



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA  
ESCUELA PROFESIONAL DE INGENIERÍA MECÁNICA  
ELÉCTRICA**

**Predicción de indicadores de mantenimiento de las  
camionetas HILUX utilizando LSTM soportado con algoritmo  
de evolución diferencial.**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:**

Ingeniero Mecánico Electricista

**AUTORES:**

Aguirre Rodriguez, Gary Alexander (orcid.org/0000-0002-6646-1964)

Urquiza Carrillo, Raul Kenjy (orcid.org/0000-0002-0348-3533)

**ASESORA:**

Mg. Serrepe Ranno, Miriam Marcela (orcid.org/0000-0001-9342-1717)

**LÍNEA DE INVESTIGACIÓN:**

Sistemas y Planes de Mantenimiento

**LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:**

Desarrollo sostenible y adaptación al cambio climático

TRUJILLO– PERÚ

2023

## **Dedicatoria**

Dedico este trabajo de investigación en primer lugar a dios, por brindarnos la salud y las fuerzas para poder cumplir con todo este proceso de aprendizaje.

A mis padres por ser un apoyo incondicional, su esfuerzo y lucha constante son ejemplo que motivan a un deseo de superación, me siento muy agradecido con la vida de contar con ustedes siempre.

Aguirre Rodríguez, Gary Alexander.

A Dios por darme fortaleza y perseverancia para poder culminar este proyecto.

A mis padres, hermanos y esposa por confiar en mí y apoyarme siempre en cada meta que me propongo.

Urquiza Carrillo, Raúl Kenjy

## **Agradecimiento**

Nuestro agradecimiento inicial a Dios por este logro, por darnos salud y paciencia para superar las dificultades, por darnos fuerza y enseñarnos a conservar la calma en momentos de debilidad.

A nuestros padres por darnos la vida, por amarnos como somos y por confiar en nosotros.

A nuestra familia, esposas e hijos, quienes son la razón de nuestra continua lucha y superación, muchas gracias por su comprensión y paciencia en estos largos años de ausencia donde tenía que dividir mi tiempo entre la familia, el trabajo y los estudios.

A nuestros asesores por sus enseñanzas impartidas durante el desarrollo de nuestro proyecto, por el apoyo y comprensión.

## Declaratoria de autenticidad del asesor



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA  
ESCUELA PROFESIONAL DE INGENIERÍA MECÁNICA ELÉCTRICA**

### Declaratoria de Autenticidad del Asesor

Yo, SERREPE RANNO MIRIAM MARCELA, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA MECÁNICA ELÉCTRICA de la UNIVERSIDAD CÉSAR VALLEJO SAC - TRUJILLO, asesor de Tesis titulada: "Predicción de indicadores de mantenimiento de las camionetas HILUX utilizando LSTM soportado con algoritmo de evolución diferencial.", cuyos autores son AGUIRRE RODRIGUEZ GARY ALEXANDER, URQUIZA CARRILLO RAUL KENJY, constato que la investigación tiene un índice de similitud de 15%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

TRUJILLO, 12 de Diciembre del 2023

Apellidos y Nombres del Asesor:	Firma
SERREPE RANNO MIRIAM MARCELA DNI: 06437594 ORCID: 0000-0001-9342-1717	Firmado electrónicamente por: SRANNOMM el 14- 12-2023 12:10:55

Código documento Trilce: TRI - 0694153



## Declaratoria de originalidad de los autores



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA**

**ESCUELA PROFESIONAL DE INGENIERÍA MECÁNICA ELÉCTRICA**

### Declaratoria de Originalidad de los Autores

Nosotros, URQUIZA CARRILLO RAUL KENJY, AGUIRRE RODRIGUEZ GARY ALEXANDER estudiantes de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA MECÁNICA ELÉCTRICA de la UNIVERSIDAD CÉSAR VALLEJO SAC - TRUJILLO, declaramos bajo juramento que todos los datos e información que acompañan la Tesis titulada: "Predicción de indicadores de mantenimiento de las camionetas HILUX utilizando LSTM soportado con algoritmo de evolución diferencial.", es de nuestra autoría, por lo tanto, declaramos que la Tesis:

1. No ha sido plagiada ni total, ni parcialmente.
2. Hemos mencionado todas las fuentes empleadas, identificando correctamente toda cita textual o de paráfrasis proveniente de otras fuentes.
3. No ha sido publicada, ni presentada anteriormente para la obtención de otro grado académico o título profesional.
4. Los datos presentados en los resultados no han sido falseados, ni duplicados, ni copiados.

En tal sentido asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de la información aportada, por lo cual nos sometemos a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

Nombres y Apellidos	Firma
RAUL KENJY URQUIZA CARRILLO DNI: 46638761 ORCID: 0000-0002-0348-3533	Firmado electrónicamente por: RURQUIZACA24 el 12- 12-2023 11:36:45
GARY ALEXANDER AGUIRRE RODRIGUEZ DNI: 47493576 ORCID: 0000-0002-6646-1964	Firmado electrónicamente por: GARGUIRRE el 12- 12-2023 09:12:23

Código documento Trilce: TRI - 0694151

## Índice de contenidos

Carátula.....	i
Dedicatoria.....	ii
Agradecimiento.....	iii
Declaratoria de autenticidad del asesor.....	iv
Declaratoria de originalidad de los autores.....	v
Índice de contenidos.....	vi
Índice de tablas.....	vii
Índice de figuras.....	viii
Resumen.....	ix
Abstract.....	x
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO.....	3
III. METODOLOGÍA.....	9
3.1 Tipo y diseño de investigación.....	9
3.2 Variables y operacionalización.....	10
3.3 Población, muestra, muestreo.....	10
3.4 Técnicas e instrumentos de recolección de datos.....	10
3.5 Procedimientos.....	11
3.6 Método de análisis de datos.....	12
3.7 Aspectos éticos.....	12
IV RESULTADOS.....	12
V DISCUSIÓN.....	19
VI CONCLUSIONES.....	21
VII RECOMENDACIONES.....	22
REFERENCIAS.....	
ANEXOS.....	

## Índice de tablas

Tabla 1 Valores de tiempos de cada camioneta.....	13
Tabla 2 Valores de indicadores de mantenimiento de cada camioneta .....	13
Tabla 3 Valores de los tiempos después de la implementación .....	17
Tabla 4 Indicadores de mantenimiento después del modelo .....	18
Tabla 5 Presupuesto del algoritmo y plan de mantenimiento .....	19
Tabla 6 Matriz de Operacionalización de variable independiente .....	28
Tabla 7 Matriz de Operacionalización de variable dependiente .....	29
Tabla 8 Ficha de registro.....	30

## Índice de figuras

Figura 1 Esquema de diseño de investigación .....	9
Figura 2 Cuadro indicadores de mantenimiento de cada una de las unidades .....	32
Figura 3 Curva de predicción de la disponibilidad .....	33
Figura 4 Curva de predicción de la confiabilidad.....	33
Figura 5 Cuadro proyectado de indicadores de mantenimiento de cada una de las unidades.....	34

## **Resumen**

Esta tesis tiene como objetivo desarrollar un algoritmo avanzado que combine redes neuronales de memoria a largo plazo (LSTM) y evolución diferencial para la predicción precisa de los valores de indicadores de mantenimiento a lo largo del tiempo. La meta es mejorar la eficiencia en la gestión de activos al anticipar cambios en los indicadores clave. La metodología implica la implementación de LSTM para la captura de patrones temporales complejos, mientras que la evolución diferencial se utiliza para optimizar los parámetros del modelo. Los resultados demuestran la efectividad del algoritmo en la predicción de indicadores de mantenimiento, respaldando su utilidad en estrategias de mantenimiento predictivo.

Palabras Clave: Mantenimiento Predictivo, Redes Neuronales LSTM, Evolución Diferencial, Predicción Temporal

## **Abstract**

The objective of this thesis is to develop an advanced algorithm that combines Long Short-Term Memory (LSTM) neural networks and differential evolution for the accurate prediction of maintenance indicator values over time. The goal is to enhance efficiency in asset management by anticipating changes in key indicators. The methodology involves implementing LSTM for capturing complex temporal patterns, while differential evolution is utilized to optimize the model parameters. Results demonstrate the algorithm's effectiveness in predicting maintenance indicators, supporting its utility in predictive maintenance strategies.

Keywords: Predictive Maintenance, LSTM Neural Networks, Differential Evolution, Temporal Prediction

## I. INTRODUCCIÓN

El mantenimiento ha ido teniendo avances a lo largo de los años dando grandes avances en los softwares de mantenimiento, en los cuales han estado inmiscuidos las universidades, institutos y la propia empresa. Este incremento ha logrado que los estudios e investigaciones hayan aumentado para lograr una mejora en la eficiencia del sistema y una disminución de los costos de mantenimiento (Bastías, Díaz y López Fenner, 2023).

El mantenimiento predictivo ha utilizado el análisis vibracional como un método muy importante en su desarrollo industrial, dado que puede determinar fallas instantáneas dentro de los mantenimientos programados y ejecutados. Los sistemas de diagnóstico de fallas se pueden usar para evaluar el estado de una máquina mientras está en uso y detectar cualquier falla en tiempo real. Las representaciones de características informativas generalmente se extraen utilizando técnicas avanzadas de procesamiento de señales, lo que permite la discriminación precisa de fallas con respecto a su ubicación. Esto ha hecho que se elija el aprendizaje profundo (*Deep Learning* - DL) para el diagnóstico de dichas fallas en mantenimiento (Tama *et al.*, 2022).

Lo complicado de las redes neuronales reside en el modelado de cada una de las posibilidades de falla de cada uno de los componentes lo que ha impulsado el desarrollo y origen de nuevas tecnologías como lo son la Técnica de diagnóstico y pronóstico de falla y el *Machine Learning* (ML). Sin embargo, la mayor complejidad y su rendimiento superior ha hecho priorizar DL en el uso de las nuevas tecnologías de mantenimiento predictivo (Qiu *et al.*, 2023).

Las Redes Neuronales de Memoria a Largo Plazo (*Long short-term memory* - LSTM) son un tipo especializado de redes neuronales recurrentes que se destacan por su capacidad para capturar y recordar patrones a largo plazo en secuencias de datos. Su arquitectura permite modelar dependencias temporales complejas y, por lo tanto, son particularmente efectivas en la predicción de series temporales, como los indicadores financieros o meteorológicos. En este sentido, las LSTM han demostrado

ser una herramienta poderosa para pronosticar valores futuros con precisión (Meng *et al.*, 2023).

Por otro lado, la optimización por evolución diferencial es una técnica de optimización inspirada en la evolución natural. Se basa en la idea de crear una población de soluciones candidatas, combinarlas y seleccionar las mejores de manera iterativa. Ella ha demostrado ser eficaz en la calibración de modelos y en la búsqueda de parámetros óptimos para algoritmos de predicción, lo que la convierte en un enfoque valioso para mejorar la precisión de las LSTM y otros modelos de predicción (Zhang *et al.*, 2020).

El análisis de fallas en una unidad automotriz, se torna difícil debido a que está conformada por varias estructuras con movimiento rotatorio, las cuales están sometidos a desgaste durante su funcionamiento a corto y largo plazo, esto genera que cada uno de los componentes sufran fallas funcionales debido a los incrementos de presión y temperatura, así como la fatiga del metal que forma sus piezas. Por esta razón la predicción de cada una de las fallas es muy difícil de mostrar, aunque se utiliza la tecnología 4.0 (Gong *et al.*, 2022).

Un monitoreo inadecuado de las fallas y de los equipos, ocasionaría que la vida útil de los vehículos varíe de manera negativa, dado que algunos componentes se han desgastado de manera más significativa en comparación con otros (Jafarzadeh *et al.*, 2022).

Por lo anterior mencionado se plantea el siguiente problema, ¿Cómo implementar un modelo predictivo basado en LSTM y evolución diferencial en los indicadores de mantenimiento en las camionetas HILUX? y a su vez las preguntas específicas: ¿Cuál es el estado actual de los indicadores de mantenimiento de las camionetas HILUX?, ¿Cómo implementar el algoritmo basado en LSTM soportado por evolución diferencial para las camionetas HILUX?, ¿Cómo implementar un algoritmo de predicción basado en LSTM y evolución diferencial?, y ¿Cuál es la factibilidad económica del modelo predictivo?.

La justificación del proyecto desde el punto de vista teórico está dada por el entendimiento del proceso de optimización de redes neuronales en el mantenimiento. Dentro del aspecto tecnológico permitirá implementar un nuevo sistema de análisis de

mantenimiento predictivo. Finalmente, en el punto de vista económico el proyecto disminuirá de manera significativa los gastos en paradas de unidad y en mantenimientos correctivos.

El objetivo general del proyecto es implementar un modelo predictivo basado en LSTM y evolución diferencial en los indicadores de mantenimiento en las camionetas HILUX. Para llegar a este objetivo general se ha planteado los siguientes objetivos específicos: Determinar el estado actual de los indicadores de mantenimiento de las camionetas HILUX, elaborar un algoritmo utilizando LSTM soportado con evolución diferencial, implementar un modelo predictivo basado en el algoritmo e implementar un análisis económico de la implementación del plan.

Por lo descrito, esta investigación se centra en determinar los indicadores del mantenimiento de las camionetas HILUX en función del plan de mantenimiento predictivo basado en LSTM soportado con evolución diferencial para así poder elevar la disponibilidad de las camionetas y mejorando la confiabilidad de éstas.

Como hipótesis de investigación tenemos que el algoritmo basado en LSTM soportado con evolución diferencial incrementará los valores de disponibilidad, confiabilidad y mantenibilidad

## **II. MARCO TEÓRICO**

Se inició la revisión de artículos relacionados con las variables de estudio en revistas indexadas de las bases de datos científicas que se mencionaron anteriormente. El primer artículo que analizamos es el de Ullah *et al.* (2023) quienes realizaron una nueva metodología basada la red *Long Short-Term Memory* (LSTM). El objetivo fue analizar la efectividad de la metodología en función del monitoreo de los datos de trabajo de los motores de aeronaves. El modelo logró predecir la salida de la variable dependiente a través de los datos obtenidos en tiempo real, que a su vez este modelo tiene una curva de aprendizaje más corta y con mayor precisión que las otras metodologías de autores anteriores.

De acuerdo con la investigación de (Pagano 2023), quienes presentaron un nuevo enfoque basado en el uso combinado de redes neuronales *LSTM* e inferencia

bayesiana para el mantenimiento predictivo de una planta industrial. La compatibilidad del modelo se fue mejorando a través de periodos de entrenamiento con la salida de la red neuronal utilizada y para culminar se utilizó probabilidad bayesiana para actualizar las condiciones de trabajo dentro de la planta.

En la investigación de Nekoonam *et al.* (2023) se propuso un nuevo enfoque que integra el análisis léxico y el análisis de redes sociales con el objetivo de identificar los temas críticos. Se emplearon herramientas como HistCite, NodeXL y VOSviewer, y se amalgamaron sus resultados para llevar a cabo el análisis a lo largo de seis intervalos temporales. Se seleccionaron los primeros cinco periodos considerando parámetros bibliográficos en HistCite y estableciendo un índice, de manera que la cantidad y calidad de los artículos en cada periodo fueran óptimas en comparación con otros años. En contraste, el sexto periodo se reservó para incluir las investigaciones más recientes.

La revisión de antecedentes continuó con la investigación de Mitici *et al.* (2023) quienes desarrollaron pronósticos de vida útil restante (RUL) probabilísticos utilizando redes neuronales convolucionales. Estas proyecciones se incorporaron de manera más profunda en la planificación de la gestión de activos, abarcando tanto componentes individuales como conjuntos. Ejemplificaron su metodología mediante la aplicación a motores turboventiladores de aeronaves. Los resultados indicaron que el momento óptimo para sustituir los motores se sitúa cercano al extremo inferior del intervalo de confianza del 99 % de las estimaciones de vida útil remanente. También demostraron que la estrategia de mantenimiento que diseñaron conllevó a una reducción de costos del 53 % en comparación con una estrategia de mantenimiento convencional basada en el tiempo. Además, al contrastar con el escenario ideal donde el RUL real se conoce de antemano, su enfoque minimiza la ocurrencia de fallas. Se propuso un marco completo para el mantenimiento predictivo basado en datos aplicable a múltiples componentes, destacando los posibles beneficios en términos de costo y confiabilidad.

Según Lee y Mitici (2023) ,quienes propusieron un marco para integrar pronósticos probabilísticos de vida útil restante (RUL) basados en datos en la planificación de mantenimiento predictivo. Además, utilizaron una nueva predicción en redes

neuronales convolucionales con refuerzo en el método de Monte Carlo. Estos pronósticos se actualizan con el tiempo, a medida que se dispone de más mediciones. El problema de planificación de mantenimiento como un problema de aprendizaje de refuerzo profundo (DRL) donde las acciones de mantenimiento se activan en función de las estimaciones de la distribución RUL. Ilustramos nuestro marco para el mantenimiento de motores turbofán de aviones. Al final de la implementación, el costo de mantenimiento tuvo una disminución del 29.3% en comparación al punto anterior al modelo, todo esto es debido a que solo se mantuvo el 4.4% de los mantenimientos programados ya que son los indispensables para el buen funcionamiento de los motores.

Además, en la investigación de Bouabdallaoui *et al.* (2021) proporcionaron pautas para implementar el mantenimiento predictivo para las instalaciones de los edificios. La metodología inició con la recopilación de datos, luego se tiene el procesamiento de ellos para continuar con el desarrollo de modelos que notificarán las fallas y poder retroalimentar los modelos y generar nuevos. La recolección se realizó en los sistemas de calefacción, ventilación y aire acondicionado a través de sistemas automatizados conectados a Internet. La predicción de las fallas se realiza con un modelo de aprendizaje profundo, en el cual el principal problema recayó en la disponibilidad de los datos y la recolección de los comentarios.

Analizando el artículo de Calvo-Bascones y Sanz-Bobi (2023) se obtuvo una metodología en el campo del Pronóstico y Mantenimiento predictivo (PdM) de componentes industriales. La finalidad del artículo fue diseñar un enfoque de mantenimiento predictivo basado en estrategias donde se caracteriza una planta industrial sin considerar la variación de su comportamiento dinámico. La metodología consistió en el análisis de la desviación y similitud para poder obtener todos los parámetros de funcionamiento del sistema industrial.

Finalmente, en la investigación de Theissler *et al.* (2021) quienes examinaron y categorizaron los documentos y los analizaron desde una perspectiva de aplicación y ML. Después de ello, en el artículo se identificaron desafíos abiertos y discutimos posibles direcciones de investigación. Las conclusiones que llegaron fue que los datos disponibles públicamente impulsaron las actividades de investigación, también la

mayoría de los artículos se basaron en métodos supervisados que requieren datos etiquetados.

Como análisis de variables tenemos como variable de entrada al modelado predictivo que se refiere a un enfoque analítico que utiliza datos históricos y técnicas estadísticas o de aprendizaje automático para crear modelos matemáticos o algorítmicos capaces de realizar predicciones sobre eventos o resultados futuros. Estos modelos permiten tomar decisiones informadas, anticipar tendencias y optimizar procesos a partir de la identificación de patrones en los datos previos (Yang 2022).

El modelado predictivo opera en un entorno de datos, donde las variables desempeñan un papel crucial. Estas variables se dividen en dos categorías fundamentales:

**Variables de Entrada (Características o Predictores):** Representan la información que se utiliza para hacer predicciones. Estas pueden ser de naturaleza espacial, temporal, categórica, numérica o de texto, según la naturaleza de los datos y el problema en cuestión.

**Variable de Salida (Objetivo o Resultado):** Esta variable es el objetivo de la predicción. Puede ser una variable continua en casos de regresión, como el pronóstico de ventas, o una variable categórica en situaciones de clasificación, como la detección de enfermedades.

Los modelos son la esencia del modelado predictivo. Pueden ser paramétricos o no paramétricos. Los modelos paramétricos, como la regresión lineal, asumen una relación funcional específica entre las variables de entrada y la salida. En cambio, los modelos no paramétricos, como los árboles de decisión o las redes neuronales, no imponen una estructura funcional predefinida y pueden capturar relaciones más complejas y no lineales.

El proceso de modelado predictivo sigue una serie de pasos que incluyen:

**Recopilación y preparación de datos:** Se adquieren datos relevantes y se realiza la limpieza, la transformación y la selección de características.

**Entrenamiento del modelo:** Se ajusta el modelo a los datos de entrenamiento, permitiendo que capture patrones y relaciones.

**Validación del modelo:** El modelo se evalúa utilizando datos de prueba para determinar su capacidad de generalización y precisión.

Optimización y ajuste del modelo: Los hiper parámetros se ajustan para mejorar el rendimiento del modelo.

Despliegue y uso en producción: Una vez validado, el modelo se implementa en un entorno de producción para realizar predicciones en situaciones reales.

La calidad de las predicciones se mide utilizando diversas métricas de evaluación, como el error cuadrático medio (MSE), la precisión, el área bajo la curva ROC (AUC), la sensibilidad y la especificidad. La elección de la métrica depende de la naturaleza del problema y los objetivos específicos.

El modelado predictivo se aplica en una amplia variedad de campos, como finanzas, salud, marketing, manufactura, medio ambiente, seguridad y más. Se utiliza para tomar decisiones informadas y anticipar eventos futuros, lo que tiene un impacto significativo en la toma de decisiones estratégicas.

El mantenimiento predictivo que según (Cavalieri y Salafia 2020) es una estrategia de mantenimiento basada en el análisis de datos y en la monitorización de parámetros de funcionamiento, que permite detectar el estado de un equipo o sistema y prever las necesidades de mantenimiento antes de que ocurran fallos. Según (Hupjé 2021) el mantenimiento predictivo está definido como una técnica de mantenimiento que utiliza datos y mediciones para evaluar el estado de los equipos, detectar anomalías y predecir posibles fallos, permitiendo la planificación de actividades de mantenimiento de manera anticipada. Finalmente se tiene la definición dada por (Cardoso y Ferreira 2021) quienes lo definen como un enfoque de mantenimiento que se basa en la recopilación y análisis de datos de rendimiento, condiciones y salud de los activos, con el fin de anticipar fallos y realizar actividades de mantenimiento de manera planificada y oportuna.

Conforme a esta variable tenemos que según (Shyr *et al.* 2022) define como las dimensiones del mantenimiento al diagnóstico del mantenimiento el cual es el proceso de recopilación y análisis de información sobre el estado de un equipo o sistema, con el fin de identificar problemas, evaluar su gravedad y determinar las acciones necesarias para su resolución. Además, según (Díaz-Concepción *et al.* 2019) menciona adicionalmente al diagnóstico la planificación y organización de las actividades de mantenimiento, considerando los recursos disponibles, los requisitos

de tiempo y las necesidades de los activos, con el objetivo de maximizar la disponibilidad y el rendimiento de los equipos. Finalmente contamos con las actividades de ejecución del mantenimiento donde incluye la implementación de las actividades de mantenimiento planificadas, incluyendo la realización de inspecciones, reparaciones, reemplazos y ajustes, de acuerdo con los procedimientos establecidos y las mejores prácticas, con el propósito de mantener o mejorar el rendimiento de los activos (Voronin 2022).

Como variable de salida tenemos el caso de los indicadores de mantenimiento parámetros o medidas utilizados para evaluar el rendimiento, la eficacia y la eficiencia de las actividades de mantenimiento, con el fin de mejorar la gestión de los activos físicos y optimizar el uso de los recursos disponibles (Mora *et al.* 2021). Así mismo tenemos la definición de (Pérez, Pérez Rodríguez y de la Paz Martínez 2021) quienes mencionan que son variables cuantitativas o cualitativas que permiten medir y evaluar el desempeño de las actividades de mantenimiento, con el propósito de tomar decisiones informadas y mejorar la eficacia y la eficiencia del mantenimiento. Luego tenemos que son mediciones o señales utilizadas para evaluar la condición y eficiencia de los motores, proporcionando información valiosa para la planificación y ejecución de actividades de mantenimiento. Según (Aivaliotis *et al.* 2023) define a los indicadores de mantenimiento como medidas utilizadas para cuantificar el desempeño del mantenimiento en términos de calidad, tiempo, costo y seguridad, con el objetivo de monitorear el rendimiento y mejorar continuamente las actividades de mantenimiento. Las dimensiones de la variable según (Geisbush y Ariaratnam 2022) está dada por la disponibilidad de los equipos que se define como la capacidad de un activo físico para desempeñar una función requerida en un momento o intervalo de tiempo determinado, bajo condiciones específicas, teniendo en cuenta la probabilidad de fallo y los tiempos de inactividad planificados o no planificados. Así mismo según (Benyssaad 2022) se menciona que la confiabilidad es otra dimensión de la variable indicador de mantenimiento que está definida como la capacidad de un activo físico para realizar una función requerida durante un período de tiempo determinado y bajo condiciones especificadas, sin fallar y con un rendimiento adecuado. Finalmente, según, (Gan, Song y Zhang 2022) considera a la mantenibilidad como una de las dimensiones a

trabajar que está definida como la capacidad de un activo o sistema para ser mantenido o reparado de manera eficiente y efectiva. Es la medida de cuán fácil es realizar tareas de mantenimiento, tales como inspecciones, ajustes, reparaciones o sustituciones de componentes, con el fin de mantener el activo en un estado operativo o restaurarlo a dicho estado.

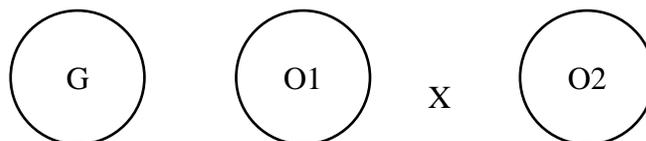
### III. METODOLOGÍA

#### 3.1 Tipo y diseño de investigación

La investigación es de tipo aplicada debido a que utiliza la teoría de mantenimiento y LSTM con evolución diferencial para solucionar el problema de las fallas. Además, es de enfoque cuantitativo debido a que podemos realizar análisis con los datos obtenidos del levantamiento de información (Marconi y Lakatos, 2003).

La investigación es de diseño preexperimental en el cual analizaremos los indicadores de mantenimiento antes y después del empleo del modelado predictivo; también es considerada de tipo longitudinal ya que analizará en las variables dos tiempos, antes y después de la implementación del algoritmo. Es explicativa, por su alcance, debido a que se analiza las causas de las variaciones en los indicadores del mantenimiento (Nazareno y Reisdorfer, 2023).

Figura 1 Esquema de diseño de investigación



Donde:

G: Camioneta HILUX.

X: Algoritmo LSTM soportado con evolución diferencial.

O1: Indicadores del mantenimiento (pre estímulo)

O2: Indicadores del mantenimiento (post estímulo)

### 3.2 Variables y operacionalización

#### **Variable 1: Algoritmo basado en LSTM soportado con evolución diferencial**

Las LSTM son un tipo especializado de red neuronal recurrente diseñadas para abordar el problema de la memoria a largo plazo en el aprendizaje secuencia y estarán optimizadas por el proceso de evolución diferencial (Tete *et al.*, 2022).

#### **Variable 2: Indicadores del mantenimiento**

Son parámetros o medidas utilizados para evaluar el rendimiento, la eficacia y la eficiencia de las actividades de mantenimiento, con el fin de mejorar la gestión de los activos físicos y optimizar el uso de los recursos disponibles (Aivaliotis *et al.* 2023).

### 3.3 Población, muestra, muestreo

#### **Población**

La población es la flota de 30 camionetas HILUX de una compañía minera.

- **Criterios de inclusión:** camionetas con al menos un mantenimiento correctivo.
- **Criterios de exclusión:** camionetas nuevas

**Muestra:** Cinco camionetas de la flota, quienes eran los equipos más críticos de la flota.

**Muestreo:** No probabilístico por conveniencia

**Unidad de análisis:** una camioneta HILUX.

### 3.4 Técnicas e instrumentos de recolección de datos

#### **Técnicas de recolección de datos**

En primer lugar, se utilizaron como técnica el análisis documental, para la toma de datos de cada uno de los indicadores de mantenimiento de la camioneta. Como segunda técnica se tuvo la encuesta, la cual fue validada por 3 ingenieros expertos en el área de mantenimiento, que se realizaron a los operarios de las camionetas y los técnicos encargados de la reparación.

El formato se muestra en el Anexo 02.

### **Instrumentos de recolección de datos**

En primer lugar, se utilizó una ficha de registro donde se ingresaron los datos de cada uno de los indicadores de mantenimiento de las camionetas. En segundo lugar, se elaboró un cuestionario de opción simple de 20 preguntas.

## **3.5 Procedimientos**

El estudio se inició con el levantamiento de información en campo de cada uno de los sistemas de las camionetas. En esta etapa se determinó el tiempo de mantenimiento, el tiempo medio entre fallas, los sistemas críticos de las camionetas, entre otros.

En la segunda etapa correspondiente al cálculo de los indicadores de mantenimiento actuales. Aquí es donde se calculó los valores actuales de disponibilidad, confiabilidad y mantenibilidad.

La siguiente etapa consistió en la implementación de un sistema formado por un algoritmo de evolución diferencial con una red de memoria largo – corto plazo para poder predecir los valores de los indicadores de mantenimiento.

Como siguiente paso se realizó una predicción de los nuevos valores de disponibilidad, confiabilidad y mantenibilidad de los sistemas una vez implementado el algoritmo basado en LSTM soportado con evolución diferencial. Después de ello se compara con las metodologías existentes de modelado predictivo.

Finalmente, se realizó un análisis económico para determinar el costo de implementación del plan y tasa de retorno de la inversión realizada.

### **3.6 Método de análisis de datos**

En la investigación se planteó el tratamiento de la información en Hojas de cálculo de Excel para obtener los indicadores de mantenimiento. Todo es obtenido del análisis documental.

Para el algoritmo del sistema de mantenimiento y toma de decisiones a través de redes neuronales, la programación se realizó en el software Python.

Para el análisis posterior se realizó en Excel.

### **3.7 Aspectos éticos**

La investigación contempló las citaciones de los antecedentes en Norma ISO para respetar los derechos de autor. También se ha empleado la normativa vigente del área de investigación de la Universidad César Vallejo para el desarrollo del Proyecto. Además, se está considerando un porcentaje de similitud no mayor al 20% tanto a nivel nacional o internacional.

## **IV RESULTADOS**

Para obtener los valores de indicadores de mantenimiento, se realizó la toma de datos de los tiempos de parada y de operación de cada una de las camionetas (Tabla 1) donde se pueden ver los valores que se utilizarán para calcular los indicadores de mantenimiento.

Tabla 1 Valores de tiempos de cada camioneta

ITEM	VEHICULO O EQUIPO	MARCA	TIEMPO DISPONIBLE(Hs)	TIEMPO DE INACTIVIDAD(Hs)	TIEMPO PRODUCTIVO(Hs)	N° DE FALLAS
1	CAMIONETA 01	HILUX	192.00	20.00	172.00	8.00
2	CAMIONETA 02	HILUX	192.00	22.00	170.00	6.00
3	CAMIONETA 03	HILUX	192.00	20.00	172.00	5.00
4	CAMIONETA 04	HILUX	192.00	19.00	173.00	9.00
5	CAMIONETA 05	HILUX	192.00	21.00	171.00	6.00
6	CAMIONETA 06	HILUX	192.00	22.00	170.00	4.00
7	CAMIONETA 07	HILUX	192.00	18.00	174.00	7.00

En segundo lugar, se realizó el cálculo de los tres indicadores de mantenimiento para cada una de las camionetas (Tabla 2) donde podemos ver como los valores son menores que el 90%.

Tabla 2 Valores de indicadores de mantenimiento de cada camioneta

VEHICULO O EQUIPO	DISPONIBILIDAD	CONFIABILIDAD	MANTENIBILIDAD
CAMIONETA 01	89.58%	92.31%	49.74%
CAMIONETA 02	88.54%	94.18%	37.10%
CAMIONETA 03	89.58%	95.12%	34.95%
CAMIONETA 04	90.10%	91.39%	55.93%
CAMIONETA 05	89.06%	94.18%	38.65%
CAMIONETA 06	88.54%	96.08%	26.59%
CAMIONETA 07	90.63%	93.24%	49.17%

En la Figura 2 podemos observar cómo los valores de disponibilidad son muy bajos llegando a valores de 88.54% para la camioneta 02 Y 06 (Ver Anexo 4).

Estos datos demuestran que las camionetas en su mayoría de casos debido a fallas no se encuentran disponibles para el trabajo de campo, lo que ocasiona paradas del proceso de trabajo.

Para el análisis del algoritmo de LSTM con evolución diferencial se iniciará con el pseudocódigo (Nakisa *et al.* 2018):

Definir el tamaño de la población NP (número de padres), la dimensión del problema, tasa de cruce  $C_r$  y factor de escala F.

**Inicialización:** Iniciar la población

$$S_i^{t=0} = \{s_{1,i}^t, s_{2,i}^t, \dots, s_{D,i}^t\}, i = 1, 2, \dots, N_p \quad (1)$$

donde cada individuo se distribuye uniformemente en el rango  
Mientras no se cumplan los criterios de rescisión

Por cada individuo, vector objetivo, en la población NP

**Mutación:** Seleccione tres individuos de la población al azar y genere un vector donante usando la siguiente ecuación de mutación

$$v_{j,i}^t = s_{j,p}^t + F_i \times (s_{j,r}^t + s_{j,q}^t) \quad (2)$$

**Cruce:** Calcule el vector prueba para el i-ésimo vector objetivo

$$u_{j,i}^{t+1}$$

$$u_{j,i}^t = v_{j,i}^t \text{ si } r_i \leq c_r \text{ o } j = J_{\text{rand}} \quad (3)$$

$$u_{j,i}^t = s_{j,i}^t \text{ otros casos}$$

**Selección:** Aplicar el clasificar LSTM como función de aptitud y evaluar  $s_i^{t+1}$  y  $u_i^t$

$$\text{Si } f(s_i^t) \leq f(u_i^t) \text{ entonces } s_i^{t+1} = u_i^t \quad (4)$$

$$\text{De lo contrario } s_i^{t+1} = s_i^t$$

Fin para  
Fin mientras

Con el pseudocódigo se puede obtener las gráficas de predicción (Ver Anexo 5), por ejemplo, en el caso de la Figura 3, tenemos la curva de predicción la disponibilidad durante los primeros 8 meses del año. De igual manera, la Figura 4, nos muestra los valores de confiabilidad durante la misma cantidad de tiempo.

Considerando las líneas de tendencia de la disponibilidad y confiabilidad, podemos predecir que a partir del mes siete caerán los valores por debajo de lo permisible, por dicha razón se plantea un plan de mantenimiento basado en la condición.

#### **1. Monitoreo continuo:**

- Implementar un sistema de telemetría para monitorear en tiempo real los parámetros del vehículo, como temperatura del motor, presión del aceite, nivel de fluidos, rendimiento del motor, entre otros.
- Este monitoreo se realizará con el algoritmo planteado en la presente investigación.

#### **2. Análisis predictivo de aceite (cada 5,000 km o según recomendaciones del sistema):**

- Utilizar sensores de calidad de aceite y realizar análisis predictivos para determinar el momento óptimo para cambiar el aceite.
- Emplear tecnologías de análisis de laboratorio para evaluar la presencia de contaminantes y desgaste en el aceite.

#### **3. Sistema de frenos (monitoreo continuo):**

- Implementar sensores en el sistema de frenos para monitorear el desgaste de las pastillas y discos en tiempo real.
- Programar alertas para indicar la necesidad de reemplazo o ajuste del sistema de frenos.

#### **4. Sistema de transmisión (análisis predictivo Cada 10,000 km):**

- Utilizar sensores para monitorear la temperatura y la presión del líquido de transmisión.
- Aplicar análisis predictivo para identificar posibles problemas en la transmisión antes de que se conviertan en fallas mayores.

#### **5. Sistema de suspensión y dirección (monitoreo continuo):**

- Implementar sensores para monitorear la altura del vehículo y la respuesta de la suspensión.
- Utilizar análisis predictivo para identificar desviaciones en el rendimiento de la suspensión y la dirección.

#### **6. Sistema de combustible (análisis predictivo cada 15,000 km):**

- Utilizar sensores para monitorear la presión del sistema de combustible.
- Aplicar análisis predictivo para identificar posibles problemas en la inyección de combustible.

#### **7. Sistema eléctrico (monitoreo continuo):**

- Implementar sensores para monitorear el estado de la batería y la carga del sistema eléctrico.
- Utilizar análisis predictivo para prever posibles fallas en el sistema de encendido y carga.

#### **8. Sistema de refrigeración (análisis predictivo cada 20,000 km):**

- Utilizar sensores para monitorear la temperatura del líquido refrigerante y el funcionamiento del radiador.

- Aplicar análisis predictivo para identificar posibles problemas en el sistema de refrigeración.

### 9. Inspección preventiva (cada 3 meses):

- A pesar del monitoreo continuo y el análisis predictivo, realizar inspecciones visuales y manuales para detectar posibles problemas no captados por los sensores.

Una vez aplicado el algoritmo a las unidades se está realizando una predicción de los valores de los indicadores de mantenimiento de las unidades quedando tal como se muestra en la Tabla 3 y Tabla 4. Aquí podemos observar en primer lugar los tiempos disponibles y de parada para cada una de las unidades.

Tabla 3 Valores de los tiempos después de la implementación

ÍTEM	VEHÍCULO O EQUIPO	MARCA	TIEMPO DISPONIBLE (Hs)	TIEMPO DE INACTIVIDAD(Hs)	TIEMPO PRODUCTIVO(Hs)	N° DE FALLAS
1	CAMIONETA 01	HILUX	192.00	10.00	182.00	4.00
2	CAMIONETA 02	HILUX	192.00	11.00	181.00	3.00
3	CAMIONETA 03	HILUX	192.00	10.00	182.00	2.00
4	CAMIONETA 04	HILUX	192.00	9.00	183.00	4.00
5	CAMIONETA 05	HILUX	192.00	10.00	182.00	3.00
6	CAMIONETA 06	HILUX	192.00	11.00	181.00	2.00
7	CAMIONETA 07	HILUX	192.00	9.00	183.00	3.00

Tabla 4 Indicadores de mantenimiento después del modelo

<b>VEHÍCULO O EQUIPO</b>	<b>DISPONIBILIDAD</b>	<b>CONFIABILIDAD</b>	<b>MANTENIBILIDAD</b>
<b>CAMIONETA 01</b>	94.79%	96.08%	51.71%
<b>CAMIONETA 02</b>	94.27%	97.04%	38.96%
<b>CAMIONETA 03</b>	94.79%	98.02%	30.51%
<b>CAMIONETA 04</b>	95.31%	96.08%	55.66%
<b>CAMIONETA 05</b>	94.79%	97.04%	42.07%
<b>CAMIONETA 06</b>	94.27%	98.02%	28.04%
<b>CAMIONETA 07</b>	95.31%	97.04%	45.66%

En la Figura 5 podemos observar que los valores de disponibilidad han aumentado donde en este caso las camionetas 02 Y 06 tienen valores de 94.27% (Ver Anexo 6). Así mismo, los valores de confiabilidad han aumentado por lo que las probabilidades de falla son bajas siendo el valor de 4% en el caso de la camioneta 1 y los demás con valores mucho menores.

Finalmente, se realizó un análisis económico de nuestro sistema incluyendo costos de mantenimiento, no se están considerando los gastos en repuestos ya que serían los mismos que se utilizarían en cualquier otro tipo de mantenimiento.

Tabla 5 Presupuesto del algoritmo y plan de mantenimiento

<b>Rubros</b>	<b>Aporte monetario</b>
- Algoritmo	3000.00
- Planner	2500.00
- Supervisor de Mantenimiento	3000.00
- Personal técnico	1500.00
<b>TOTAL</b>	<b>10,000.00</b>

## **V DISCUSIÓN**

En primer lugar, al determinar el estado actual de los indicadores de mantenimiento de las camionetas de la unidad minera, se pudo encontrar que los valores de disponibilidad están rondando entre 80.54% y 90.63%, el valor de la confiabilidad entre 91.39% y 96.08% y el valor de la mantenibilidad está entre 26.59% y 55.93%. Esto quiere decir que las camionetas no siempre están operativas en su totalidad ocasionando tiempos muertos en la producción, que en este caso se evidencia con la falta de unidades para el transporte. Con esto se tiene un punto de partida para corroborar que la hipótesis de investigación ya que si se podrá mejorar dichos valores que son relativamente bajos. La metodología usada para este punto fue la utilizada en los mantenimientos basado en la confiabilidad, lo que coincide con la investigación de (Fatma, Ponda y Saputra 2022) quienes utilizaron la misma metodología y un análisis estadístico para poder determinar los valores de confiabilidad de los sistemas de aire acondicionado, los cuales fueron valores mucho menores que los hallados en nuestra investigación, llegando a valores de 40% por lo que podemos decir que nuestro punto de inicio es mucho más alentador que el de su artículo. En tal sentido, analizando nuestro resultado y comparando nuestro artículo de referencia podemos ver que la metodología de mantenimiento centrado en la confiabilidad es la correcta para el cálculo de nuestro estado actual de los valores de los indicadores de mantenimiento.

En segundo lugar, al elaborar el algoritmo de predicción utilizando *LSTM* soportado con evolución diferencial, se utilizó un pseudo código para poder manejar la data histórica de nuestros valores de los indicadores de mantenimiento, con los que se puede encontrar una predicción de los valores de disponibilidad, confiabilidad y mantenibilidad en los meses posteriores a la toma de datos. (Peng *et al.* 2018) utilizan el mismo algoritmo *LSTM* soportado por evolución diferencial para predecir el precio de la electricidad obteniendo un valor de porcentaje de error promedio del 3% lo cual es aceptable para el sistema predictivo tratado. Esto demuestra que el algoritmo nos ayuda a poder realizar un análisis predictivo de nuestros valores de indicadores y poder dar un plan de mejora de los mismos tal como se vieron en la figura 3 y figura 4. En tal sentido, el algoritmo presentado si cumple con el objetivo de predecir los indicadores de mantenimiento.

En tercer lugar, al implementar un plan de mantenimiento predictivo basado en el algoritmo se pudo obtener todos los pasos concernientes a un mantenimiento basado en la condición, con los cuales se puede atacar cada uno de los puntos de mayor falla de nuestros sistemas antes que se realice la disminución de los valores de disponibilidad a menores del 80%. Además, con dicho plan de mantenimiento se puede elevar los valores de los indicadores de mantenimiento por sobre el 92% para la disponibilidad y la confiabilidad. Con respecto al uso de este modelo de plan de mantenimiento Sharma *et al.* (2022) menciona que es el método más utilizado cuando se utiliza sistema de redes neuronales para poder atacar las fallas antes que se produzcan y poder mejorar los indicadores de mantenimiento de los equipos con los que se trabaja. Esto apoya nuestra hipótesis de que el algoritmo unido a un plan de mantenimiento basado en la condición mejorará los valores de los indicadores. En tal sentido, se puede interpretar que el plan de mantenimiento basado en la condición es un mantenimiento óptimo para nuestro caso de estudio.

## VI CONCLUSIONES

1. Se realizaron los cálculos de los indicadores actuales de mantenimiento obteniendo valores promedios de 80 a 90 % para los valores de disponibilidad con lo cual se analiza que las unidades no siempre están operativas. Esta metodología utilizada fue acorde a lo observado en cada uno de los artículos de mantenimiento hallados.
2. Se realizó el algoritmo basado en *LSTM* soportado con evolución diferencial con lo que se pudo predecir los valores de disponibilidad y confiabilidad de las unidades de la muestra. Para nuestro caso se realizó un pseudocódigo que se utilizó para obtener las curvas de predicción de nuestros indicadores.
3. Se realizó un plan de mantenimiento basado en la condición con lo que se proyectó un incremento de los valores de disponibilidad sobre el 90% asegurando un mejor rendimiento de las unidades
4. Se realizó un presupuesto de la implementación del plan de mantenimiento y del algoritmo llegando a un valor de S/. 10, 000. 00 que será presentado a la empresa.

## VII RECOMENDACIONES

El algoritmo utilizado puede ser enriquecido con data en tiempo real o para que pueda ir actualizándose las curvas en función de los cambios.

Se recomienda utilizar un modelo distinto para la optimización de los datos para poder dar un mejor manejo de los mismos.

## REFERENCIAS

- AIVALIOTIS, P., ARKOULI, Z., GEORGOULIAS, K. y MAKRIS, S., 2023. Methodology for enabling dynamic digital twins and virtual model evolution in industrial robotics - a predictive maintenance application. *International Journal of Computer Integrated Manufacturing*, ISSN 13623052. DOI 10.1080/0951192X.2022.2162591.
- BASTÍAS, O.A., DÍAZ, J. y LÓPEZ FENNER, J., 2023. Exploring the Intersection between Software Maintenance and Machine Learning—A Systematic Mapping Study. *Applied Sciences (Switzerland)*, vol. 13, no. 3, ISSN 20763417. DOI 10.3390/app13031710.
- BENYSSAAD, Y., 2022. A NEW OPTIMIZATION MODEL BASED ON 'RELIABILITY CENTERED MAINTENANCE' OF ELECTRICAL DISTRIBUTION NETWORK. *Revue Roumaine des Sciences Techniques Serie Electro technique et Energetique*, vol. 67, no. 1, ISSN 00354066.
- BOUABDALLAOUI, Y., LAFHAJ, Z., YIM, P., DUCOULOMBIER, L. y BENNADJI, B., 2021. Predictive maintenance in building facilities: A machine learning-based approach. *Sensors (Switzerland)*, vol. 21, no. 4, ISSN 14248220. DOI 10.3390/s21041044.
- CALVO-BASCONES, P. y SANZ-BOBI, M.A., 2023. Advanced Prognosis methodology based on behavioral indicators and Chained Sequential Memory Neural Networks with a diesel engine application. *Computers in Industry*, vol. 144, ISSN 01663615. DOI 10.1016/j.compind.2022.103771.
- CARDOSO, D. y FERREIRA, L., 2021. Application of predictive maintenance concepts using artificial intelligence tools. *Applied Sciences (Switzerland)*, vol. 11, no. 1, ISSN 20763417. DOI 10.3390/app11010018.
- CAVALIERI, S. y SALAFIA, M.G., 2020. A model for predictive maintenance based on asset administration shell. *Sensors (Switzerland)*, vol. 20, no. 21, ISSN 14248220. DOI 10.3390/s20216028.
- DÍAZ-CONCEPCIÓN, A., VILLAR-LEDO, L., RODRÍGUEZ-PIÑEIRO, A.J. y TAMAYO-MENDOZA, J.E., 2019. Methodology for maintenance management

based on diagnostic criteria. *DYNA (Colombia)*, vol. 86, no. 211, ISSN 00127353. DOI 10.15446/dyna.v86n211.77704.

FATMA, N.F., PONDA, H. y SAPUTRA, T.A., 2022. Perbaikan Perencanaan Penjadwalan Maintenance Pada Air Conditioner (AC) Menggunakan Metode Realibility Centered Maintenance (RCM) Di PT. Tifico Fiber Indonesia Tbk. *Journal Industrial Manufacturing*, vol. 7, no. 2, ISSN 2502-4582. DOI 10.31000/jim.v7i2.6935.

GAN, S., SONG, Z. y ZHANG, L., 2022. A maintenance strategy based on system reliability considering imperfect corrective maintenance and shocks. *Computers and Industrial Engineering*, vol. 164, ISSN 03608352. DOI 10.1016/j.cie.2021.107886.

GEISBUSH, J. y ARIARATNAM, S.T., 2022. Reliability centered maintenance (RCM): literature review of current industry state of practice. *Journal of Quality in Maintenance Engineering*, ISSN 13552511. DOI 10.1108/JQME-02-2021-0018.

GONG, C.S.A., SU, C.H.S., CHEN, Y.H. y GUU, D.Y., 2022. *How to Implement Automotive Fault Diagnosis Using Artificial Intelligence Scheme*. 2022. S.l.: s.n.

HUPJÉ, 2021. 9 Types Of Maintenance How To Choose The Right Maintenance Strategy. *The Official Website of «road to RELIABILITY»*,

JAFARZADEH, E., LI, D., RAHIMIFARD, S., ANNA, P.S., CAO, Y. y SADJADI, H., 2022. Fault injection method and ground-truth state of health development for a low-cost bearing fault monitoring system in the automotive industry. *Proceedings of the Annual Conference of the Prognostics and Health Management Society, PHM*. S.l.: s.n., vol. 14. DOI 10.36001/phmconf.2022.v14i1.3180.

LEE, J. y MITICI, M., 2023. Deep reinforcement learning for predictive aircraft maintenance using probabilistic Remaining-Useful-Life prognostics. *Reliability Engineering and System Safety*, vol. 230, ISSN 09518320. DOI 10.1016/j.ress.2022.108908.

MARCONI, M. y LAKATOS, E., 2003. Fundamentos de metodología científica. *Editora Atlas S. A.*, ISSN 9788522457588. DOI 10.1590/S1517-97022003000100005.

MENG, J., LI, C., TAO, J., LI, Y., TONG, Y., WANG, Y., ZHANG, L., DONG, Y. y DU, J., 2023. RNN-LSTM-Based Model Predictive Control for a Corn-to-Sugar Process. *Processes*, vol. 11, no. 4, ISSN 22279717. DOI 10.3390/pr11041080.

MITICI, M., DE PATER, I., BARROS, A. y ZENG, Z., 2023. Dynamic predictive maintenance for multiple components using data-driven probabilistic RUL prognostics: The case of turbofan engines. *Reliability Engineering and System Safety*, vol. 234, ISSN 09518320. DOI 10.1016/j.ress.2023.109199.

MORA, M., PUERTO, H., ROCAMORA, C. y ABADIA, R., 2021. New Indicators to Discriminate the Cause of Low Energy Efficiency in Deep-Well Pumps. *Water Resources Management*, vol. 35, no. 4, ISSN 15731650. DOI 10.1007/s11269-021-02792-9.

NAKISA, B., RASTGOO, M.N., RAKOTONIRAINY, A., MAIRE, F. y CHANDRAN, V., 2018. Long short-term memory hyperparameter optimization for a neural network-based emotion recognition framework. *IEEE Access*, vol. 6, ISSN 21693536. DOI 10.1109/ACCESS.2018.2868361.

NAZARENO, G.G. y REISDORFER, G., 2023. METODOLOGIA CIENTÍFICA - REFLEXÕES SOBRE PENSAMENTOS EPISTEMOLÓGICOS. *COGNITIONIS Scientific Journal*, vol. 6, no. 1, DOI 10.38087/2595.8801.176.

NEKOONAM, A., NASAB, R.F., JAFARI, S., NIKOLAIDIS, T., ALE EBRAHIM, N. y MIRAN FASHANDI, S.A., 2023. A Scientometric Methodology Based on Co-Word Analysis in Gas Turbine Maintenance. *Tehnicki Vjesnik*, vol. 30, no. 1, ISSN 18486339. DOI 10.17559/TV-20220118165828.

PAGANO, D., 2023. A predictive maintenance model using Long Short-Term Memory Neural Networks and Bayesian inference. *Decision Analytics Journal*, vol. 6, ISSN 27726622. DOI 10.1016/j.dajour.2023.100174.

PENG, L., LIU, S., LIU, R. y WANG, L., 2018. Effective long short-term memory with differential evolution algorithm for electricity price prediction. *Energy*, vol. 162, ISSN 03605442. DOI 10.1016/j.energy.2018.05.052.

PÉREZ PÉREZ, M., PÉREZ RODRÍGUEZ, Á.T. y DE LA PAZ MARTÍNEZ, E.M., 2021. Cuadro de mando integral para gestión del mantenimiento con enfoque

sostenible en industrias del plástico. *Retos de la Dirección*, vol. 15, no. 2, ISSN 2306-9155.

QIU, S., CUI, X., PING, Z., SHAN, N., LI, Z., BAO, X. y XU, X., 2023. *Deep Learning Techniques in Intelligent Fault Diagnosis and Prognosis for Industrial Systems: A Review*. 2023. S.l.: s.n.

SHARMA, J., MITTAL, M.L. y SONI, G., 2022. *Condition-based maintenance using machine learning and role of interpretability: a review*. 2022. S.l.: s.n.

SHYR, W.J., TSAI, C.J., LIN, C.M. y LIAU, H.M., 2022. Development and Assessment of Augmented Reality Technology for Using in an Equipment Maintenance and Diagnostic System. *Sustainability (Switzerland)*, vol. 14, no. 19, ISSN 20711050. DOI 10.3390/su141912154.

TALALAEV, M.V., 2023. PREDICTIVE MODELS IN BRAIN'S MRI: THE SAMPLE SIZE DEFINITION ON DEEP LEARNING MODEL. *Современные наукоемкие технологии (Modern High Technologies)*, no. №1 2023, ISSN 18127320. DOI 10.17513/snt.39498.

TAMA, B.A., VANIA, M., LEE, S. y LIM, S., 2022. Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals. *Artificial Intelligence Review*, ISSN 15737462. DOI 10.1007/s10462-022-10293-3.

TETE, M.F., SOUSA, M. de M., DE SANTANA, T.S. y FELLIPE, S., 2022. *Predictive Models for Higher Education Dropout: A Systematic Literature Review*. 2022. S.l.: s.n.

THESSLER, A., PÉREZ-VELÁZQUEZ, J., KETTELGERDES, M. y ELGER, G., 2021. Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry. *Reliability Engineering and System Safety*, vol. 215, ISSN 09518320. DOI 10.1016/j.ress.2021.107864.

ULLAH, S., LI, S., KHAN, K., KHAN, S., KHAN, I. y ELDIN, S.M., 2023. An Investigation of Exhaust Gas Temperature of Aircraft Engine Using LSTM. *IEEE Access*, vol. 11, ISSN 21693536. DOI 10.1109/ACCESS.2023.3235619.

VORONIN, V., 2022. Diagnostic principles in maintenance systems. *Transportation Research Procedia*. S.l.: s.n., vol. 63. DOI 10.1016/j.trpro.2022.06.323.

YANG, C.C., 2022. Explainable Artificial Intelligence for Predictive Modeling in Healthcare. *Journal of Healthcare Informatics Research*, vol. 6, no. 2, ISSN 2509498X. DOI 10.1007/s41666-022-00114-1.

ZHANG, B., SUN, X., LIU, S. y DENG, X., 2020. Adaptive Differential Evolution-Based Distributed Model Predictive Control for Multi-UAV Formation Flight. *International Journal of Aeronautical and Space Sciences*, vol. 21, no. 2, ISSN 20932480. DOI 10.1007/s42405-019-00228-8.

## ANEXOS

### Anexo 1.

Tabla 6 Matriz de Operacionalización de variable independiente

Variable	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Escala
<b>Variable Independiente:</b> Algoritmos basados en LSTM soportado con evolución diferencial.	Las LSTM son un tipo especializado de red neuronal recurrente diseñadas para abordar el problema de la memoria a largo plazo en el aprendizaje secuencia y estarán optimizadas por el proceso de evolución diferencial (Tete et al., 2022).	Implica la descripción detallada de cómo se lleva a cabo el proceso de crear modelos matemáticos o algorítmicos para predecir eventos o resultados futuros (Talalaev 2023)	Dominio	Tipo de muestra	Razón
			Método	Tipo de modelo	Razón
			Evaluación	Métricas de rendimiento	Razón

Tabla 7 Matriz de Operacionalización de variable dependiente

Variable	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Escala
<b>Variable Independiente:</b> Indicadores de mantenimiento	Son parámetros o medidas utilizados para evaluar el rendimiento, la eficacia y la eficiencia de las actividades de mantenimiento, con el fin de mejorar la gestión de los activos físicos y optimizar el uso de los recursos disponibles (Aivaliotis et al. 2023).	La variable se analizará para poder disminuir la cantidad de fallas en las camionetas y los tiempos de parada que tienen.	Disponibilidad.	Tiempo medio entre fallas	Razón
			Confiabilidad.	Tiempo medio entre fallas	Razón
			Mantenibilidad.	Tiempo medio de mantenimiento	Razón

## Anexo 2. Instrumento de recolección de datos

Tabla 8 Ficha de registro

ÍTEM	VEHÍCULO O EQUIPO	MARCA	TIEMPO DISPONIBLE(Hs)	TIEMPO DE INACTIVIDAD(Hs)	TIEMPO PRODUCTIVO(Hs)	N° DE FALLAS

#### Anexo 4. Indicadores actuales de mantenimiento

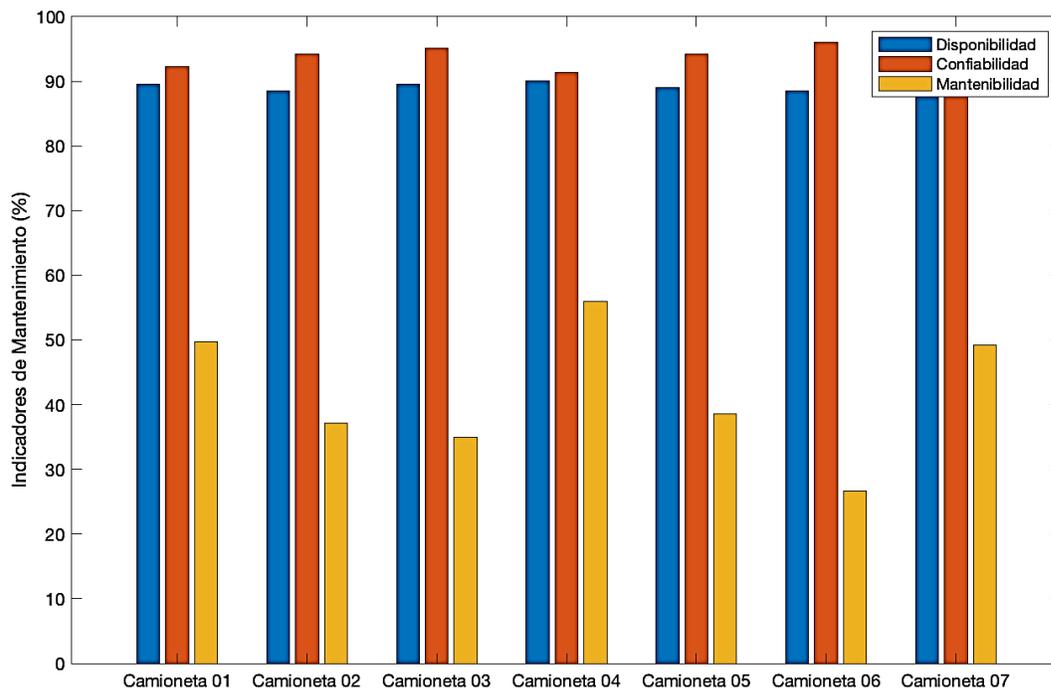


Figura 2 Cuadro indicadores de mantenimiento de cada una de las unidades

## Anexo 5. Curvas de predicción de los valores de indicadores de mantenimiento

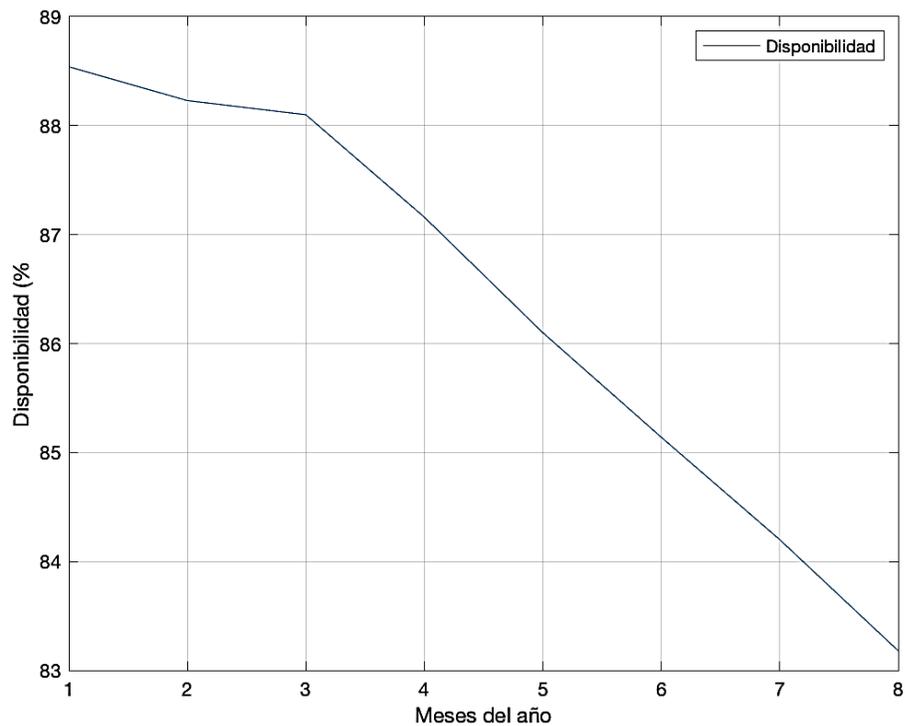


Figura 3 Curva de predicción de la disponibilidad

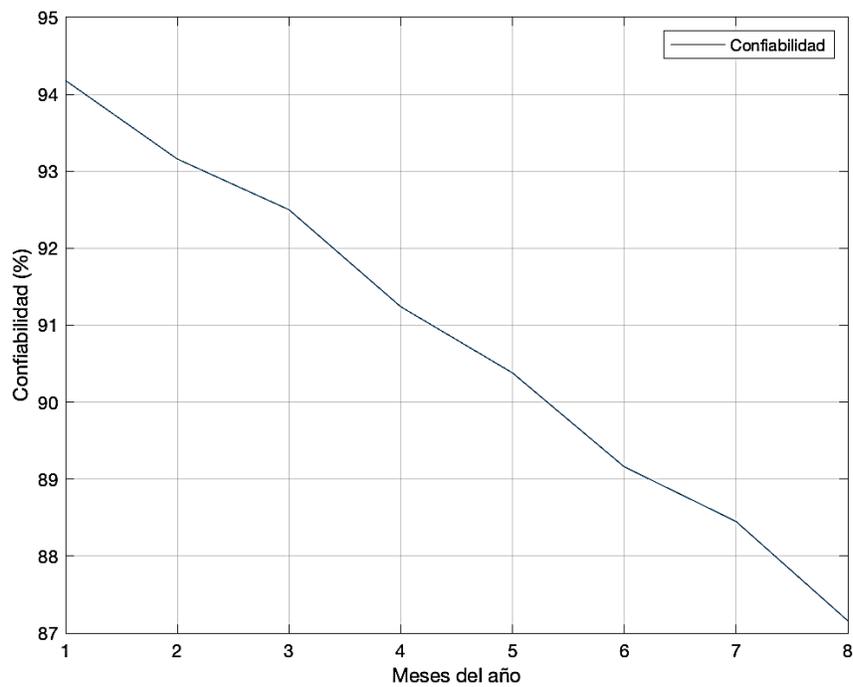


Figura 4 Curva de predicción de la confiabilidad

## Anexo 6. Indicadores proyectados de mantenimiento

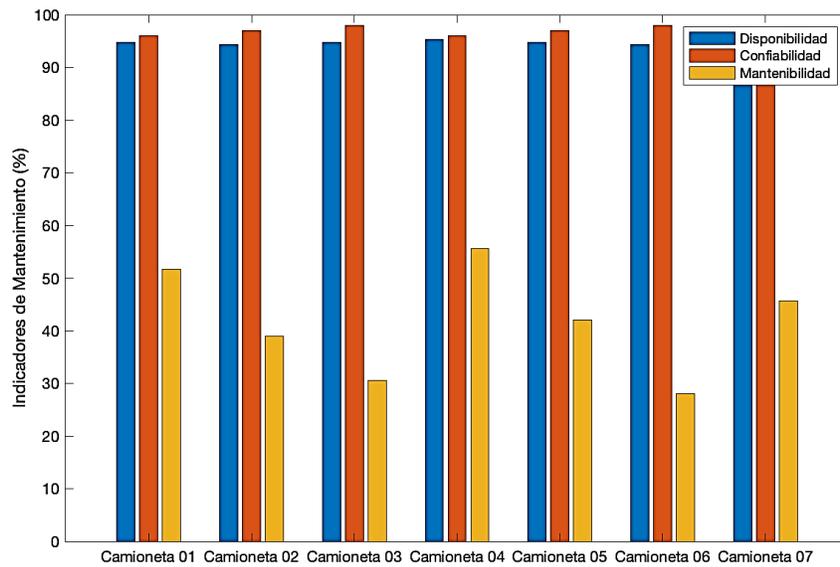


Figura 5 Cuadro proyectado de indicadores de mantenimiento de cada una de las unidades