



UNIVERSIDAD
DE PIURA

FACULTAD DE INGENIERÍA

**Análisis y detección de fallas en motores eléctricos
aplicando algoritmos de inteligencia artificial**

Tesis para optar el Título de
Ingeniero Mecánico - Eléctrico

Brayand Alejandro Odar Chero

**Asesor(es):
Mgtr. Ing. Juan Junior Valdiviezo Espinoza**

Piura, setiembre de 2023



Declaración Jurada de Originalidad del Trabajo Final

Yo, Brayand Alejandro Odar Chero, egresado del Programa Académico de Ingeniería mecánico - eléctrica de la Facultad de Ingeniería de la Universidad de Piura, identificado(a) con DNI N° 70489659.

Declaro bajo juramento que:

1. Soy autor del trabajo final titulado:
"Análisis y detección de fallas en motores eléctricos aplicando algoritmos de inteligencia artificial".
El mismo que presento bajo la modalidad de Tesis¹ para optar el Título profesional² de Ingeniero mecánico – eléctrico.
2. Que el trabajo se realizó en coautoría con los siguientes alumnos de la Universidad de Piura.
 - Haga clic o pulse aquí para escribir texto, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto, identificado con DNI N° Escribir número
3. La asesoría del trabajo estuvo a cargo de:
 - Juan Junior Valdiviezo Espinoza, identificado con DNI N° 47107712
 - Haga clic o pulse aquí para escribir texto, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto, identificado con DNI N° Escribir número
4. El texto de mi trabajo final respeta y no vulnera los derechos de terceros o de ser el caso derechos de los coautores, incluidos los derechos de propiedad intelectual, datos personales, entre otros. En tal sentido, el texto de mi trabajo final no ha sido plagiado total ni parcialmente, para la cual he respetado las normas internacionales de citas y referencias de las fuentes consultadas.
5. El texto del trabajo final que presento no ha sido publicado ni presentado antes en cualquier medio electrónico o físico.
6. La investigación, los resultados, datos, conclusiones y demás información presentada que atribuyo a mi autoría son veraces.
7. Declaro que mi trabajo final cumple con todas las normas de la Universidad de Piura.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad de Piura y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Fecha: 18/08/2023.



Firma del autor optante³

¹ Indicar si es tesis, trabajo de investigación, trabajo académico o trabajo de suficiencia profesional.

² Grado de Bachiller, Título profesional, Grado de Maestro o Grado de Doctor.

³ Idéntica al DNI; no se admite digital, salvo certificado.



Dedicatoria

A Dios y la virgen, fuente inagotable de sabiduría y amor.

A María Chero y José Odar, mis pilares, por su guía y apoyo constante.

A Jean Paull, Gianella y Yazid Odar, quienes siempre han estado allí para celebrar cada logro.

A Mónica Pacherras, por su amor y apoyo, esenciales en esta etapa de mi vida.

A Pedro, Rosa, Sergio y Luisa, abuelos cuyo legado han sido la luz en este camino.

A todos mis familiares y seres queridos que han estado conmigo.





Resumen

La Inteligencia Artificial (IA) ha transformado diversos ámbitos de la industria, facilitando la automatización, optimización y, consecuentemente, potenciando la eficiencia de los procesos productivos. Uno de los ámbitos más prometedores de la IA en la industria es el mantenimiento predictivo, caracterizado por la habilidad de prever desviaciones o fallos en maquinarias antes de que estas se manifiesten. Esta anticipación permite una intervención oportuna, reduciendo tiempos muertos y pérdidas económicas asociadas a paradas inesperadas de la producción.

En este contexto, las Redes Neuronales Recurrentes (RNN), y en particular las Long Short-Term Memory (LSTM), se han consolidado como herramientas imprescindibles para estas tareas, gracias a su capacidad para retener y procesar información a lo largo de secuencias extensas, logrando detectar patrones y anomalías que insinúan un posible fallo. No obstante, las LSTM, no están exentas de desafíos puesto que enfrentan dificultades de exactitud y confiabilidad de su modelo cuando se trata de secuencias de datos discontinuas o irregulares. Esto se convierte en un problema en sectores industriales, como el pesquero, donde la producción es por temporadas y la toma de datos no es continua.

Ante este escenario es donde el modelo Red Neuronal de Memoria a Largo Plazo Atencional Multivariante (MA-LSTM) presenta una solución innovadora. Aunque originalmente fue desarrollado para aplicaciones en medicina y finanzas, este modelo se combina con la robustez de las LSTM ofreciendo mecanismos de atención diseñados para manejar datos multivariados. Estos mecanismos permiten que el modelo priorice y preste atención a partes específicas de la entrada según su relevancia, lo que lo hace especialmente apto para lidiar con secuencias irregulares.

Para evidenciar la eficacia del modelo MA-LSTM en un entorno industrial real, se llevó a cabo un estudio en campo con un decantador centrífugo, maquinaria comúnmente utilizada para separar sólidos de líquidos en diversas industrias. Al aplicarlo a este equipo, se pudo demostrar su aptitud para predecir fallas con una precisión considerable, incluso cuando los datos presentaban secuencias discontinuas o irregularidades. Este caso de estudio no solo confirma la idoneidad del MA-LSTM para enfrentar desafíos en contextos industriales específicos, sino que también sugiere su potencial aplicación en otros ámbitos industriales con desafíos similares en el mantenimiento predictivo.




Tabla de contenido

Introducción	15
Capítulo 1 Inteligencia artificial en el análisis de fallas	17
1.1 Fundamentos teóricos.....	17
1.1.1 Motores eléctricos.....	17
1.1.2 Separador decantador centrífugo	24
1.1.3 Inteligencia Artificial: Conceptos, Tecnologías y Aplicaciones.....	28
1.1.4 El mantenimiento industrial y la inteligencia artificial.....	37
Capítulo 2 Evaluación y resultados	43
2.1 Recolección de datos.....	43
2.1.1 Parámetros de interés en fallas de motores eléctricos de decantadores	43
2.1.2 Técnicas de recolección de datos.....	45
2.1.3 Proceso de recolección.....	45
2.1.4 Almacenamiento de datos	49
2.2 Preprocesamiento y análisis de datos.....	50
2.2.1 Preprocesamiento de la base de datos.....	50
2.2.2 Selección de principales variables para el modelo.....	53
2.3 Diseño y entrenamiento del modelo.....	55
2.3.1 Selección del algoritmo de inteligencia artificial.....	55
2.3.2 Diseño de la arquitectura del modelo.....	56
2.3.3 Entrenamiento y ajuste del modelo.....	58
2.4 Evaluación del modelo	63
2.4.1 Métricas de evaluación para confiabilidad del modelo	63
2.5 Pruebas y validación del modelo en un entorno real	65
2.5.1 Comparación con métodos tradicionales de detección de fallas	67
2.5.2 Análisis e interpretación de resultados.....	67
Conclusiones.....	73
Referencias.....	75
Apéndices	81
Anexos.....	95



Lista de tablas

Tabla 1 Principales parámetros para la detección de fallas en motores eléctricos	44
Tabla 2 Parámetros de equipos decantadores centrífugos.....	44
Tabla 3 Variables que pueden ser medidas por sensor WEG Motor Scan	49
Tabla 4 Cantidad de datos por tipos de plantas pesqueras	51
Tabla 5 Ejemplo de base de datos.....	51
Tabla 6 Estructura de base de datos para el modelo	52
Tabla 7 Tabla de prueba de épocas para capa de entrada del modelo	60
Tabla 8 Tabla de prueba de tamaño de lote para el modelo	60
Tabla 9 Tabla de prueba de número de neuronas para capa de entrada del modelo.....	60
Tabla 10 Tabla de prueba de dropout para el modelo.....	61
Tabla 11 Tabla de prueba de activador de capa de salida para el modelo	61
Tabla 12 Tabla de prueba de función de costo para el modelo	62
Tabla 13 Tabla de prueba de optimizador para el modelo	63
Tabla 14 Métricas de modelo LSTM	67
Tabla 15 Métricas de validación de modelo con datos reales	71





Lista de figuras

Figura 1 Clasificación general de las máquinas eléctricas rotativas	17
Figura 2 Partes de un rotor	18
Figura 3 Estator de un motor eléctrico	19
Figura 4 Tipos de motores eléctricos	20
Figura 5 Tipos de desalineamientos.....	21
Figura 6 Fallas en los rodamientos: principales causas.....	22
Figura 7 Factores de separación eficiente.....	25
Figura 8 Tipos de separación.....	26
Figura 9 Partes de un separador centrífugo de sólidos	27
Figura 10 Tipos de aprendizaje automático	29
Figura 11 Representación condensada de las redes neuronales convolucionales.....	32
Figura 12 Estructura de cadena a árbol binario de la RN permite a la red neuronal recursiva extrapolar a partir de secuencias de imágenes y palabras de longitud variable	33
Figura 13 Principales interfaces o cuadernos para Python.....	34
Figura 14 Lenguajes de programación	35
Figura 15 Estrategias de mantenimiento	37
Figura 16 Metodologías de optimización de mantenimiento industrial.....	38
Figura 17 Análisis de parámetros operativos con sensores.....	41
Figura 18 Decantador centrífugo Z73	44
Figura 19 Flujo de adquisición, procesamiento y generación de diagnóstico de datos	45
Figura 20 Parámetros de motor eléctrico de decantador Flottweg Z 73-4/454.....	46
Figura 21 Parámetros de motor WEG 400/690V	46
Figura 22 Distancias para fijación del sensor	47
Figura 23 Dimensión de M en mm	47
Figura 24 Sensor fijado en el motor	47
Figura 25 Ejemplo del antes y después del periodo de aprendizaje.....	48
Figura 26 Flujo de adquisición de parámetros operacionales	49
Figura 27 Primer bosquejo de flujo de datos para creación de modelo y validación de este .	51
Figura 28 Histograma de los sensores.....	52

Figura 29 División de valores de muestra a predecir	54
Figura 30 Diagrama de Flujo de Proyecto: "Análisis de fallas de motor eléctrico de decantadores centrífugos en el rubro pesquero" – Etapa: Estructura del modelo.....	56
Figura 31 Ejemplo de funcionamiento de padding	57
Figura 32 Estructura de MA-LSTM	59
Figura 33 Parámetros óptimos de Red Neuronal MA-LSTM	63
Figura 34 ROC de modelo para predicción de fallas	65
Figura 35 Flujo de ingreso a modelo de predicción	66
Figura 36 Estructura de LSTM para predicción de fallas con sensores	67
Figura 37 Resultado de matriz de confusión de base de datos M4 con modelo MA-LSTM	68
Figura 38 Resultado de matriz de confusión de base de datos M4 con modelo LSTM	69
Figura 39 Resultado de matriz de confusión de base de datos M5 con modelo MA-LSTM	70
Figura 40 Resultado de matriz de confusión de base de datos M5 con modelo LSTM	71



Introducción

En el dinámico mundo industrial contemporáneo, los procesos de producción y manufactura han alcanzado niveles de complejidad nunca vistos, llevando a las organizaciones a depender en gran medida de la eficiencia y funcionalidad de sus equipos y maquinarias. Sin embargo, con el aumento de esta complejidad, también ha crecido el desafío de mantener estos sistemas operativos y libres de fallos, un aspecto crucial para asegurar la continuidad y rentabilidad de las operaciones.

Aunque la tecnología ha avanzado significativamente, y se han desarrollado múltiples estrategias para prever y detectar fallos en estos sistemas, todavía existen brechas significativas que impiden una predicción precisa en determinados escenarios, especialmente en aquellos sectores donde la producción no es continua o es influenciada por múltiples variables incontrolables. Esta incapacidad no solo representa pérdidas económicas, sino que puede poner en riesgo la integridad de los equipos y la seguridad de los operarios. Ante este panorama, la presente investigación busca explorar y proponer soluciones innovadoras que permitan abordar estas problemáticas, aprovechando las últimas tendencias y avances en inteligencia artificial y análisis de datos.

Una de las alternativas emergentes es el modelo MA-LSTM (Red Neuronal de Memoria a Largo Plazo Atencional Multivariante), anteriormente utilizado en campos como la medicina y las finanzas, y que promete una adaptabilidad superior en escenarios con secuencias de datos irregulares. La aplicación y potencial de este modelo en entornos industriales, será el eje central de la presente investigación. Con ello, se espera contribuir y validar metodologías que permitan a la industria adaptarse y responder eficazmente ante las variaciones y desafíos propios de su operación.



Capítulo 1

Inteligencia artificial en el análisis de fallas

En los últimos años, la inteligencia artificial (IA) se ha desarrollado muy rápidamente, revolucionando diversas áreas de la sociedad y cambiando la forma en que interactuamos con la tecnología. Una de las aplicaciones más prometedoras de la IA es el análisis de fallas, donde su capacidad para procesar grandes volúmenes de datos y encontrar patrones ocultos ha abierto nuevas oportunidades para mejorar el rendimiento y confiabilidad de los sistemas.

1.1 Fundamentos teóricos

1.1.1 Motores eléctricos

En tecnología e ingeniería, los motores eléctricos son fundamentales en la conversión de energía eléctrica a mecánica, lo que lleva a su aplicación en diversos sectores industriales. Estos dispositivos electromecánicos han revolucionado la forma en que funcionan los sistemas y las máquinas, logrando avances significativos en rendimiento, eficiencia y sostenibilidad.

La demanda creciente de sistemas energéticamente eficientes y respetuosos con el medio ambiente ha impulsado el constante desarrollo y mejoramiento de los motores eléctricos a lo largo del tiempo. Desde los primeros motores de corriente continua hasta los modernos motores de corriente alterna, se ha logrado mejorar la eficiencia al reducir las pérdidas de energía y aumentar la densidad de potencia. A continuación, se muestra en la Figura 1 de la clasificación de los motores.

Figura 1

Clasificación general de las máquinas eléctricas rotativas

Máquina eléctrica \ Tipo de corriente	Corriente continua	Corriente alterna
Generadores	Dinamo (con excitación) <ul style="list-style-type: none"> Independiente Serie Shunt o derivación Compound 	Alternador <ul style="list-style-type: none"> Monofásico Trifásico Polos lisos Polos salientes
Motores	Motor (con excitación) <ul style="list-style-type: none"> Independiente Serie Shunt o derivación Compound 	<ul style="list-style-type: none"> Monofásicos <ul style="list-style-type: none"> Inducción <ul style="list-style-type: none"> Jaula <ul style="list-style-type: none"> Fase partida Condensador Espira de sombra Rotor devanado <ul style="list-style-type: none"> Repulsión Repulsión en arranque Repulsión-inducción Síncrono <ul style="list-style-type: none"> Histéresis Reluctancia Imán permanente Polifásicos <ul style="list-style-type: none"> Inducción <ul style="list-style-type: none"> Jaula de ardilla Rotor devanado Universales <ul style="list-style-type: none"> Síncronos

Nota. Tomado de (Guerrero, Sánchez, Moreno, & Ortega, 2003)

1.1.1.1 Principales componentes. Para entender mejor el principio de funcionamiento es importante saber que los motores constan de varias partes fundamentales que trabajan en conjunto para lograr un funcionamiento eficiente y confiable.

En su forma más básica, un motor eléctrico consta de dos componentes principales: el estator y el rotor. En este marco, es importante mencionar los conceptos descritos por Hughes y Drury (2019):

- Rotor: El rotor es una parte importante de un motor eléctrico y se encuentra en la parte móvil del dispositivo. Es responsable de convertir la energía eléctrica generada en el estator en movimiento mecánico. Para el diseño y la construcción del rotor cuenta con diferentes partes, como se puede ver en Figura 2, y estos tienen un impacto significativo en el rendimiento y la eficiencia del motor eléctrico.

Figura 2

Partes de un rotor



Nota. Tomado de (ComoFunciona, 2020)

También hay que considerar que hay varios tipos de rotores usados en diferentes tipos de motores eléctricos. Algunos de los tipos más comunes son:

- Rotor de jaula de ardilla: utilizado en motores de inducción o asíncronos. Consiste en barras conductoras cortocircuitadas en ambos extremos por anillos, lo que da la apariencia de una jaula de ardilla.
- Rotor de bobinas enrolladas: se utiliza en corriente continua (DC) o en algunos motores de corriente alterna (AC) de velocidad variable. Consiste en bobinas de alambres enrolladas alrededor de un núcleo, similar al estator.
- Rotor de imán permanente: se utiliza en motores DC sin escobillas y en algunos motores AC. Este tipo de rotor contiene imanes permanentes que generan el campo magnético necesario para accionar el motor.

En el caso de un rotor de jaula de ardilla y de bobinas enrolladas, el campo magnético generado por el estator induce corriente en el rotor. Estas corrientes crean un campo

magnético secundario que interactúa con el campo magnético del estator, haciendo que el rotor se mueva. En un rotor de imán permanente, los imanes del rotor crean un campo magnético constante que interactúa con el campo magnético giratorio del estator para producir movimiento. El diseño y la selección del tipo de rotor correcto depende de la aplicación específica del motor. La eficiencia, el par de arranque y la velocidad de funcionamiento son importantes para considerar al elegir el tipo de rotor.

Asimismo, otra parte importante del motor es el estator. Según los autores Wu & El-Refai (2019):

- El estator es una parte fundamental de las máquinas eléctricas como se puede apreciar en la Figura 3, incluyendo los motores y generadores. Es una estructura estacionaria con varias capas de laminaciones apiladas, utilizadas para reducir las pérdidas por corrientes de Foucault y las de por histéresis, lo que mejora la eficiencia del motor. Además, ayudan a dirigir el flujo magnético a través del estator, optimizando la generación del campo magnético. El estator puede tener diferentes configuraciones de devanados, por ejemplo, el estator de reluctancia variable, que utiliza un diseño vernier para mejorar la eficiencia y el torque. Además, se han investigado materiales avanzados como los superconductores de alta temperatura para mejorar el rendimiento del estator y reducir las pérdidas de energía.

Figura 3

Estator de un motor eléctrico



Nota. Tomado de (Wu & El-Refai, 2019)

1.1.1.2 Principio de funcionamiento. Comprender cómo funciona un motor eléctrico es importante para apreciar su importancia y descubrir las múltiples formas en que se puede utilizar en nuestra sociedad. En el libro del autor Chapman (2012), hace referencia sobre el principio de funcionamiento de los motores eléctricos y la base para comprender cómo estas máquinas convierten la energía eléctrica en energía mecánica. En este sentido, es útil tener en cuenta la distinción que hace:

En general, un motor eléctrico se basa en la interacción entre un campo magnético y una corriente eléctrica para producir un movimiento de rotación. El principio de funcionamiento de un motor eléctrico se basa en la ley de Faraday y la ley de Lenz, que establece que un cambio en el flujo magnético induce una corriente eléctrica en un conductor. Existen diferentes tipos de motores eléctricos, pero uno de los más comunes es el motor de inducción de corriente alterna (AC).

Este tipo de motor consta de dos componentes principales: el estator y el rotor. En un motor eléctrico, el campo magnético giratorio del estator induce una corriente eléctrica en el rotor, que a su vez crea un campo magnético en el rotor. Estos campos magnéticos interactúan entre sí y producen un par motor que controla el movimiento.

Cabe señalar que existen otros tipos de motores eléctricos como se observa en Figura 4, que incluyen motores de corriente continua (DC), motores de corriente alterna (AC) monofásicos y trifásicos, motores síncronos, motores asíncronos o de inducción, que funcionan de formas ligeramente diferentes. Sin embargo, siempre la interacción del campo magnético y la corriente es necesaria para el funcionamiento del motor eléctrico.

Figura 4

Tipos de motores eléctricos



Nota. Tomado de (Potenciahp, 2019)

1.1.1.3 Fallas más comunes en motores eléctricos. Debido a que los motores eléctricos juegan un papel importante en una amplia gama de aplicaciones industriales, comprender sus fallas comunes es fundamental para adoptar una estrategia de mantenimiento y conocer la causa raíz de una falla puede ayudar a los técnicos y operadores a aplicar prácticas adecuadas de mantenimiento predictivo y/o preventivo para minimizar el riesgo de falla y aumentar la vida útil del motor. Considerando lo previamente expuesto y según lo indicado por Llacua (2020):


Las principales fallas en los motores eléctricos de inducción se pueden clasificar en cuatro categorías: fallas por desalineamiento, fallas del rodamiento, fallas del estator y fallas

de excentricidad. Estas fallas son causadas por diferentes factores y pueden tener diferentes consecuencias en el rendimiento y vida útil del motor (págs.39-40).

- Fallas por desalineamiento: Es la falla más común de los motores eléctricos que ocurre cuando el eje impulsor del motor o las piezas del acoplamiento no están correctamente alineados con la carga. Esto provoca una transferencia de esfuerzos mecánicos, aumentando el desgaste y la carga mecánica aparente en el motor. La desalineación se puede dividir en tres tipos: paralela, angular o combinada. Para mayor entendimiento de las 3 podemos referenciarlos de la Figura 5. El desalineamiento afecta a la capacidad de producción, acorta la vida útil, así como la eficiencia de los equipos y aumenta el uso de energía eléctrica. Es recomendable realizar seguimiento a los factores de vibración y temperatura del equipo para evitar este tipo de fallos.

Figura 5

Tipos de desalineamientos



Nota. Tomado de (Tractian, 2021)

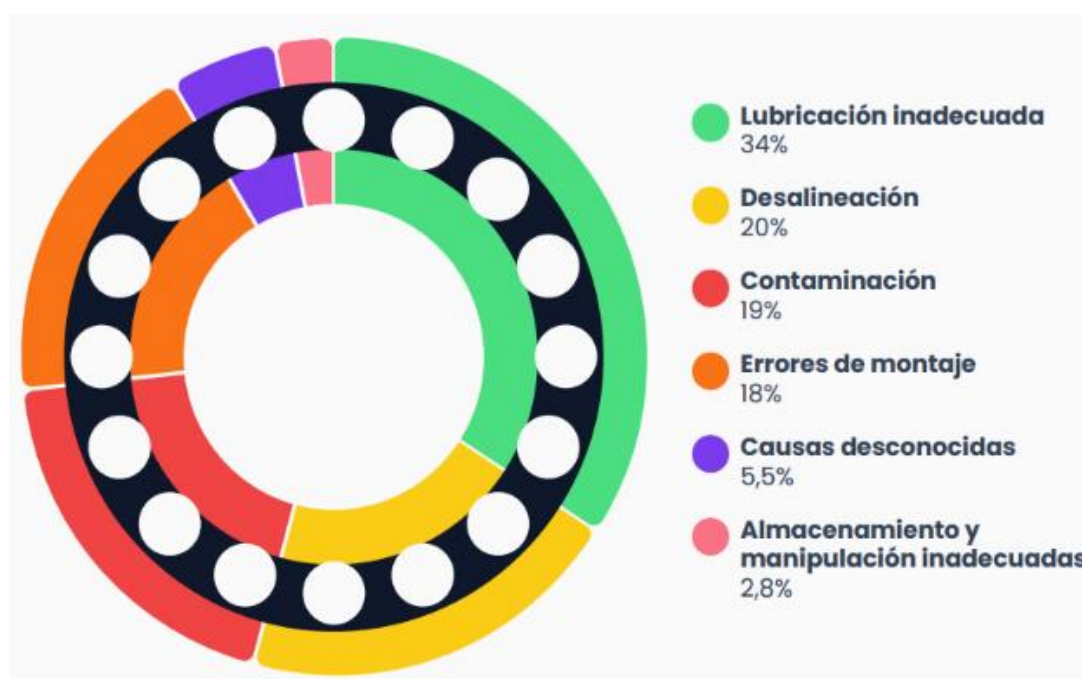
- Falla en rodamientos: Se estima estadísticamente que es la segunda falla con mayor presencia cuando hablamos de motores eléctricos. Los rodamientos aseguran un movimiento suave y preciso de las partes móviles, reduciendo la fricción y soportando las cargas generadas durante la operación. Un dato que destacar de la investigación de Dong et al. (2021) es que “la pista interior o exterior es responsable de alrededor del

90% de los fallos de los rodamientos, mientras que el elemento rodante o la jaula lo son del 10% restante” (págs.1-2).

Cuando los rodamientos son un problema, pueden producirse ruidos inusuales, vibraciones e incluso bloqueos. Esto puede hacer que el motor se pare por completo. Es crucial realizar un mantenimiento adecuado de los rodamientos, asegurándose de engrasarlos a menudo y de utilizar lubricantes de alta calidad, para evitar este tipo de fallos. También es fundamental vigilar la temperatura de los rodamientos, ya que un aumento brusco de la misma podría indicar un mal funcionamiento. Como tales, los rodamientos son un elemento clave para garantizar la eficiencia, la fiabilidad y la durabilidad de los motores. Las principales fallas en estos componentes se presentan a continuación en la Figura 6.

Figura 6

Fallas en los rodamientos: principales causas



Nota. Tomado de (Tractian, 2021)

- Fallas del estator: Otro aspecto crucial de los motores eléctricos es el aislamiento del bobinado, y cuando éste se degrada, el funcionamiento del motor puede verse afectado considerablemente. Una de las causas más frecuentes de esta avería es la rotura del aislamiento del bobinado y están muy relacionadas a factores de sobrecarga mecánica o térmica, como la exposición a altas temperaturas, humedad, vibraciones extremas o materiales corrosivos.

- La sobrecarga ocurre cuando el motor está sujeto a una demanda mayor que el par nominal, lo que resulta en una corriente de funcionamiento superior a la normal, causando un sobrecalentamiento. Esto acorta la vida del motor y, dependiendo del grado de sobrecarga, el sistema de protección del motor puede dispararse y la máquina detenerse bruscamente. Algunos síntomas de sobrecarga del motor son sobrecarga de corriente y par insuficiente. El enorme calor generado por el sobrecalentamiento causa un desgaste prematuro en el motor y sus componentes mecánicos, lo que puede conllevar a fallas permanentes.

Como recomendación, para evitar este tipo de averías, es fundamental realizar inspecciones periódicas del aislamiento del bobinado mediante técnicas de ensayo no destructivas, como las pruebas de resistencia del aislamiento. Además, es necesario evitar las condiciones climáticas adversas y tomar medidas para prevenir el motor de la corrosión y la humedad.

- Falla de excentricidad: El fallo por excentricidad del motor eléctrico es un suceso común que puede dar lugar a varios tipos de problemas, como fallos de aislamiento entre vueltas, cortocircuitos entre fases y cortocircuitos en la carcasa. También es importante mencionar que “El juego radial en los rodamientos y la desalineación del rotor son dos explicaciones de las razones por las que puede producirse la excentricidad” (Prudnikov, 2023, págs. 1-2).

Se han diseñado varios métodos para diagnosticar la excentricidad. Uno de ellos se basa en el estudio de la velocidad del rotor, donde el parámetro de diagnóstico que se utiliza es la amplitud de la desviación de la velocidad del rotor. Otro método, el cual se menciona en la publicación de Antonino-Daviu et al. (2018) consiste en “vigilar valores eléctricos como las corrientes del motor, que podrían proporcionar detalles sobre el estado de varias piezas del motor como el rotor y la excentricidad” (págs.3934-3936).

Las sobretensiones de alta energía en la señal del inversor pueden permitir el desarrollo de descargas parciales en los devanados de baja tensión del motor, lo que podría acelerar la rotura del aislamiento eléctrico. Además, los errores de excentricidad en los diseños de los motores eléctricos pueden provocar una mayor ondulación del par y una tracción magnética desproporcionada.

En su investigación Bessous (2017) menciona los defectos de excentricidad de los motores eléctricos y cómo pueden identificarse mediante diversos enfoques, como la transformada de ondícula discreta (DWT), el análisis de la firma de corriente del motor (MCSA) y el análisis de la firma de vibración del motor (MVSA). Aunque los enfoques más recientes basados en el análisis de transitorios (ATCSA) son cada vez más populares debido a su capacidad para proporcionar indicaciones tempranas de las asimetrías eléctricas del rotor en condiciones de velocidad variable, los enfoques tradicionales basados en el análisis de las

corrientes del motor durante el funcionamiento en estado estacionario (MCSA) también se siguen utilizando con frecuencia.

1.1.2 Separador decantador centrífugo

Los decantadores centrífugos son una forma sencilla y rentable de separar las fases sólida y líquida de un producto. Esta máquina realiza la separación mediante tambores de alta velocidad y puede utilizarse para una gran variedad de industrias y procesos. Gracias a su versátil configuración, el decantador centrífugo puede funcionar automáticamente con control táctil PLC y HMI. Además, mediante la regulación de la velocidad de alimentación de sólidos, puede lograr una adecuada humedad de los sólidos a diferentes cargas de sólidos totales (%SST). El principio o concepto que separa las fases sólida y líquida es la alta fuerza centrífuga. Este subcapítulo discutirá los principios operativos de los decantadores centrífugos y explorará sus aplicaciones en diversas industrias.

1.1.2.1 Principios básicos de sedimentación. Poder separar los componentes de una mezcla es crucial en muchas industrias, sobre todo en el procesamiento de harina de pescado, alimentos, fabricación de productos farmacéuticos, purificación del agua, producción de petróleo y gas, y algunas más. La sedimentación es una de las estrategias más eficaces para lograr dicha separación. Sin embargo, para entender correctamente su utilidad y potencial, se debe comprender los principios fundamentales que subyacen a este fenómeno.

- Separación por sedimentación gravitacional: es uno de los métodos más básicos en la separación de fases, convirtiéndolo en una opción sencilla y económica para las industrias, ya que su principio depende de la fuerza de gravedad. Las partículas sólidas, que suelen ser más densas que el líquido, empezarán a hundirse en el fondo del recipiente con el tiempo debido a la fuerza de la gravedad y al mismo tiempo, el líquido menos denso subirá a la superficie.

La rapidez con que una partícula puede sedimentarse está definida por la Ley de Stokes descrita a continuación en la Ecuación 1:

$$V_g = \frac{d^2(\rho_p - \rho_l)}{18\eta} * g \quad [1]$$

Donde:

V_g : Velocidad de Decantación

ρ_p : Densidad de la partícula

ρ_l : Densidad del Líquido

η : Viscosidad del Líquido

g : Aceleración de la Gravedad

d : Diámetro de la Partícula

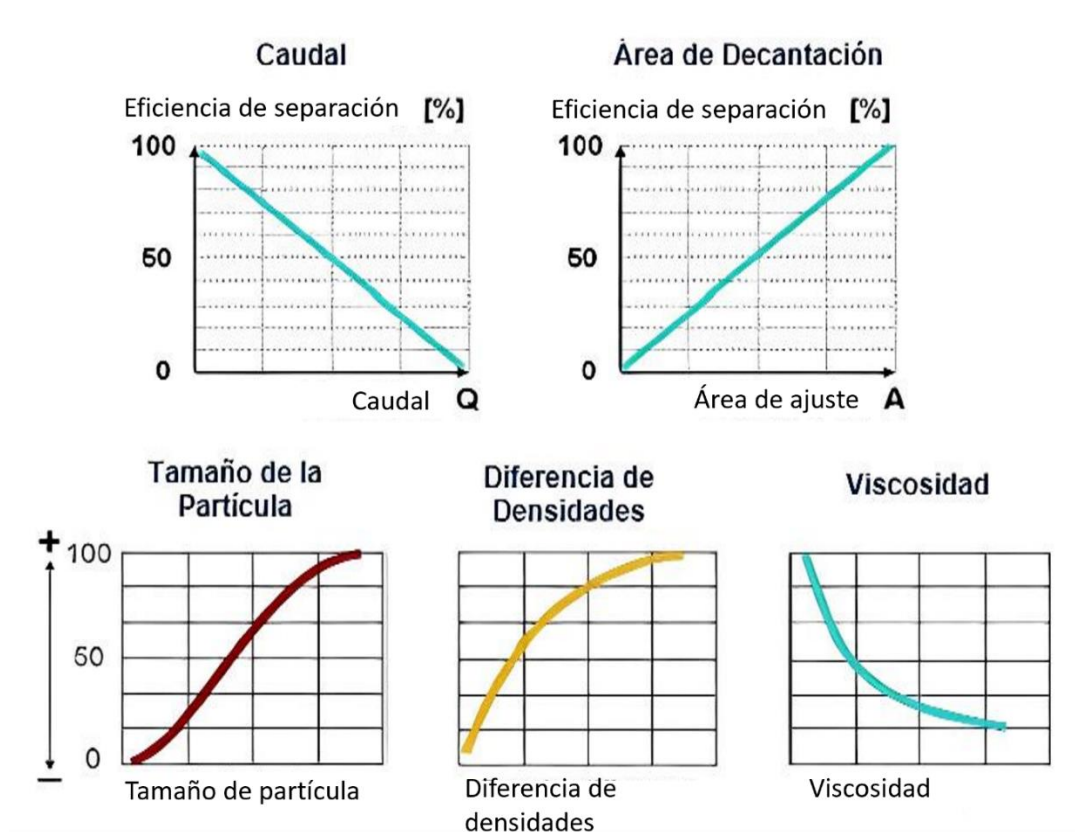
Es importante destacar los siguientes factores, mostrados en la Figura 7, que intervienen en la ecuación de Stokes, como:

Densidad de fase, similar a la separación centrífuga, la diferencia de densidad entre las fases de la mezcla afecta la eficiencia de separación. Cuanto mayor es la diferencia de densidad, más rápido se produce la sedimentación. Tamaño de partícula, debido a que las partículas más grandes se asientan más rápido debido a una mayor inercia. En mezclas con partículas muy finas, la deposición puede ser muy lenta. Viscosidad del fluido, puesto que un líquido puede afectar la velocidad a la que se asientan las partículas. En líquidos más viscosos, la resistencia al movimiento de partículas es mayor, lo que ralentiza el proceso de deposición.

Finalmente, otro factor importante es el tiempo asignado para la liquidación. Cuanto más tiempo repose la mezcla, más completa será la separación.

Figura 7

Factores de separación eficiente



Nota. Tomado de (Christoffersen, 2013)

- Separación por sedimentación centrífuga: La separación de partículas de un fluido empleando la fuerza centrífuga es conocido como sedimentación centrífuga. Esta técnica se utiliza en diversos sectores, como el tratamiento de aguas residuales, la extracción de gas y petróleo y sobre todo la pesca y minería. En un proceso de sedimentación centrífuga, la mezcla se introduce en un recipiente, como una

centrifugadora, que gira a gran velocidad. La fuerza centrífuga generada por la rotación acelera la sedimentación de las partículas más densas hacia las paredes del recipiente.

El proceso de sedimentación centrífuga se rige por la ecuación del movimiento de las partículas en un campo centrífugo, tomando como base la ecuación de Stokes, pero en una sedimentación centrífuga la aceleración de la gravedad es suplantada por la aceleración centrífuga generada por una velocidad de giro como se puede observar en la Figura 8. De igual forma en la Ecuación 2 se detalla la expresión matemática:

$$V_g = \frac{d^2(\rho_p - \rho_l)}{18\eta} * r\omega^2 \quad [2]$$

Donde:

V_g : Velocidad de decantación


r: Radio de giro

ω : Velocidad de giro

d: Diámetro de la partícula

Figura 8

Tipos de separación



Nota. Tomado de (Nilsson, Sjöberg, & Widén, 2007)

1.1.2.2 Principios de funcionamiento de un separador centrífugo. Los avances tecnológicos en la separación de componentes de una mezcla han permitido a numerosas industrias incrementar su eficiencia y productividad. Un componente clave en este panorama es la separadora centrífuga, un dispositivo que permite realizar una separación bifásica utilizando el principio de sedimentación centrífuga. Para describir el proceso de separación es conveniente mencionar a Menesklou et al. (2021):

La separadora funciona de forma continua y se basa en introducir la mezcla en una tubería de alimentación que transporta un lodo con una fracción volumétrica de sólidos y un

caudal volumétrico definidos al tambor de la centrifugadora, que gira con una velocidad de rotación específica (pág.5).


En tal sentido y complementando lo expuesto anteriormente los mismos autores, Menesklou et al. (2021), en otra investigación mencionan lo siguiente:

El recipiente es accionado por un motor y gira a gran velocidad, generando una fuerza centrífuga que hace que las partículas sólidas más densas se depositen en la pared interior del recipiente. A continuación, los sólidos sedimentados se transportan hacia el extremo cónico de la cuba mediante un transportador de tornillo helicoidal, mientras que el líquido clarificado se extrae por la salida del centrifugado. Este proceso de sedimentación, consolidación de sedimentos y transporte de sedimentos tiene lugar en el canal de tornillo helicoidal de la centrifugadora decantadora (págs.3-4).

En la Figura 9 se observan las principales partes que componen a un separador centrifugo.

Figura 9

Partes de un separador centrifugo de sólidos



Nota. Tomado de (Alfa Laval, 2019)

Se pueden identificar dos zonas principales a lo largo del tornillo: la laguna es la zona donde predomina la fase líquida de separación y una fase intermedia de sólidos - agua, la playa es la zona donde se concentra la mayor cantidad de sólidos separados por el equipo. La fuerza centrífuga hace que los sólidos en suspensión se vayan depositando en la parte inferior del rotor. El tornillo transportador va transportando esos sólidos continuamente hacia la parte cónica del rotor (playa). La separación de los sólidos tiene lugar a todo lo largo de la parte cilíndrica del rotor y el líquido clarificado sale por su extremo de mayor diámetro por desbordamiento a través de salidas ajustables en diámetro(laguna). Durante el control del proceso identificamos diferentes variables principales, como:

- Torque de Trabajo: Impactado por la concentración de sólidos acumulados en la playa del equipo.
- Velocidad de Bowl: Permite decantar los sólidos depositados en la parte interior del rotor.

- Velocidad Diferencial: Determinada principalmente por la diferencia de velocidad entre el bowl y el tornillo.

La velocidad diferencia y el torque de trabajo están directamente relacionadas. Un incremento en el torque de trabajo refleja el aumento de concentración de sólidos en la playa (menor humedad). Al incrementar la velocidad diferencial, las RPM del tornillo disminuyen y el flujo de sólidos sedimentados son dirigidos a la playa con menor rapidez permitiendo descargar los sólidos concentrados y disminuyendo el torque de trabajo.

1.1.3 Inteligencia Artificial: Conceptos, Tecnologías y Aplicaciones

La inteligencia artificial (IA) es una disciplina en rápido desarrollo que abarca un amplio abanico de ciencias, tecnologías y aplicaciones. Se utiliza para construir sistemas capaces de copiar habilidades humanas como el aprendizaje, la toma de decisiones, el procesamiento del lenguaje natural y la visión por computador. La inteligencia artificial permite a las empresas procesar y analizar grandes volúmenes de datos, extrayendo conclusiones valiosas que potencian la rentabilidad en diversos sectores y operaciones. En este contexto, es fundamental comprender los conceptos fundamentales y la tecnología que hay detrás de la IA, así como sus aplicaciones en los diferentes sectores y áreas de las industrias.

1.1.3.1 Definición de inteligencia artificial. Actualmente hay muchos debates sobre el significado de la Inteligencia artificial (IA), puesto que no existe una definición única y consensuada de este término. Sin embargo, los autores definen la IA como "la frontera de los avances computacionales que hacen referencia a la inteligencia humana a la hora de abordar problemas de toma de decisiones cada vez más complejos" (Berente, Gu, Recker, & Santhanam, 2021, págs. 2-3). No obstante, es ideal rescatar también la descripción del autor Helm et al. (2020), el cual comenta que:

La inteligencia artificial (IA) se refiere al desarrollo de sistemas informáticos capaces de realizar tareas que normalmente requieren inteligencia humana, como la percepción visual, el reconocimiento del habla, la toma de decisiones y la traducción de idiomas. Los sistemas de IA pueden aprender de la experiencia y mejorar su rendimiento con el tiempo mediante el uso de algoritmos y modelos estadísticos (págs.1-2).

Por lo tanto, la Inteligencia Artificial, en su amplio espectro, se destaca como una disciplina que busca no solo emular la capacidad cognitiva humana, sino optimizar procesos, solucionar problemas complejos y abrir nuevas vías de exploración en diversos campos. La IA, es una herramienta que se moldea y adapta de acuerdo con las necesidades humanas y los desafíos que enfrenta la sociedad en la era de la información.

1.1.3.2 Ramas y disciplinas de la inteligencia artificial. El entendimiento de los componentes nos permitirá tener una noción más concreta de cómo la IA logra sus tareas, desde procesamiento de datos hasta toma de decisiones y aprendizaje autónomo. Del mismo modo, al adentrarnos en cada componente, podremos conocer más el potencial de la IA.


- Aprendizaje Automático (Machine Learning): El Aprendizaje Automático o Machine Learning (ML) es una disciplina fundamental dentro de la Inteligencia Artificial (IA). Como afirma el autor Cynthia et al. (2022), “El propósito de ML es permitir a los sistemas informáticos aprender y perfeccionarse con la experiencia, sin requerir una programación específica. Es decir, estos algoritmos identifican patrones y realizan predicciones basadas en datos” (págs.4-11). Esto significa que las aplicaciones de ML son vastas, y pueden abarcar desde el reconocimiento de imágenes hasta el procesamiento del lenguaje natural, pasando por la detección de fraudes y los sistemas de recomendación.

Así mismo, “el ML implica el uso de algoritmos y modelos estadísticos que permiten a los sistemas informáticos llevar a cabo tareas que normalmente requerirían de inteligencia humana, como el reconocimiento de patrones y la toma de decisiones” (Helm, 2020, págs. 1-2). Los sistemas de ML mejoran su rendimiento con el tiempo, a medida que se les proporcionan más datos de entrada y salida. De acuerdo con el autor Janiesch, Zscheck, & Heinrich (2021), “este proceso de aprendizaje a partir de datos específicos del problema para automatizar la construcción de modelos analíticos es una descripción precisa de cómo funciona el aprendizaje automático” (pág.2). En resumen, el aprendizaje automático es una metodología para entrenar sistemas con aprendizaje de los datos, lo que les permitirá construir modelos analíticos y resolver las tareas asociadas a detectar patrones sutiles y tendencias complejas.

En el campo del aprendizaje automático, existen tres tipos de aprendizaje, como en la Figura 10 que son la base de muchos algoritmos y aplicaciones en uso hoy en día: el aprendizaje supervisado, el no supervisado y el aprendizaje por refuerzo.

Figura 10

Tipos de aprendizaje automático



Nota. Tomada de (Sarker, 2021)

- El aprendizaje supervisado es un tipo de aprendizaje automático que implica entrenar un modelo con datos etiquetados. En este contexto, los datos etiquetados son aquellos en los que la salida o resultado correcto ya es conocido. De acuerdo con Sarker (2021), “este modelo utiliza la información aprendida de los ejemplos previamente etiquetados para realizar predicciones precisas sobre nuevos datos” (pág.3). Asimismo, el autor Janiesch et al. (2021) refuerza la idea al señalar que, “una vez entrenado el modelo, este se utiliza para hacer predicciones sobre datos no etiquetados” (pág.3). En ambos casos, el objetivo es crear un modelo que pueda generalizar bien a partir de los datos de entrenamiento y hacer predicciones precisas en datos no vistos.

Los usos del aprendizaje supervisado son amplios y variados. Por un lado, se menciona que “el aprendizaje supervisado se utiliza comúnmente para tareas de clasificación y regresión, como la clasificación de imágenes o la predicción de precios de viviendas” (Sarker, 2021, pág. 4). Por otro lado, Janiesch et al. (2021) aporta más ejemplos de uso en diversas áreas, como la detección de fraudes, la puntuación crediticia, el reconocimiento de voz e imagen, y el procesamiento del lenguaje natural. A pesar de su utilidad, es importante tener en cuenta, como señala Sarker (2021), “el aprendizaje supervisado requiere de grandes cantidades de datos etiquetados para el entrenamiento de modelos precisos, y puede no ser adecuado para tareas en las que no hay datos etiquetados disponibles” (pág.4).

En resumen, el aprendizaje supervisado utiliza datos de entrada junto con salidas deseadas para entrenar un modelo que pueda predecir las etiquetas correctas para nuevas instancias de datos. Como resultado, proporciona una base sólida para el desarrollo de modelos de aprendizaje automático precisos y efectivos.

- El segundo tipo principal de aprendizaje, el aprendizaje no supervisado, es un tipo de aprendizaje automático que no depende de etiquetas previas para encontrar patrones y estructuras en los datos. Según Ray (2019), “el algoritmo se encarga de agrupar los datos en diferentes clúster o categorías sin ninguna información sobre las categorías o clases a las que pertenecen”. De igual manera, el autor Janiesch (2021) agrega que este enfoque se utiliza para descubrir información útil y estructuras ocultas en los datos. En ambos casos, el algoritmo intenta extraer características significativas y establecer relaciones entre los datos sin tener ningún conocimiento previo sobre los resultados o etiquetas.

El aprendizaje no supervisado puede proporcionar un panorama más detallado, “resaltando la importancia de esta técnica en los mercados electrónicos para segmentar a los clientes en grupos específicos y personalizar la comunicación. También menciona que se puede usar en la minería de datos, detección de anomalías, y compresión de datos” (Janiesch et al., 2021, pág. 3). Sin embargo, según Ray (2019) es importante recordar que “el aprendizaje no supervisado puede tener algunas limitaciones, como la dificultad para evaluar la calidad de los resultados obtenidos” (pág.5).

- El aprendizaje por refuerzo es un tipo de aprendizaje que “permite a los modelos aprender a través de la interacción con un entorno. Su implementación puede ser complicada en contextos complejos y dinámicos y puede requerir grandes cantidades de tiempo y recursos para entrenar modelos precisos” (Sarker, 2021, pág. 4). Cabe resaltar lo mencionado por Ray (2019), “la naturaleza interactiva de esta forma de aprendizaje, donde un agente se entrena para tomar decisiones en un entorno particular, siendo recompensado o castigado según las acciones que lleva a cabo, con el objetivo final de maximizar la recompensa obtenida” (pág.4).

Por otro lado, Janiesch et al. (2021) y Mahesh (2019) extiende esta descripción al contextualizarla en un escenario de aplicación real:

En los mercados electrónicos el aprendizaje se emplea para optimizar la toma de decisiones y maximizar los beneficios. Asimismo, se destaca la experiencia y la retroalimentación del entorno como elementos clave en este tipo de aprendizaje, con el objetivo de hallar la mejor política de acción que maximice la recompensa total a largo plazo (pág.3). Además, aporta una amplia variedad de aplicaciones, que incluyen robótica, juegos, control de procesos y publicidad en línea (pág.5).

- Aprendizaje Profundo (Deep Learning): El aprendizaje profundo, o "deep learning", es una subdisciplina avanzada de la inteligencia artificial que imita el funcionamiento del cerebro humano para procesar datos, crear patrones y tomar decisiones con precisión. Se basa en redes neuronales artificiales de múltiples capas y gran capacidad para aprender y mejorar en tareas específicas a partir de grandes volúmenes de datos. Sin embargo, la implementación del aprendizaje profundo presenta desafíos significativos, incluyendo la necesidad de vastos conjuntos de datos y el manejo de la complejidad de las redes neuronales.

Para comprender mejor este tipo de aprendizaje es conveniente citar a los autores australianos Alzubaidi et al. (2021):

Es una técnica de aprendizaje que emplea redes neuronales artificiales para aprender y mejorar en tareas específicas. Este método ha demostrado su eficacia en diversas aplicaciones como el reconocimiento de voz, la visión por computadora y el procesamiento del lenguaje natural. La base de esta técnica radica en el hecho de que las redes neuronales pueden aprender a partir de grandes cantidades de datos y mejorar su rendimiento conforme se les proporciona más información. Sin embargo, también se destacan ciertos desafíos asociados a esta técnica, como la necesidad de grandes cantidades de datos y la complejidad inherente de las redes neuronales (págs.1-2).

En el mismo sentido, se debe señalar también a Mazurowski et al. (2019):

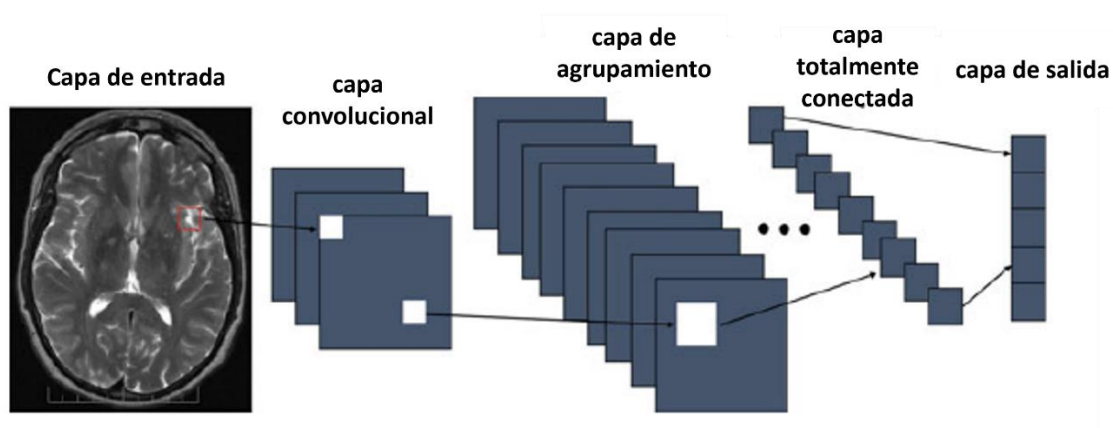
Los algoritmos de aprendizaje profundo son capaces de aprender a partir de grandes volúmenes de datos, en lugar de depender de instrucciones preprogramadas. Este texto pone en relieve el éxito notable de estos algoritmos en los últimos años, en tareas que van desde la localización y clasificación de objetos en imágenes hasta la comprensión del lenguaje y el desempeño en juegos (págs.1-2).

Las redes neuronales (RN) son modelos de aprendizaje automático inspirados en la estructura y funcionamiento del cerebro humano, tal como se ilustra en la Figura 11. De igual forma, es importante mencionar a los autores Witold & Shyi-Ming (2020), quienes destacan que:

Existen diferentes arquitecturas de aprendizaje profundo, incluyendo redes neuronales convolucionales, redes neuronales recurrentes y redes neuronales pre entrenadas no supervisadas. Cada una de estas arquitecturas tiene sus propias características y se utiliza para diferentes tareas de aprendizaje profundo (pág.18).

Figura 11

Representación condensada de las redes neuronales convolucionales




Nota. Tomado de (Witold & Shyi-Ming, 2020)

Por otra parte, en la Figura 12 los autores del libro presentan la arquitectura básica de una red neuronal profunda y la describen de la siguiente forma:

Figura 12

Estructura de cadena a árbol binario de la RN permite a la red neuronal recursiva extrapolar a partir de secuencias de imágenes y palabras de longitud variable



Nota. Tomado de (Witold & Shyi-Ming, 2020)

Las redes neuronales constan de una capa de entrada, una o varias capas ocultas y una capa de salida. Cada capa está compuesta por un conjunto de neuronas que realizan operaciones matemáticas en los datos de entrada. La salida de una capa se convierte en la entrada de la siguiente capa, y así sucesivamente, hasta que se obtiene la salida final (Witold & Shyi-Ming, 2020, pág. 19). Finalmente, los autores también mencionan que:

Las redes neuronales se utilizan en una amplia variedad de aplicaciones de aprendizaje automático, como la clasificación de imágenes, el reconocimiento de voz, la traducción automática y el procesamiento del lenguaje natural. Asimismo, se abordan los temas de cómo las redes neuronales profundas han permitido correlacionar grandes cantidades de datos de múltiples modalidades, y se han utilizado para la extracción de características, el análisis de patrones y la abstracción de datos (Witold & Shyi-Ming, 2020, págs. 21-22).

1.1.3.3 Lenguajes de Programación en Inteligencia Artificial. Para aprovechar al máximo el potencial de la IA, es fundamental entender y utilizar correctamente los lenguajes de programación que permiten su implementación. Estos lenguajes y herramientas constituyen la base para el desarrollo de soluciones innovadoras basadas en IA, permitiendo el procesamiento y análisis de grandes cantidades de datos, la implementación de algoritmos de aprendizaje automático y el desarrollo de aplicaciones de IA potentes.

Dentro del amplio repertorio de lenguajes de programación utilizados en el campo de la inteligencia artificial, Python es el más popular entre los científicos de datos y desarrolladores de software debido a su amplia gama de aplicaciones, simplicidad y versatilidad. Como mencionan Hao & Ho (2019) en su estudio sobre Python:

Es un lenguaje de programación el cual, a diferencia del lenguaje de programación R, que se utiliza principalmente para el análisis estadístico de datos, Python es más versátil y se utiliza en una variedad de campos, como, en el desarrollo de sitios web, acceso a bases de

datos, cálculo científico y desarrollo de software y juegos. Además, presenta un lenguaje interpretado, lo que significa que no se compila en binario, sino que se traduce en tiempo real durante la ejecución del código (pág.5).

Python es multiplataformas, siendo compatible con Windows, MacOS y Linux. Se encuentra en constante evolución, teniendo diferentes plataformas de interfaz para la manipulación de códigos, como se observa en la Figura 13, las principales son: Anaconda, spyder, Jupyter Notebook y Google Colab, siendo esta última la interfaz más amigable para el usuario y más adecuada para la mayoría del trabajo de análisis de datos.

Figura 13

Principales interfaces o cuadernos para Python



Nota. Tomado de (Kök, 2022)

Python es conocido por su amplia variedad de bibliotecas que lo hacen ideal para el desarrollo de proyectos de inteligencia artificial. Para Deep Learning estas son las más conocidas:

Desarrollado por Google, TensorFlow es una biblioteca de software de código abierto para el flujo de datos y la programación diferenciable en una amplia gama de tareas. Se utiliza para aplicaciones de aprendizaje automático y aprendizaje profundo, incluidas las redes neuronales, el procesamiento del lenguaje natural y la visión por ordenador (Soklaski, Goodwin, Brown, Yee, & Matterer, 2022, pág. 4).

PyTorch es una biblioteca de aprendizaje automático de código abierto basada en la biblioteca Torch. Se utiliza principalmente para desarrollar aplicaciones de aprendizaje profundo, incluido el procesamiento del lenguaje natural y la visión por ordenador. PyTorch es conocida por su grafo computacional dinámico, que permite una mayor flexibilidad en la construcción de modelos (Soklaski et al., 2022, pág. 2).

Las bibliotecas Pandas y Scikit-learn son herramientas imprescindibles pues proporcionan una variedad de funciones que permiten desde el procesamiento y análisis de

datos hasta el desarrollo y entrenamiento de modelos de aprendizaje automático. De modo que es conveniente citar la perspectiva de estos autores:

Pandas es una biblioteca de Python de alto rendimiento y eficiente en la manipulación de datos que brinda un amplio conjunto de herramientas para leer y escribir datos entre diferentes formatos, manipulación de datos desordenados, reestructuración, indexación, manipulación de series temporales, entre otras funcionalidades. Su misión es convertirse en el bloque de construcción para el análisis de datos prácticos en Python, y tiene la visión de ser accesible, flexible, potente, fácil de usar y rápido. Se utiliza en una variedad de contextos académicos y comerciales, incluyendo finanzas, neurociencia, economía, publicidad, análisis web, y más (AQR Capital Management, 2018).

Sci-kit Learn es un paquete de aprendizaje automático de código abierto y completo en Python que se utiliza para una amplia gama de aplicaciones de aprendizaje automático. Es el paquete de aprendizaje automático más completo y de código abierto en Python, y se utiliza cada vez más en aplicaciones relacionadas con el aprendizaje automático. Incluye varios algoritmos de clasificación, regresión y agrupación, como máquinas de vectores soporte, bosques aleatorios y agrupación de k-means (Hao & Ho, 2019, pág. 6).

Así como Python existen otras alternativas de lenguajes como se observa en la Figura 14.

Figura 14

Lenguajes de programación



Nota. Tomada de (Maun, 2018)

R es un lenguaje de programación de código abierto especializado en el análisis de datos y la creación de gráficos. Sus capacidades integrales para manejar datos, realizar análisis estadísticos y representar resultados gráficamente lo convierten en una herramienta práctica y útil. Su facilidad de uso y aprendizaje hacen de R una herramienta valiosa tanto para los principiantes que recién se introducen en el análisis de datos como para los expertos en la materia. Por consiguiente, la compañía desarrolladora R Core Team (2023) expone lo siguiente:

R es ampliamente utilizado por una variedad de profesionales, incluyendo científicos, investigadores y analistas de datos, para explorar y analizar grandes volúmenes de datos y extraer información útil a partir de ellos. La capacidad de R para llevar a cabo una variedad de análisis estadísticos, desde la regresión hasta el análisis de series de tiempo, junto con su habilidad para generar gráficos y visualizaciones de datos de alta calidad, lo hace perfectamente adecuado para una amplia gama de aplicaciones y hace que la presentación de los resultados del análisis de datos sea más eficiente y atractiva (pág.3).

Cuando se trata de lenguajes de programación versátiles y robustos, Java resalta en muchos aspectos. Para citar una fuente que explica sus principales características y aplicaciones, consideramos el libro de Schildt (2022):

Java es un lenguaje de programación de alto nivel que se caracteriza por su portabilidad, seguridad y capacidad para crear programas multiplataforma. Java es utilizado en una amplia variedad de aplicaciones, desde aplicaciones de escritorio hasta aplicaciones web y móviles. Además, Java es utilizado en la creación de sistemas de gestión de bases de datos, sistemas de comercio electrónico y sistemas de gestión de contenido. Además, su soporte para la programación en red lo hace ideal para aplicaciones web y móviles (págs.27-30).

Finalmente, el lenguaje de programación C++ es una herramienta multifuncional que juega un papel significativo en la informática y la programación. Este lenguaje, creado por Bjarne Stroustrup como una extensión de C, ha evolucionado a lo largo de los años para convertirse en una entidad independiente con su propio conjunto de características y capacidades. A pesar de sus raíces, es importante enfatizar que C y C++ son lenguajes distintos y no deben confundirse.

En relación con la diversidad de usos y la flexibilidad del lenguaje de programación C++, una referencia que detalla estas características la menciona el autor Dmitrović (2023) en su libro ¿Qué es C++?:

C++ se utiliza de manera extensa en diversos ámbitos de programación, desde la programación de sistemas hasta la creación de aplicaciones. Lo que distingue a C++ es su versatilidad, permitiendo a los programadores trabajar en operaciones de bajo nivel, mientras que también ofrece la opción de utilizar mecanismos de abstracción más altos, como plantillas

y clases. Esta combinación de flexibilidad y eficacia convierte a C++ en una herramienta valiosa para cualquier programador (págs.3-4).

1.1.4 El mantenimiento industrial y la inteligencia artificial

En esta sección se analizará cómo la inteligencia artificial está cambiando el mantenimiento industrial al mejorar la identificación de defectos y optimizar las operaciones para mejorar la productividad y reducir el tiempo de inactividad.

1.1.4.1 Conceptos Básicos del Mantenimiento Industrial. El mantenimiento industrial juega un papel crucial en garantizar el correcto funcionamiento de los equipos y maquinarias en una planta de producción. Este conjunto de acciones técnicas, administrativas y gerenciales se realizan a lo largo del ciclo de vida de un equipo para mantenerlo en óptimas condiciones de operación. “El objetivo es preservar la funcionalidad requerida de un equipo, evitando interrupciones en la producción que pueden generar costos significativos” (Bokrantz, Skoogh, Berlin, Wuest, & Stahre, 2020, pág. 9)

En el contexto de la industria moderna, el mantenimiento industrial no sólo se limita a la reparación de equipos. Según el autor Bokrantz et al. (2020), cita lo siguiente:

Según Jonsson (1999), se debe considerar la integración de la estrategia de mantenimiento en la gestión de activos de toda la empresa. Esta perspectiva se refuerza con la exploración del impacto del mantenimiento 4.0 y el análisis de big data en la gestión de activos estratégicos por Kans y Galar (2017) (pág.16).

Existen diferentes tipos de mantenimiento que se pueden aplicar en función de las necesidades de la planta y los equipos. Estos pueden clasificarse principalmente en cuatro estrategias: mantenimiento correctivo, preventivo, predictivo y proactivo como se puede observar en la Figura 15.

Figura 15

Estrategias de mantenimiento



Nota. Tomado de (Berge, 2019)

“El mantenimiento correctivo se lleva a cabo después de que se produce una falla en el equipo, con el objetivo de repararlo y restablecer su operatividad” (Silvestri & Forcina,

2020). Por otro lado, “el mantenimiento preventivo se realiza de manera programada para evitar posibles fallos” (Bokrantz et al., 2020, pág. 9). Se basa en la premisa de que es más rentable prevenir problemas que solucionarlos una vez que han ocurrido. “El mantenimiento predictivo, mientras tanto, utiliza técnicas de monitoreo y análisis de datos para predecir cuándo es probable que se produzca una falla, permitiendo planificar la intervención antes de que suceda” (Bokrantz et al., 2020, pág. 16).

“El mantenimiento proactivo se centra en la mejora continua del diseño y la fabricación del equipo para reducir la necesidad de mantenimiento” (Silvestri & Forcina, 2020, pág. 2). “Esta aproximación estratégica aporta ventajas significativas al aumentar la confiabilidad y el rendimiento del equipo, y puede ser de particular interés en el contexto del llamado Smart Maintenance” (Bokrantz et al., 2020, pág. 2).

Además de los tipos de mantenimiento mencionados, también existen diferentes metodologías de optimización de mantenimiento industrial como se observa en la Figura 16. Como afirma Bokrantz et al. (2020), las más importantes son:

El mantenimiento basado en la condición se centra en el monitoreo del estado de los equipos para determinar cuándo es necesario realizar el mantenimiento. Por otro lado, el mantenimiento centrado en la confiabilidad se enfoca en identificar los equipos críticos y realizar el mantenimiento necesario para garantizar su confiabilidad.

El mantenimiento basado en la gestión de activos se enfoca en maximizar el valor de los activos de la empresa a través de la optimización del mantenimiento. Finalmente, también existen otras estrategias de mantenimiento como el mantenimiento autónomo y el mantenimiento productivo total, que se enfocan en la capacitación de los operadores para realizar tareas de mantenimiento básicas y en la mejora continua de los procesos de producción y el mantenimiento, respectivamente (págs.10-11).

Figura 16

Metodologías de optimización de mantenimiento industrial



Nota. Tomado de (Fitch, 2016)

La elección de la estrategia de mantenimiento adecuada depende de varios factores, incluyendo el tipo de equipo, su criticidad y el costo del mantenimiento. En última instancia, la estrategia de mantenimiento óptima es aquella que minimiza el costo total de propiedad del equipo. Para determinar esta estrategia, es llevar a cabo un análisis de costo-beneficio de las diferentes estrategias de mantenimiento y seleccionar aquella que proporcione el mayor beneficio al menor costo (Silvestri & Forcina, 2020, pág. 2).

1.1.4.2 Inteligencia Artificial en el Mantenimiento Predictivo. La inteligencia artificial (IA) se está convirtiendo en un recurso clave para la eficiencia y la reducción de costos en el mantenimiento predictivo industrial. Silvestri & Forcina (2020) destaca que:

La IA mejora la precisión del mantenimiento predictivo a través del análisis de grandes cantidades de datos y la detección de patrones que pueden ser difíciles de identificar por los humanos. Esta aplicación de la IA ayuda en la programación del mantenimiento al predecir el tiempo de vida útil restante del equipo y, además, reduce la necesidad de inspecciones manuales.

Silvestri subraya la utilidad de técnicas como el análisis de vibraciones, el análisis de imágenes y el análisis de datos de sensores para el diagnóstico temprano de fallas, lo que finalmente contribuye a prevenir interrupciones no planificadas y costosas reparaciones de emergencia (pág.5).

En el marco de la Industria 4.0, la IA se está utilizando en sinergia con otras tecnologías como el Internet de las Cosas (IoT) para hacer predicciones de fallas más precisas. Dalzochio et al. (2020) analiza el estado actual y los desafíos de esta integración, resaltando la necesidad de datos de alta calidad y la complejidad de los modelos de aprendizaje automático. Sin embargo, a pesar de los desafíos, los estudios que han aplicado estas técnicas han mostrado resultados prometedores, con ejemplos de detección y diagnóstico de fallas en centros de máquinas y control de producción autónomo. Ruiz-Sarmiento (2020), en su análisis del mantenimiento predictivo en el contexto de la Industria 4.0, destaca:

Se evidencia la efectividad de la combinación de la IA con tecnologías de sistemas ciberfísicos, IoT, Big Data e Internet de servicios para recopilar y procesar datos de sensores, lo que ha resultado en mejoras significativas en la detección temprana de fallos y la reducción de los costos de mantenimiento (pág.3).

El mantenimiento predictivo, gracias a la integración de IA, no solo se está aplicando en la industria en general, sino que también se está extendiendo a campos especializados como la aeronáutica, según Ceruti (2019):

La IA también contribuye a optimizar el mantenimiento preventivo, lo que se traduce en la realización del mantenimiento en el momento óptimo, en lugar de en intervalos fijos. La implementación de estas técnicas puede requerir una inversión inicial significativa en

tecnología y capacitación, sin embargo, las ventajas de reducción de costos de mantenimiento y aumento de la eficiencia compensan con creces esta inversión (págs.6-7).

1.1.4.3 Algoritmos de Inteligencia Artificial para el Análisis de Fallas. El estudio de fallos en sistemas industriales ha experimentado una evolución significativa con la incorporación de la inteligencia artificial (IA). Mediante técnicas avanzadas como el aprendizaje automático y las redes neuronales, la IA ofrece la capacidad de detectar y anticipar fallos con una buena precisión y rapidez.

Según el autor AlShorman (2020) detalla cómo los algoritmos de aprendizaje automático y las redes neuronales se utilizan para procesar grandes cantidades de datos de sensores y detectar patrones de fallas:

El análisis de grandes volúmenes de datos puede revelar anomalías sutiles que podrían pasar desapercibidas a través del análisis humano. Por ejemplo, las redes neuronales han sido aplicadas en el monitoreo de los rodamientos, identificando patrones en las señales de vibración y acústica para detectar fallas incipientes antes de que provoquen daños graves (pág.2).

- Asimismo el autor Soares (2022) presenta un enfoque más específico del uso del aprendizaje automático en la detección de fallas, enfocándose en la técnica de clasificación del "Bosque Aleatorio":

Este algoritmo, que opera a través de una combinación de árboles de decisión, ha logrado resultados excepcionales en la detección y diagnóstico de fallas, con precisión superior al 98% en ciertos casos. Además, las redes neuronales han demostrado ser particularmente efectivas en la detección de fallas en sistemas eléctricos y electrónicos, así como en la predicción de la vida útil de los componentes mecánicos (pág.3).

- Por último, Kumar & Shanka (2020) resalta la utilidad de algoritmos de aprendizaje profundo, como las redes neuronales convolucionales y las redes de creencias profundas, en la detección de fallas en motores de inducción:

Estos algoritmos de aprendizaje profundo permiten la extracción y selección automática de características, reduciendo el riesgo de errores humanos y mejorando la eficiencia del sistema. Además, se propone la creación de sistemas híbridos que combinan aprendizaje profundo y máquinas de alta computación para mejorar aún más el rendimiento diagnóstico (pág.5).

1.1.4.4 Aplicaciones de la Inteligencia Artificial en el Análisis de Fallas. La creciente integración de la inteligencia artificial (IA) en la detección y análisis de fallos en entornos industriales ha abierto una amplia gama de posibilidades para mejorar la eficiencia y la seguridad en dichos entornos como se observa en la Figura 17. A continuación, se presentan algunos casos de éxitos mencionados por algunos autores.

Figura 17*Análisis de parámetros operativos con sensores*

Nota. Tomado de (IPEMAN, 2021)

- Según Ruiz-Sarmiento (2020), se ha desarrollado un modelo de mantenimiento predictivo que utiliza técnicas de aprendizaje automático para predecir fallos en la maquinaria industrial:

Los modelos de mantenimiento predictivo se basan en la recopilación y procesamiento de datos de sensores. Ejemplos prácticos de su aplicación incluyen su uso en la industria aeronáutica para analizar los datos de los sensores de los aviones y predecir fallos en los sistemas antes de que ocurran, y en la industria automotriz para anticipar problemas en los sistemas de frenado y dirección (pág.14).

- El análisis de Ceruti et al. (2019) destaca cómo la IA puede ayudar a detectar patrones en los datos de mantenimiento:

Se ha aplicado la IA en la detección y análisis de fallos en turbinas de gas, donde los algoritmos de aprendizaje automático han sido capaces de identificar patrones que podrían indicar un fallo inminente. Este análisis predictivo de los datos permite a los técnicos de mantenimiento tomar medidas preventivas antes de que ocurra un fallo (pág.7).

- Finalmente, AlShorman (2020) y Zhao, Blaabjerg, & Wang (2021) presentan una mirada más técnica a la aplicación de la IA en la detección y análisis de fallos. Según Alshorman, “las técnicas de IA como las redes neuronales se utilizan para el monitoreo de la condición y el diagnóstico de fallos en motores de inducción, con ejemplos prácticos para el monitoreo de rodamientos” (pág.12). Asimismo, Zhao destaca sobre “las aplicaciones de la IA en el campo de la electrónica de potencia, como la detección de fallos en sistemas de energía renovable y la identificación de la causa raíz de los fallos. En conjunto, estas aplicaciones de la IA prometen mejoras significativas en la eficiencia y la confiabilidad de los sistemas industriales” (págs.1-2).



Capítulo 2

Evaluación y resultados

La principal finalidad del estudio ha sido la predicción anticipada de falla en los motores eléctricos, por lo que he optado por aplicar técnicas de inteligencia artificial, como la Red Neuronal de Memoria a Largo Plazo Atencional Multivariante (MA-LSTM). El análisis de estos resultados servirá para corroborar la metodología que se ha adoptado, así como para subrayar la eficiencia de la inteligencia artificial en el diagnóstico de fallas en los motores eléctricos.

2.1 Recolección de datos

La recopilación de datos es un aspecto crucial en cualquier estudio que busque el análisis y la detección de fallos, especialmente cuando se emplean algoritmos de inteligencia artificial. En este proceso de recolección hay que distinguir las variables que utilizaremos, ya que pueden clasificarse de diversas maneras. Según Ramos-Galarza (2021), uno de los sistemas de clasificación más comunes y útiles es el que distingue entre variables dependientes (o targets) e independientes (o features):

En un estudio experimental, la variable independiente es aquella que se manipula para observar su efecto en la variable dependiente. Es decir, se controla y cambia para evaluar cómo afecta a otra variable, determinando así los diferentes grupos de intervención. Por su parte, la variable dependiente se mide en el estudio y se espera que cambie como resultado de la manipulación de la variable independiente. Este proceso pone en relieve el nexo causal entre la variable independiente y la variable dependiente, facilitando así la comprensión y la predicción de ciertos fenómenos (pág.2).

Esta distinción entre variables dependientes e independientes es importante para diseñar la metodología de la investigación, analizar los datos y, en última instancia, interpretar los resultados del estudio. En este proceso se define la base de datos (o data set) y se asegura de que estén listos para ser usados de la manera más eficaz por los algoritmos. A partir de aquí, el primer paso crucial es definir los parámetros de interés para la recolección de datos, en este caso de los motores eléctricos.

2.1.1 *Parámetros de interés en fallas de motores eléctricos de decantadores*

En el contexto de los motores eléctricos, esta recopilación de datos implica la captura sistemática de parámetros operativos y de rendimiento mediante instrumentos de medición y sensores, para una visión detallada del estado de funcionamiento de los motores. Aquí se definirán qué datos son relevantes para la detección de fallas.

Para los autores Kumar & Shankar (2020), destacan la importancia de la selección adecuada de características para el análisis de fallas. Estos autores mencionan algunos de los parámetros que se utilizan en los estudios de detección de fallas los cuales serán presentados en la Tabla 1:

Tabla 1*Principales parámetros para la detección de fallas en motores eléctricos*

Parámetro de fallas de motor	Importancia
Temperatura	El monitoreo de la temperatura puede ser útil para detectar fallas relacionadas con el sobrecalentamiento, como problemas en los devanados o en el sistema de enfriamiento.
Vibración	La vibración del motor puede indicar la presencia de fallas mecánicas, como desalineación, desgaste de rodamientos o barras de rotor rotas.
Corriente	La corriente eléctrica que fluye a través del motor puede proporcionar información sobre posibles fallas, como desequilibrios en el rotor o problemas en los devanados del estator.
Ruido	El análisis del ruido generado por el motor puede revelar anomalías.

Por otro lado, desde el punto de vista operacional, es importa identificar una serie de parámetros del equipo que puedan tener una buena correlación con la generación de fallas de componentes del motor o paradas de equipos. El enfoque de este proyecto es para equipos decantadores centrífugos como se observa en la Figura 18. Por lo cual, se debe considerar las características presentadas en la Tabla 2.

Figura 18*Decantador centrífugo Z73***Tabla 2***Parámetros de equipos decantadores centrífugos*

Parámetros operacionales	Unidades
Flujo de alimentación	m^3/h
Torque de decantador	kN
Velocidad del bowl	RPM
Velocidad diferencial	RPM
Tiempo de operación	Horas

Estos valores presentados serán tomados en cuenta para realizar el análisis de correlación y validar su importancia en la identificación de anomalías y prevención de fallas.


2.1.2 Técnicas de recolección de datos

Para el presente trabajo de tesis se utilizó el sistema WEG Motor Scan como una herramienta de recolección de datos. Este sistema consiste en un conjunto de productos y servicios que incluyen un sensor, una aplicación móvil y un portal web (WEG IoT Platform). El sensor, un dispositivo no invasivo que funciona a través de una batería de litio con una vida útil de 3 años, se instala en el motor eléctrico y recoge datos como la vibración, la temperatura y el tiempo de funcionamiento. Además, estima la carga si el activo es un motor eléctrico.

La comunicación entre el sensor y el dispositivo móvil se realiza con Bluetooth Low Energy, lo que permite una transmisión inalámbrica de datos. Posteriormente, estos datos se envían a la nube y se procesan a través del portal web de la WEG IoT Platform, como se puede observar en la Figura 19. En este espacio seguro, los datos se recogen y pueden descargarse en diversos formatos, incluyendo csv, json, excel, y sql, lo que facilita su posterior análisis.

Figura 19

Flujo de adquisición, procesamiento y generación de diagnóstico de datos



Nota. Tomado de (WEG, 2020)

Este tipo de recolección de datos es relevante en el análisis de fallas en motores eléctricos, ya que permite un monitoreo en tiempo real de diversos parámetros, aportando datos precisos y oportunos para la detección y el análisis de posibles anomalías. Con su capacidad para integrarse con otros sistemas como reductores, generadores, bombas y compresores, el WEG Motor Scan se posiciona como una herramienta valiosa para el análisis y la detección de fallas en diversas aplicaciones industriales.

2.1.3 Proceso de recolección

Para la obtención de los datos necesarios, se utilizará el sensor del sistema WEG Motor Scan. El sensor será colocado en motores de equipos decantadores centrífugos Z73, los cuales tienen las características presentadas en la Figura 20. La recolección de datos se realizará de manera periódica y los parámetros que se medirán incluirán vibración, temperatura y tiempo de funcionamiento.

Figura 20

Parámetros de motor eléctrico de decantador Flottweg Z 73-4/454

4. Mecanismo reductor:

tipo:		SIMP-DRIVE®
Accionamiento:	tipo	SP 3.11
accionamiento del tambor:		
Motor eléctrico:	tipo	315 S
	potencia	110 kW
	voltaje	400; 690 V
	frecuencia	50 Hz
accionamiento del sinfín:		
Motor eléctrico:	tipo	132 M
	potencia	7,5 kW
	voltaje	400; 690 V
	frecuencia	50 Hz

Nota. Tomado de (Flottweg AG, 2010)

Para una correcta lectura de los parámetros, se debe verificar la equivalencia del motor Siemens 315S a WEG, siendo este el W21 400/690 como se muestra en la Figura 21:

Figura 21

Parámetros de motor WEG 400/690V

DETALLES DEL PRODUCTO

[DATOS TÉCNICOS](#)
[CURVAS DE DESEMPEÑO](#)
[DIBUJO DIMENSIONAL](#)
[GENERAR DOCUMENTOS](#)
[380/660 V 50 Hz 6P](#)
[400/690 V 50 Hz 6P](#)
[415 V 50 Hz 6P](#)
[460 V 60 Hz 6P](#)


Motores Eléctricos

Carcasa	315S/M	Momento de inercia (J)	4.93 kgm ²
Potencia	110 kW (150 HP)	Categoría	N
Numero de polos	6	Clase de aislamiento	F
Frecuencia	50 Hz	Factor de servicio	1.00

Nota. Tomado de (WEG, 2023)

Teniendo definido la equivalencia del motor y para un correcto posicionamiento del sensor en el motor se deben tener en cuenta las recomendaciones de WEG (2020):


El posicionamiento del sensor para la instalación en motores eléctricos WEG de las líneas W21, W22 y W50. Según la Figura 22, el sensor debe ser instalado a una distancia máxima D = 20 mm del centro del motor y a una distancia M de la parte superior de la aleta.

Figura 22*Distancias para fijación del sensor**Nota.* Tomada de (WEG, 2020)

La distancia M varía con la carcasa, así como con la línea del motor, y está indicada en la Figura 23. Finalmente, en la Figura 24 muestra la fijación del sensor en el motor W22.

Figura 23*Dimensión de M en mm*

Carcasas 225 a 355 - W21		
Carcasa	M (mm)	M (pol.)
225	45	1.772
250	45	1.772
280	55	2.165
315	55	2.165
355	55	2.165


Nota. Tomado de (WEG, 2020)**Figura 24***Sensor fijado en el motor**Nota.* Tomado de (WEG, 2020)

Una de las observaciones que puede surgir es el por qué la norma ISO 10816-3 (2009), ampliamente adoptada en los programas de mantenimiento predictivo industriales, no detalla la posición específica para el uso del sensor WEG Motor Scan en la medición de vibración. Ante esta observación, la empresa WEG hace referencia en la ISO 13373-1 (2002), la cual sí aboga por la instalación de sensores en diversas posiciones, siempre que aporten datos relevantes sobre la vibración. Reforzando esto, estudios de WEG, líder global con más de 60 años en el ámbito eléctrico y especializado en máquinas eléctricas y automatización, han corroborado la eficiencia de estos puntos de medición alternativos, alineándose con las indicaciones de la ISO 10816-3. Además, WEG sostiene que sus sensores, cuando se colocan adecuadamente, se convierten en una herramienta estratégica y útil para el mantenimiento predictivo.

Una de las recomendaciones que se deben destacar para este correcto funcionamiento es que “antes de suministrar cualquier información de diagnóstico, es necesario un período de aprendizaje de 10 a 15 días. Durante este período, el sensor recopila datos de vibración y temperatura para establecer los estándares de funcionamiento del motor” (WEG, 2020). Después del período de aprendizaje y cumpliendo los estándares establecidos en la norma ISO10816-3 sobre los niveles de vibración, el sensor puede proporcionar información de diagnóstico sobre la salud del motor como se puede observar en Figura 25.

Figura 25

Ejemplo del antes y después del periodo de aprendizaje



Nota. Tomado de (WEG, 2020)

Finalmente, los valores que se medirán con este software serán los presentados en la Tabla 3:

Tabla 3

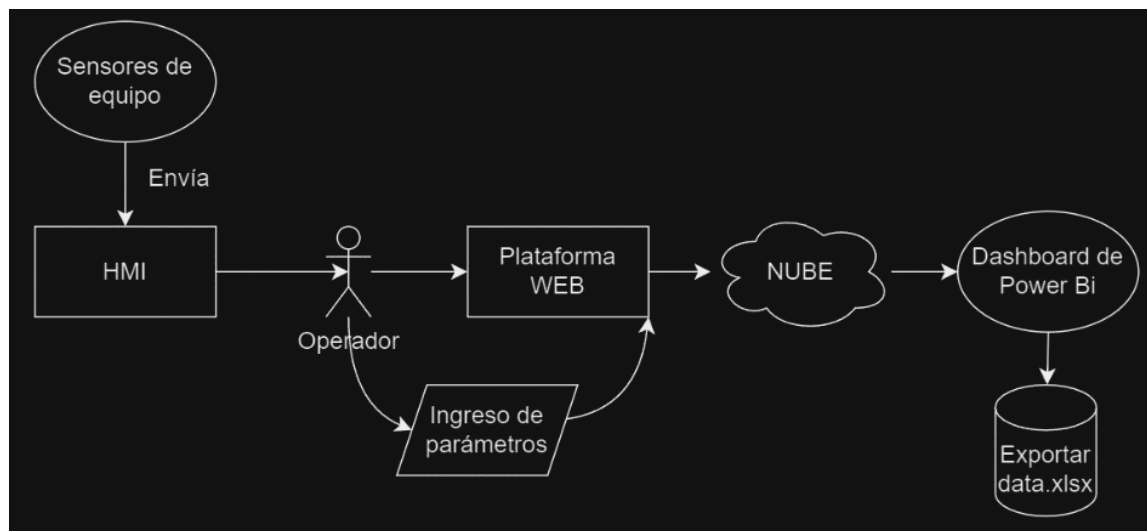
Variables que pueden ser medidas por sensor WEG Motor Scan

Variable	Unidad de medida
Vibración	mm/s
	RMS (g)
Frecuencia	Hertz (Hz)
Temperatura	Centígrados (°C)
Velocidad	Rpm

Para la recolección de los datos operacionales se utilizará una plataforma web propia de la empresa, en la cual se registrarán de forma horaria los valores del equipo centrífugo. Asimismo, estos datos serán cargados automáticamente en la nube. En la Figura 26 se observa el flujo de registro.

Figura 26

Flujo de adquisición de parámetros operacionales



2.1.4 Almacenamiento de datos

Para el almacenamiento de los parámetros se programó un horario de mediciones en el aplicativo de toma de datos de forma horaria en funcionamiento. Como se mencionó en el punto 2.1.2, el sensor se integra con la plataforma WEG IoT, lo que permite a los usuarios descargar los datos en diferentes formatos. Para el caso de esta tesis se descargará en formato Excel, extensión xlsx.

En el caso de los parámetros operacionales, se presentarán en un dashboard de la plataforma Power Bi de Microsoft, de la cual podemos extraerlos en formato de Excel para su limpieza y análisis.

2.2 Preprocesamiento y análisis de datos

En esta sección se detallará sobre el preprocesamiento y análisis de datos, procesos cruciales para preparar y entender los datos recolectados de los motores eléctricos vistos en la sección anterior.

2.2.1 Preprocesamiento de la base de datos

El preprocesamiento nos ayudará a asegurar la calidad de los datos y su adecuación para los algoritmos de inteligencia artificial. “Esta etapa, en la minería de datos predictiva, es crucial ya que puede afectar significativamente el rendimiento de los algoritmos” (Alexandropoulos, 2019).

Para esta tesis, la base de datos que se utilizó es de equipos decantadores centrífugos, encargados de la deshidratación de los sólidos recuperados en el tratamiento de agua de una empresa pesquera. La toma de datos se realizó en equipos Z73 en las mismas condiciones de instalación y capacidad, pero con diferente cantidad de datos acumulados, debido a que se encuentran en diferentes plantas.

2.2.1.1 Limpieza de base de datos. La limpieza de la base de datos es un paso indispensable en el preprocesamiento y análisis de datos, especialmente en la construcción de modelos de inteligencia artificial. Esta fase se encarga de corregir las inconsistencias y errores que puedan existir en los datos. Estos pueden incluir valores faltantes, datos duplicados, errores de entrada y otros tipos de ruido que podrían afectar la efectividad y precisión del modelo de detección de fallas.

- Validación de tamaño de base de datos: Para la correcta limpieza de la base de datos primeros cargamos los valores a la plataforma Python y verificamos, la cantidad real de datos y los datos faltantes, para determinar el tamaño usamos la Ecuación 3.

$$\text{Tamaño de muestra} = \text{filas} \times \text{columnas} \quad [3]$$

El entrenamiento efectivo de un modelo depende en gran medida de la disponibilidad de un conjunto de datos amplio y de secuencia no variable. Sin embargo, en el contexto del sector pesquero, obtener un volumen extenso y continuo de datos suele ser complicado, en especial cuando nos referimos a plantas de bajo tonelaje. Esta situación se manifiesta claramente en la Tabla 4. Esta restricción en la adquisición de datos no solo pone a prueba las capacidades predictivas del modelo, sino que también puede limitar la aplicación de técnicas avanzadas de análisis.

Tabla 4

Cantidad de datos por tipos de plantas pesqueras

Tipo de planta	Días de producción	Tipo de producción	Muestra de datos (Por temporada)
Alto tonelaje (>200 ton/h)	Temporada 1: 50 Temporada 2: 40	Casi continua	Alto (>800)
Medio tonelaje (130 – 200 ton/h)	Temporada 1: 40 Temporada 2: 30	Media Continua	Medio (500 - 800)
Bajo tonelaje (<130 Ton/h)	Temporada 1: 30 Temporada 2: 20	No es continua	Bajo (< 500)

Para la tesis, se planteó unir las bases de datos de los diferentes equipos para tener un adecuado tamaño de muestra para la generación del modelo, como se observa en la Figura 27. Esta unión se realizará de forma cronológica y teniendo en cuenta que los datos siguen una secuencia de longitud variable al pertenecer a diferentes plantas. Seguido, se ingresó una columna denominada "ID_MOTOR" que me permita identificar los diferentes motores.

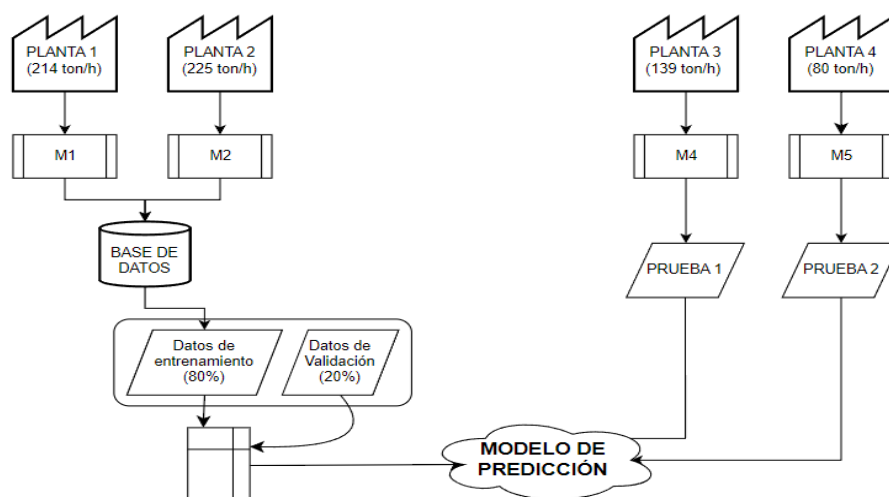
Tabla 5

Ejemplo de base de datos

ID_MOTOR	SECUENCIA	SENSOR 1	SENSOR 9	MOTOR_FALLO
[M1 – M5]	[1 – 14]	X1	X9	[0:1]

Figura 27

Primer bosquejo de flujo de datos para creación de modelo y validación de este



- Manejo de valores faltantes: Se observa que contamos con datos faltantes. Por lo cual, se tienen 2 opciones:

Opción 1: Quedarnos solo con los valores que cuenten con el valor a predecir y eliminar el resto. Solo se puede hacer esto si el tamaño de muestra a eliminar es menor al 5%, porque sería una muestra no representativa.

Opción 2: Balancear datos para predecir valores mediante media, mediana o moda.

En este caso utilizaremos la opción 1, como se muestra en la Ecuación 4, debido a que la muestra que eliminaríamos representa menos del 5% de la base de datos, presentada en la Tabla 6, por lo cual es considerada no significativa.

Tabla 6

Estructura de base de datos para el modelo

Base de datos	Tamaño de muestra	Datos faltantes (NaN)
M1 + M2	6921	189

$$\text{Muestra que representa} = 100\% * \left(\frac{\text{Cant. datos a eliminar}}{\text{Cant. datos total}} \right) \quad [4]$$

$$\text{Cantidad de datos} = 6921$$


$$\text{Datos faltantes} = 189$$

$$\text{Muestra} = 100\% * \left(\frac{189}{6921} \right) = 2.73\% < 5\%. \text{ No significativo}$$

- Tipos de variables: Para entender la data, debemos validar qué tipo de variables tenemos y si éstas siguen una distribución normal. Por lo cual, apliqué una herramienta de calidad denominada histograma, como se observa en la Figura 28, para validar el comportamiento de los datos.

Figura 28

Histograma de los sensores



Como se observa, los valores no siguen una distribución normal, esto servirá para saber si escoger un escalado o normalizado para el modelo.

2.2.1.2 Normalización de datos. La normalización de datos permite garantizar que las variables se traten con igual importancia al entrenar un modelo. Dado que diferentes características pueden tener diferentes rangos y unidades, generando una influencia con diferentes pesos en el modelo, descartando algunas características sobre otras. Un enfoque común para la normalización es la estandarización. La estandarización escala las características de manera que tengan una media de 0 y una desviación estándar de 1. Esto se logra restando la media de cada observación y luego dividiendo por la desviación estándar.

Según Cournapeau et al. (2016) menciona que hay una regla general para la estandarización de los conjuntos de datos, la cual es un requisito común para muchos estimadores de aprendizaje automático implementados en scikit-learn; podrían comportarse mal si las características individuales no se parecen más o menos a datos estándar distribuidos normalmente: Gaussianos con media cero y varianza unitaria.

2.2.1.3 Escalado de datos. Así como el normalizado, el escalado de datos también es una técnica crucial en el procesamiento previo de datos, especialmente cuando trabajamos con algoritmos de aprendizaje automático o deep learning.

Un enfoque común para el escalado de datos es el uso del escalador MinMax. Es una técnica que transforma las características reescalándolas en un rango específico, generalmente entre 0 y 1. Esta transformación se logra utilizando la Ecuación 5:

$$X' = \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) \quad [5]$$

Donde:

X' , es el valor transformado.

X , es el valor original.

X_{\min} , es el valor mínimo.

X_{\max} es el valor máximo.

Como comenta Cournapeau et al. (2016), lo importante del escalador MinMax es que cambia el rango de los datos, pero mantiene la forma de la distribución de los datos. Por lo cual, es la mejor opción cuando se trabaja con datos que no siguen una distribución normal.

2.2.2 Selección de principales variables para el modelo

Para el entrenamiento del modelo se utilizarán los parámetros operacionales del equipo decantador centrífugo Z73 y los valores recolectados por el sensor WEG. Por lo cual, la base de datos tendrá 12 filas, divididas entre:

- Sensores: Variables recolectadas para predecir el modelo, las cuales son:

Velocidad diferencial (VEL_DIF): Es la diferencia entre las velocidades de rotación del tambor y del tornillo transportador, facilitando la separación y el transporte del material sólido en el equipo decantador centrífugo.

Flujo de floculante (FLUJO_FLOC): Es la cantidad o tasa a la que se añade un floculante a un sistema o proceso, para aglomerar o agrupar partículas finas suspendidas en un líquido, facilitando su separación o sedimentación.

Flujo de ingreso al equipo (FLUJO_ING): Es la tasa o volumen al que la mezcla se introduce en el equipo.

Torque de trabajo (TORQUE): Es la fuerza que el sistema de transmisión debe ejercer para mantener el equipo en operación bajo condiciones de carga específicas.

Temperatura de contacto (TEMP_CONTACTO): Es la medición de la temperatura superficial del activo en la región donde éste está instalado.

Velocidad Axial (VEL_AXIAL): Es la dirección a lo largo del eje de rotación de una máquina o componente, capturando las vibraciones en ese sentido específico.

Velocidad Radial Y (VEL_RAD_Y): Es una dirección perpendicular tanto al eje de rotación como al eje radial "X", capturando las vibraciones en ese plano específico.

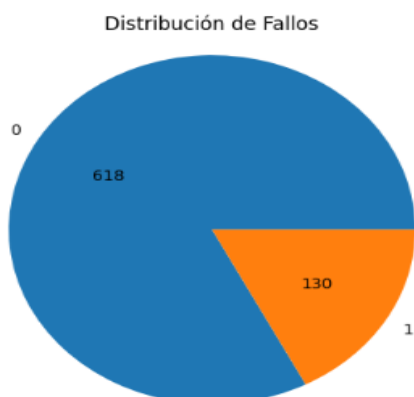
Velocidad Radial X (VEL_RAD_X): Es la dirección perpendicular al eje de rotación de una máquina o componente, representando las vibraciones en ese plano específico.

- Variable secuencia: Variable utilizada para identificar cantidad de horas en que se tomaron los datos día a día. (guía para determinar la secuencia de longitud).
- Variable falla: Indica en 0:1 si el motor falló o no falló, respectivamente.
- Variable de ID: Indica a qué motor le pertenecen los datos en la base de datos.

De nuestra variable a predecir tenemos 748 datos los cuales se dividen como se observa en la Figura 29, donde 0 es "No Falló" y 1 es "Falló":

Figura 29

División de valores de muestra a predecir



2.3 Diseño y entrenamiento del modelo

Para el desarrollo del modelo es importante determinar la cantidad de muestras correspondientes a entrenamiento y testeo de validez. Existen diferentes particiones como 60:40, 70:30 y 80:20.

Para los autores Teimouri & Kornejady (2020), comentan que, si se va a trabajar con grandes volúmenes de datos, es recomendable utilizar una partición 60:40 para modelado y validación, respectivamente. Para modelos de aprendizaje automático la partición 70:30 ofrece mejores resultados de precisión. Finalmente, para modelos nuevos o con una data que no es de gran volumen se recomienda utilizar 80:20, para obtener un mejor modelo sacrificando un porcentaje de la precisión. Sin embargo, con el tiempo y la adquisición de más data, se puede seguir entrenando el modelo y hasta migrarlo a un 60:40.

Para el modelo desarrollado, se decidió utilizar una partición 80:20 al ser un modelo de predicción nuevo y del que no se cuentan aún con grandes volúmenes.

2.3.1 Selección del algoritmo de inteligencia artificial

El avance tecnológico en el campo de la inteligencia artificial ha llevado a descubrimientos significativos en la predicción de fallas. Para el siguiente proyecto, se tomará como base 2 estudios enfocadas al tema que se está presentado.

Las tesis de Toscano & Mario (2020) y Yoshida & Hiroshi (2021) convergen en la idea de que el uso de deep learning, especialmente cuando se utiliza en combinación con las redes LSTM (Long Short-Term Memory), han demostrado ser herramientas poderosas consolidándose como la elección preferida para abordar problemas relacionados con series temporales y datos secuenciales. Estas redes pueden aprender y recordar información en secuencias largas y, por lo tanto, son ideales para tareas de predicción basadas en historiales de datos.

Ambos trabajos destacan que estas técnicas no solo mejoran la precisión de las predicciones, sino que también posibilitan una anticipación más temprana de las fallas, lo que puede ser crucial para optimizar la gestión de mantenimientos y reducir costos operativos.

Para este proyecto, en vez de adoptar las técnicas convencionales, se propone un modelo utilizado para pronósticos financieros, monitoreo de salud y traducción automática, conocido como MA-LSTM. Según Ma, Zhao, Wang, & Shen (2023), este modelo es una secuencia-secuencia multipaso basado en redes neuronales LSTM de atención y tiene como objetivo mejorar el rendimiento del modelado de sensores en procesos industriales que presentan una fuerte dinámica, no linealidad y una secuencia variable.

La estructura MA-LSTM combina la potencia de las redes LSTM con mecanismos de atención. Estos mecanismos permiten que el modelo pese de manera diferente las entradas en función de su relevancia para la salida en un momento determinado, dándole al modelo una especie de "memoria selectiva". Es como si el modelo pudiera centrarse en las partes más informativas de la entrada para hacer una predicción más precisa.


Recientemente, los modelos basados en MA-LSTM han ganado popularidad debido a su flexibilidad y capacidad para manejar datos complejos los han convertido en una herramienta valiosa en múltiples sectores industriales y de investigación. En resumen, mediante la implementación del modelo MA-LSTM en este proyecto, se busca no solo prever fallas con una mayor precisión, sino también abrir nuevas puertas para aplicaciones más avanzadas y complejas en el ámbito del mantenimiento industrial.

2.3.2 Diseño de la arquitectura del modelo

Para garantizar una comprensión clara y sistemática del diseño sobre la lógica subyacente del proyecto, se desarrolló un diagrama de flujo que ilustra cada fase, esta se encuentra en el Apéndice A. Este flujograma no solo sirve como guía para cualquier interesado a través de las múltiples etapas del proyecto, sino que también resalta la interdependencia entre los diversos componentes y subprocesos involucrados. El diseño, entrenamiento y validación del modelo se llevará a cabo utilizando Python, dada su versatilidad, amplia gama de bibliotecas y herramientas de código abierto. Para esta parte específicamente, se ha extraído el apartado de la arquitectura del modelo, como se observa en la Figura 30.

Figura 30

Diagrama de Flujo de Proyecto: "Análisis de fallas de motor eléctrico de decantadores centrífugos en el rubro pesquero" – Etapa: Estructura del modelo



La arquitectura del modelo que se está diseñando busca abordar problemas de secuencias de datos temporales, específicamente para la predicción de fallas basadas en datos de sensores. A continuación, se explica cada componente:

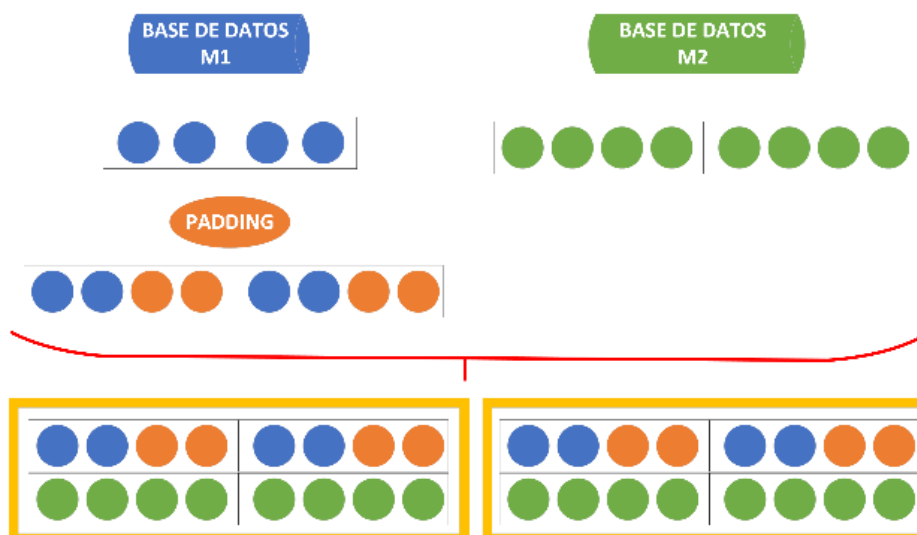
- Entrada (Input): Representado por el código `input_shape = (None, 8)`. Esta representa la primera capa o conocida también como la capa de entrada, donde “None” indica que la longitud de la secuencia puede variar y “8” representa la cantidad de sensores distintos con los que estamos trabajando.
- Enmascaramiento (Masking): Después de la capa de entrada, introducimos una capa de masking o enmascaramiento. El propósito de esta capa es ignorar ciertas secuencias durante el entrenamiento, las cuales usamos para estandarizar la base de datos para lograr la idea de una secuencia continua.

Para lograr esta estandarización de la estructura emplee la técnica de “padding” o relleno. En problemas donde las secuencias tienen diferentes longitudes, es común rellenar las secuencias más cortas con un valor específico para que todas las secuencias tengan la misma longitud, como se observa en la Figura 31. En el modelo, he utilizado -1 como valor de relleno, puesto que la base de datos no cuenta con valores negativos por lo cual cuando sean ignorados, solo eliminarán el relleno mas no otro dato.

Al utilizar el enmascaramiento con un valor de -1, se está indicando al modelo que no preste atención a estos valores de relleno durante el entrenamiento.

Figura 31

Ejemplo de funcionamiento de padding



- LSTM con Atención: Se utiliza la primera capa LSTM, pero agregando los argumentos de “`return_sequences=True`” y “`return_state=True`”. Esto permite que la capa devuelva la secuencia completa y también el estado final, utilizando una serie de unidades LSTM, indicando la capacidad de memoria y complejidad de la capa.

La capa de “Attention” se introduce después de la primera capa LSTM. El propósito de esta capa de atención es permitir que el modelo dé diferentes pesos a diferentes partes de la secuencia de entrada, permitiéndole centrarse en las partes más relevantes de la secuencia cuando realice una predicción.

- Segunda Capa LSTM: La salida de la capa de atención se pasa a través de una segunda capa LSTM. Esto añade una capa adicional de complejidad y permite que el modelo capture relaciones temporales aún más profundas.
- Dropout: Después de la segunda capa LSTM, hay una capa de “dropout”. El dropout es una técnica de regularización que impide el sobreajuste al apagar aleatoriamente un porcentaje de neuronas en cada paso del entrenamiento.
- Capa Densa (Dense): La capa final es una capa densa con una única unidad y una función de activación. Esta capa proporciona la salida final del modelo.
- Compilación: Finalmente, el modelo se compila con un optimizador, una función de pérdida y una métrica.

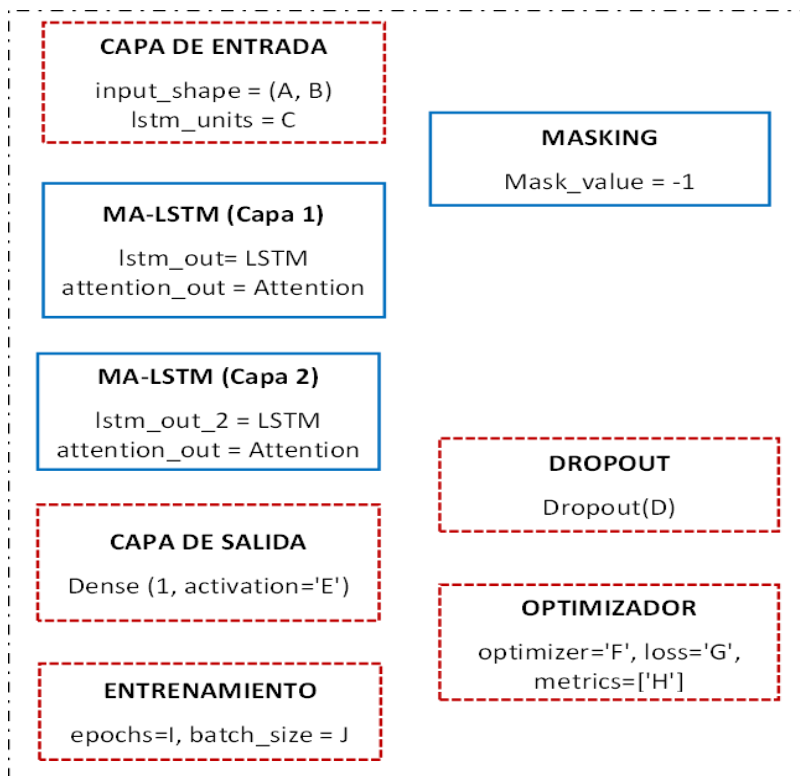
Esta arquitectura combina las capacidades de las redes LSTM para manejar secuencias temporales con la capacidad de las capas de atención para centrarse en las partes más informativas de las secuencias, ofreciendo un enfoque robusto y eficaz para la predicción de fallas basada en datos de sensores.

2.3.3 Entrenamiento y ajuste del modelo

La etapa de entrenamiento y ajuste del modelo es una de las fases más cruciales en el proceso de desarrollo de soluciones basadas en aprendizaje automático. No solo involucra alimentar el modelo con datos y esperar predicciones precisas; es un proceso iterativo y meticuloso que exige una profunda comprensión tanto del modelo en cuestión como de los datos a mano.

Dentro del ámbito de las redes neuronales, y en particular cuando se abordan problemas complejos relacionados con series temporales o datos secuenciales, no existe un único enfoque o configuración que garantice resultados óptimos en todos los escenarios. Por eso, en este proceso de entrenamiento, se explorarán varias optimizaciones adecuadas a la naturaleza única de los datos y al problema que se desea resolver.

En la Figura 32, que ilustra la arquitectura MA-LSTM utilizada para la predicción de fallas en esta tesis, es posible observar distintos recuadros, algunos de ellos en color rojo y otros en azul. Los recuadros rojos simbolizan los parámetros del modelo abiertos a modificación, elementos que se pueden ajustar para mejorar y optimizar el desempeño del modelo. Por otro lado, los recuadros en tonalidad azul representan parámetros que ya han sido preestablecidos por el código de Python y, por ende, no requieren intervención o modificación adicional.

Figura 32*Estructura de MA-LSTM*

A continuación, se presentan diferentes tablas donde se recopila las distintas configuraciones experimentadas para el modelo MA-LSTM. Esta tabla no solo proporciona una visión clara de cómo se han ajustado y modificado los parámetros en cada iteración, sino que también muestra el impacto de dichas configuraciones en el desempeño del modelo, representado por dos métricas cruciales: la precisión y el ROC.

El experimentar parte por parte con cada parámetro, permitirá comprender mejor cómo ciertos ajustes pueden influir en los resultados finales y ayudará en la decisión de qué configuración es la óptima para la predicción de fallas en el contexto específico de la predicción de fallas.

Es importante destacar que los datos que son presentados a continuación en las tablas corresponden a diferentes pruebas que se realizaron y que los valores han sido seleccionados de manera aleatoria con el propósito principal de validar el rendimiento del modelo.

- **Entrenamiento:** El proceso de entrenamiento afina un modelo de redes neuronales, siendo las épocas y el tamaño de lote factores críticos en su efectividad. Las épocas determinan cuántas veces el modelo verá todo el conjunto de datos, influyendo directamente en su convergencia. Por otro lado, el tamaño de lote determina cuántas muestras se utilizan en cada actualización de los pesos, afectando la precisión y velocidad del entrenamiento.

Experimentar con estos parámetros es de suma importancia para optimizar el rendimiento y se pueda marcar la diferencia entre un modelo subóptimo y uno altamente efectivo, como se observa en las Tabla 7 y Tabla 8.

Tabla 7

Tabla de prueba de épocas para capa de entrada del modelo

Épocas	Precisión del modelo	Rendimiento del modelo	Error
10	83.561%	0.87	5.925
100	83.561%	0.88	5.925
200	96.570%	1.00	1.234
300	98.630%	1.00	0.4937
500	96.570%	0.99	1.2343
600	95.890%	0.99	1.4812
1000	83.561%	0.87	5.925

Tabla 8

Tabla de prueba de tamaño de lote para el modelo

Tamaño de lote	Precisión del modelo	Rendimiento del modelo	Error
50	95.890%	0.99	1.4812
100	98.630%	1.00	0.4937
200	95.205%	0.99	1.7281

- **Capa de Entrada:** La capa de entrada es crucial ya que define cómo el modelo procesa los datos iniciales. El número de neuronas en esta capa determina la dimensión de la representación aprendida, afectando la capacidad del modelo para capturar patrones complejos. Ajustar el número de neuronas puede influir significativamente en el desempeño, tal como se observa en las variaciones experimentadas en la Tabla 9.

Tabla 9

Tabla de prueba de número de neuronas para capa de entrada del modelo

Número de neuronas	Precisión del modelo	Rendimiento del modelo	Error
50	98.630%	1.00	0.4937
100	93.830%	0.98	2.2218
200	92.460%	0.95	2.715

- **Dropout:** El dropout actúa como una técnica de regularización, evitando el sobreajuste. Esta técnica consiste en desactivar aleatoriamente ciertas neuronas durante el entrenamiento. Al hacer esto, se fomenta que la red se vuelva más robusta y no dependa fuertemente de cualquier neurona individual. La Tabla 10 refleja las

variaciones de rendimiento al ajustar este parámetro, evidenciando su impacto en el comportamiento del modelo.

Tabla 10

Tabla de prueba de dropout para el modelo

%Apagado de neuronas	Precisión del modelo	Rendimiento del modelo	Error
0.1	92.465%	0.98	2.7156
0.2	98.630%	1.00	0.4937
0.25	89.720%	0.88	3.7031
0.5	95.890%	1.00	1.4812

Tras analizar los datos presentados en la Tabla 10, donde se experimentó con diferentes valores de dropout, se determinó que un valor de 0.2 para el dropout es el más adecuado para el modelo.

- **Capa de salida:** La capa de salida es fundamental en una red neuronal, ya que traduce las características aprendidas a una predicción concreta. Las funciones de activación en esta capa determinan cómo se procesan esas características para emitir una predicción. ReLU, es utilizada para la regresión. Sigmoide, es preferido para clasificación binaria, devolviendo valores entre 0 y 1. Finalmente Softmax por otro lado, es ideal para clasificación multiclase, dando una distribución de probabilidad entre las clases. En la Tabla 11, se evaluó cómo diferentes funciones de activación afectan el desempeño del modelo.

Tabla 11

Tabla de prueba de activador de capa de salida para el modelo

Función de activación en Capa de salida	Precisión del modelo	Rendimiento del modelo	Error
ReLU	83.560%	0.5	5.9249
Sigmoid	98.630%	1.00	0.4937
Softmax	16.438%	0.49	30.1186

- **Función de costo en optimización:** Las funciones de costo juegan un papel importante en la formación y optimización de modelos de aprendizaje automático, sirviendo como una medida de cuán bien el modelo está realizando su tarea. Entre las más utilizadas encontramos:

Error Cuadrático Medio (ECM): Esta función calcula la diferencia cuadrática promedio entre las predicciones del modelo y los valores reales. Suele usarse en problemas de regresión por su capacidad para penalizar errores grandes. Proporciona un paisaje de optimización suave, lo que puede facilitar la convergencia del modelo.

Entropía Cruzada Categórica: Es utilizada principalmente en problemas de clasificación donde las salidas pueden pertenecer a múltiples categorías. Esta función de costo mide el desempeño de un modelo de clasificación cuyas salidas son probabilidades entre 0 y 1. Penaliza las predicciones incorrectas realizadas con alta confianza, lo que la hace ideal para problemas de predicción de fallas.

En el contexto de nuestro estudio, se realizaron experimentos variando estas funciones de costo para evaluar su impacto en el desempeño del modelo. Los resultados de estas pruebas pueden consultarse en la Tabla 12.

Tabla 12

Tabla de prueba de función de costo para el modelo

Función de costo	Precisión del modelo	Rendimiento del modelo	Error
Error Cuadrático Medio	97.940%	0.99	0.74062
Entropía Cruzada Categórica	98.630%	1.00	0.4937

- Optimizador: El entrenamiento de modelos de aprendizaje profundo se basa en la optimización iterativa de una función de costo. Los optimizadores son herramientas que determinan cómo se actualizan los pesos del modelo a partir de esta función. A continuación, se presentan varios optimizadores populares:

RMSprop: Se basa en la adaptación de las tasas de aprendizaje. Es una extensión del Adagrad que resuelve su drástica reducción de la tasa de aprendizaje. Es especialmente bueno para redes recurrentes.

SGD (Stochastic Gradient Descent): Es el optimizador tradicional. Aunque es más lento que los otros algoritmos, su convergencia es más garantizada. A menudo se combina con momentum para acelerar el proceso.

ADAM (Adaptive Moment Estimation): Combina las ventajas de Adagrad y RMSprop, y es efectivo en la práctica. Se adapta al tamaño de los gradientes, lo que lo hace adecuado para problemas con recursos limitados o grandes conjuntos de datos.

Adadelta: Es una extensión más robusta de Adagrad que adapta las tasas de aprendizaje basadas en una media móvil del reciente rendimiento del gradiente.

Cada optimizador tiene su nicho donde brilla, dependiendo de la naturaleza del problema y de los datos. Al entrenar modelos, es crucial experimentar con varios optimizadores para encontrar el más adecuado. En este contexto, en la Tabla 13, se llevaron a cabo pruebas variando estos optimizadores para evaluar su impacto en el rendimiento del modelo.

Tabla 13

Tabla de prueba de optimizador para el modelo

Optimizador de modelo	Precisión del modelo	Rendimiento del modelo	Error
RMSprop	90.411%	0.99	3.456
Gradiente Descendiente Estocástico (SGD)	83.560%	0.88	5.924
ADAM	98.630%	1.00	0.4937
Adadelta	83.560%	0.83	5.924


2.4 Evaluación del modelo

Tras determinar la configuración óptima de los parámetros del modelo, presentada en la Figura 33, se debe llevar a cabo una evaluación rigurosa de su desempeño. Esta etapa garantiza que el modelo no solo se ajusta a los datos de entrenamiento, sino que también puede generalizar adecuadamente a datos no vistos. Es imperativo someter al modelo a métricas de evaluación que validen aspectos como precisión, sensibilidad y capacidad de recall, dadas las necesidades específicas del problema que se aborda.

Dichas métricas ofrecen una visión completa del comportamiento del modelo en variadas condiciones. Especialmente en la detección de fallos, es importante asegurarse de que el modelo detecte anomalías de manera correcta y minimice los falsos positivos. Esta evaluación es crucial para confirmar la efectividad y confiabilidad del modelo MA-LSTM en su tarea propuesta.

Figura 33

Parámetros óptimos de Red Neuronal MA-LSTM



2.4.1 Métricas de evaluación para confiabilidad del modelo

La confiabilidad de un modelo de predicción, especialmente cuando se trata de determinar eventos tan críticos como fallas en equipos, es muy importancia debido a los costos que se podrían originar por tener de forma consecutiva falsos positivos. En este contexto, se evaluará la confiabilidad del modelo con métricas de evaluación robustas y relevantes presentadas a continuación:

- Exactitud (o accuracy): Representa la proporción de predicciones correctas respecto al total de predicciones realizadas. Matemáticamente, se observa en la Ecuación 6.

$$\text{Accuracy} = \frac{\text{Número total de predicciones correctas}}{\text{Número total de predicciones}} * 100\% \quad [6]$$

La importancia de la exactitud radica en su interpretación directa: un modelo con una exactitud del 100% predice correctamente todas las observaciones. En términos generales, para evaluar si un valor de exactitud es "bueno" o no, se puede considerar lo siguiente:

Excelente: > 95%

Muy bueno: 90% - 95%

Bueno: 80% - 90%

Aceptable: 70% - 80%

Pobre: < 70%

Para el modelo, se logró una exactitud o accuracy de 0.983 o 98.3%, lo cual se considera como excelente. Sin embargo, es crucial considerar diferentes contextos como el balanceo de las clases y otras métricas complementarias para tener una imagen completa del rendimiento del modelo. Ya que esta métrica es susceptible cuando el conjunto de datos es desequilibrado, una clase es mucho más frecuente que la otra. Ante esta situación, el F1-score es especialmente valioso en situaciones de desbalance de clases.

- F1-score: La importancia del F1-Score radica en su capacidad para representar en una sola métrica dos aspectos cruciales del rendimiento de un modelo: la precisión (cuántos de los elementos identificados como positivos eran realmente positivos) y la exhaustividad (cuántos de los verdaderos positivos fueron correctamente identificados por el modelo). Se calcula utilizando la fórmula de la Ecuación 7:

$$\text{F1 - score} = 2 \times \frac{\text{Precisión} \times \text{Exhaustividad (Recall)}}{\text{Precisión} + \text{Exhaustividad (Recall)}} \quad [7]$$

El F1-Score proporciona un equilibrio entre precisión y exhaustividad. En situaciones donde ambas son importantes, el F1-Score es una métrica excelente para evaluar la eficiencia global del modelo. En términos generales, para evaluar si un valor de exactitud es "bueno" o no, se puede considerar lo siguiente:

Excelente: > 0.90

Muy bueno: 0.80 - 0.90

Bueno: 0.70 - 0.80

Aceptable: 0.60 - 0.70


Pobre: < 0.60

Para el modelo, se logró un F1-Score de 0.9565, por lo cual se clasificaría como excelente. Sin embargo, es importante validar el rendimiento del modelo, por lo cual optamos por la siguiente métrica:

- Curva ROC y el área bajo la curva (AUC): Son métricas que proporcionan una visión completa del rendimiento del modelo en todos los umbrales de clasificación posibles. Un AUC cercano a 1 indica un modelo perfecto, mientras que un valor cercano a 0.5 sugiere que el modelo no tiene capacidad discriminativa. Para el modelo desarrollado se utiliza el ROC obteniendo la gráfica presentada en la Figura 34. Asimismo, se obtuvo un AUC = 0.9836.

Figura 34

ROC de modelo para predicción de fallas



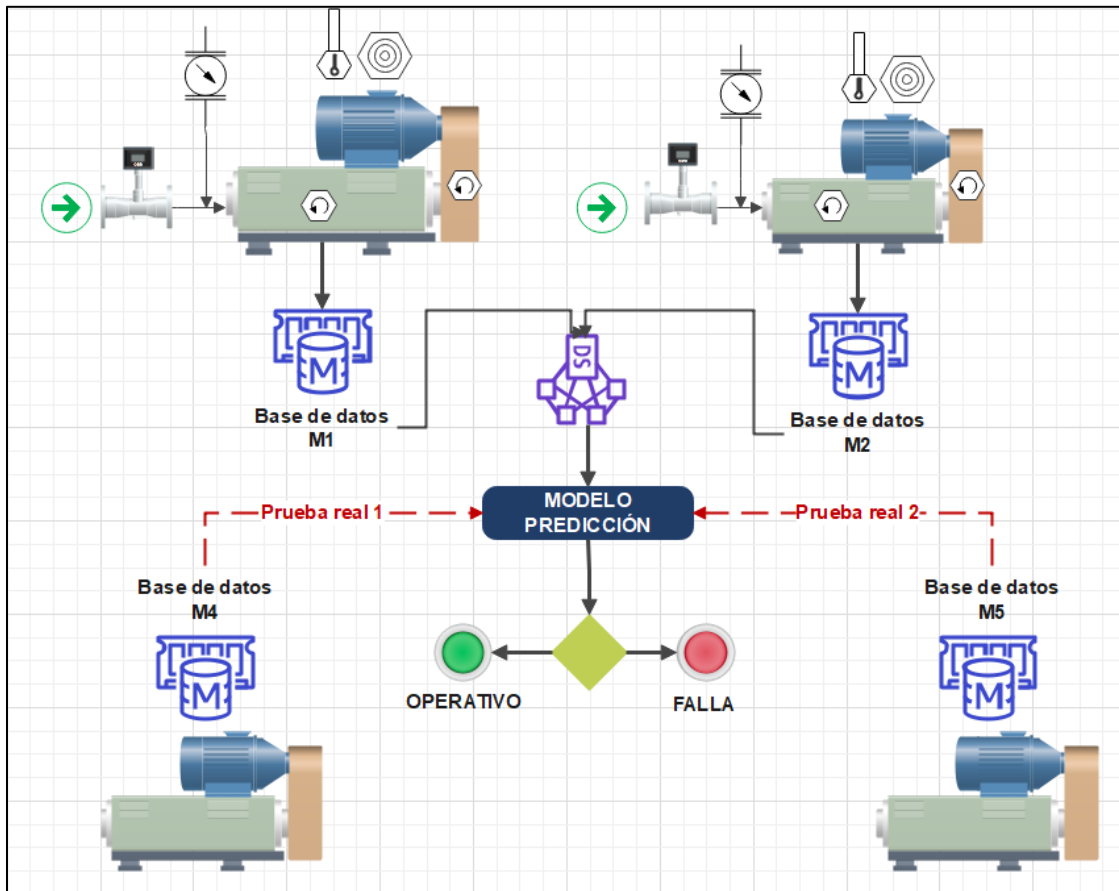
Estas métricas dan una imagen clara y comprensiva de la confiabilidad del modelo al predecir fallos, permitiendo asegurarse de que mi sistema propuesto es preciso, robusto y confiable en diversas condiciones.

2.5 Pruebas y validación del modelo en un entorno real

Si bien se desarrollaron diversas pruebas de validación del modelo, la auténtica medida de confiabilidad de un modelo radica en su capacidad para actuar con precisión en datos no vistos, y sobre todo de escenarios del mundo real. Con esta premisa, procederemos a poner a prueba el modelo de MA-LSTM en dos bases de datos auténticas del año 2022. Estas bases de datos provienen de distintas plantas industriales del sector pesquero y se denotan como M4 y M5, como se observa en la Figura 35. El uso de datos reales brinda un marco robusto para evaluar la generalización y aplicabilidad práctica del modelo.

Figura 35

Flujo de ingreso a modelo de predicción



La cantidad de registros, características y la distribución de variables de las bases de datos, que se introducirán al modelo, son aspectos cruciales para interpretar correctamente los resultados. Asimismo, es necesario identificar y gestionar cualquier valor NaN o faltante, pues una base de datos desequilibrada puede influir de manera significativa en las predicciones. Es por ello por lo que, antes de someter los datos a cualquier proceso de análisis, se realiza una revisión de la estructura y principales estadísticos.


Se debe adaptar adecuadamente las bases de datos M4 y M5 antes de introducirlas en el modelo. Se tiene que dada la estructura intrínseca del modelo MA-LSTM, que espera una secuencia estandarizada de datos, es necesario aplicar "padding" para uniformar las secuencias de entrada. Además, el normalizar los datos para asegurar que el modelo interprete correctamente las variaciones y tendencias en ellos. Una vez que estos pasos de preprocesamiento están completos, ya puedo introducir los datos en el modelo y generar predicciones. Al culminar este proceso, enfrente las predicciones de fallas del modelo con los valores reales registrados en los motores para evaluar su precisión y fiabilidad.

2.5.1 Comparación con métodos tradicionales de detección de fallas

Para comprender plenamente la eficacia y las mejoras introducidas por el modelo MA-LSTM, es fundamental cotejarlo con enfoques convencionales en el ámbito de detección de fallas. En este segmento, se enfrentarán las predicciones de fallas generadas por un modelo estándar de LSTM con el modelo desarrollado con MA-LSTM. A través de esta comparación directa, se evaluará no solo la precisión, sino también otras métricas críticas, para discernir las ventajas tangibles y los avances logrados con el uso de la arquitectura MA-LSTM en relación con los métodos tradicionales. Para la métrica de LSTM se tomará como base el estudio de Vera et al. (2020), por lo cual la estructura del modelo sería la presentada en la Figura 36:

Figura 36

Estructura de LSTM para predicción de fallas con sensores



El modelo LSTM desarrollado cuenta con una estructura de dos capas principales: la primera con 50 neuronas y la segunda con 30 neuronas, ambas utilizando la función de activación ReLU. Para prevenir el sobreajuste y mejorar la generalización, se ha incorporado una capa de dropout con un 20% de apagado de neuronas. La capa de salida utiliza la función de activación sigmoide, lo que es indicativo de que el modelo realiza clasificaciones binarias. Para el proceso de entrenamiento, se utiliza un optimizador de entropía cruzada binaria. Es una función de pérdida utilizada comúnmente en problemas de clasificación binaria. Finalmente, se ha establecido un número de épocas y un tamaño de lote de 100. En la Tabla 14 se representan las métricas obtenidas.

Tabla 14

Métricas de modelo LSTM

	Exactitud (Accuracy)	F1-Score	ROC
Modelo LSTM	94.6666%	0.76	0.83

2.5.2 Análisis e interpretación de resultados


Después de someter los modelos a rigurosas pruebas con conjuntos de datos reales y simulados, es imperativo discernir la calidad, relevancia y aplicabilidad de las predicciones generadas. A través de este análisis, no sólo se valida la efectividad del modelo, sino que también se obtienen aprendizajes valiosos que pueden guiar futuras optimizaciones y aplicaciones en entornos industriales. Se debe rescatar siempre que, “mediante el análisis, se

extraiga la información relevante, identificando patrones y tendencias que serán vitales para la creación y comprensión de los modelos de inteligencia artificial” (Luengo, 2020).

Un aspecto crítico de esta fase de pruebas es la utilización de la matriz de confusión. Esta herramienta permite discernir detalladamente cómo el modelo clasifica las instancias en términos de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos. Esta información es invaluable para entender la precisión real y las áreas potenciales de mejora. Para la base de datos M4, se detallan los resultados de la evaluación y se ilustran en las Figura 37 y Figura 38.

Figura 37


Resultado de matriz de confusión de base de datos M4 con modelo MA-LSTM



En el análisis realizado utilizando la matriz de confusión para el modelo MA-LSTM, se observó una detección precisa en la mayoría de los casos. De 200 predicciones positivas, hubo 5 instancias erróneamente clasificadas, lo que se conoce como falsos positivos. Además, al evaluar los casos negativos, se identificó 1 falso negativo de un total de 11. Estos resultados nos proporcionan una perspectiva sobre la eficacia de mi modelo en la identificación fallas.

Figura 38

Resultado de matriz de confusión de base de datos M4 con modelo LSTM




Al analizar los resultados de la matriz de confusión para el modelo LSTM, se identifica una mayor cantidad de clasificaciones erróneas en comparación con el modelo MA-LSTM. De las 181 predicciones positivas realizadas por el modelo, 19 resultaron ser falsos positivos. Más preocupante aún, el modelo no logró identificar correctamente ninguna de las fallas reales, resultando en 11/11 falsos negativos. Estos hallazgos ponen de relieve áreas de mejora y consideración para futuras iteraciones del modelo.

A continuación, se detallan los resultados específicos de la evaluación realizada para la base de datos M5.

Al analizar los resultados de la matriz de confusión, en la Figura 39, para el modelo MA-LSTM aplicado a la base M5, encontramos que el modelo demostró ser bastante preciso. De un total de 247 predicciones positivas, solo 4 fueron clasificadas erróneamente como falsos positivos. Además, el modelo fue excepcionalmente bueno en identificar casos negativos, ya que no se registraron falsos negativos de un total de 9.

Figura 39


Resultado de matriz de confusión de base de datos M5 con modelo MA-LSTM



Por otro lado, los resultados obtenidos al aplicar el modelo LSTM tradicional a la base M5, en la Figura 40, fueron significativamente diferentes. De las 247 predicciones positivas, el modelo cometió errores en 114 de ellas, clasificándolas como falsos positivos. Además, el modelo no fue capaz de identificar correctamente ningún caso negativo, resultando en 9 falsos negativos de un total de 9. Estos resultados indican que, al menos para la base M5, el modelo LSTM convencional no es tan eficiente o confiable como el modelo MA-LSTM.

Figura 40

Resultado de matriz de confusión de base de datos M5 con modelo LSTM



Finalmente, se consolidarán los resultados a través de un resumen presentando en la Tabla 15 que incluirá métricas para validar el comportamiento del modelo con nuevos datos. Estas métricas proporcionarán una imagen holística de la eficacia de mi modelo con un conjunto de datos reales, solidificando nuestra comprensión de su aplicabilidad en entornos industriales prácticos.

Tabla 15

Métricas de validación de modelo con datos reales

Base de datos	MA - LSTM			LSTM		
	Exactitud (Accuracy)	ROC	F1-Score	Exactitud (Accuracy)	ROC	F1-Score
M4 (139 Ton/h)	98.2142%	0.99	0.946938	53.8461%	0.49	0.500000
M5 (80 Ton/h)	95.9537%	0.95	0.922222	46.1538%	0.49	0.136363



Conclusiones

Conforme a los objetivos establecidos, el estudio ha resultado exitoso al establecer un puente desde el estado del arte hasta la validación empírica. Esta investigación ha evidenciado la eficacia del MA-LSTM en contextos industriales reales, debido a sus métricas como la exactitud = 98.3% y un AUC = 0.9836, lo que subraya su destacada precisión en la predicción de fallas de motores eléctricos.

Se concluye que la validación del modelo de MA-LSTM con datos no vistos confirmó su robustez y capacidad de generalización. La notable área bajo la curva ROC de 1 y el F1-score de 0.9565 demostraron que el modelo no solo es preciso, sino que también mantiene un balance adecuado entre sensibilidad y especificidad.

Los resultados del estudio destacan un avance en la detección temprana de fallas en motores eléctricos con procesos no continuos. De 247 predicciones positivas, solo 4 fueron falsos positivos y ningún falso negativo de 9. Estos datos refuerzan la eficacia y fiabilidad del modelo MA-LSTM.

A partir del análisis, se observa que, aunque el modelo LSTM inicialmente presentó un accuracy del 94.666% y un ROC de 0.83, su rendimiento disminuyó significativamente al enfrentar data de secuencia variable, logrando solo un 46.1538% y 0.136363, de accuracy y F1-score respectivamente. Esto destaca sus limitaciones ante este tipo de desafíos.

Lo anterior lleva a pensar que una elección precisa de modelos de IA influye directamente en la eficiencia de monitoreo predictivo. El MA-LSTM superó notablemente al LSTM tradicional en detección de fallas, incluso en las pruebas con datos nuevos, con una ventaja de hasta un 44% de exactitud.

Esta investigación ha cumplido con éxito los objetivos propuestos, estableciendo el modelo MA-LSTM como una herramienta avanzada y confiable en el campo de la detección de fallas de motores eléctricos y presentando un aporte significativo para el desarrollo de estrategias de mantenimiento predictivo en la industria.

En virtud de lo estudiado, se puede afirmar que la investigación ha logrado sentar una base sólida para futuras exploraciones en el campo, y ha establecido un estándar al que otros modelos y estudios pueden aspirar, se recomienda complementar con un clasificador de fallas y una sincronización de ingreso de data automática y/o implementación a PLC.



Referencias

- Alexandropoulos, S. N. (2019). Data preprocessing in predictive data mining. *Knowledge Engineering Review*, 34, 1-33. doi:<https://doi.org/10.1017/s026988891800036x>
- Alfa Laval. (29 de Octubre de 2019). Alfa Laval. Obtenido de [alfalaval.it: https://www.alfalaval.it/prodotti/separazione/separatori-centrifughi/decanter/olive-oil-x/](https://www.alfalaval.it/prodotti/separazione/separatori-centrifughi/decanter/olive-oil-x/)
- AlShorman, O. e. (2020). A Review of Artificial Intelligence Methods for Condition Monitoring and Fault Diagnosis of Rolling Element Bearings for Induction Motor. *Hindawi: Shock and Vibration*, 1-20.
- Alzubaidi, L., Zhang, J., & Humaidi, A. e. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 1-74.
- Antonino-Daviu, J. Q.-L.-A. (2018). Advanced Analysis of Motor Currents for the Diagnosis of the Rotor Condition in Electric Motors Operating in Mining Facilities. *IEEE Transactions on Industry Applications*, 3934-3936.
- AQR Capital Management. (2018). pandas - Python Data Analysis Library. Obtenido de [Pydata.org: https://pandas.pydata.org/about/](https://pandas.pydata.org/about/)
- Berente, N., Gu, B., Recker, J., & Santhanam, R. (2021). Managing artificial intelligence. *Mis Quarterly*, 2-3.
- Berge, J. (17 de Julio de 2019). Pervasive Predictive Maintenance Made Possible - A Day in a Life. Obtenido de [Linkedin Web site: https://www.linkedin.com/pulse/pervasive-predictive-maintenance-made-possible-day-life-jonas-berge/?trackingId=b2xIOdT2SFO1mo0rT%2BJpfA%3D%3D](https://www.linkedin.com/pulse/pervasive-predictive-maintenance-made-possible-day-life-jonas-berge/?trackingId=b2xIOdT2SFO1mo0rT%2BJpfA%3D%3D)
- Bessous, N. Z. (2017). Static eccentricity fault detection of induction motors using MVSA, MCSA and discrete wavelet transform (DWT). . 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B), 1-9.
- Bokrantz, J., Skoogh, A., Berlin, C., Wuest, T., & Stahre, J. (2020). Smart Maintenance: a research agenda for industrial maintenance management. *International Journal of Production Economics* 224, 1-14.
- Bokrantz, J., Skoogh, A., Berlin, C., Wuest, T., & Stahre, J. (2020). Smart Maintenance: an empirically grounded conceptualization. *International Journal of Production Economics* 223, 1-17.
- Ceruti, A., Marzocca, P., Liverani, A., & Bil, C. (2019). Maintenance in aeronautics in an Industry 4.0 context: The role of Augmented Reality and Additive Manufacturing. *Journal of Computational Design and Engineering* Vol. 6, 516-526.

- Chapman, S. J. (2012). *Fundamentos de Maquinaria Eléctrica*. México, D.F.: McGraw-Hill Education.
- Christoffersen, H. D. (13 de Julio de 2013). MAN Diesel & Turbo. Obtenido de Man-es.com: https://www.man-es.com/docs/default-source/service-letters/sl2013-582.pdf?sfvrsn=bbb8d1e9_4
- Cournapeau, D. e. (2016). Scikit-learn: Preprocessing data. Obtenido de Scikit-learn.org: <https://scikit-learn.org/stable/modules/preprocessing.html#preprocessing>
- Cynthia, R., Chaofan, C., Zhi, C., Haiyang, H., & Lesia, S. (2022). Interpretable machine learning: Fundamental principles and 10 grand challenges. *Statistics Surveys*, 4-11. doi:<https://doi.org/10.1214/21-SS133>
- Dalzochio, J. e. (2020). Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Computers in Industry* vol. 123, 1-15.
- Dmitrović, S. (2023). What Is C++?. In: *Modern C++ for Absolute Beginners*. Berkeley: Apress.
- Dong, Yuqing, L., Huailiang, Z., Rixin, W., & Minqiang, X. (2021). A new dynamic model and transfer learning based intelligent fault. *ISA Transactions*, 1-2.
- Fitch, J. (28 de Noviembre de 2016). Noria Corporation. Obtenido de Machinerylubrication.com: <https://www.machinerylubrication.com/Read/30672/world-class-tpm>
- Flottweg AG. (24 de Octubre de 2010). Instrucciones para el manejo DECANTER Z 73 N°010.362.15. Vilsbiburg.
- Guerrero, A., Sánchez, O., Moreno, J., & Ortega, A. (2003). *Electrotecnia*. Madrid: McGraw-Hill.
- Hao, J., & Ho, T. K. (2019). Machine learning made easy: A review of Scikit-learn package in Python programming language. *Journal of educational and behavioral statistics: a quarterly publication sponsored by the American Educational Research Association and the American Statistical Association*, 348-361.
- Helm, J. S. (2020). *Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions*. *Curr Rev Musculoskelet Med*, 1-2.
- Hughes, A., & Drury, B. (2019). *Motores eléctricos y accionamientos (quinta edición)*. Newnes.
- International Organization for Standardization (ISO). (Febrero de 2002). ISO 13373-1:2002. Obtenido de iso.org: <https://www.iso.org/standard/21831.html>
- International Organization for Standardization (ISO). (Febrero de 2009). ISO 10816-3:2009. Obtenido de iso.org: <https://www.iso.org/standard/50528.html>

- IPEMAN. (21 de Abril de 2021). Análisis de Fallas de Equipos – AMEF (FMEA) Failure Mode and Effects Analysis. Obtenido de ipeman.com: <https://www.ipeman.com/analisis-de-fallas-de-equipos-amef-fmea-failure-mode-and-effects-analysis/>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electron Markets*, 685–695.
- Kök, A. (1 de Julio de 2022). Not Tutuyoruz. Obtenido de Medium website: <https://medium.com/nottutuyoruz/jupyter-notebook-vs-google-colab-d1a0bb3ae4ba>
- Kumar, P., & Shankar, A. (2020). Review on Machine Learning Algorithm Based Fault Detection in Induction Motors. *Archives of Computational Methods in Engineering*, 1-12.
- Llacua, J. (2020). Procedimiento de análisis predictivo en motores de inducción mediante la transformada de Hilbert. *Universidad Continental*, 39-40.
- Luengo, J. G.-G.-G. (2020). *Big data preprocessing*. Cham, Switzerland: Springer Nature Switzerland AG. doi:<https://doi.org/10.1007/978-3-030-39105-8>
- Ma, L., Zhao, Y., Wang, B., & Shen, F. (15 de Mayo de 2023). A Multistep Sequence-to-Sequence Model With Attention LSTM Neural Networks for Industrial Soft Sensor Application. *IEEE Sensors Journal*, 23(10), 10801-10813. doi:10.1109/JSEN.2023.3266104.
- Mahesh, B. (1 de Enero de 2019). Machine Learning Algorithms -A Review. *International Journal of Science and Research (IJSR)*, 381-386.
- Maun, U. (25 de Julio de 2018). Latest News, Updates and Events. Obtenido de Seasiainfotech Web site: <https://www.seasiainfotech.com/blog/java-vs-python-vs-r-language/>
- Mazurowski, M. A., Buda, M., Saha, A., & Bashir, M. R. (2019). Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *Journal of magnetic resonance imaging*, 939-954.
- Menesklou, P., Sinn, T., Nirschl, H., & Gleiss, M. (2021). Grey Box Modelling of Decanter Centrifuges by Coupling a Numerical Process Model with a Neural Network. *Minerals*, 5.
- Menesklou, P., Sinn, T., Nirschl, H., & Gleiss, M. (2021). Scale-Up of Decanter Centrifuges for the Particle Separation and Mechanical Dewatering in the Minerals Processing Industry by Means of a Numerical Process Model. *Minerals*, 3-4.
- Nilsson, D., Sjöberg, M., & Widén, P. (2007). To increase the efficiency in sugar and ethanol industries by using a decanter centrifuge. *Universidad de Skövde*, 19.
- Potenciahp. (1 de Noviembre de 2019). Motor de corriente CONTINUA y ALTERNA. Obtenido de Youtube: <https://www.youtube.com/watch?v=7K6hJFqZp-Q>

- Prudnikov, A. B. (2023). The results of the production tests of the method for diagnosing the eccentricity of the rotor of an asynchronous electric motor. *E3S Web of Conferences*, 1-2.
- R Core Team. (16 de Junio de 2023). An Introduction to R. Obtenido de r-project.org: <https://cran.r-project.org/doc/manuals/r-release/R-intro.pdf>
- R., J. (16 de Enero de 2020). ComoFunciona. Obtenido de Como-funciona Web site. : <https://como-funciona.co/un-rotor/>
- Ramos-Galarza, C. (2021). Diseños de investigación experimental. *CienciAmérica*, 1-7. doi:10.33210/ca.v10i1.356
- Ray, S. (2019). A Quick Review of Machine Learning Algorithms. 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon) (págs. 35-39). Faridabad: IEEE.
- Ruiz-Sarmiento, J.-R. e. (2020). A predictive model for the maintenance of industrial machinery in the context of industry 4.0. *Engineering Applications of Artificial Intelligence* Vol. 87, 1-15.
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 3-4.
- Schildt, H. (2022). *Java: A Beginner's Guide*. 9th ed. New York: McGraw Hill.
- Silvestri, L., & Forcina, A. (2020). Maintenance transformation through Industry 4.0 technologies: A systematic literature review. *Computers in Industry* 123, 1-16.
- Soares, D. e. (2022). Detección De Fallas Mecánicas Mediante "Machine Learning", Utilizando El Clasificador "Random Forest". XV Congreso Iberoamericano de Ingeniería Mecánica, 1-8.
- Soklaski, R., Goodwin, J., Brown, O., Yee, M., & Matterer, J. (2022). Tools and Practices for Responsible AI Engineering. MIT Lincoln Laboratory, 1-8.
- Teimouri, M., & Kornejady, A. (2020). The dilemma of determining the superiority of data mining models: optimal sampling balance and end users' perspectives matter. *Bulletin of Engineering Geology and the Environment*(79), 1707–1720. doi:<https://doi.org/10.1007/s10064-019-01687-9>
- Toscano, L., & Mario, J. (2020). Procedimiento de análisis predictivo en motores de inducción mediante la transformada de Hilbert. *Universidad Continental*, 125. doi:<https://hdl.handle.net/20.500.12394/7609>
- Tractian. (13 de Agosto de 2021). Tractian Tecnología Industrial S. DE R.L. Obtenido de Tractian Website: <https://tractian-webpage.s3.amazonaws.com/ebooks/es/ebook-motores-electricos.pdf>

- Vera, M., López-Ortega, O., Ramos-Velasco, L., Ortega-Mendoza, R., Neri, B., & Zuñiga, N. (2020). Diagnostico de fallas mediante una LSTM y una red elástica. *Revista Iberoamericana de automática e informática industrial (RIAI)*, 164-175. doi:<https://doi.org/10.4995/riai.2020.13611>
- WEG. (02 de Setiembre de 2020). WEG Motor Scan. Obtenido de Wnology.io: <https://files.wnology.io/5eed0126ec59a70008902b45/guides/motor-scan.pdf>
- Weg. (2022). Brasil Patente nº V2.2.20. Obtenido de <https://mfm.wnology.io/page/dash/626ae385384c43eca6515d43?dashType=analytics-vibration>
- WEG. (2023 de Febrero de 2023). W21 A.R.Plus/High Efficiency 110 kW 6P 315S/M 3F 380-400-415/660-690//460 V 50 Hz IC411 - TEFC - B3T. Obtenido de [weg.net](https://www.weg.net/):
- Witold, P., & Shyi-Ming, C. (2020). *Deep Learning: Concepts and Architectures*. Warsaw: Springer Cham.
- Wu, F., & El-Refaie, A. (2019). Permanent magnet vernier machine: a review. *IET Electric Power Applications* vol. 13, 127-137.
- Yoshida, I., & Hiroshi, A. (2021). Diseño e implementación de un sistema de diagnóstico de fallas para la inspección y detección de fallas en componentes de procesos industriales utilizando un robot móvil y algoritmos de inteligencia artificial. *Pontificia Universidad Católica del Perú*, 134. doi:<http://hdl.handle.net/20.500.12404/17779>
- Zhao, S., Blaabjerg, F., & Wang, H. (2021). An Overview of Artificial Intelligence Applications for Power Electronics Vol. 36. *IEEE Transactions on Power Electronics*, 4633-4658.




Apéndices





Apéndice A. Diagrama de Flujo de Proyecto: "Análisis de fallas de motor eléctrico de decantadores centrífugos en el rubro pesquero"



Apéndice B. Modelo de predicción para detección de fallas en motores eléctricos de decantadores centrífugos

```

LIBRERIA
# Tratamiento de datos
#=====
import pandas as pd
from pandas.core import describe import numpy as np
from sklearn.datasets import load_diabetes from google.colab import files
# Gráficos
#=====
import matplotlib.pyplot as plt from matplotlib import style
import seaborn as sns
# Preprocesado y análisis
#=====
import statsmodels.api as sm from scipy import stats
from scipy.stats import pearsonr from scipy.stats import kstest
from scipy.stats import shapiro
# RNN -> MODELO LSTM
#=====
from keras.models import Sequential
from keras.layers import LSTM, Dropout, Dense, Masking, Embedding from
keras.optimizers import Adam
from sklearn.model_selection import train_test_split from
sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.preprocessing.sequence import pad_sequences
*CARGA DE DATOS *
##CARGAR DOCUMENTOS EXCEL EN GOOGLE COLAB
uploaded = files.upload()
Modelo.xlsx
Modelo.xlsx(application/vnd.openxmlformats-
officedocument.spreadsheetml.sheet) - 325752 bytes, last modified: 17/8/2023
- 100% done
Saving Modelo.xlsx to Modelo.xlsx
##CONVERTIR EXCEL A DATA FRAME
file_path = next(iter(uploaded))
df = pd.read_excel(file_path, sheet_name='MOD1')
PREPROCESAMIENTO DE DATOS
# CANTIDAD TOTAL DE DATOS
total_data = df.size
print(f'Total de datos (sin col item): {total_data}')

```

```

# CANTIDAD DE DATOS FALTANTES
missing_data = df.isna().sum().sum()
print(f'Datos faltantes: {missing_data}')

Total de datos (sin col item): 8228 Datos faltantes: 0
#ESTADISTICOS POR VARIABLES
summary = pd.DataFrame()
summary['count'] = df.count()
summary['missing'] = df.isna().sum() print(summary)
#ELIMINAMOS LAS FILAS FALTANTES
df = df.dropna()
missing_data = df2.isna().sum().sum()
print (f'Datos faltantes ACTUAL: {missing_data}')
df1 = df.drop(columns=['ID_MOTOR','SECUENCIA'])
# Crear un nuevo DataFrame para almacenar el resumen de estadísticas summary
= pd.DataFrame()
summary['mean'] = df1.mean() print(summary)
#CALCULAR CANTIDAD DE FALLOS [1] O NO FALLOS [0]
fallo_counts = df['MOTOR_FALLO'].value_counts() # Crear la gráfica de pie CON
%
#plt.pie (fallo_counts, labels=fallo_counts.index, autopct='%1.1f%%')
# Crear la gráfica de pie CON VALORES
plt.pie(fallo_counts, labels=fallo_counts.index, autopct=lambda p:
'{:.0f}'.format(p * sum(fallo_counts) / 100))
# Asegurar que la gráfica se muestre como un círculo plt.axis('equal')
# Agregar título
plt.title('Distribución de Fallos') # Mostrar la gráfica
plt.show()
#VALIDAR DISTRIBUCIÓN DE DATOS
df1.hist(figsize= (15,13))
# Preprocesamiento de los datos
#=====
df2 = df.drop(columns=['SECUENCIA'])
# Excluir la columna ID_MOTOR y Motor_Fallo del escalamiento features =
df2.drop(columns=['ID_MOTOR', 'MOTOR_FALLO'])
scaler = MinMaxScaler()
scaled_features = scaler.fit_transform(features)
df_scaled = pd.DataFrame(scaled_features, columns=features.columns)
df2[features.columns] = scaled_features
# Creación de secuencia
def create_sequences(df, motor_id, seq_length):

```

```

motor_data = df2[df2['ID_MOTOR'] == motor_id].drop(columns=['ID_MOTOR']) X =
[]
y = []
for i in range(len(motor_data) - seq_length + 1):
X.append(motor_data.iloc[i:i+seq_length,
:-1].values)
y.append(motor_data.iloc[i+seq_length-1, -1])
return X, y
X_M1, y_M1 = create_sequences(df, 'M1', 14) X_M2, y_M2 = create_sequences(df,
'M2', 8)
X = X_M1 + X_M2
y = y_M1 + y_M2
# PADDING
from tensorflow.keras.preprocessing.sequence import pad_sequences
# Asumiendo que X_M1 y X_M2 son las secuencias de entrada creadas para cada
motor X_all = X_M1 + X_M2
X_padded = pad_sequences(X_all, padding='post', dtype='float32',value=-1.0)
y = np.array(y)
## División en entrenamiento y prueba
X2_train, X2_test, y2_train, y2_test = train_test_split(X_padded, y,
test_size=0.2, random_state=123)
# ENTRENAMIENTO DE MODELO
#-----
import tensorflow as tf
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Input, LSTM, Dense, Dropout, Attention,
Masking
input_shape = (None, 8) lstm_units = 100
inputs = Input(shape=input_shape)
masking = Masking(mask_value=-1.0)(inputs)
lstm_out, _, _ = LSTM(lstm_units, return_sequences=True,
return_state=True)(masking)
attention_out =
Attention(use_scale=True)([lstm_out, lstm_out])
lstm_out_2 = LSTM(lstm_units)(attention_out) dropout_out =
Dropout(0.2)(lstm_out_2)
outputs = Dense(1, activation='sigmoid')(dropout_out)
model = Model(inputs=inputs, outputs=outputs)
model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy']) model.summary()
Model: "model"
Layer (type) Output Shape Param # Connected to

```

```

=====
input_1 (InputLayer) [(None, None, 8)] 0 []
masking (Masking) (None, None, 8) 0 ['input_1[0][0]']
lstm (LSTM) [(None, None, 100),
            (None, 100), 43600 ['masking[0][0]']
            (None, 100)]
attention (Attention)
            (None,
            None,
            100)
            1
            ['lstm[0][0]',
            'lstm[0][0]']
lstm_1 (LSTM) (None, 100) 80400 ['attention[0][0]']
dropout (Dropout) (None, 100) 0 ['lstm_1[0][0]']
dense (Dense) (None, 1) 101 ['dropout[0][0]']
=====
Total params: 124,102
Trainable params: 124,102
Non-trainable params: 0
history = model.fit(X2_train, y2_train, epochs=300, batch_size=100,
validation_data=(X2_test, y2_test))
# VALIDACION DEL MODELO
#=====
y_pred_probs = model.predict(X2_test)
5/5 [=====] - 3s 18ms/step
y_pred = (y_pred_probs > 0.5).astype(int) from sklearn.metrics import
accuracy_score
accuracy = accuracy_score(y2_test, y_pred) print("Accuracy:", accuracy)
Accuracy: 0.8356164383561644
from sklearn.metrics import roc_curve, auc import matplotlib.pyplot as plt
# Calcular la curva ROC
fpr, tpr, thresholds = roc_curve(y2_test, y_pred_probs)
# Calcular el AUC
roc_auc = auc(fpr, tpr)
# Graficar la curva ROC plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label='ROC curve (area = %0.2f)'
% roc_auc) plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])

```

```

plt.xlabel('False Positive Rate') plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic (ROC)') plt.legend(loc="lower
right")
plt.show()
from sklearn.metrics import roc_auc_score
auc = roc_auc_score(y2_test, y_pred) print(f"AUC: {auc:.4f}")
from sklearn.metrics import log_loss
error = log_loss(y2_test, y_pred)
print(f"Entropía Cruzada: {error}")
from sklearn.metrics import f1_score
f1 = f1_score(y2_test, y_pred) print(f"F1-score: {f1:.4f}")
F1-score: 0.8421
##otras metricas
import matplotlib.pyplot as plt
plt.plot(history.history['loss'], label='Training Loss')
plt.plot(history.history['val_loss'], label='Validation Loss') plt.legend()
plt.show()
from sklearn.metrics import confusion_matrix import matplotlib.pyplot as plt
import seaborn as sns
cm = confusion_matrix(y2_test, y_pred) plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='g', cmap='Blues', cbar=False)
plt.xlabel('Predicted labels') plt.ylabel('True labels')
plt.title('Confusion Matrix') plt.show()
# PRUEBA
#=====
df2_new = pd.read_excel(file_path, sheet_name='MOD4')
# Resumen de M4
print("Resumen de M4:")
print(df2_new.describe())
import pandas as pd
from IPython.display import display, HTML
# Función para visualizar en bonita tabla HTML def display_df(dfnew, title):
styled = dfnew.style.set_table_attributes("border=1").set_caption(title)
display(HTML(styled.render()))
# Resumen de M4
display_df(df2_new.describe(), "Resumen de M5")
<ipython-input-41-15d5cf89ce05>:7: FutureWarning: this method is deprecated
in favour o display(HTML(styled.render()))
Resumen de M5
# Excluir la columna ID_MOTOR y Motor_Fallo del escalamiento features2 =
df2_new.drop(columns=['ID_MOTOR', 'MOTOR_FALLO'])

```

```

scaler = MinMaxScaler()
scaled_features2 = scaler.fit_transform(features2)
df_scaled2 = pd.DataFrame(scaled_features2, columns=features2.columns)
df2_new[features2.columns] = scaled_features2
def create_sequences(df2_new, motor_id2, seq_length2):
    motor_data2 = df2_new[df2_new['ID_MOTOR'] == motor_id2].drop(columns=['ID_MOTOR'])
    X3 = []
    y3 = []
    for i in range(len(motor_data2) - seq_length2 + 1):
        X3.append(motor_data2.iloc[i:i+seq_length2, :-1].values)
        y3.append(motor_data2.iloc[i+seq_length2-1, -1])
    return X3, y3
X3_M4, y3_M4 = create_sequences(df2_new, 'M4', 14)
X3 = X3_M4
y3 = y3_M4
# Aplica padding
X4 = pad_sequences(X3, padding='post', dtype='float32', value=-1.0)
y4 = np.array(y3)
predictions4 = model.predict(X4)
6/6 [=====] | 0s 8ms/step
# VALIDACIÓN CON DATOS REALES
#-----
y_pred2_new = (predictions4 > 0.5).astype(int)
from sklearn.metrics import accuracy_score, f1_score
accuracy = accuracy_score(y4, y_pred2_new)
f1 = f1_score(y4, y_pred2_new)
print(f"Accuracy: {accuracy}") print(f"F1 Score: {f1}")
from sklearn.metrics import confusion_matrix import matplotlib.pyplot as plt
import seaborn as sns
cm = confusion_matrix(y4, y_pred2_new) plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='g', cmap='Blues', cbar=False)
plt.xlabel('Predicted labels')
plt.ylabel('True labels')
plt.title('Confusion Matrix') plt.show()
from sklearn.metrics import roc_curve, auc import matplotlib.pyplot as plt

# Calcular la curva ROC
fpr, tpr, thresholds = roc_curve(y4, y_pred2_new)
# Calcular el AUC
roc_auc = auc(fpr, tpr)
# Graficar la curva ROC plt.figure()

```

```

plt.plot(fpr, tpr, color='darkorange', lw=2, label='ROC curve (area = %0.2f)'
% roc_auc) plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate') plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic (ROC)') plt.legend(loc="lower
right")
plt.show()
# PRUEBA2
#=====
df3_new = pd.read_excel(file_path, sheet_name='MOD5')
# Resumen de M4
print("Resumen de M5:")
print(df3_new.describe()) Resumen de M5:
# Excluir la columna ID_MOTOR y Motor_Fallo del escalamiento features3 =
df3_new.drop(columns=['ID_MOTOR', 'MOTOR_FALLO'])
scaler = MinMaxScaler()
scaled_features3 = scaler.fit_transform(features3)
df_scaled3 = pd.DataFrame(scaled_features3, columns=features3.columns)
df3_new[features3.columns] = scaled_features3
def create_sequences(df3_new, motor_id3, seq_length3):
motor_data3 = df3_new[df3_new['ID_MOTOR'] ==
motor_id3].drop(columns=['ID_MOTOR']) X6 = []
y6 = []
for i in range(len(motor_data3) - seq_length3 + 1):
X6.append(motor_data3.iloc[i:i+seq_length3, :-1].values)
y6.append(motor_data3.iloc[i+seq_length3-1, -1])
return X6, y6
X_M5, y_M5 = create_sequences(df3_new, 'M5', 14)
X7 = X_M5
y7 = y_M5
# Aplica padding
X5 = pad_sequences(X7, padding='post', dtype='float32',value=-1.0) y5 =
np.array(y7)
predictions5 = model.predict(X5)
8/8 [=====] - 0s 8ms/step
# VALIDACION PRUEBA 2
#=====
y_pred5_new = (predictions5 > 0.5).astype(int)
from sklearn.metrics import accuracy_score, f1_score accuracy =
accuracy_score(y5, y_pred5_new)

```



```
f1 = f1_score(y5, y_pred5_new)
print(f"Accuracy: {accuracy}") print(f"F1 Score: {f1}")
from sklearn.metrics import confusion_matrix import matplotlib.pyplot as plt
import seaborn as sns
cm5 = confusion_matrix(y5, y_pred5_new) plt.figure(figsize=(8, 6))
sns.heatmap(cm5, annot=True, fmt='g', cmap='Blues', cbar=False)
plt.xlabel('Predicted labels')
plt.ylabel('True labels')
plt.title('Confusion Matrix') plt.show()
```



Apéndice C. Gráficas de validación de modelo MA-LSTM vs LSTM

Valores MA LSTM

```
from sklearn.metrics import log_loss  
  
error = log_loss(y2_test, y_pred)  
print(f"Entropía Cruzada: {error}")  
  
Entropía Cruzada: 0.4937486765632489
```




```
✓ [21] from sklearn.metrics import accuracy_score, f1_score
0s
accuracy = accuracy_score(y4, y_pred2_new)
f1 = f1_score(y4, y_pred2_new)

print(f"Accuracy: {accuracy}")
print(f"F1 Score: {f1}")

Accuracy: 0.989010989010989
F1 Score: 0.968
```

Valores LSTM





Anexos





Anexo A. Manual WEG motor scan

1. DEFINICIONES

Sensor - A lo largo de este manual, el término "sensor" es usado en referencia al dispositivo WEG Motor Scan.

Activo - A lo largo de este manual, el término "activo" es usado para referirse al equipo al cual el sensor será instalado. Pudiendo ser: reductores, bombas, ventiladores, compresores y otros sistemas accionados por motores eléctricos.

IoT (Internet of Things) - Se define como la tecnología que permite comunicación máquina a máquina (M2M) vía internet para el intercambio de datos e informaciones para fines predefinidos.

App - Aplicación de celular.

Gateway - Máquina intermedia entre el usuario y la red, destinada a interconectar redes, separar dominios de colisión o traducir protocolos.

Nube - Es la utilización de la memoria y de la capacidad de almacenamiento y cálculo de computadoras y servidores compartidos e interconectados a través de Internet, siguiendo el concepto de la computación en red.

Bluetooth - Tecnología de comunicación inalámbrica que interconecta y permite la transmisión de datos entre ordenadores, teléfonos móviles y otros dispositivos a través de ondas de radio.

Bluetooth Low Energy - Tecnología de comunicación inalámbrica que interconecta y permite la transmisión de datos entre ordenadores, teléfonos móviles y otros dispositivos a través de ondas de radio. Esta tecnología está diseñada para minimizar el consumo de energía eléctrica.

NFC (Near Field Communication) - Es una tecnología que permite el intercambio de información entre dispositivos sin necesidad de cables o cables (wireless), siendo necesaria sólo una aproximación física.

2. AVISOS DE SEGURIDAD EN EL MANUAL

¡PELIGRO!
No considerar las precauciones recomendadas en este aviso puede llevar a la muerte, heridas graves y daños materiales considerables. Pueden también cancelarse la garantía.

¡ATENCIÓN!
No considerar las precauciones recomendadas en este aviso puede llevar a daños materiales.

En este manual son utilizados los siguientes avisos de seguridad:

NOTA!
Informaciones importantes para el correcto entendimiento y el buen funcionamiento del producto.

3. RECOMENDACIONES PRELIMINARES

Este manual contiene las informaciones necesarias para la correcta instalación y uso del WEG Motor Scan (dispositivo de monitoreo inteligente de las características del activo).

Fue desarrollado para ser utilizado por personas con capacitación o cualificación técnica adecuadas para operar este tipo de producto.

No seguir las instrucciones del producto puede ocasionar accidentes operacionales, daños al medio ambiente, al dispositivo, además de la cancelación de la garantía.

La correcta definición de las características del entorno y de la aplicación es de responsabilidad del usuario.

Durante el periodo de garantía del WEG Motor Scan, los servicios



NOTA!
Lea completamente este manual antes de instalar u operar el WEG Motor Scan.

¡PELIGRO!
Solamente personas con cualificación adecuada y familiaridad con el WEG Motor Scan deben planear o ejecutar la instalación, operación y mantenimiento de este dispositivo. Estas personas deben seguir todas las instrucciones de seguridad contenidas en esta guía y/o definidas por normas locales. Por cuestiones de seguridad, mantenga una distancia segura del sensor y del activo durante su operación (no inferior a 20 cm) restringiendo la aproximación solamente a los trabajadores autorizados. No seguir las instrucciones de seguridad puede resultar en riesgo de muerte y/o daños al dispositivo. Existen riesgos de explosión o incendio cuando son expuestos a llamas, sometidos a la presión o cuando entren en contacto con materiales conductores de energía (metales o líquidos), además de contaminar el medio ambiente, debido a los materiales que hacen parte de su composición.

3.1. VERIFICACION A LA RECEPCION

Al recibir el WEG Motor Scan verifique si el embalaje contiene los siguientes ítems: 1 sensor, 1 tornillo de fijación (M4x20mm) y 1 casquillo de fijación. Verifique el sensor inmediatamente después de desembalar, por posibles daños que puedan haber ocurrido debido al transporte inadecuado.



Figura 3.1 - Sensor



Figura 3.2 - Tornillo de fijación M4x20mm



Figura 3.3 - Casquillo de fijación

¡PELIGRO!
Ante la ocurrencia de cualquier daño, regístrelo por escrito junto al transportista, y comuníquelo inmediatamente a la compañía aseguradora y a WEG. La no comunicación puede resultar en la cancelación de la garantía.

3.2. ALMACENAMIENTO

NOTA!
Se recomienda almacenar el WEG Motor Scan a una temperatura máxima de 30°C, y evitar almacenarlo bajo luz solar directa.

NOTA!
El WEG Motor Scan es enviado de fábrica deshabilitado.

NOTA!
El WEG Motor Scan es enviado con una batería de Célula de Lítio-Cloruro de Tionilo (Li-SOCl₂).

3.3. DESCARTE Y RECICLAJE

Pensando en el medio ambiente, WEG desarrolla y suministra productos que contribuyen a la reducción de los impactos ambientales, a lo largo del su ciclo de vida. La participación del usuario en la Recolección Selectiva y reciclaje de la Batería y equipo electro-electrónico usado también es importante para minimizar cualquier efecto potencial de éstos, en el ambiente y en la salud humana. El descarte adecuado del sensor, siguiendo las legislaciones aplicables, es muy importante para su seguridad, así como para el medio ambiente, además de ayudar a economizar recursos.



¡ATENCIÓN!
La batería del WEG Motor Scan es encapsulada a través de resina junto al sensor. El usuario no tiene como acceder, sustituir, remover, separar o cargar la batería. Al término de su vida útil, la batería es recolectada como equipo electro-electrónico usado. Para informaciones de retorno o recolecta disponible para el adecuado tratamiento y reciclaje, entre en contacto con WEG o envíe el sensor a nuestra red de servicio autorizado. Los sensores deben eliminarse por separado en un punto de recolección adecuado y no deben colocarse en el flujo de desechos convencional. Ni deben ser descartados en incineradores o vertederos de basura municipal. El descarte de los sensores debe ser hecho en conformidad con la normativa local. La remoción y el reciclaje de la batería debe solamente ser conducida por profesionales cualificados.

NOTA!
Este símbolo indica que:
- El producto no puede ser descartado en punto de recolección de basura municipal.
- Se trata de recolección selectiva para equipos eléctricos, electrónicos y baterías.
- Todo el dispositivo y su embalaje son fabricados a partir de materiales que pueden ser reciclados y al final de su vida útil deben ser enviados a empresas de reciclaje especializadas.
- La barra horizontal debajo del basurero indica que el equipo fue comercializado después del 13 de agosto de 2005.



Figura 3.4 - Símbolo de descarte

NOTA!
Los sensores sustituidos por la Asistencia Técnica son recogidos por WEG y remitidos a los respectivos proveedores para que ejecuten su correcto descarte. Todo el dispositivo y su embalaje son fabricados a partir de materiales que pueden ser reciclados por empresas de reciclaje especializado.

Las informaciones sobre los materiales que constituyen el WEG Motor Scan pueden ser visualizadas en: www.weg.net/wegmotorscan

4. SEGURIDAD

Durante la instalación, los activos deben estar desconectados de la red, completamente parados y deben ser tomados cuidados adicionales para evitar arranques accidentales.

Los profesionales que trabajan en instalaciones eléctricas, sea en el montaje, en la operación o en el mantenimiento, deben utilizar herramientas apropiadas y ser instruidos sobre la aplicación de las normas y prescripciones de seguridad, inclusive sobre el uso de Equipamientos de Protección Individual (EPI), los que deben ser cuidadosamente observados.

Los activos poseen circuitos energizados, componentes giratorios y superficies calientes, durante su operación normal, que pueden causar lesiones. De esta forma, todas las actividades relacionadas a su transporte, almacenamiento, instalación y operación del WEG Motor Scan deben ser realizadas por personal capacitado.

5. SOBRE EL WEG MOTOR SCAN

El WEG Motor Scan es un "sistema" que comprende un paquete de productos y servicios, compuesto por sensor, aplicación móvil (App) y portal web (WEG IoT Platform). Toda la comunicación es realizada a través de la tecnología Bluetooth® Low Energy.



Figura 5.1 - Sistema WEG Motor Scan

El sensor es un dispositivo no invasivo que monitorea periódicamente los datos del activo, como vibración, temperatura y tiempo en funcionamiento y, en caso de que el activo sea un motor eléctrico, realiza la estimativa de la carga y diagnósticos de eventuales fallas.
El sensor no tiene cables para conexión, ya que su alimentación es hecha a través de una batería de Lito que está incorporada al dispositivo. La expectativa de vida de la batería es de 3 años (para operación en ambiente de 25 °C).

Fue desarrollado para ser utilizado en el activo motor eléctrico y, a partir de la versión de firmware 2.1.4, en otros activos, como: reductores, generadores, bombas, compresores y otros sistemas accionados por motores eléctricos.

Luego de una fácil instalación en el activo, el WEG Motor Scan debe ser configurado por un dispositivo móvil, a través de la aplicación disponible para las plataformas iOS™ e Android™.

Los datos compartidos entre el sensor y el dispositivo móvil/App o Gateway son enviados a la nube donde son almacenados y procesados en la WEG IoT Platform. En un servidor seguro, los datos son analizados y transformados en informes, que pueden ser visualizados desde cualquier lugar: directamente en la pantalla del dispositivo móvil/App y en la WEG IoT Platform. El proceso de adquisición, procesamiento y análisis de datos se puede ver en la Figura 5.2. El proceso de adquisición, procesamiento y análisis de datos se puede ver en la Figura 5.2.




Figura 5.2- Flujo de adquisición, procesamiento y generación de diagnóstico de datos

Con base en los datos monitoreados es posible tomar decisiones más rápidas y asertivas, vía análisis predictivo, principalmente en torno de los cronogramas de mantenimiento preventivo, garantizando una mayor eficiencia, así como una mayor vida útil del activo.

Gateway: A través del gateway (modelo Cassia X1000) es posible transferir los datos de los sensores a la plataforma WEG IoT de forma automatizada. El gateway cuenta con protección IP65 y está certificado en los principales órganos Internacionales. Las informaciones de la instalación y el funcionamiento del gateway pueden ser visualizados en el manual completo (www.weg.net/wegmotorscan).

6.4. DIRECTIVA DE EQUIPOS DE RADIO (UE)

Declaración UE de Conformidad

Fabricante:
WEG Equipamentos Elétricos S.A.
Av. Prefeito Waldemar Grubbs, 3000
85256-900 - Jaraguá do Sul - SC - Brazil
www.weg.net

El fabricante, declara bajo su responsabilidad que:

Equipo radioeléctrico para la supervisión de la temperatura y la vibración, modelo:
WEG Motor Scan

cuando se instalen, mantengan y utilicen en las aplicaciones para las cuales fueron proyectados, y cuando se sigan las debidas normas de instalación e instrucciones del fabricante, los mismos cumplen los requisitos de las siguientes normativas de armonización de la Unión Europea, cuando sean de aplicación:

Directiva de Equipos Radioeléctricos 2014/53/UE
Directiva RoHS 2011/65/UE y sus enmiendas

El cumplimiento de los objetivos de seguridad de la legislación pertinente de armonización de la Unión Europea ha sido demostrado por la conformidad de las siguientes normativas, donde sean de aplicación:

2014/53/UE - Artículo 3.1 (a) Seguridad/Salud	EN 61010-1:2010 EN 62311:2008
2014/53/UE - Artículo 3.1 (b) CEM	EN 301 489-1 V2.2.0 EN 301 489-17 V3.2.0 EN 61326-1:2013
2014/53/UE - Artículo 3.2 Espectro Radioeléctrico	EN 300 328 V2.1.1
RoHS 2011/65/UE	EN 50581:2012

WEG EQUIPAMENTOS ELÉTRICOS
Depo. Sistema de Qualidade e Certificações
Alexandre Eiji Amano

Firmado por o en nombre del fabricante:

Eriberto Augusto Neves
Superior Compliance

Alexandre Eiji Amano
Gerente Sistema de Qualidade e Certificações

Jaraguá do Sul, 24 de agosto de 2018. DEC10018 1/1

6. CERTIFICACIONES Y NORMATIVAS

6.1. HOMOLOGACIÓN ANATEL

02193-18-11265
Este equipo no tiene derecho a la protección contra interferencia perjudicial, ni puede causar interferencia en sistemas debidamente autorizados.

Para consulta del certificado de homologación ANATEL, Acceda a:

sistemas.anatel.gov.br/mosaico/sch/publicView/listarProdutosHomologados.xhtml

6.2. REGLAMENTACIÓN FCC (EUA)

Contiene FCC ID: S9NSPBTLERF

Este dispositivo está en conformidad con la parte 15 de las reglas de la FCC. La operación está sujeta a las dos condiciones a seguir: (1) este dispositivo no puede causar interferencia perjudicial y (2) este dispositivo debe aceptar cualquier interferencia recibida, incluyendo interferencias que puedan causar operación no deseada.

¡PELIGRO!
Alteraciones o modificaciones no expresamente aprobadas por la parte responsable por la conformidad pueden anular la autoridad del usuario para operar el dispositivo (Parte 15.21).

6.3. REGLAMENTACIÓN IC (CANADÁ)

Contiene IC: 8976C-SPBTLERF

Este dispositivo está en conformidad con el RSS-210 de las Reglas del IC. La operación está sujeta a las dos condiciones a seguir: (1) este dispositivo no puede causar interferencia perjudicial y (2) este dispositivo debe aceptar cualquier interferencia recibida, incluyendo cualquier interferencia que pueda causar operación no deseada.

¡PELIGRO!
Alteraciones o modificaciones no expresamente aprobadas por la parte responsable por la conformidad pueden anular la autoridad del usuario para operar el dispositivo (RSS-210).

7. INSTALACIÓN

¡PELIGRO!
Riesgo de shock eléctrico. No toque las partes o los equipos eléctricamente energizados. Antes de iniciar la instalación del dispositivo desconecte la fuente de alimentación del activo.

¡PELIGRO!
El activo puede estar con la temperatura de la superficie elevada y causar quemaduras o heridas. Antes de iniciar la instalación del sensor aguarde un tiempo necesario para que el activo se enfríe. Use instrumentos adecuados para medir la temperatura del activo.

¡ATENCIÓN!
Condiciones ambientales de operación permitidas: temperatura de -10 °C a 70 °C (condiciones nominales)

Para ahorrar energía, a partir de la versión de firmware 2.1.4, todos los sensores serán enviados de fábrica deshabilitados. Por lo tanto, antes de instalarlo en el activo es necesario hacer la habilitación del sensor. Esto es hecho a través de la aplicación WEG Motor Scan.

7.1. INSTALACIÓN Y REGISTRO DE LA APLICACIÓN

La aplicación WEG Motor Scan está disponible en las plataformas iOS™ y Android™. Puede ser descargada directamente de las tiendas App Store y Google Play Store, buscando por WEG MOTOR SCAN, o a través de QR Code.

Figura 7.1 – Código QR para descargar la aplicación WEG Motor Scan

Con la aplicación instalada, abra el WEG Motor Scan y haga clic en "ENTRAR" para entrar con su cuenta WEG IoT.

En caso de que aún no posea una cuenta válida, haga clic en "REGISTRAR" para hacer su registro. También puede ser hecho en la web lot.weg.net.

7.2. HABILITACIÓN DEL SENSOR

Luego de la instalación y registro en WEG IoT Platform, siga los pasos que pueden ser visualizados directamente en la aplicación, o conforme es indicado en el procedimiento de abajo:

1. Siendo necesario, Inicie la sesión nuevamente – Iniciar Sesión*

2. Presione "NUEVO DISPOSITIVO" y, en seguida, "SELECCIONAR". En la pantalla de selección de dispositivos, presione "Activar".



3. Coloque el sensor en posición horizontal, conforme es ilustrado en la aplicación, y presione "INICIAR". Espere 15 segundos, invierta la posición del sensor, dejándolo con el logotipo WEG hacia abajo, conforme es ilustrado en la aplicación. Presione "CONTINUAR" y espere nuevamente 15 segundos.



4. Luego de 15 segundos, la aplicación le direccionará a la pantalla de emparejamiento manual o por NFC, en caso de que el modelo de smartphone posea tal funcionalidad.

Para realizar el emparejamiento manual, deje el sensor a ser configurado lo más próximo posible del smartphone, asegúrese de que ningún otro sensor esté próximo. Seleccione el primer sensor de la lista.

Para realizar el emparejamiento con el NFC, presione "ESCANEAR SENSOR". Aproxime la parte trasera del sensor, conforme es indicado en la aplicación, de la región del NFC del smartphone. Luego de la lectura del NFC, el sensor será emparejado con el smartphone y la activación finalizará automáticamente.



7.3. CONFIGURACIÓN DEL SENSOR

7.3.1 CONFIGURACIÓN DEL SENSOR: APLICACIÓN: ACTIVO MOTOR ELÉCTRICO

Luego de instalar y registrar la aplicación, habilite el sensor e inicie su configuración. Los pasos para hacer las configuraciones del sensor pueden ser visualizados directamente en la aplicación, o como es indicado en los pasos abajo:


1. Incluir nuevo sensor:

Haga clic en el botón "NUEVO DISPOSITIVO" y seleccione la opción "Configurar" en el menú de opciones.



5. Adicionar palabras clave (Tags):


Las palabras clave son una manera fácil de localizar el motor en la WEG IoT Platform. Se pueden adicionar cuantas palabras clave desee.



6. Programar horario de las mediciones:

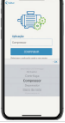
Gestione los horarios en los que el sensor hará las mediciones y haga clic en "Guardar". Nosotros ingresamos horarios estándares para usted. Siéntase a gusto para modificarlos. Es posible insertar hasta 12 horarios.

NOTA!
A partir de versión de firmware 2.1.4, el sensor realiza una medición de vibración por hora, totalizando 24 mediciones diarias fijas.




7. Seleccionar la aplicación:

Seleccione la aplicación donde el motor está instalado. Tiene una lista con las aplicaciones más comunes. En caso de que no logre encontrar su aplicación, seleccione "otra" y digite su aplicación manualmente.




8. Seleccionar la tensión:

Seleccione la tensión de alimentación del motor. Contiene una lista con las tensiones de alimentación que son soportadas para el número de serie del motor que fue registrado anteriormente. Seleccione si el motor utiliza convertidor.



9. Sincronización:

Para finalizar, espere la sincronización de los datos, permaneciendo cerca del sensor hasta que el proceso esté concluido. El dispositivo móvil precisará de conexión con Internet para este último paso. Asegúrese de que el sensor ya no esté registrado en otra planta.



Entre en la WEG IoT Platform para verificar si el sensor aparece en la planta del activo motor eléctrico. A partir de ahora, el sensor estará correctamente configurado y aparecerá en la pantalla home de la APP. Ejecute la sincronización periódicamente para bajar las mediciones programadas.


Seleccione la aplicación del sensor: "Motor"

Haga clic en el botón "NUEVO DISPOSITIVO" y ejecute el emparejamiento del sensor usando NFC o mantenga el sensor en frente a la cámara alineándolo de acuerdo con el visor (dependiendo del modelo del dispositivo móvil).



2. Registrar el número de serie del motor:

¿El número de serie no fue encontrado?
 ■ Por favor, entre en contacto con el equipo WEG IoT para ser registrado.
 ■ Haga clic en "No tengo número de serie" en caso de que quiera registrar manualmente el motor.



3. Registrar el sensor en una planta:

Elija en qué planta desea registrar el sensor. En la lista aparecerán solamente las plantas registradas en la WEG IoT Platform en la que usted es el administrador.

¿No tiene planta registrada?
 Haga clic en "Nueva planta" y regístrela.



4. Crear apodo del motor:

El apodo del motor será utilizado para identificarlo en el emparejamiento y en la WEG IoT Platform.



7.3.1 CONFIGURACIÓN DEL SENSOR: APLICACIÓN: OTROS ACTIVOS

Luego de instalar y registrar la aplicación, habilite el sensor e inicie su configuración. Los pasos para hacer las configuraciones del sensor pueden ser visualizados directamente en la aplicación, o como es indicado en los pasos abajo:

1. Incluir nuevo sensor:

Haga clic en el botón "NUEVO DISPOSITIVO" y seleccione la opción "Configurar" en el menú de opciones.



2. Haga clic en el botón "NUEVO DISPOSITIVO" y realice el emparejamiento del sensor usando NFC o con la cámara (depende del modelo del dispositivo móvil).



3. Registrar el sensor en una planta:

Elija en qué planta desea registrar el sensor. En la lista aparecerán solamente las plantas registradas en la WEG IoT Platform en la que usted es el administrador.

¿No tiene planta registrada?
 Haga clic en "Nueva planta" y regístrela.



4. Crear apodo del sensor:

El apodo del motor será utilizado para identificarlo en el emparejamiento y en la WEG IoT Platform. El apodo puede contener hasta 10 caracteres. El apodo no puede contener caracteres especiales.



5. Adicionar palabras clave (Tags):

Las palabras clave son una manera fácil de localizar el sensor en la WEG IoT Platform. Se pueden adicionar cuantas palabras clave desee.



6. Ingresar detalles sobre el activo que será monitoreado. Las informaciones no son obligatorias y pueden ser modificadas en la WEG IoT Platform.

7. Seleccionar el activo:
Seleccionar el tipo de equipo donde el sensor será instalado. El equipo podrá ser modificado en la WEG IoT Platform.

8. Ingresar los límites de alerta y crítico para el sensor.
Los límites son obligatorios y pueden ser modificados en la WEG IoT Platform.

9. Sincronización:
Para finalizar, espere la sincronización de los datos, permaneciendo cerca del sensor hasta que el proceso esté concluido. El dispositivo móvil precisará de conexión con internet para este último paso. Asegúrese de que el sensor ya no esté registrado en otra planta.

Entre en la WEG IoT Platform para verificar si el sensor aparece en la planta. A partir de ahora, el sensor estará correctamente configurado y realizará mediciones de vibración y temperatura cada 10 minutos. Utilice el smartphone o gateway para bajar las mediciones y enviarlas a WEG IoT Platform.

¡ATENCIÓN!
Dependiendo del modelo del aparato y/o de la versión del software, puede ser que la conexión entre el dispositivo móvil y el sensor no se establezca. En ese caso, se recomienda utilizar otro aparato para hacer la conexión.

7.4. MATERIALES NECESARIOS PARA INSTALACIÓN

Para la correcta instalación del sensor en el activo son necesarios las herramientas y materiales indicados en la Figura 7.2.




Figura 7.2 – Materiales necesarios para instalar el sensor en el activo

Tabla 7.1 – Dimensión M

Carcasas 63 a 200 – W21 y W22			W21	W22	
Carcasa	M (mm)	M (pol)			
63	6	0.236			
71	8	0.315			
80	8	0.315			
90	8	0.315			
100	8	0.315			
112	10	0.394			
132	10	0.394			
160	16	0.630			
180	16	0.630			
200	16	0.630			
225	45	1.772			
250	45	1.772			
280	55	2.165			
315	55	2.165			
355	55	2.165			
Carcasas 225 a 355 – W21			W21	W22	
Carcasa	M (mm)	M (pol)			
225	45	1.772			
250	45	1.772			
280	55	2.165			
315	55	2.165			
355	55	2.165			
Carcasas 225 a 355 – W22			W21	W22	
Carcasa	M (mm)	M (pol)			
225	25	0.984			
250	25	0.984			
280	28	1.102			
315	38	1.496			
355	48	1.890			
Carcasas 315 a 450 – W50			W21	W22	
Carcasa	M (mm)	M (pol)			
315	15	0.591			
355	30	1.181			
400	30	1.181			
450	40	1.575			

7.5. POSICIONAMIENTO DEL SENSOR PARA LA INSTALACIÓN

7.5.1. Posicionamiento del sensor - Aplicación: activo motor eléctrico WEG de las líneas W21, W22 y W50

Conforme puede ser visto en la Figura 7.3, el sensor debe ser instalado a una distancia máxima D = 20 mm del centro del motor y a una distancia M de la parte superior de la aleta. La distancia M varía con la carcasa, así como con la línea del motor, y está indicada en la Tabla 7.1.




Figura 7.3 – Distancias D y M para fijación del sensor

Abajo (Figura 7.4) es mostrada la fijación del sensor en el motor W22.




Figura 7.4 – Sensor fijo en el motor

7.5.2. Posicionamiento del sensor - Aplicación: activo motor eléctrico WEG de la línea W40

El sensor se puede instalar en los motores de la línea W40 siguiendo las ubicaciones indicadas en la Figura 7.5 (para las carcassas IEC de 160 a 280, optar por una de las posiciones indicadas en la figura):




Figura 7.5 – Local de fijación del WEG Motor Scan para motores de línea W40

Para realizar la correcta instalación, se deben seguir las recomendaciones de perforación mostradas en la Figura 7.6.




Figura 7.6 – Detalle de la perforación para fijación del WEG Motor Scan para la línea W40

7.5.3. Posicionamiento del sensor - Aplicación: activo motor eléctrico WEG de la línea ODP IP23




Figura 7.7 - Local de fijación del WEG Motor Scan para la línea ODP IP23

En función de las características constructivas de estos motores, la posición a ser adoptada para el WEG Motor Scan debe ser la región superior trasera del motor (Figura 7.6). La perforación y el posicionamiento de fijación del WEG Motor Scan, para los motores ODP IP23, deben seguir las recomendaciones mostradas en la Figura 7.8. Donde D y L son los desvíos máximos admisibles. D (máximo): 20 mm L (máximo): 80 mm




Figura 7.8 - Detalle de la perforación para fijación del WEG Motor Scan

¡ATENCIÓN!
Para la instalación del WEG Motor Scan en activos no contemplados en este manual y motores de otros fabricantes, consultar a WEG: www.weg.net/wegmotorscan.

Recomendaciones:

1. Utilizar el tornillo M4 que viene en los accesorios del WEG Motor Scan.
2. Garantizar que el orificio roscado sea perpendicular a la superficie del activo.
3. Atornillar el sensor en el activo con destornillador Allen de 3 mm (NO utilizar alicates u otros destornilladores para apretar el sensor más de lo necesario).

¡ATENCIÓN!
Para otras formas de fijar el WEG Motor Scan consultar a WEG, en nuestro canal de soporte: www.weg.net/wegmotorscan.

7.7 ACTUALIZACIÓN DEL FIRMWARE DEL SENSOR

Para actualizar, siga el procedimiento:

1. Haga el emparejamiento seleccionando el sensor en la pantalla inicial de la aplicación móvil. Es necesario estar próximo al sensor y tener conexión con internet.
2. Espere a la recolección de los datos almacenados en la memoria.
3. Haga clic en "Más".
4. Haga clic en "Actualizar sensor".
5. Espere a la finalización de la actualización. Se le solicitará registrar nuevamente los datos del activo.
6. ¡Listo! El sensor está actualizado.

8. WEG IOT PLATFORM

La WEG IOT Platform es una plataforma basada en la nube, que contiene todos los productos conectados de WEG. Acceda a WEG IOT Platform a través de la siguiente dirección: iot.weg.net.



Abra el WEG IoT Platform con la misma cuenta de login de la aplicación WEG Motor Scan.



9. ANÁLISIS REALIZADOS CON EL SENSOR

9.1. CONFIGURACIONES DE ALERTA

Aplicación: todos los activos

Es posible configurar el sensor para disparar alertas con base en estos datos y realizar el seguimiento de todos los activos equipados con el WEG Motor Scan en la misma pantalla de la WEG IoT Platform. Para configurar los niveles de los criterios de alarma, se debe considerar la aplicación donde el WEG Motor Scan está instalado y atribuir valores apropiados a la operación saludable del activo, tanto para vibración como para temperatura, siguiendo la lógica definida para los criterios de alarma. Normal (verde): el motor está en su condición normal de operación. Alerta (amarillo): sugiere la programación de una parada preventiva del activo para mejorar el diagnóstico. Crítico (rojo): sugiere una acción inmediata de mantenimiento correctivo en el activo.

7.6 PROCEDIMIENTO DE INSTALACIÓN DEL SENSOR EN EL MOTOR

7.6.1 PROCEDIMIENTO DE INSTALACIÓN - APLICACIÓN: ACTIVO MOTOR ELÉCTRICO

Para la correcta fijación del sensor en el motor ejecute la secuencia de pasos de abajo:

1. Con el motor desconectado y obedeciendo todas las instrucciones de seguridad indicadas en este manual, localice la aleta del motor donde el sensor debe fijarse. De acuerdo con las orientaciones de posicionamiento indicadas en el ítem 7.5, haga el marcado para realizar el taladrado.
2. Haga un orificio con una broca de 5,9 mm (1/64") de diámetro para fijar el casquillo.
3. Usando un martillo, inserte el casquillo estrizado en el orificio hasta que la pestaña toque la aleta del motor. (Nota: si el casquillo se inserta sin el auxilio del martillo significa que el agujero se ha quedado con un diámetro ligeramente superior y en ese caso la fijación del sensor en el motor estará comprometida, por lo que es necesario realizar una nueva perforación para la correcta fijación del casquillo).




Figura 7.9 - Detalle de la inserción del casquillo roscable

4. Usando una llave Allen de 3 mm, atornille el sensor en el casquillo estrizado y verifique su apriete. El torque máximo de apriete es de 2,8 Nm.




Figura 7.10 - Detalle del atornillado del sensor en el casquillo roscable

7.6.2 PROCEDIMIENTO DE INSTALACIÓN - APLICACIÓN: OTROS ACTIVOS

Con el activo desconectado y obedeciendo todas las instrucciones de seguridad indicadas en este manual, el sensor debe ser instalado conforme es indicado en la Figura 7.11.





Figura 9.1 - Diagnóstico basado en los criterios de alarma

9.2. GRANDEZAS MONITOREADAS

9.2.1 Vibración

Aplicación: todos los activos

El WEG Motor Scan mide la vibración (mm/s) eficaz o RMS en 3 ejes (A Axial, Rx Radial X, y Ry Radial Y) conforme es indicado en la Figura 9.2 de abajo.




Figura 9.2 - Definición de los ejes coordinados en el WEG Motor Scan

El monitoreo del nivel RMS de vibración y la evaluación de tendencias y estándares de funcionamiento son usados para indicar alteraciones circunstanciales o permanentes en la aplicación. Con eso, podrá ser realizada una evaluación más precisa, a fin de determinar la causa del cambio, y si es una falla en la máquina.

La Figura 9.3 muestra la razón, en dB, entre las mediciones de vibración simultáneas del WEG Motor Scan y de un acelerómetro estándar de calibración, en un mismo punto sobre un excitador electrodinámico capaz de producir vibraciones en un largo rango de frecuencias. El WEG Motor Scan tiene una óptima respuesta con relación al acelerómetro estándar dentro del rango de frecuencias de trabajo de hasta 820 Hz de evaluación del valor global RMS de vibración.





Figura 9.3 - Razón entre las respuestas del WEG Motor Scan y de un acelerómetro estándar de calibración sujetos simultáneamente a los mismos niveles de vibración dentro de un rango largo de frecuencias.

A seguir son descritos los análisis realizados en el activo motor eléctrico, no obstante, pueden ser aplicadas consideraciones similares a todos los activos a los cuales el sensor pueda ser fijado.

El ítem 7 de este manual presenta las orientaciones para instalación del WEG Motor Scan sobre la superficie del activo motor eléctrico, en una región donde se encuentra el estator. Esta posición fue cuidadosamente analizada y escogida para albergar la posibilidad de obtención de informaciones de temperatura próxima a la región del estator, vibración del motor y otras informaciones para funcionalidades futuras. A pesar de no ser una posición de medición de vibración recomendada en la norma ISO 10816-3 (*), normalmente utilizada en los programas de mantenimiento predictivo de las industrias, la norma ISO 13373-1 (*), también utilizada en los programas de mantenimiento predictivo, permite que los sensores de vibración sean instalados en otras posiciones que produzcan informaciones adecuadas de vibración. Los estudios realizados en WEG comprobaron la adecuación del punto de medición con misma indicación de tendencias obtenidas en las mediciones en los puntos de los cojinetes.

Las mediciones de vibración realizadas por el WEG Motor Scan pueden ser comparadas con equipos convencionales de vibración, no obstante, el local de medición utilizado como referencia para esa comparación debe ser el más próximo posible del local de fijación estándar en el Motor (ver Figuras 7.3 y 7.4). En esa condición es esperada poca o ninguna variación entre las mediciones. La Figura 9.4 ilustra esa condición.




Detalle:

- Variación por encima del medido por el WEG Motor Scan
- Ninguna/poca variación con respecto al medido por el WEG
- Variación por debajo del medido por el WEG Motor Scan

Figura 9.4 – Comparando las mediciones de un equipo convencional próximo al local de fijación estándar del WEG Motor Scan.

Cuando las mediciones del equipo convencional de vibración son realizadas en los puntos tradicionales de recolecta de datos de vibración (sugeridos por la ISO 10816-3), es esperada alguna variación cuando son comparadas con los valores medidos por el WEG Motor Scan en su local de fijación estándar. Esos valores pueden ser inferiores, semejantes o superiores a aquellos medidos por el WEG Motor Scan, dependiendo de la condición del motor y del local de referencia para la comparación. Esa variación es esperada y no es un problema, ya que el objetivo del WEG Motor Scan es monitorear la evolución de los niveles de vibración. Debido a esas características, es recomendado ajustar los niveles de alerta y crítico del WEG Motor Scan, para adecuarlos al medido por el equipo convencional. La Figura 9.5 ilustra esa condición.



Detalle:

- Variación por encima del medido por el WEG Motor Scan
- Ninguna/poca variación con respecto al medido por el WEG
- Variación por debajo del medido por el WEG Motor Scan

Figura 9.5 – Comparando las mediciones de un equipo convencional realizadas en los puntos tradicionales sugeridos por la ISO 10816-3 con las mediciones del Motor Scan en su local de fijación estándar.

Los niveles estándares de alerta y críticos de vibración, definidos en la WEG IoT Platform, en el caso del activo motor eléctrico, son los límites definidos en la norma ISO 10816-3 para motores instalados en base flexible, ya considerando 25% además de los límites de las zonas B y C de vibración de la norma (Tabla 9.1). Estos niveles podrán ser redefinidos por el usuario, de acuerdo con el nivel base de operación del motor en la aplicación y/o experiencia acumulada por el usuario. Los niveles definidos en la norma son para puntos sobre los cojinetes del motor o de la máquina acoplada. La redefinición deberá tomar en cuenta el tipo de base de fijación del motor y la ubicación del sensor lejos de los cojinetes. La Tabla 9.1 es una referencia en caso de que no haya otros valores de experiencia con la aplicación y local de medición.

Tabla 9.1 – Límites de los niveles de alerta y de los niveles críticos de vibración – ISO 10816-3

Velocidad de Vibración RMS (mm/s)	Potencia ≤ 300kW Grupo 2 de ISO 10816-3		Potencia > 300 kW Grupo 1 de ISO 10816-3	
	Base Rígida	Base Flexible	Base Rígida	Base Flexible
V ≤ 2.8				
2.8 < V ≤ 5.6				
5.6 < V ≤ 8.9				
8.9 < V ≤ 13.8				
V > 13.8				

Detalle:

	NORMAL
	ALERTA
	CRÍTICO

10. ESPECIFICACIÓN TÉCNICA

SENSOR	
Material del envoltorio	PA6
Encapsulamiento	Epoxi
Masa	80 g
Dimensiones	25 x 44 x 38 mm (AxLxP)
Grado de protección	IP68
Temperatura de la electrónica	-40 °C a 80 °C
Humedad relativa del aire	hasta 95% sin condensación
Conformidad	RoHS, WEEE, REACH, CE (UE), FCC (EUA), IC (Canadá), ICASA (África do Sul), ANATEL (Brasil), RCM (Australia), SUBTEL (Chile), apto para comercialización para Malasia, Singapur y Colombia.
Software	Consultar iot.weg.net
BATERÍA	
Material	Célula primaria de Litio-Cloruro de Tionilo (Li-SOCl ₂)
Capacidad Nominal	2.1 Ah
Tensión Nominal	3.6V
Expectativa de vida	3 años (Ambiente 25°C - 24 adquisiciones al día)
Contenido metal de litio	aprox. 0.6 g
MÓDULO RF	
Rango de frecuencia	2402 - 2480 MHz
Alcance (máximo)	hasta 10 m (usando la aplicación) o aprox. 30 m (usando el gateway)
Bluetooth® 2.4GHz	BLE 4.1 version
MEMORIA	
Almacenamiento	1 mes
MEDICIONES	
Vibración Global RMS	3 ejes (820 Hz @ ±16 g)
Temperatura en la superficie del motor	Superficie del motor: -40 °C a 135 °C (cada 10 minutos)
Tiempo de operación del motor	Cada 10 minutos

¡ATENCIÓN!
El WEG Motor Scan está constantemente en actualización. Por ese motivo, las informaciones contenidas en esta guía pueden ser alteradas sin previo aviso.

Nota. Tomado de Manual WEG

11. CERTIFICADO DE GARANTÍA

WEG Equipos eléctricos S/A, unidad Motores ("WEG"), ofrece garantía contra defectos de fabricación y de materiales, para el producto WEG Motor Scan, por el periodo de 12 meses contados a partir de la fecha de emisión de la factura de fábrica o del distribuidor/revendedor.

En los plazos de garantía de arriba están contenidos los plazos de la garantía legal, no siendo acumulativos entre sí.

En caso de que esté definido, en la propuesta técnico-comercial, un plazo de garantía diferenciado para determinado suministro, éste prevalecerá sobre los plazos de arriba.

Los plazos establecidos arriba independen de la fecha de instalación del producto y de su puesta en operación.

Ante un eventual desvío, con relación a la operación normal del producto, el cliente deberá comunicar inmediatamente por escrito a WEG los defectos ocurridos, y proveer el producto para WEG o su Asistente Técnico Autorizado, por el plazo necesario para la identificación de la causa del desvío, verificación de la cobertura de la garantía, y para la debida reparación.

Para tener derecho a la garantía, el cliente debe seguir las especificaciones de los documentos técnicos de WEG, especialmente aquellas previstas en el Manual de Instalación y Operación de los productos, y las normas y reglamentaciones vigentes en cada país.

No poseen cobertura de garantía los defectos derivados de utilización, operación y/o instalación inadecuadas o inapropiadas de los equipos, así como defectos provenientes de factores externos o equipos y componentes no suministrados por WEG.

La garantía no se aplica si el cliente, por propia iniciativa, efectúa reparaciones y/o modificaciones en el equipo, sin previo consentimiento por escrito de WEG.

La garantía no cubre equipos, partes y/o componentes, cuya vida útil sea inferior al período de garantía. No cubre, igualmente, defectos y/o problemas derivados de fuerza mayor u otras causas que no puedan ser atribuidas a WEG, como por ejemplo, pero no limitado a: especificaciones o datos incorrectos o incompletos por parte del cliente, transporte, almacenamiento, manipulación, instalación y operación en desacuerdo con las instrucciones suministradas, accidentes, deficiencias de obras civiles, utilización en aplicaciones y/o ambientes para los cuales el producto no fue proyectado, equipos y/o componentes no incluidos en el alcance de suministro de WEG. La garantía no incluye los servicios de desmontaje en las instalaciones del cliente, los costos de transporte del producto ni los gastos de locomoción, hospedaje o alimentación del personal de la Asistencia Técnica, cuando sean solicitados por el cliente.

Los servicios en garantía serán prestados exclusivamente en los talleres de Asistencia Técnica Autorizada por WEG o en su propia fábrica. Bajo ninguna hipótesis, estos servicios en garantía prorrogarán los plazos de garantía del equipo.

La responsabilidad civil de WEG está limitada al producto suministrado, no responsabilizándose por daños indirectos o emergentes, tales como lucros cesantes, pérdidas de utilidades y afines que, eventualmente, provengan del contrato firmado entre las partes.

Anexo B. Ficha de decanter Z73**Datos técnicos****1.3**DECANTER *Flottweg* Z 73-4/454

No. de máquina: 010.362.15

- 1. Decantador** dimensionado para fango
- 2. Rotor**
- | | | | |
|---------|-------------------------------|--------|------------------------------|
| Tambor: | revolución máxima | 2750 | min ⁻¹ |
| | densidad máx.de los sólidos | 1,3 | g/cm ³ |
| | diámetro del tambor | 725 | mm |
| | diámetro salida sólidos | 435 | mm |
| | material tambor | 1.4463 | |
| | material juntas | NBR | |
| | temperatura máx. del producto | 0/90 | ° C |
| Sinfin: | Protección contra desgaste: | | |
| | espiral | | volframio carburo |
| | pieza de entrada | | casquillos de fundición dura |
- 3. Ajustes** (de fábrica):
- | | |
|---------------------------------------|--------------------------------|
| Modo de funcionamiento | retrasado |
| revolución del tambor | ...2750 min ⁻¹ |
| diferencia de revoluciones del sinfin | -0,5...-10,4 min ⁻¹ |
| diámetro del nivel | 433 mm |
- 4. Mecanismo reductor:**
- | | |
|---------------------------|--------------------|
| tipo: | SIMP-DRIVE® |
| Accionamiento: | tipo SP 3.11 |
| accionamiento del tambor: | |
| Motor eléctrico: | tipo 315 S |
| | potencia 110 kW |
| | voltaje 400; 690 V |
| | frecuencia 50 Hz |
| accionamiento del sinfín: | |
| Motor eléctrico: | tipo 132 M |
| | potencia 7,5 kW |
| | voltaje 400; 690 V |
| | frecuencia 50 Hz |
- 5. Medidas y pesos:**
- | | |
|------------------------------|---------------|
| Hoja de medidas para montaje | C 367.0007.50 |
|------------------------------|---------------|
- 6. Lubricantes:** vea capítulo 3