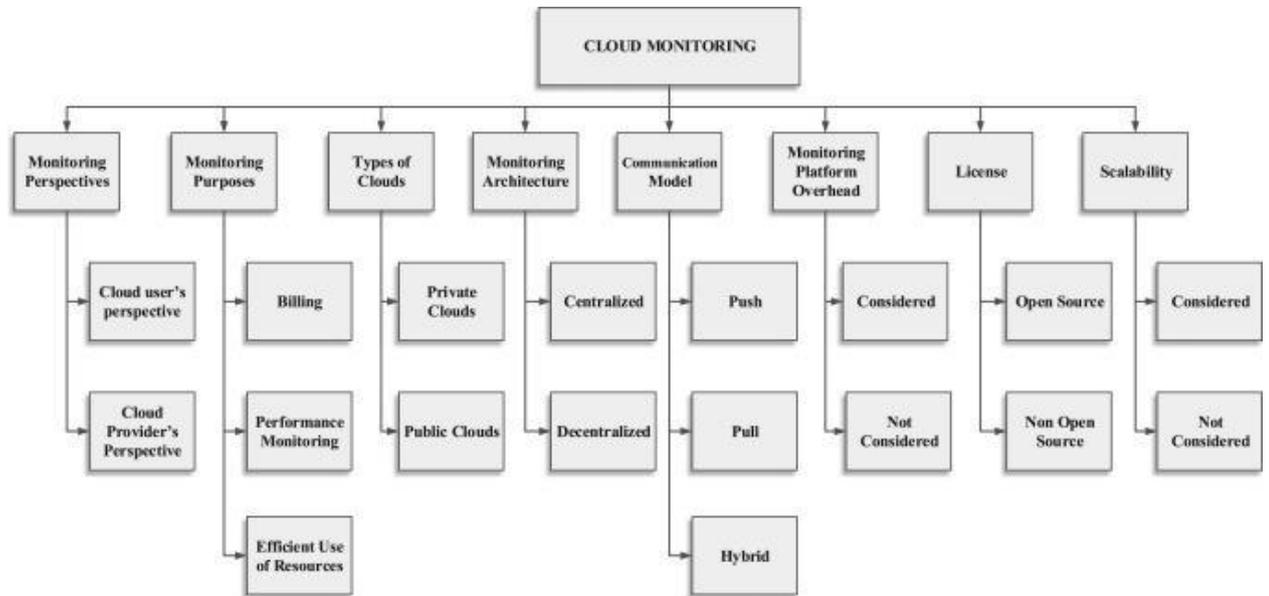


Figura 2.7 Clasificación de soluciones de monitoreo en la nube. [12]

2.6.2 Tipos de nube

Las nubes se pueden clasificar en dos tipos, I) La nube privada que son propiedad de una sola organización, En estas las infraestructuras físicas como virtuales pertenecen a la misma organización, por lo tanto, el monitoreo tiene sus propios aspectos de seguridad y nivel de acceso. II) La nube publica en cambio alquila sus recursos informáticos a una variedad de usuarios que pertenecen a diferentes organizaciones. Mantener la privacidad y la seguridad es una tarea desafiante al considerar monitoreo en la nube pública.

En un entorno de nube pública la seguridad de la infraestructura física se vuelve esencial por lo que es necesario la implementación de políticas y niveles de acceso separados para proveedor de nube y usuarios.

2.6.3 Arquitectura de Monitoreo

Esta se elabora de forma que se recopilan los datos monitoreados utilizando arquitecturas centralizadas o descentralizadas. I) La arquitectura centralizada consta de un único servidor de monitoreo, que recopila métricas los agentes

implementados en los nodos monitoreados. El servidor es una maquina física separada o un servidor designado que se ejecuta en el nodo de control de la nube, requiere de mayor ancho de banda de red y el nodo centralizado debe ser enriquecido de recursos para procesar solicitudes de forma simultánea.

II) En la arquitectura descentralizada, la tarea del servidor se distribuye entre varios o todos los nodos. Cada nodo recopila las métricas de monitoreo y las comparte con sus pares según los requisitos, como ventaja es que se elimina un único punto posible de falla, mejorar la distribución del poder computacional entre varios nodos mediante el control del uso de la red.

CAPÍTULO 3

3. Diseño de categorización de estado de los motores

En este capítulo se detallan las consideraciones de diseño, funcionamiento y características del sistema. Se detalla el procedimiento para definir y desarrollar el sistema de monitoreo en nube que permita categorizar y predecir con una alta fidelidad la falla de un motor eléctrico

3.1 Propuesta inicial del diseño

El sistema propuesto tiene como finalidad categorizar el estado de operación de un motor y presentar un conjunto de acciones recomendadas según su condición, este proceso es realizado por medio de técnicas de aprendizaje automático supervisado que utilizado los datos recolectados de las pruebas estándar e índice polarizado con el equipo MCE.

Descripción del sistema

El sistema se compone de la recolección de datos de las pruebas de mantenimiento realizado a diferentes motores de inducción AC de la planta de producción de cemento Holcim. Cada motor se distingue por sus propias especificaciones técnicas, se resalta que son motores de media tensión (5 kV).

El equipo de medición MCE almacena los datos de las pruebas realizadas, generando un histórico de pruebas por cada motor el cual se puede descargar como un archivo Excel. El usuario a cargo de las pruebas interpreta los resultados de las pruebas categorizando la condición del motor y estableciendo las acciones de mantenimiento a seguir según la norma IEEE Std. 43-2000.

Los datos recopilados se procesan y se agrupan en una tabla de datos con los parámetros de las pruebas de mantenimiento ordenados y depurados cuya finalidad es establecer la condición (Normal, Precaución, Alerta) de cada arreglo de datos según la interpretación del experto de mantenimiento.

Los datos se envían a una base de datos por medio de la interfaz de mantenimiento instalada en la nube; luego se envía esta tabla de datos (inicial) al sistema de categorización (predictor) el cual se ejecuta en Matlab, una vez que se establece el

estado de operación de cada arreglo de datos, el sistema de categorización almacena en otra tabla de datos (final) la matriz de datos con su respectiva condición de operación.

Luego, el usuario puede acceder a la interfaz de diagnóstico y eventos para supervisar los estados de precaución y alerta que se hayan generado, y en base al diagnóstico generar un reporte con las acciones de mantenimiento.

El análisis de la predicción de condición del motor se realiza por medio de una función de predicción obtenida del modelo de entrenamiento resultante del procesamiento de datos inicial en Matlab. En la siguiente figura se ilustra el proceso de funcionamiento del sistema.

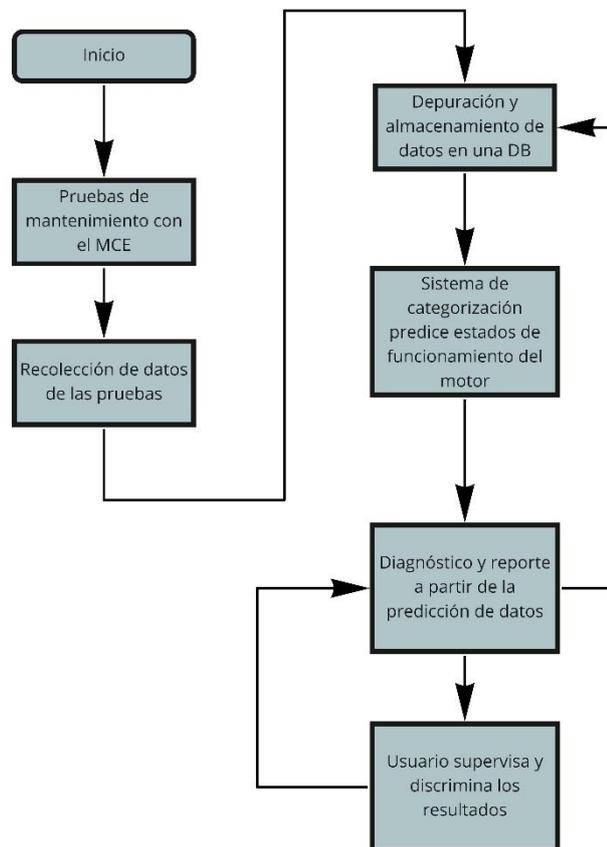


Figura 3.1 Diagrama de flujo del proceso

3.1.1 Representación del sistema

El sistema está compuesto por una interfaz central de monitoreo que se utilizara para monitorear los datos del motor, revisar los históricos y tendencias de los

valores medidos y diagnosticar el mantenimiento acorde a la categorización. Un servidor en la nube almacenará los datos iniciales y finales de mantenimiento de los motores, el cual se podrá acceder por medio de cualquier dispositivo con conexión a internet

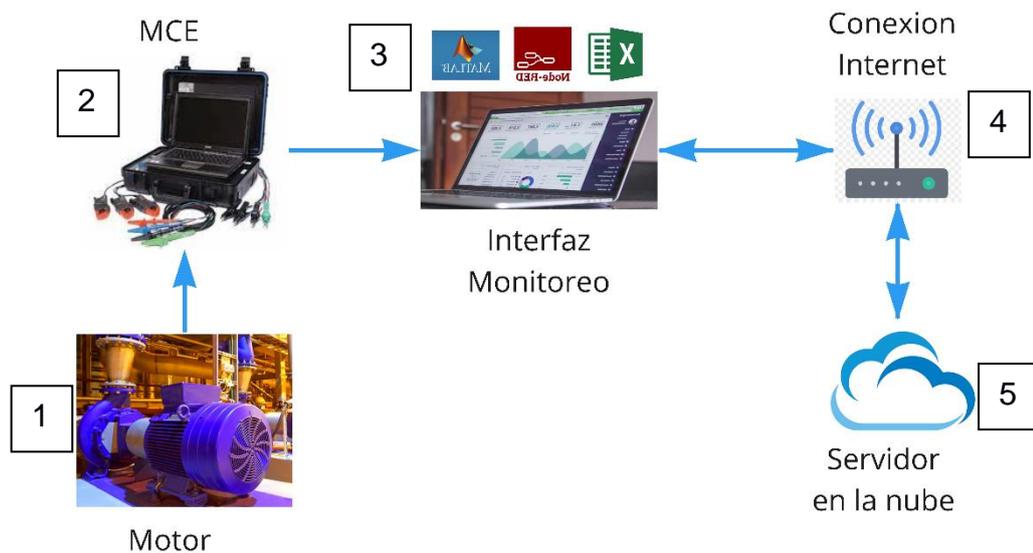


Figura 3.2 Diagrama esquemático del sistema de categorización de motores en la nube

En el esquema anterior se puede observar un diagrama de bloques que indica los pasos que conforman el sistema de mantenimiento predictivo.

1. El motor se debe desenergizar para las pruebas de mantenimiento, por lo que se deben planificar paradas de producción, estas paradas no se pueden evitar ya que las pruebas consideran aplicación de valores de voltaje en C.C. y tiempos de muestreo para la obtención de datos
2. El equipo MCE se configura para el desarrollo de las pruebas estándar y de índice de polarización, hay que tener en cuenta el punto de medición y factores de ajuste como la temperatura al momento de realizar el test.
3. Los datos de las pruebas se exportan y recolectan en el sistema central (Laptop o PC), de aquí se realiza un tratamiento de los datos para conformar las matrices de datos inicial y final. También, se realiza el proceso de entrenamiento del modelo predictivo y se obtienen los indicadores de estado mediante la función de predicción programada en Matlab. Además, se levanta la interfaz de monitoreo y categorización utilizando Node Red.

4. Se utiliza un router que permita acceso a internet a los diferentes dispositivos de tal forma que se puedan conectar de manera remota a la interfaz visual, cabe destacar que los dispositivos deben estar en la misma red para conectarse al servidor.
5. Se establece un servidor en la nube para el almacenamiento de los datos la cual permitirá generar histórico de datos, analizar tendencias y generar un reporte en base al diagnóstico realizado.

3.1.2 Funcionamiento del sistema

El sistema dispondrá de las siguientes funciones:

- I. Determinar la probabilidad que exista un fallo del motor por medio de un análisis de históricos y tendencias
- II. Disposición de un sistema de aprendizaje para categorizar el estado del motor
- III. Evaluar y diagnosticar la información a través de los datos recopilados de las pruebas de mantenimiento
- IV. Crear una base de datos de las variables obtenidas para ser representadas como históricos
- V. Realizar un proceso de supervisión remoto por medio del sistema en la nube

3.2 Procesamiento de la información

El procesamiento de la información es realizada previo a ser tratada por el sistema de entrenamiento, se deben recopilar los datos de las pruebas de mantenimiento para luego depurarlos en una matriz de datos que contenga las variables que condicionan el estado de operación del motor. En base a las condiciones establecidas por la norma IEEE Std. 43-2000, se establece la categorización y el almacenamiento de datos en la nube

3.2.1 Recolección de datos

Es necesario exportados los datos de las pruebas de mantenimiento realizadas con el MCE, estas pruebas entregan una información que debe ser procesada y depurada antes de ingresar al sistema de entrenamiento.

Los datos entregados por la prueba estándar para un motor de inducción de 5 kV se muestran en la Tabla 6.

Como se mencionó en la sección 2.3, los parámetros a tener en cuenta se resaltan de color verde para la conformación de la tabla de datos inicial.

Tabla 6 Datos obtenidos de la prueba estándar

Test Date	7/10/2015	5/29/2018	12/12/2018
Test Time	2:17:25 PM	10:50:46 AM	12:22:19 PM
Test Location	Motor Leads	Motor Leads	Motor Leads
User	Administrator	Administrator	Administrator
Tester Serial			
MTAP ID			
	Baseline		
Frequency	1200	1200	1200
Charge Time	600	60	60
Voltage	2500	2500	2500
Motor Temp	30	30	35
Measured Mohm	7325	10190	16610
Corrected Mohm	3700	5100	11700
pF Ph 1 to Ground	159750	81750	83250
ohm Ph 1 to 2	0,647	0,364	0,371
ohm Ph 2 to 3	0,647	0,362	0,37
ohm Ph 3 to 1	0,647	0,364	0,372
mH Ph 1 to 2	38,92	79,7	82,85
mH Ph 2 to 3	38,89	78,5	81,45
mH Ph 3 to 1	38,9	80,5	80,95
Average Inductance	38,9	79,55	81,75
% Res. Imbalance	0	0,37	0,27
% Ind. Imbalance	0,04	1,34	1,35

La prueba de índice de polarización de un motor de inducción de 5 kV nos entrega los datos mostrados en la Tabla 7. En dicha tabla se resaltan los parámetros a considerarse para la conformación de datos de la tabla inicial.

Tabla 7 Datos recolectados de la prueba de PI

Test Date	7/10/2015	5/29/2018	12/12/2018
Test Time	2:17:25 PM	10:57:33 AM	1:41:12 PM
Test Location	Motor Leads	Motor Leads	Motor Leads
User	Administrator	Administrator	Administrator
Tester Serial			
MTAP ID			
	Baseline		
Voltage	2500	2500	2500
Duration	600	600	600
D/A Ratio	1,909	1,79	1,732
Polar. Index	7,807	5,126	6,527

Una vez que se hayan recopilado los datos, estos se agrupan de tal forma que se establece una matriz o tabla de datos inicial (Tabla 8) la cual será analizada para la categorización del estado del motor según las condiciones presentadas en la sección 2.4

Tabla 8 Tabla de datos inicial, incluye área de trabajo, datos placa del motor y resultados prueba estándar MCE.

ID	FECHA	HORA	YEAR	AREA	POTENCI	VOLTAJ	MOHN	COHM	TEMI	RES_IM	IND_IV	PI
1	27/07/2010	13:34:57	2010	562VE9	470	4000	42420	24400	32	0,06	0,13	8,461
2	05/09/2011	11:20:18	2011	54XPX1MOVIL	939	4000	7289	15600	51	0,12	0,04	5,019
3	25/01/2012	9:49:11	2012	54XPX1MOVIL	939	4000	4552	3000	34	0,12	0,04	2,263
4	13/02/2012	11:20:39	2012	442VE1	3754,8	4160	882,1	358	27	0,69	0,07	2,137
5	26/06/2012	10:32:45	2012	562VE9	470	4000	23820	23820	40	0,04	0,14	5,419
6	05/07/2012	10:40:37	2012	564VE1	3620,7	4000	9081	6000	34	0,68	0,07	4,831

3.2.2 Condiciones de categorización

Para aplicar la categorización del estado de cada motor, nos basamos en los criterios presentados en la sección 2.4, en esta se definen los rangos para la generación de los eventos (Operación Normal, Precaución y Alerta) ponderados para cada parámetro, por lo tanto, en la tabla de datos inicial se añadirá una columna que representa un indicador para el estado del motor, finalmente esta tabla se la denominará tabla de datos final.

Tabla 9 Tabla de datos final con el indicador de estados de cada motor

ID	FECHA	HORA	YEAR	AREA	POTENCI	VOLTAJ	MOHN	COHM	TEMI	RES_IM	IND_IM	PI	INDICADC
88	04/02/2019	10:54:31	2019	564AP1	6839,1	4160	3778	3778	40	0	0,11	4,677	N
89	10/02/2019	15:11:00	2019	442VE1	3754,8	4160	588,4	239	27	0	0,07	1,198	P
90	13/02/2019	8:40:16	2019	422VE2	1367,82	4160	3676	1600	28	0	0	4,409	N
91	13/02/2019	14:54:24	2019	D31CN1	350	4160	44300	19300	28	0,21	0,05	1,498	N
92	17/02/2019	10:09:36	2019	D31CN3	321,84	4160	863,4	351	27	0,06	0,12	1,436	N
93	18/02/2019	16:49:23	2019	D31CN2	350	4160	24510	42700	48	0,34	5,18	6,26	P
94	21/02/2019	9:45:55	2019	L61VE6	475	4160	6319	2800	28	0,49	2,9	2,555	N
95	25/02/2019	15:56:20	2019	D31CN4	300	4160	52,98	23,1	28	1	0,95	1,693	A
96	04/04/2019	10:27:51	2019	L11TZ1	300	4160	24490	24490	29	0,08	0	4,733	N
97	24/04/2019	4:49:06	2019	562VE9	470	4000	17670	7700	28	0,09	0,13	3,763	N
98	12/06/2019	13:31:01	2019	564VE1	3620,7	4000	4359	2200	30	0	0,07	5,702	N
99	13/08/2019	10:39:59	2019	561VE9	470	4000	25320	25320	40	0,32	0,18	5,928	N
100	28/08/2019	10:52:04	2019	423VE1	1609,2	4000	4829	2400	30	0	0,4	6,25	N
101	28/08/2019	8:27:22	2019	443VE1	3486,6	4000	4424	1800	27	0	0,07	5,145	N
102	09/09/2019	9:01:40	2019	54XPX1.FIJO	939	4000	10910	13400	43	0,24	0	5,174	N
103	09/09/2019	9:35:53	2019	54XPX1.MOVIL	939	4000	7542	9300	43	0,24	0,04	4,816	N
104	28/11/2019	10:14:45	2019	564AP1	6839,1	4160	5037	2200	28	2,41	0,56	4,365	P
105	04/12/2019	9:36:32	2019	363VE1	5095,8	4160	5260	2300	28	0	0,1	6,244	N
106	13/01/2020	15:26:27	2020	D31CN2	350	4160	18700	49300	54	0,39	3,71	5,825	N
107	05/05/2020	17:43:02	2020	D31CN3	321,84	4160	275,6	129	29	0,1	0,09	1,304	P
108	05/05/2020	10:37:08	2020	D31CN4	300	4160	125,3	62,7	30	1,16	2,96	1,665	A
109	06/05/2020	17:18:55	2020	442VE1	3754,8	4160	1282	520	27	1,37	0,07	0,795	A
110	20/05/2020	12:16:33	2020	423VE1	1609,2	4000	3601	2100	32	0	0,49	6,411	N
111	20/05/2020	15:27:12	2020	443VE1	3486,6	4000	3709	1900	30	0	0,07	6,806	N

Como se observa en la tabla de datos final a cada fila se le ha colocado un indicador de estado de funcionamiento donde: N, establece una operación normal de funcionamiento, P indica un estado de precaución, es decir ciertos parámetros de los mencionados anteriormente se encuentra en un rango que no corresponde al funcionamiento normal pero aun así el motor puede seguir trabajando y A que indica el estado de Alerta donde ciertos parámetros del motor se encuentran en valores críticos y se debe recurrir a un mantenimiento correctivo.

3.2.3 Almacenamiento de los datos

Es necesario establecer una base de datos para las tablas de datos inicial y final que permita manejar el acceso, selección y búsqueda de información según lo requiera el usuario, por tanto, se hace uso de una base de datos denominada "DatosMotor.db" en SQLite donde se ira almacenando los datos de las futuras pruebas de mantenimiento.

Se hizo uso de SQL_studio para la creación de las tablas PARAMETROS e INDICADORES, la primera será llenada desde la interfaz central con los datos provenientes de la tabla inicial y luego esta será enviada a Matlab para su respectiva categorización. La tabla INDICADORES será actualizada desde Matlab una vez se hayan establecido los resultados de predicción

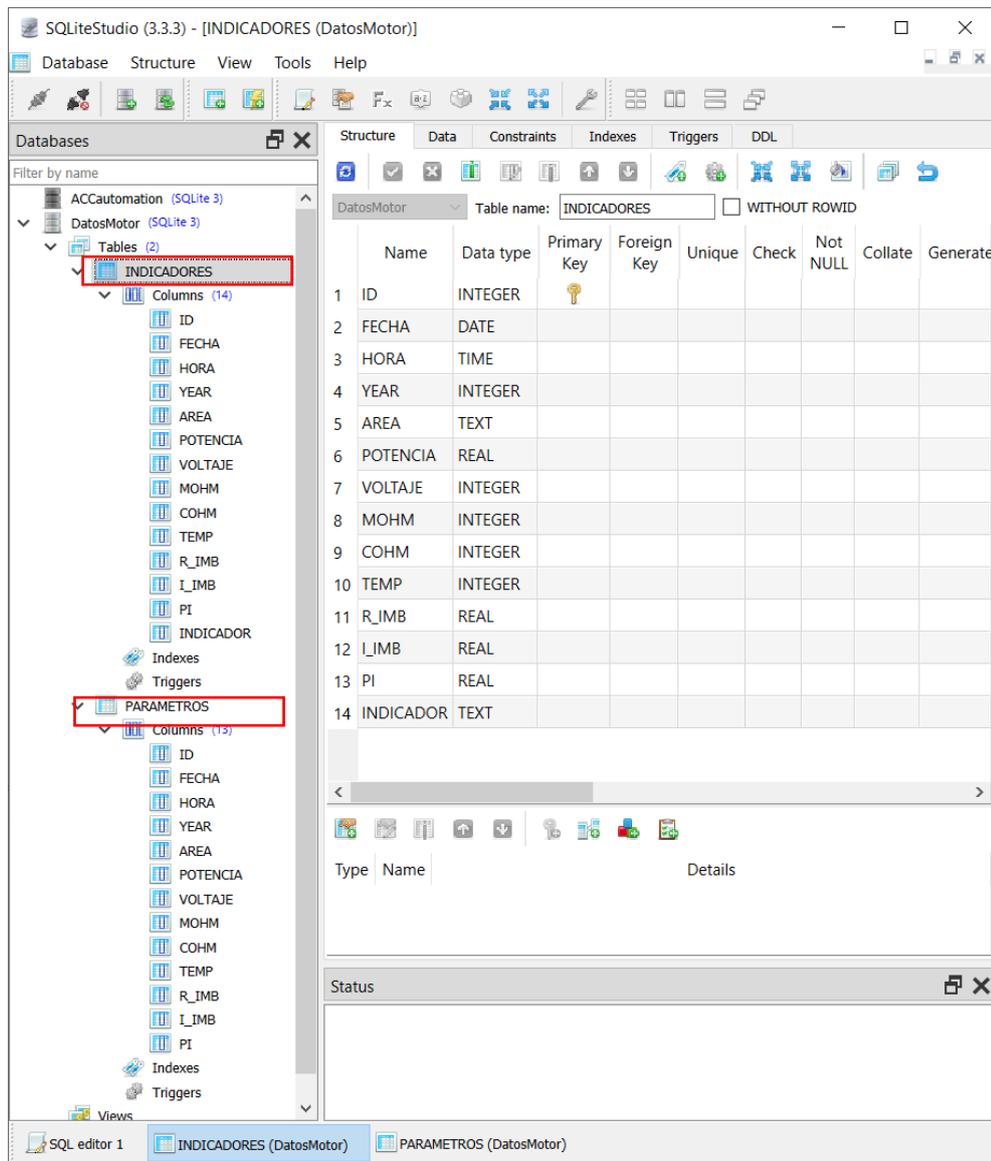


Figura 3.3 Base de datos DatosMotor.db y sus tablas PARAMETROS e INDICADORES

En la Figura 3.3 se demuestran las columnas y tipo de datos que conforman a las tablas PARAMETROS e INDICADORES. De estas se resalta la columna ID la cual se establece como parámetro principal y de autoincremento, es decir nos indicara cuantos datos se han ido almacenando históricamente.

La tabla PARAMETROS la conforma 13 columnas las cuales están asociadas a las variables de la tabla de datos inicial, mientras que la tabla INDICADORES está conformada por 14 columnas, una columna más debido al indicador de estados del motor.

3.3 Desarrollo del modelo de predicción

Para el desarrollo del modelo de predicción se utilizó la herramienta de Matlab, Classification Learner la cual permite entrenar modelos mediante diferentes algoritmos, el utilizado fue el de árbol de decisión de ajuste fino.

El procedimiento para el entrenamiento del modelo consta de dos partes:

- I. Validar el modelo: Entrenar un modelo con un esquema de validación, la herramienta se asegura que no se produzca el sobreajuste mediante la aplicación de una validación cruzada. El modelo con su porcentaje de ajuste es visible en la interfaz.
- II. Modelo entrenado: Entrenar el modelo de predicción con datos nuevos mejora las predicciones y esto se puede realizar simultáneamente con el modelo validado.

El siguiente diagrama sistemático representa el proceso de aprendizaje automático.

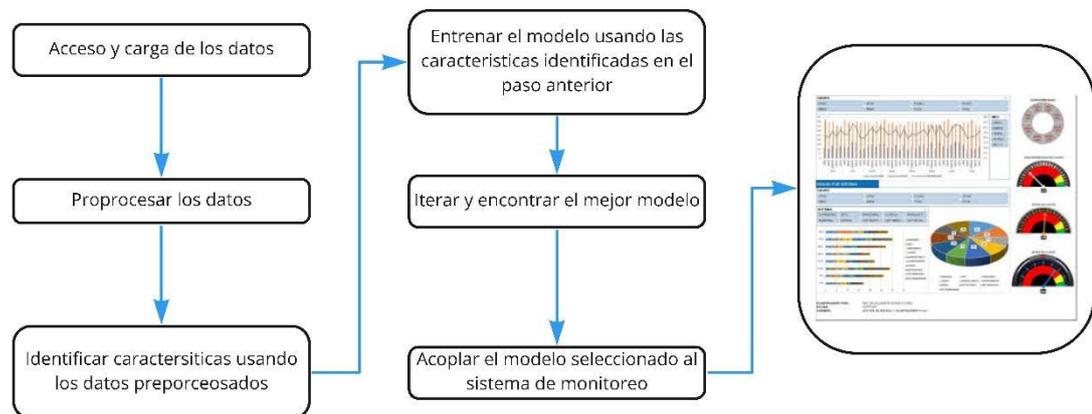


Figura 3.4 Diagrama sistemático de aprendizaje automático

3.3.1 Selección del modelo de aprendizaje

Para la obtención del modelo es necesario discriminar las variables que son esenciales para el proceso de entrenamiento, por lo que se establecerá una matriz de datos con los parámetros de **COHM**, **RIMB**, **IIMB** y **PI** para ser ingresadas a la herramienta de clasificación de aprendizaje automático.

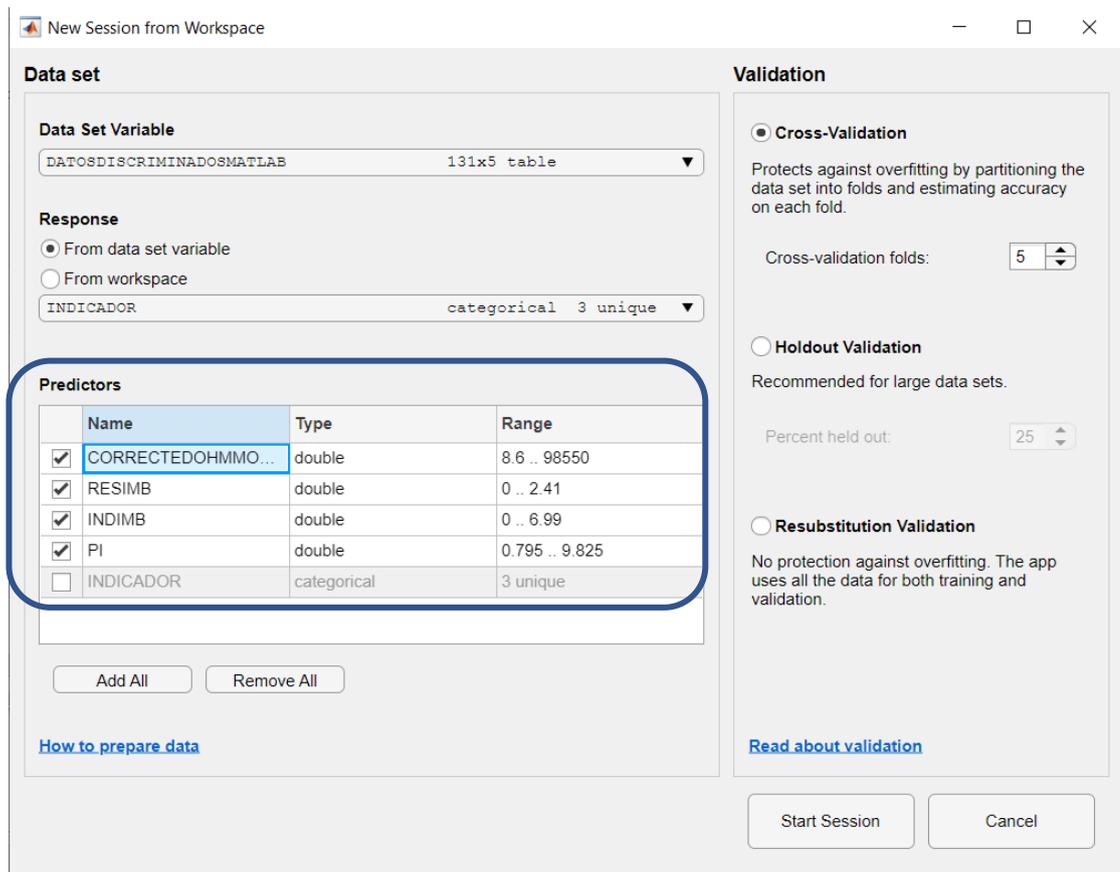


Figura 3.5 Carga de los datos

Luego, se debe seleccionar diferentes algoritmos de aprendizaje automático para establecer los modelos de entrenamiento, es importante entrenar los modelos con diferentes algoritmos ya que no se garantiza que un algoritmo sea el propicio para el modelo de predicción.

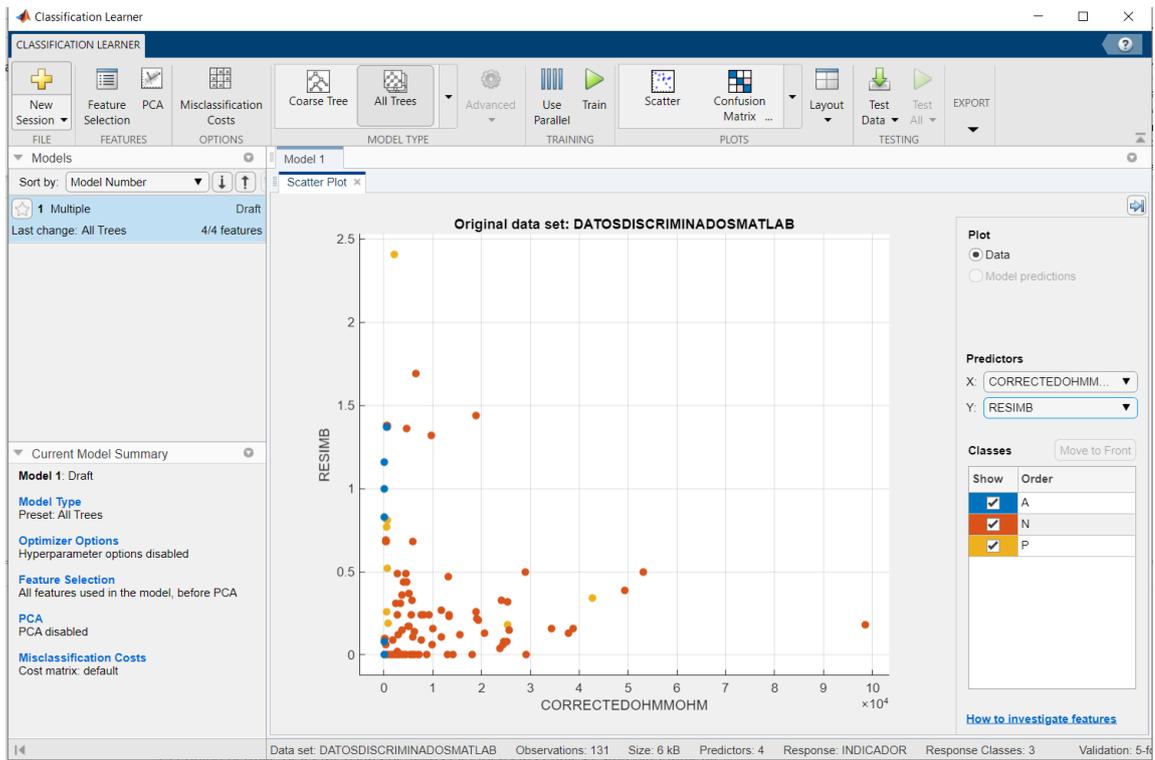


Figura 3.6 Dispersión de los datos, RIMB vs COHM

En la Ilustración 17 se observa la dispersión de los datos para RIMB vs COHM con los indicadores establecidos de N (anaranjado), P (amarillo) y A (azul). Se puede observar una mayor concentración de datos con el indicador N, seguido del indicador P y casi en igual porcentaje el grupo de indicador A, esto hace evidente que los eventos de Precaución y Alarma son puntuales y fáciles de detectar.

Una vez realizado el entrenamiento del modelo con los diferentes algoritmos, la herramienta virtual presenta los modelos sintonizados con sus respectivos porcentajes de validación. Elegir el modelo que tenga el porcentaje de validación por encima del 90% y seleccionar el modelo según el criterio establecido en la sección 2.5.3.

Model Number	Model Name	Accuracy (Validation)	Last change	Features
1.1	Tree	94.7%	Fine Tree	4/4 features
1.2	Tree	94.7%	Medium Tree	4/4 features
1.3	Tree	94.7%	Coarse Tree	4/4 features
1.4	Linear ...	87.0%	Linear Discriminant	4/4 features
1.5	Quadratic Discriminant	Failed	Quadratic Discriminant	4/4 features
1.6	Naive ...	84.0%	Gaussian Naive Bayes	4/4 features
1.7	Naive ...	87.8%	Kernel Naive Bayes	4/4 features
1.8	SVM	88.5%	Linear SVM	4/4 features
1.9	SVM	88.5%	Quadratic SVM	4/4 features
1.10	SVM	90.8%	Cubic SVM	4/4 features
1.11	SVM	88.5%	Fine Gaussian SVM	4/4 features

Figura 3.7 Modelos sintonizados con su porcentaje de validación

Para obtener una mejor descripción del clasificador para su proyecto, se debe consultar con la tabla que muestra las características típicas de los diferentes algoritmos de aprendizaje supervisado. Al usar esta tabla como guía se facilita la compensación que se desea en velocidad, flexibilidad e interpretabilidad. En mejor clasificador depende de los datos.

Para este proyecto se seleccionó el modelo **FineTree** por su elevado porcentaje de validación de 94.7% y son fáciles de interpretar, rápidos para el ajuste y la predicción y utilizan pocos recursos de memoria; solo poseen la desventaja de tener una precisión predictiva baja, esto se compensa con la rapidez en la interpretación de los resultados.

3.3.2 Generación de función de predicción

Después de haber seleccionado el mejor modelo de clasificación este se debe exportar al espacio de trabajo para usarlo como predictor de nuevos datos. El modelo se exporta con el nombre por defecto **trainedModel**.

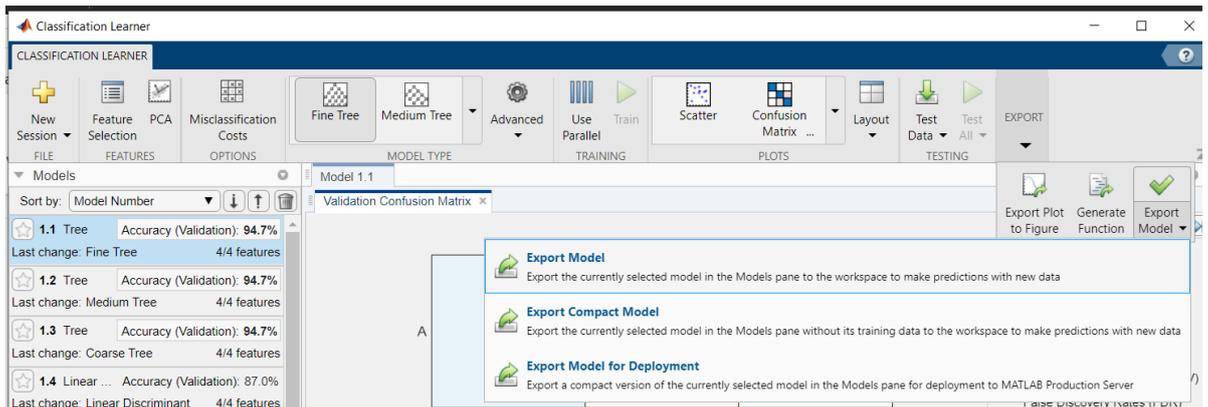


Figura 3.8 Exportación el mejor modelo al espacio de trabajo

Después de exportar el modelo al espacio de trabajo, se genera una función de predicción denominada **trainedClassifier**, la cual se utiliza para realizar predicciones usando nuevos datos. La estructura contiene un objeto de clasificación y una función de predicción.

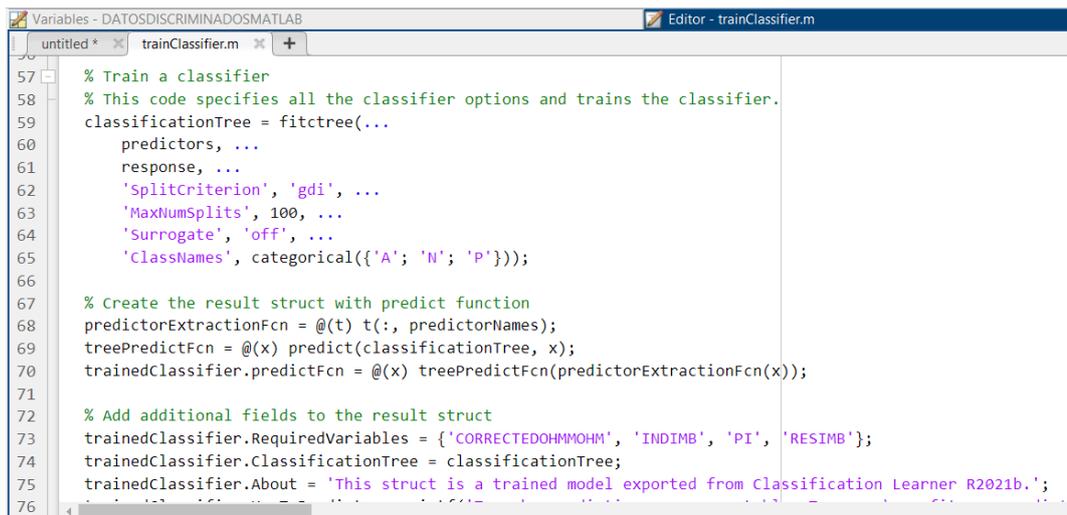


Figura 3.9 Función de predicción

Para usar la función de predicción para un nuevo arreglo de datos T usar el comando `yFit= C.predecirFcn(T)` donde, C corresponde al nombre de su modelo, en este caso **trainedModel**. El arreglo de datos T debe ser una tabla que contenga

los mismos nombres y cantidad de columnas que la tabla de datos que utilizado para entrenar el modelo clasificador. La salida yFit contiene un indicador de predicción para cada fila de datos.

3.3.3 Entrenamiento del modelo con nuevos datos

Es indispensable mejorar el modelo de clasificación entrenándolo con nuevos datos para lo cual se puede utilizar la generación de código de Matlab para lo siguiente:

- I. Entrenar grandes conjuntos de datos. Explorar los modelos entrenados en la herramienta virtual en un subconjunto de datos, luego generar código para entrenar el modelo seleccionado en un conjunto de datos más grande.
- II. Crear scripts para entrenar los modelos sin necesidad de aprender la sintaxis de las diferentes funciones
- III. Examinar el código para aprender a entrenar los clasificadores mediante programación
- IV. Modificar el código para un análisis más detallado
- V. Repetir el análisis en diferentes datos y automatizar el entrenamiento

Para volver a entrenar el modelo clasificador, ejecute la función desde la ventana de comando con sus datos originales o nuevos datos como argumento de entrada. Copiar la primera línea de código generado, excluyendo la palabra function y edite el argumento de entrada **trainingData** para reflejar el nombre de la variable de los datos de entrenamiento o nuevos datos. Del mismo modo se puede modificar el argumento **responseData** si corresponde.

[modelo entrenado, precisión de validación] = clasificador de entrenamiento

El código entrenado devuelve una estructura de **trainedModel** que contiene los mismos campos que se exporta de la herramienta virtual

3.4 Diseño y desarrollo de la interfaz de monitoreo

La interfaz de monitoreo de mantenimiento predictivo es programada en Node Red, el cual es una plataforma abierta de programación basada en flujo de nodos y soportada por varios sistemas operativos y dispositivos a escala académica e industrial. Mediante la programación en Node Red, el usuario interactuara con las diferentes interfaces tales como:

- I) Usuario y Contraseña: Permite un acceso seguro solo para usuarios permitidos ya que el sistema puede ser accedido por diferentes dispositivos que estén conectados a la red
- II) Histórico de Datos: Permite ingresar y visualizar los datos almacenados en la base de datos.
- III) Análisis de Tendencias: Se puede visualizar las gráficas de los diferentes parámetros medidos y realizar un análisis de tendencia de cada uno de ellos
- IV) Diagnóstico y Reporte: Se observa los eventos etiquetados como Precaución y Alertas y se puede generar reportes con acciones recomendadas de mantenimiento según los indicadores y valores de los parámetros.

3.4.1 Históricos y Base de Datos

Para el diseño de esta interfaz se utilizaron los siguientes paquetes de nodos

- Node-red-dashboard
- Node-red-function
- Node-red-debug
- Node-red-Node-sqlite

La programación se compone de los siguientes nodos que se los divide en 3 secciones:

1. La primera sección la conforman los nodos de Node-Red-dashboard los cuales están configurados para que el usuario pueda ingresar los valores para los diferentes parámetros que conforman a la tabla PARAMETROS de la base de datos DatosMotor.db. Los diferentes tipos de nodos corresponden a entradas de texto, numéricos, fecha, hora y botones virtuales de mostrar, enviar y borrar.
2. Nodo de función que utiliza sintaxis java script para declarar las variables globales que están asociadas a los parámetros de ingreso de la tabla PARAMETROS
3. En esta sección se utilizó el nodo de Node-Red-Node-sqlite donde se configura el fichero donde se ubicará la base de datos. Se observa los nodos de función SELECT, INSERT y DELETE los cuales fueron programados con las

respectivas sentencias SQL para acceso, selección, ingreso y depuración de los datos de la tabla PARAMETROS.

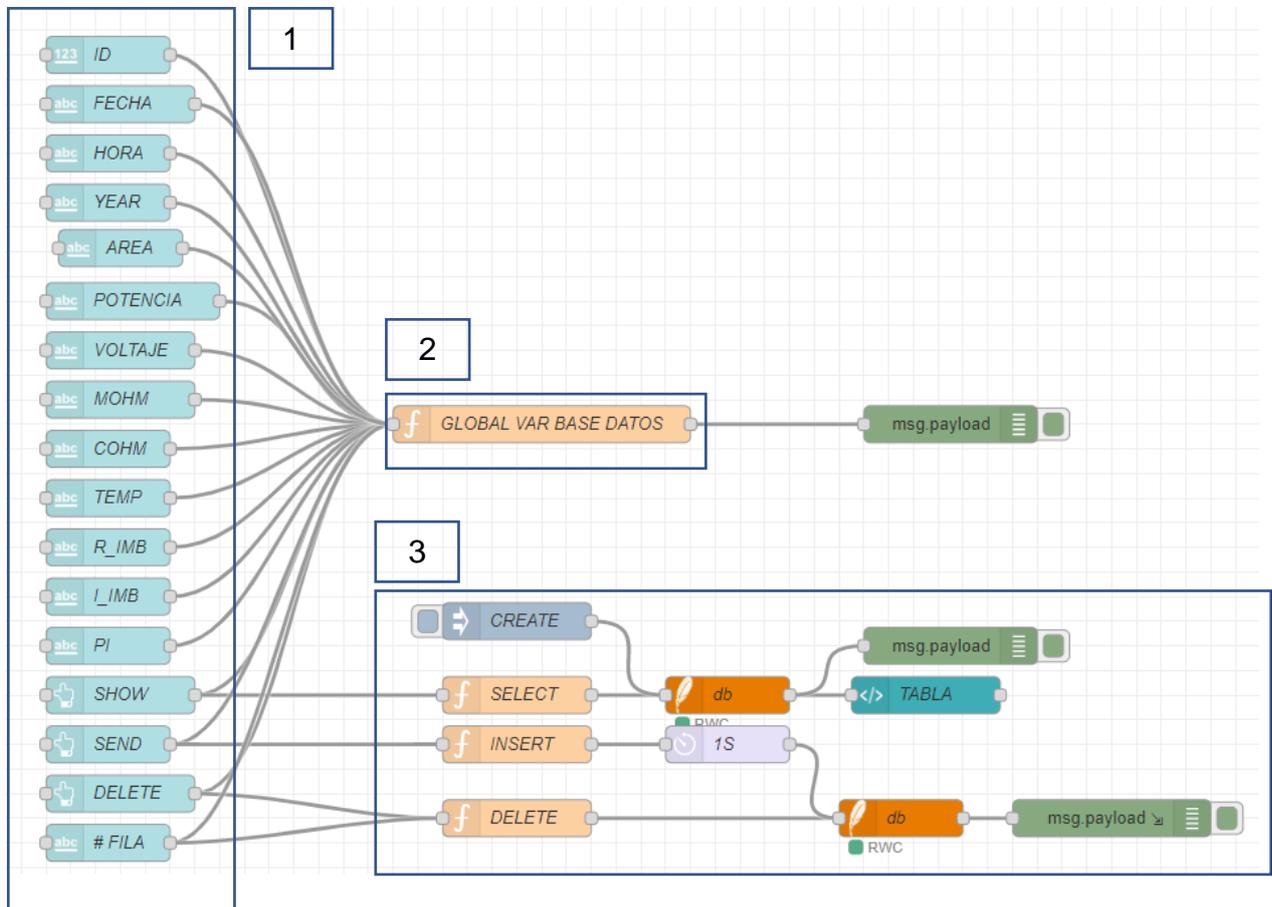


Figura 3.10 Flujo de nodos de historico de datos

El nodo denominado “TABLA” se utiliza para presentar en la interfaz los datos históricos almacenados en la base de datos, este se programa usando sentencias HTML y presenta los últimos 50 datos ingresados.

3.4.2 Análisis y Tendencias

Para el diseño de la interfaz de análisis de tendencias se programaron los siguientes nodos:

- Node-Red-dashboard
- Node-Red-function
- Node-Red-Node-sqlite

- Node-Red-Change

La programación se la puede dividir en 4 secciones:

1. La primera sección está conformada por los nodos selectores para activar las gráficas de tendencia de temperatura, desbalance resistivo, desbalance inductivo, resistencia de aislamiento a tierra, resistencia de aislamiento a tierra corregida por temperatura.
2. La cual está conformada por los nodos de función que accedan a la tabla de datos PARAMETROS y devuelven los datos ordenados por año de manera ascendente.
3. Conformada por los nodos de base de datos y de selección de datos en formato JSON, esto debido a que para graficar las tendencias se necesita recolectar los datos estableciendo las leyendas, series y vector de datos
4. Esta sección dispone de los nodos para la selección de área a la que pertenece el motor y graficar solo la tendencia de ese motor

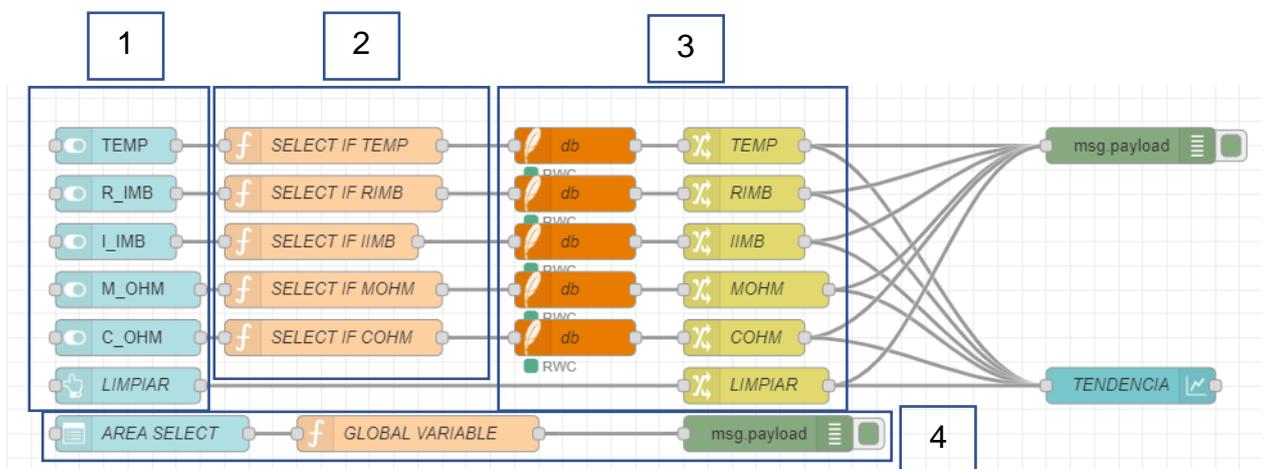


Figura 3.11 Flujo de nodos para los análisis de tendencias

3.4.3 Diagnóstico y Reporte

La programación de diagnóstico y reporte está constituida por los siguientes nodos

- Node-Red-dashboard
- Node-Red-function
- Node-Red-Node-sqlite

La programación se divide en 3 secciones: La primera corresponde a los nodos de selección de eventos, Alarmas y Advertencias que corresponde a los indicadores de estados Alerta y Precaución respectivamente. La segunda sección conformada por los de función de selección de datos si se identificó una alarma o precaución proveniente de la tabla INDICADORES. La tercera sección corresponde a los nodos de salida template, los cuales se programa con sentencias HTML para representar los eventos con etiquetas P y A. La sección 4 genera el reporte a partir de la programación del nodo de función reporte, la finalidad es representar las condiciones y acciones recomendadas a seguir para el mantenimiento del motor.

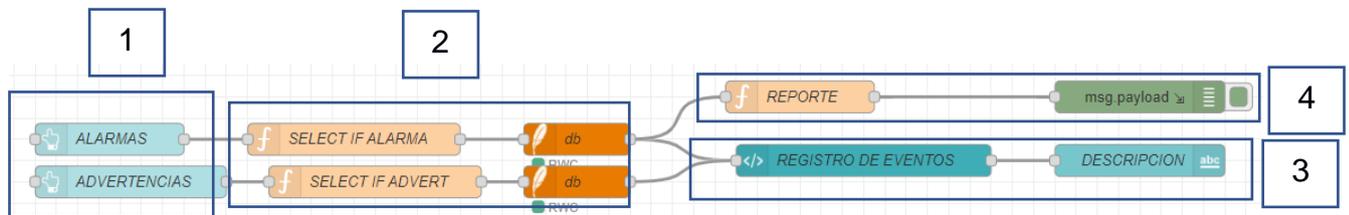


Figura 3.12 Flujo de nodos de Diagnóstico y Reporte

CAPÍTULO 4

4. Diseño de pruebas y análisis de resultados

4.1 Pruebas de funcionamiento

Las pruebas de funcionamiento del sistema permiten establecer si el sistema cumple con los objetivos planteados y determinar si las predicciones realizadas por la función de predicción son precisas.

4.1.1 Prueba de histórico de datos

La finalidad de la siguiente prueba es determinar si el sistema almacena los datos del proceso en la base de datos DatosMotor.db. Las variables que intervienen en el almacenamiento son: ID, FECHA, HORA, YEAR, AREA, POTENCIA, VOLTAJE, MOHM, COHM, TEMP, R_IMB, I_IMB y PI.

Para el desarrollo de la prueba se utilizó la interfaz DATA BASE, la cual está conformada por tres grupos: ACCIONES, VARIABLES y TABLA DE DATOS (Figura 4.1). El primer grupo contiene los botones virtuales para enviar, borrar y mostrar la información desde la base de datos, el segundo grupo permite modificar los datos a enviarse, y el tercer grupo muestra la información almacenada en la base de datos.

En la interfaz (Figura 4.1) se puede verificar 20 registros almacenados, a continuación, se enviaron 20 registros nuevos para comprobar el almacenamiento, dando como resultado la Figura 4.2, que muestra la tabla de datos actualizada hasta el registro 40. Adicional en la Figura 4.3 también se evidencia los 40 registros en la base de datos Sqlite.

DATA BASE																
ACCIONES		PARAMETROS		TABLA DE DATOS												
SHOW		ID	▼ 0 ▲	ID	FECHA	HORA	YEAR	AREA	POTENCIA	VOLTAJE	MOHM	COHM	TEMP	R_JMB	I_JMB	PI
SEND				POTENCIA	VOLTAJE	YEAR	FECHA	HORA	AREA	MOHM	COHM	TEMP	R_JMB	I_JMB	PI	
DELETE				TEMP	R_JMB	I_JMB	PI									
# FILA																
1	07/27/2010			01:34:57 PM	2010	562VE9	470	4000	42420	24400	32	0.06	0.13	8.461		
2	09/05/2011			11:20:18 AM	2011	54XPX1MOVIL	939	4000	7289	15600	51	0.12	0.04	5.019		
3	01/25/2012			09:49:11 AM	2012	54XPX1MOVIL	939	4000	4552	3000	34	0.12	0.04	2.263		
4	02/13/2012			11:20:39 AM	2012	442VE1	3754.8	4160	882.1	358	27	0.69	0.07	2.137		
5	06/26/2012			10:32:45 AM	2012	562VE9	470	4000	23820	23820	40	0.04	0.14	5.419		
6	07/05/2012			10:40:37 AM	2012	564VE1	3620.7	4000	9081	6000	34	0.68	0.07	4.831		
7	07/10/2012	10:44:25 AM	2012	K31TS1	600	4160	1175	590	30	0.26	5.94	3.138				
8	08/21/2012	11:46:28 AM	2012	564AP1	6839.1	4160	6824	18000	54	0	0.11	6.773				
9	11/23/2012	12:32:11 PM	2012	562VE9	470	4000	22060	29100	44	0	0.13	5.309				
10	01/03/2013	10:21:44 AM	2013	564AP1	6839.1	4160	6138	14100	52	0	0.11	5.363				
11	01/17/2013	11:04:01 AM	2013	K31TS1	600	4160	1309	650	30	0.81	6.68	3.798				
12	01/29/2013	06:05:30 PM	2013	562VE9	470	4000	51440	25700	30	0.15	0.15	7.839				
13	03/01/2013	03:18:36 PM	2013	422VE2	1367.82	4160	7334	3700	30	0.15	0.03	4.795				
14	03/03/2013	12:22:35 PM	2013	442VE1	3754.8	4160	851	346	27	0.68	0.07	2.247				
15	03/04/2013	02:16:15 PM	2013	D31CN1	350	4160	62130	29000	29	0.5	0.03	1.6				
16	03/08/2013	10:55:06 AM	2013	D31CN3	321.84	4160	6054	2800	29	0.02	0.09	1.346				
17	03/28/2013	10:04:43 AM	2013	K31TS1	600	4160	1077	540	30	0.68	6.99	4.082				
18	04/17/2013	10:21:10 AM	2013	211TI2	400	4160	13970	9900	35	0.06	0.06	3.526				
19	07/02/2013	02:05:13 PM	2013	564VE1	3620.7	4000	9192	7000	36	0	0.07	4.34				
20	07/31/2013	10:10:40 AM	2013	K31TS1	600	4160	1163	580	30	0.77	6.31	3.797				

Figura 4.1 Interfaz de Histórico de Datos

DATA BASE																
ACCIONES		PARAMETROS		TABLA DE DATOS												
SHOW		ID	▼ 0 ▲	ID	FECHA	HORA	YEAR	AREA	POTENCIA	VOLTAJE	MOHM	COHM	TEMP	R_JMB	I_JMB	PI
SEND				POTENCIA	VOLTAJE	YEAR	FECHA	HORA	AREA	MOHM	COHM	TEMP	R_JMB	I_JMB	PI	
DELETE				TEMP	R_JMB	I_JMB	PI									
# FILA																
11	01/17/2013			11:04:01 AM	2013	K31TS1	600	4160	1309	650	30	0.81	6.68	3.798		
12	01/29/2013			06:05:30 PM	2013	562VE9	470	4000	51440	25700	30	0.15	0.15	7.839		
13	03/01/2013			03:18:36 PM	2013	422VE2	1367.82	4160	7334	3700	30	0.15	0.03	4.795		
14	03/03/2013			12:22:35 PM	2013	442VE1	3754.8	4160	851	346	27	0.68	0.07	2.247		
15	03/04/2013			02:16:15 PM	2013	D31CN1	350	4160	62130	29000	29	0.5	0.03	1.6		
16	03/08/2013			10:55:06 AM	2013	D31CN3	321.84	4160	6054	2800	29	0.02	0.09	1.346		
17	03/28/2013	10:04:43 AM	2013	K31TS1	600	4160	1077	540	30	0.68	6.99	4.082				
18	04/17/2013	10:21:10 AM	2013	211TI2	400	4160	13970	9900	35	0.06	0.06	3.526				
19	07/02/2013	02:05:13 PM	2013	564VE1	3620.7	4000	9192	7000	36	0	0.07	4.34				
20	07/31/2013	10:10:40 AM	2013	K31TS1	600	4160	1163	580	30	0.77	6.31	3.797				
21	12/02/2013	11:13:18 AM	2013	K31TS1	600	4160	1432	720	30	0.52	5.59	4.001				
22	01/22/2014	11:51:10 AM	2014	564AP1	6839.1	4160	5692	5692	40	0	0.11	5.103				
23	01/22/2014	12:34:21 PM	2014	564VE1	3620.7	4000	4781	3200	34	0	0	5.037				
24	02/14/2014	03:22:43 PM	2014	442VE1	3754.8	4160	1941	790	27	1.37	0	7.414				
25	02/14/2014	04:11:39 PM	2014	442VE1	3754.8	4160	1918	780	27	1.38	0.07	2.365				
26	04/22/2014	10:49:02 AM	2014	211TI2	400	4160	8580	34300	60	0.16	0.03	3.131				
27	07/08/2014	02:46:44 PM	2014	562VE9	470	4000	53490	37800	35	0.13	0.24	8.747				
28	09/01/2014	04:04:42 PM	2014	564AP1	6839.1	4160	5668	2800	30	0	0.11	4.932				
29	09/01/2014	11:44:45 AM	2014	564VE1	3620.7	4000	13300	6200	29	0	0.07	5.462				
30	09/30/2014	11:42:36 AM	2014	211TI2	400	4160	13840	6000	28	0.11	0.05	4.44				
31	11/04/2014	02:08:12 PM	2014	54XPX1.FIJO	939	4000	6435	3700	32	0.36	0.71	4.683				
32	11/04/2014	02:54:26 PM	2014	54XPX1.MOVIL	939	4000	5676	2800	30	0.24	0.04	5.99				
33	11/17/2014	10:40:42 AM	2014	443VE1	3486.6	4000	6148	3100	30	0	0.07	6.975				
34	11/26/2014	02:22:05 PM	2014	363VE1	5095.8	4160	4913	2500	30	0	0	4.823				
35	12/08/2014	03:14:28 PM	2014	423VE1	1609.2	4000	4915	2500	30	0	0.43	4.784				
36	01/20/2015	01:24:44 PM	2015	D31CN4	300	4160	10660	4600	28	1.36	1.58	2.827				
37	02/03/2015	10:59:19 AM	2015	D31CN1	350	4160	98550	98550	40	0.18	0.07	9.433				
38	02/11/2015	03:51:03 PM	2015	363VE1	5095.8	4160	6312	3200	30	0	0.09	7.027				
39	02/12/2015	03:40:39 PM	2015	443VE1	3486.6	4000	6327	3200	30	0	0.07	6.532				
40	02/13/2015	09:39:08 AM	2015	423VE1	1609.2	4000	6167	6167	40	0	0.31	6.985				

Figura 4.2 Interfaz de Histórico de Datos actualizada

ID	FECHA	HORA	YEAR	AREA	POTENCIA	VOLTAJE	MOHM	COHM	TEMP	R_IMB	I_IMB	PI
17	03/28/2013	10:04:43 AM	2013	K31TS1	600	4160	1077	540	30	0.68	6.99	4.082
18	04/17/2013	10:21:10 AM	2013	211TI2	400	4160	13970	9900	35	0.06	0.06	3.526
19	07/02/2013	02:05:13 PM	2013	564VE1	3620.7	4000	9192	7000	36	0	0.07	4.34
20	07/31/2013	10:10:40 AM	2013	K31TS1	600	4160	1163	580	30	0.77	6.31	3.797
21	12/02/2013	11:13:18 AM	2013	K31TS1	600	4160	1432	720	30	0.52	5.59	4.001
22	01/22/2014	11:51:10 AM	2014	564AP1	6839.1	4160	5692	5692	40	0	0.11	5.103
23	01/22/2014	12:34:21 PM	2014	564VE1	3620.7	4000	4781	3200	34	0	0	5.037
24	02/14/2014	03:22:43 PM	2014	442VE1	3754.8	4160	1941	790	27	1.37	0	7.414
25	02/14/2014	04:11:39 PM	2014	442VE1	3754.8	4160	1918	780	27	1.38	0.07	2.365
26	04/22/2014	10:49:02 AM	2014	211TI2	400	4160	8580	34300	60	0.16	0.03	3.131
27	07/08/2014	02:46:44 PM	2014	562VE9	470	4000	53490	37800	35	0.13	0.24	8.747
28	09/01/2014	04:04:42 PM	2014	564AP1	6839.1	4160	5668	2800	30	0	0.11	4.932
29	09/01/2014	11:44:45 AM	2014	564VE1	3620.7	4000	13300	6200	29	0	0.07	5.462
30	09/30/2014	11:42:36 AM	2014	211TI2	400	4160	13840	6000	28	0.11	0.05	4.44
31	11/04/2014	02:08:12 PM	2014	54XPX1.FUJO	939	4000	6435	3700	32	0.36	0.71	4.683
32	11/04/2014	02:54:26 PM	2014	54XPX1.MOVIL	939	4000	5676	2800	30	0.24	0.04	5.99
33	11/17/2014	10:40:42 AM	2014	443VE1	3486.6	4000	6148	3100	30	0	0.07	6.975
34	11/26/2014	02:22:05 PM	2014	363VE1	5095.8	4160	4913	2500	30	0	0	4.823
35	12/08/2014	03:14:28 PM	2014	423VE1	1609.2	4000	4915	2500	30	0	0.43	4.784
36	01/20/2015	01:24:44 PM	2015	D31CN4	300	4160	10660	4600	28	1.36	1.58	2.827
37	02/03/2015	10:59:19 AM	2015	D31CN1	350	4160	98550	98550	40	0.18	0.07	9.433
38	02/11/2015	03:51:03 PM	2015	363VE1	5095.8	4160	6312	3200	30	0	0.09	7.027
39	02/12/2015	03:40:39 PM	2015	443VE1	3486.6	4000	6327	3200	30	0	0.07	6.532
40	02/13/2015	09:39:08 AM	2015	423VE1	1609.2	4000	6167	6167	40	0	0.31	6.985

Figura 4.3 Tabla de datos PARAMETROS en SQL_studio

Esta prueba permitió comprobar el acceso y selección de datos desde la base de datos DatosMotor.db y presentarla en la interfaz Histórico de Datos sin perder ningún registro de por medio, por consiguiente, se tiene una conexión confiable entre el servidor de monitoreo y el servidor de la base de datos.

4.1.2 Prueba del sistema de predicción del estado del motor

La siguiente prueba permite determinar si el sistema aumenta sus datos de entrenamiento con cada registro de información. Las variables que intervienen en la prueba son: COHM, R_IMB, I_IMB y PI.

Para comprobar el correcto funcionamiento del sistema se envía un arreglo de datos con todos los datos. El arreglo está compuesto por dos conjuntos, el primer conjunto representa los datos de entradas provenientes de las pruebas de mantenimiento y que sirven como entrada al modelo de aprendizaje supervisado, y el segundo conjunto de datos es la salida, define el estado en el que se encuentra el motor, este parámetro indica la categorización normal (N), preventiva (P) o de alerta (A).

Esta prueba es de relevante importancia ya que el ingreso de los nuevos datos sirve para diagnosticar el estado del motor, por lo que si el sistema no recibe los nuevos datos entonces no se estaría realizando un diagnóstico actualizado del motor. Para esto se ha desarrollado un script en Matlab que accede a la tabla PARAMETROS de la base de datos DatosMotor.db y construye la matriz de datos (Figura 4.4) que servirá de entrada a la función de predicción.

```
Command Window
New to MATLAB? See resources for Getting Started.

>> totree

totree =

128x4 table

    CORRECTEDOHHMOHM    RESIMB    INDIMB    PI
    _____    _____    _____    _____
    24400            0.06            0.13            8.46
    15600            0.12            0.04            5.02
    3000             0.12            0.04            2.26
    358              0.69            0.07            2.14
    23820            0.04            0.14            5.42
    6000             0.68            0.07            4.83
    590              0.26            5.94            3.14
    18000            0              0.11            6.77
    29100            0              0.13            5.31
    14100            0              0.11            5.36
    650              0.81            6.68            3.8
    25700            0.15            0.15            7.84
    3700             0.15            0.03            4.79
    346              0.68            0.07            2.25
    29000            0.5             0.03            1.6
    2800             0.02            0.09            1.35
    540              0.68            6.99            4.08
    9900             0.06            0.06            3.53
    7000             0              0.07            4.34
    580              0.77            6.31            3.8
    720              0.52            5.59            4
    5692             0              0.11            5.1
```

Figura 4.4 Conformación de matriz de datos “totree” para el predictor de estado

El proceso de categorización consiste en utilizar la función de predicción con la matriz de datos totree y almacenar los valores de predicción en un arreglo denominado yfit (Figura 4.5).

```

Command Window
New to MATLAB? See resources for Getting Started.

>> %se envia la tabla al modelo entrenado
yfit = trainedModel11.predictFcn(totree);
yfit'

ans =
|
1x128 categorical array
|
Columns 1 through 19
|
N N N N N N P N N N P N N N N N P N
|
Columns 20 through 38
|
P P N N N N N N N N N N N N N N N N

```

Figura 4.5 Arreglo “yfit” con los indicadores de estado para cada registro

El arreglo yfit devuelve los indicadores para cada registro ingresado en la función de predicción, estableciéndose el estado del motor. Luego, se tiene que enviar esta información a la tabla INDICADORES de la base de datos, por lo cual se debe concatenar este arreglo a la matriz de datos inicial y actualizar la tabla INDICADORES (Figura 4.6)

```

Command Window
New to MATLAB? See resources for Getting Started.

{[110]} {'2020-07-09'} {'8:30:40 AM'} {[2020]} {'422-VE1'} {[3.7348e+03]} {[4160]} {[ 1163]}
{[114]} {'2020-08-17'} {'8:55:28 AM'} {[2020]} {'422-VE2'} {[1.3678e+03]} {[4160]} {[ 7774]}
{[115]} {'2020-08-19'} {'4:49:39 PM'} {[2020]} {'L61-VE6'} {[ 475]} {[4160]} {[12990]}
{[116]} {'2020-09-21'} {'2:34:22 PM'} {[2020]} {'564-VE1'} {[3.6207e+03]} {[4000]} {[11300]}
{[117]} {'2020-09-22'} {'8:43:01 AM'} {[2020]} {'564-AP1'} {[6.8391e+03]} {[4160]} {[ 6686]}
{[118]} {'2020-12-14'} {'9:34:27 AM'} {[2020]} {'D31-CN2'} {[ 350]} {[4160]} {[58030]}
{[119]} {'2021-01-11'} {'9:43:15 AM'} {[2021]} {'54X-FX1.FIJO'} {[ 939]} {[4000]} {[ 3626]}
{[120]} {'2021-01-11'} {'10:39:56 AM'} {[2021]} {'54X-FX1.MOVIL'} {[ 939]} {[4000]} {[ 5087]}
{[121]} {'2021-03-16'} {'9:23:35 AM'} {[2021]} {'423-VE1'} {[1.6092e+03]} {[4000]} {[ 4656]}
{[122]} {'2021-03-16'} {'9:50:20 AM'} {[2021]} {'443-VE1'} {[3.4866e+03]} {[4000]} {[ 4069]}
{[123]} {'2021-03-25'} {'12:28:36 PM'} {[2021]} {'363-VE1'} {[5.0958e+03]} {[4160]} {[ 4244]}
{[124]} {'2021-04-05'} {'7:50:22 AM'} {[2021]} {'422-VE2'} {[1.3678e+03]} {[4160]} {[ 7853]}
{[125]} {'2021-04-07'} {'7:44:38 AM'} {[2021]} {'442-VE1'} {[3.7548e+03]} {[4160]} {[ 1142]}
{[126]} {'2021-04-13'} {'8:08:45 AM'} {[2021]} {'D31-CN1'} {[ 350]} {[4160]} {[122100]}
{[127]} {'2021-04-13'} {'4:50:43 PM'} {[2021]} {'D31-CN2'} {[ 350]} {[4160]} {[19350]}
{[128]} {'2021-04-13'} {'9:11:21 AM'} {[2021]} {'D31-CN3'} {[ 321.8400]} {[4160]} {[ 677]}

Columns 9 through 14

{[24400]} {[32]} {[0.0600]} {[0.1300]} {[8.4600]} {'N'}
{[15600]} {[51]} {[0.1200]} {[0.0400]} {[5.0200]} {'N'}
{[ 3000]} {[34]} {[0.1200]} {[0.0400]} {[2.2600]} {'N'}
{[ 358]} {[27]} {[0.6900]} {[0.0700]} {[2.1400]} {'N'}
{[23820]} {[40]} {[0.0400]} {[0.1400]} {[5.4200]} {'N'}
{[ 6000]} {[34]} {[0.6800]} {[0.0700]} {[4.8300]} {'N'}
{[ 590]} {[30]} {[0.2600]} {[5.9400]} {[3.1400]} {'P'}

```

Figura 4.6 Conformación de la tabla de datos INDICADORES con la columna de predicción

La condición del motor se debe mostrar en el sistema de monitoreo, por lo que se implementó la interfaz de DIAGNOSTICO la cual contiene un grupo denominado “EVENTOS” conformado por dos botones virtuales, el botón ALARMAS muestra

todos los eventos que se hayan categorizado con el indicador A, mientras que el botón ADVERTENCIAS muestra los eventos categorizados con el indicador P. Como se muestran en la Figura 4.7 y 4.8 se distinguen los eventos que indican que el motor registrado presenta un fallo grave (A) o moderado (P) por lo que en base a esto se debe propiciar las acciones de mantenimiento recomendadas por el estándar IEEE 43-2000.

≡ DIAGNOSTICO													
EVENTOS													
ALARMAS													
ADVERTENCIAS													
ID	FECHA	HORA	YEAR	AREA	POTENCIA	VOLTAJE	MOHM	COHM	TEMP	R_IBM	i_IBM	PI	INDICADOR
7	2012-07-10	10:44:25 AM	2012	K31-TS1	600	4160	1175	590	30	0.26	5.94	3.14	P
11	2013-01-17	11:04:01 AM	2013	K31-TS1	600	4160	1309	650	30	0.81	6.68	3.8	P
17	2013-03-28	10:04:43 AM	2013	K31-TS1	600	4160	1077	540	30	0.68	6.99	4.08	P
20	2013-07-31	10:10:40 AM	2013	K31-TS1	600	4160	1163	580	30	0.77	6.31	3.8	P
21	2013-12-02	11:13:18 AM	2013	K31-TS1	600	4160	1432	720	30	0.52	5.59	4	P
53	2015-12-10	10:29:55 AM	2015	K31-TS1	600	4160	1312	930	35	0.19	5.24	4.55	P
61	2016-08-29	1:58:55 PM	2016	D31-CN3	321.84	4160	543	253	29	0.1	0.18	1.4	P
89	2019-02-10	3:11:00 PM	2019	442-VE1	3754.8	4160	588.4	239	27	0	0.07	1.2	P
93	2019-02-18	4:49:23 PM	2019	D31-CN2	350	4160	24510	42700	48	0.34	5.18	6.26	P
104	2019-11-28	10:14:45 AM	2019	564-AP1	6839.1	4160	5037	2200	28	2.41	0.56	4.37	P
107	2020-05-05	5:43:02 PM	2020	D31-CN3	321.84	4160	275.6	129	29	0.1	0.09	1.3	P
118	2020-12-14	9:34:27 AM	2020	D31-CN2	350	4160	58030	25300	28	0.18	5.56	9.82	P

Figura 4.7 Diagnostico del estado del motor, Eventos de Precaución

DIAGNOSTICO													
EVENTOS													
ALARMAS													
ADVERTENCIAS													
ID	FECHA	HORA	YEAR	AREA	POTENCIA	VOLTAJE	MOHM	COHM	TEMP	R_IMB	I_IMB	PI	INDICADOR
72	2018-02-20	4:53:29 PM	2018	D31-CN3	321.84	4160	19.77	8.6	28	0.08	0.15	1.46	A
74	2018-02-21	3:40:00 PM	2018	442-VE1	3754.8	4160	207.9	84.4	27	0	0	1.07	A
95	2019-02-25	3:56:20 PM	2019	D31-CN4	300	4160	52.98	23.1	28	1	0.95	1.69	A
108	2020-05-05	10:37:08 AM	2020	D31-CN4	300	4160	125.3	62.7	30	1.16	2.96	1.67	A
109	2020-05-06	5:18:55 PM	2020	442-VE1	3754.8	4160	1282	520	27	1.37	0.07	0.8	A
129	2021-04-13	11:18:29 AM	2021	D31-CN4	300	4160	113.1	56.5	30	0.83	2.2	1.11	A

Figura 4.8 Diagnostico del estado del motor, Eventos de Alerta

Los eventos que se han categorizado como Prevención o de Alarma implican un mayor estudio del motor, por lo que se ha establecido una interfaz para el análisis de tendencias de las variables que inciden en el estado del motor. La interfaz denominada TENDENCIAS (Figura 4.9) contiene dos grupos, el grupo de SELECCIÓN que permite alternar entre las diferentes graficas que se desea observar y el grupo GRAFICO para visualizar la tendencia de la variable seleccionada.

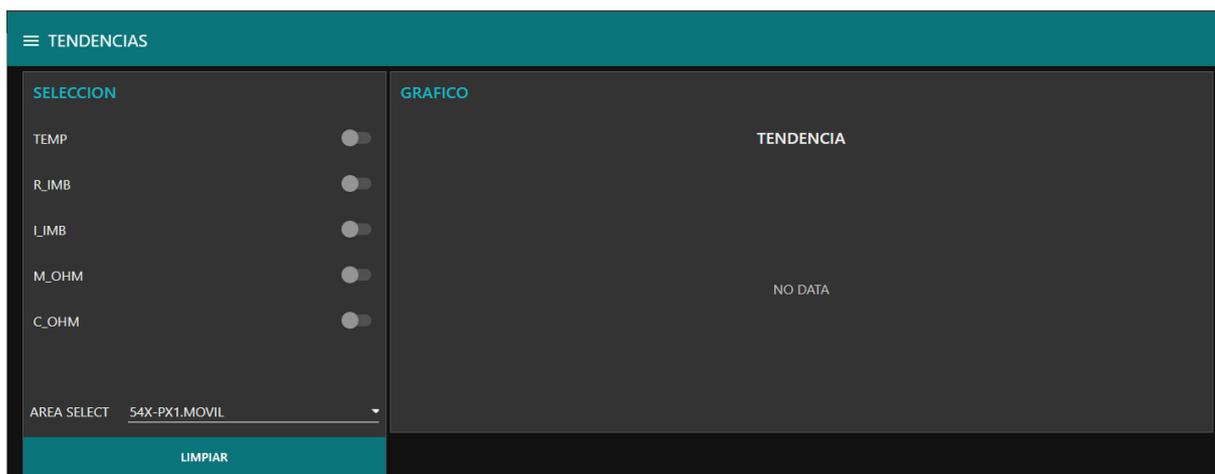


Figura 4.9 Interfaz para el análisis de tendencias

En las siguientes figuras se muestran las tendencias para las variables de TEMP, R_IMB, I_IMB y PI, esto permite profundizar el diagnostico presentado por el sistema de predicción y discriminar el estado de operación del motor según el

criterio del supervisor de mantenimiento. Es importante señalar que conforme se vayan actualizando los datos en la base de datos, las gráficas de tendencia también lo harán ya que se accede a la tabla PARAMETROS de DatosMotor.db.

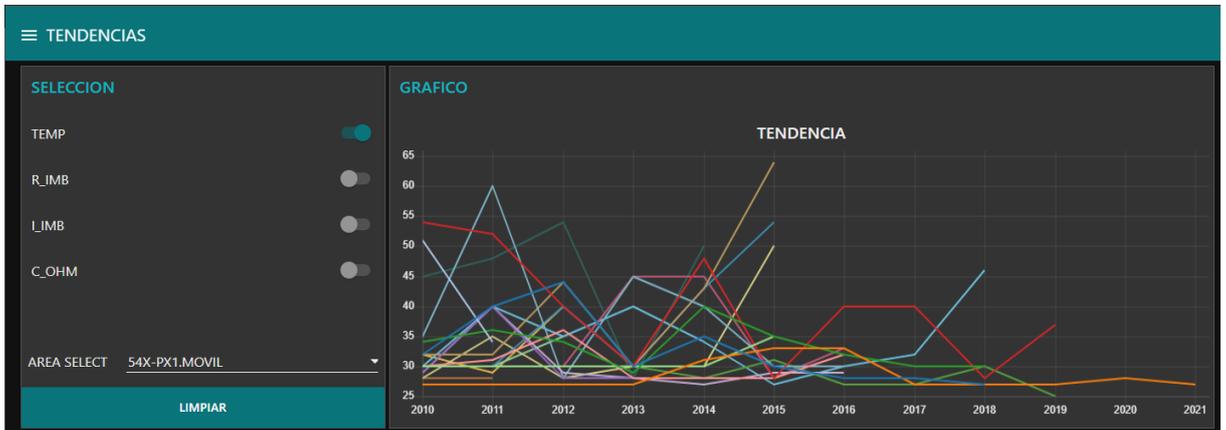


Figura 4.10 Tendencia de Temperatura

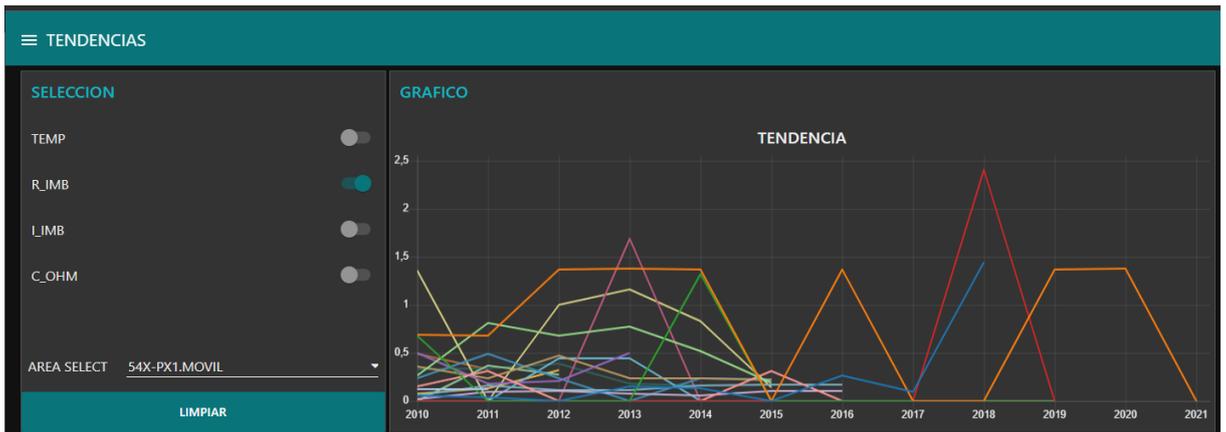


Figura 4.11 Tendencia de Desbalance Resistivo

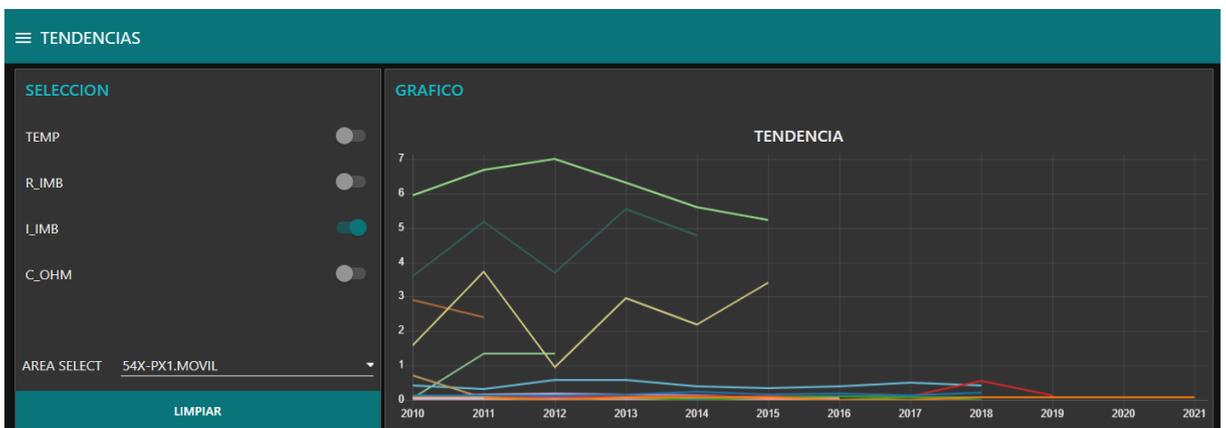


Figura 4.12 Tendencia de Desbalance Inductivo

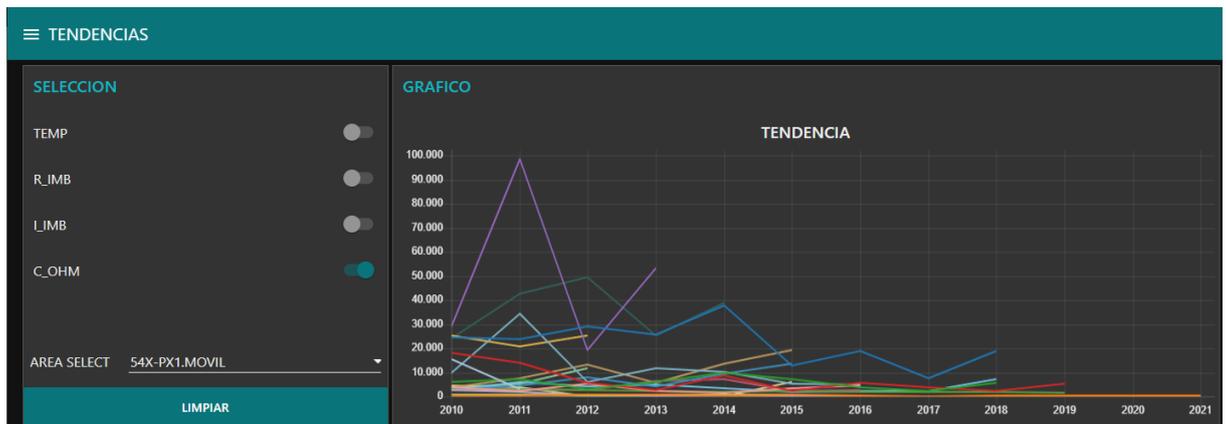


Figura 4.13 Tendencia de Índice de Polarización

4.2 Análisis de Resultados

En esta sección se presenta un análisis de resultados que obtuvieron de las pruebas, teniendo en cuenta el equipo utilizado para las pruebas de mantenimiento, programas de desarrollo, herramientas virtuales y las interfaces de usuario.

4.2.1 Análisis de las pruebas de mantenimiento

Los datos son fundamentales para la implementación del sistema, podríamos decir que es la materia prima del proceso, por lo que es importante que las pruebas de mantenimiento para la recolección de datos sean satisfactorias y no generen valores aberrantes que afecten al modelo de predicción. Es indispensable tanto la instrumentación como el equipo de medición, para este caso se utilizó el software MCEGold y el equipo evaluador de circuito de motor eléctrico MCE de PdMA. El equipo utilizado beneficia a la recolección de datos ya que se puede exportar un archivo Excel con las variables eléctricas que se utilizan como información para el modelo de predicción.



Figura 4.14 Medición con el equipo PdMA

4.2.2 Análisis de la prueba de histórico de datos

Esta prueba permitió comprobar el almacenamiento de datos en la base de datos DatosMotor.db y su posterior visualización en la interfaz de monitoreo realizada en Node Red. Se obtuvo una conexión satisfactoria entre el servidor principal de monitoreo de datos y la base de datos, la comprobación se la realizó ingresando 20 registros de datos mediante la interfaz de Histórico de Datos y luego observando la base de datos actualizada por medio de SQL_studio. Es importante resaltar que Node Red y SQL_studio son plataformas de programación de libre acceso, lo que facilitó el desarrollo del sistema de monitoreo y almacenamiento de datos.

4.2.3 Análisis de la prueba del sistema de categorización

Se realizó una prueba para verificar el sistema de categorización de motores eléctricos. Se entrenó el modelo de aprendizaje automático con 100 registros de datos obtenidos de las pruebas de mantenimiento y luego se comprobó con 30 registros nuevos la validez del modelo. El resultado de la categorización es satisfactorio, ya que como se pudo observar en la Figura 4.6 la función de predicción desarrollada en Matlab devuelve el arreglo de indicadores de estados de cada registro de datos y luego actualiza la base de datos para su posterior visualización en el sistema de monitoreo. Cabe señalar que se utilizó Matlab para el entrenamiento del modelo y la programación de la función de predicción debido a que cuenta con herramientas virtuales dedicadas para estas aplicaciones de

aprendizaje automático, facilitando el desarrollo de este sistema. La implementación del sistema de entrenamiento y predicción en Node Red conlleva a un conocimiento específico de programación en lenguaje JavaScript y esto no forma parte de los objetivos del proyecto.

Las interfaces de Diagnóstico y Tendencias permiten al usuario discriminar el estado del motor al observar los eventos de precaución y alarmas categorizados por el sistema de predicción y al observar las gráficas de tendencias de los parámetros que inciden de forma directa en el diagnóstico de fallo de motores.

CAPITULO 5

5. Conclusiones y recomendaciones

5.1 Conclusiones

- El sistema de monitoreo y diagnóstico implementado permitió categorizar en tres indicadores diferentes el estado de operación de un motor (Normal, Preventivo y de Alarma), además de monitorizar los mencionados eventos en un servidor alojado en la nube para el acceso remoto de los dispositivos que se encuentren en la misma red que el servidor.
- Las pruebas de mantenimiento realizadas con el equipo de medición de PdMA facilitó la recolección de datos y su posterior almacenamiento en una base de datos. Mediante la interfaz de histórico de datos se ingresaron los nuevos datos, se seleccionaron y mostraron los datos almacenados mediante una tabla programada en HTML.
- El toolbox Classification Learner de Matlab permitió el desarrollo del sistema de entrenamiento y predicción de estados de los motores. El modelo entrenado tuvo un 94.5% de confiabilidad de predicción y para su entrenamiento se utilizaron 100 registros de datos de la base de datos y para su validación 31 registros de datos diferentes obtenidos de la base de datos, los resultados de predicción fueron satisfactorios
- La categorización del estado de los motores fue presentada en una interfaz de diagnóstico desarrollada en Node Red, se pudo observar los eventos de Precaución y Alerta que se obtuvieron de la función de predicción desarrollada en Matlab. Se puede complementar el diagnóstico sobre el estado o condición del motor al observar las gráficas de tendencias de temperatura, desbalance resistivo e inductivo y el índice de polarización.
- El sistema propuesto permite un análisis de datos históricos a partir de las pruebas de mantenimiento realizadas con el equipo MCE, permitiendo así agregar registro de datos nuevos a la base de datos e incorpóralos en el modelo de aprendizaje y actualizar el sistema de predicción conforme se realicen pruebas de mantenimiento, esto es una ventaja en comparación con los sistemas comerciales

que brindan servicio de mantenimiento predictivo de motores ya que estos sistemas son propietarios que dependen de licencias y no permiten modificaciones en sus interfaces de visualización.

5.2 Recomendaciones

- El sistema se basa en un proceso de aprendizaje que depende del histórico de datos, por lo tanto, es recomendable actualizar de manera periódica el registro de datos en base a las pruebas de mantenimiento que se vayan realizando; mientras más datos tenga el modelo más preciso será su predicción.
- Es importante resaltar que el sistema de monitoreo y de predicción están separados, el monitoreo se desarrolló en Node Red mientras que el entrenamiento del modelo y predicción de estados en Matlab esto por la facilidad en el desarrollo de ambos sistemas, esto no representa ningún inconveniente al ejecutarse en un ordenador ya que los recursos computacionales permiten la ejecución de ambos sistemas por separado, pero en caso se requiera montar sobre un sistema local industrial como el IOT2040, entonces los recursos computacionales se deben optimizar, por lo que se recomienda utilizar una plataforma de desarrollo que contenga ambos sistemas.
- El sistema propuesto utiliza datos recolectados de las pruebas de mantenimiento que son realizadas en intervalos de tiempo planificados, por lo que el usuario solo sabrá si el motor tiene un fallo cuando se ingresen los nuevos registros en la base de datos, esto se podría mejorar al tener un sistema de análisis en tiempo real, se podría hacer registro de corriente de operación, torque, voltaje entre otros parámetros eléctricos proveniente de un PLC y que complemente el sistema de predicción en caso se produzca una falla en tiempo real.

BIBLIOGRAFÍA

- [1] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. da P. Francisco, J. P. Basto, y S. G. S. Alcalá, «A systematic literature review of machine learning methods applied to predictive maintenance», *Comput. Ind. Eng.*, vol. 137, p. 106024, nov. 2019, doi: 10.1016/j.cie.2019.106024.
- [2] T. Zonta, C. A. da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, y G. P. Li, «Predictive maintenance in the Industry 4.0: A systematic literature review», *Comput. Ind. Eng.*, vol. 150, p. 106889, dic. 2020, doi: 10.1016/j.cie.2020.106889.
- [3] «Industry 4.0 | SpringerLink». <https://link.springer.com/book/10.1007%2F978-1-4842-2047-4> (accedido ago. 13, 2021).
- [4] I. S. Candanedo, S. R. González, y L. Muñoz, «Diseño de un Modelo Predictivo en el Contexto Industria 4.0», *KnE Eng.*, pp. 543-551, feb. 2018, doi: 10.18502/keg.v3i1.1458.
- [5] M. Vathoopan, M. Johny, A. Zoitl, y A. Knoll, «Modular Fault Ascription and Corrective Maintenance Using a Digital Twin», *IFAC-Pap.*, vol. 51, n.º 11, pp. 1041-1046, ene. 2018, doi: 10.1016/j.ifacol.2018.08.470.
- [6] E. I. Basri, I. H. Abdul Razak, H. Ab-Samat, y S. Kamaruddin, «Preventive maintenance (PM) planning: a review», *J. Qual. Maint. Eng.*, vol. 23, n.º 2, pp. 114-143, ene. 2017, doi: 10.1108/JQME-04-2016-0014.

- [7] F. Z. Dekhandji, S. E. Halledj, y O. Zaboub, «Predictive Maintenance Applied to Three phase Induction Motors», *Algerian J. Signals Syst.*, vol. 4, n.º 2, Art. n.º 2, dic. 2019, doi: 10.51485/ajss.v4i2.84.
- [8] «Insulation testing of AC generator windings». <https://ieeexplore.ieee.org/abstract/document/8004652> (accedido ago. 13, 2021).
- [9] Ortiz Dominguez J, Manual de Equipo de Pruebas PdMA, Pagina: equipodepruebas.mx, 2016. Disponible en: [Equipo de Pruebas – Líderes en confiabilidad](#)
- [10] M. Armbrust, A. Fox, R. Griffith, A.D. Joseph, R. Katz, A. Konwinski, G. Lee, D. Patterson, A. Rabkin, I. Stoica, et al. A view of cloud computing *Commun. ACM*, 53 (4) (2010), pp. 50-58
- [11] Zhang, Q., Cheng, L., & Boutaba, R. Cloud computing: state-of-the-art and research challenges. *Journal of internet services and applications*, (2010), 1(1), 7-18.
- [12] Syed, HJ, Gani, A., Ahmad, RW, Khan, MK y Ahmed, AIA. Monitoreo en la nube: una revisión, taxonomía y problemas de investigación abiertos. *Journal of Network and Computer Applications*, (2017), 98, 11-26.
- [13] Mahesh, B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], (2020). 9, 381-386.
- [14] A. Singh, N. Thakur, and A. Sharma, "A review of supervised machine learning algorithms," 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), 2016, pp. 1310-1315.
- [15] S. Ray, "A Quick Review of Machine Learning Algorithms," 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), 2019, pp. 35-39, doi: 10.1109/COMITCon.2019.8862451.

[16] Introduccion a MCEmax, PdMA Corporation, Hamption Oaks Parkway, Tampa Florida, (2016)