



UNIVERSIDAD CÉSAR VALLEJO

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

Machine learning en la disponibilidad y confiabilidad de la flota
vehicular de una calera

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:

Ingeniero Mecánico Electricista

AUTOR:

Rondon Chavez, Ronald Edwin (orcid.org/0000-0001-9236-5960)

ASESOR:

Mg. Sialer Diaz, Cesar Dany (orcid.org/0000-0002-7430-9524)

LÍNEA DE INVESTIGACIÓN:

Sistemas y Planes de Mantenimiento

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Desarrollo sostenible y adaptación al cambio climático

**TRUJILLO – PERÚ
2022**

Dedicatoria

Dedicar la presente tesis a todos los que confían en mí y aportan su granito de arena para mi crecimiento personal y profesional.

Rondón Chávez, Ronald Edwin

Agradecimiento

Agradecer a Dios y mi familia por todo el soporte brindado durante el desarrollo de mis estudios. A la UCV por abrir sus puertas y brindar las facilidades para incrementar mis conocimientos, a los profesores por todas las experiencias vividas durante mi formación profesional.

Rondón Chávez, Ronald Edwin

Índice de Contenidos

Dedicatoria	ii
Agradecimiento	iii
Índice de Contenidos.....	iv
Índice de Tablas	v
Índice de Figuras.....	vi
Resumen.....	vii
Abstract	viii
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO.....	4
2.1. Marco Conceptual	7
III. METODOLOGÍA.....	12
3.1. Tipo y diseño de investigación	12
3.2. Variables y operacionalización	12
3.3. Población, muestra, muestreo y unidad de análisis.....	13
3.4. Técnicas e instrumentos de recolección de datos	14
3.5. Procedimientos	15
3.6. Método de análisis de datos.....	15
3.7. Aspectos éticos.....	15
IV. RESULTADOS.....	16
4.1. Determinar la disponibilidad y confiabilidad de la flota vehicular de una calera.	16
4.2. Desarrollar un modelo de machine learning para pronosticar la disponibilidad y confiabilidad de la flota vehicular de la calera.	29
4.3. Determinar la disponibilidad y confiabilidad pronosticada de la flota vehicular de una calera posterior a la implementación de machine learning.	39
4.4. Determinar el costo beneficio al implementar el machine learning en el mantenimiento de la flota vehicular de una calera.	47
V. DISCUSIÓN.....	49
VI. CONCLUSIONES.....	53
VII. RECOMENDACIONES.....	54
REFERENCIAS	55
ANEXOS.....	61

Índice de Tablas

Tabla 1: <i>Variables, descripción y datos.</i>	9
Tabla 2: <i>Total de maquinarias</i>	13
Tabla 3: <i>Instrumentos y técnicas de medición</i>	14
Tabla 4: Informe técnico desde mayo hasta el mes de julio del año 2022	16
Tabla 5: Análisis de variables	31
Tabla 6: Resultados por modelo	33
Tabla 7: Variables del modelo de disponibilidad	35
Tabla 8: Resultados por modelo	38
Tabla 9: Resultados por modelo	39
Tabla 10: Resultados por modelo	40
Tabla 11: Disponibilidad y prueba de muestras	41
Tabla 12: Confiabilidad y prueba de muestras	41
Tabla 13: Disponibilidad y prueba de muestras	42
Tabla 14: Confiabilidad y prueba de muestras	42
Tabla 15: Disponibilidad y prueba de muestras	43
Tabla 16: Confiabilidad y prueba de muestras	43
Tabla 17: Disponibilidad y prueba de muestras	44
Tabla 18: Confiabilidad y prueba de muestras	44
Tabla 19: Listado de equipos de la empresa calera	46
Tabla 20: Costo invertido en el software de aplicación predictiva	47
Tabla 21: Indicadores VAN y TIR	48

Índice de Figuras

<i>Figura 1:</i> Etapas genéricas para el planteamiento de un proyecto con M.L.	7
<i>Figura 2:</i> Ciclo de vida de minería de datos	8
<i>Figura 3:</i> Escenarios de confiabilidad	11
<i>Figura 4:</i> Disponibilidad del cargador frontal	21
<i>Figura 5:</i> Disponibilidad de la retro excavadora	22
<i>Figura 6:</i> Disponibilidad del mini cargador	23
<i>Figura 7:</i> Disponibilidad de la excavadora	24
<i>Figura 8:</i> Confiabilidad del cargador frontal	25
<i>Figura 9:</i> Confiabilidad de la retroexcavadora	26
<i>Figura 10:</i> Confiabilidad del minicargador	27
<i>Figura 11:</i> Confiabilidad de la excavadora	28
<i>Figura 12:</i> Matriz de correlación de Spearman	29
<i>Figura 13:</i> Selección de variables por Random Forest	30
<i>Figura 14:</i> Disponibilidad vs Disponibilidad estimada (RLM)	31
<i>Figura 15:</i> Disponibilidad vs Disponibilidad estimada (RF)	32
<i>Figura 16:</i> Disponibilidad vs Disponibilidad estimada (Xgboost)	32
<i>Figura 17:</i> Matriz de correlación de Spearman	34
<i>Figura 18:</i> Selección de variables por Random Forest	35
<i>Figura 19:</i> Confiabilidad vs Confiabilidad estimada (RLM)	36
<i>Figura 20:</i> Confiabilidad vs Confiabilidad estimada (RF)	37
<i>Figura 21:</i> Confiabilidad en Xgboost	37
<i>Figura 22:</i> Disponibilidad vs Disponibilidad estimada	39
<i>Figura 23:</i> Confiabilidad vs Confiabilidad estimada	40
<i>Figura 24:</i> Valor promedio en disponibilidad	45
<i>Figura 25:</i> Valor promedio en confiabilidad	45

Resumen

La investigación tuvo por objetivo general, analizar el impacto al implementar machine learning para lograr una disponibilidad y confiabilidad de una flota vehicular. Se realizó investigación de tipo aplicada, diseño pre experimental, con enfoque cuantitativo; así mismo, la población y muestra del estudio, estuvo constituida por 4 maquinarias pesadas las cuales fueron el cargador frontal, mini cargador, retroexcavadora y excavadora. Se aplicaron diferentes modelos de Machine Learning entre ellas el SVM, Arboles de decisión, y redes neuronales. La información recopilada, se procesó haciendo uso del programa Excel, obteniendo como resultado incremento en el cargador frontal de 24.95% en disponibilidad y 36,7% en confiabilidad, con relación a la retroexcavadora se obtuvo un incremento del 25.48% en disponibilidad y 35,24% en confiabilidad, también se pudo apreciar con respecto al minicargador un incremento del 22.75% en disponibilidad y 34.79% en confiabilidad, con relación a la excavadora se obtuvo un incremento de 27.42% en disponibilidad y 42.46% en confiabilidad. Finalmente se concluyó que el Machine Learning mejora la gestión de mantenimiento de la maquinaria pesada, ya que contar con una herramienta tecnológica que predice las fallas, genera grandes beneficios a la empresa y así como puede ser aplicado a otros tipos de empresas similares.

Palabras clave: Machine Learning, disponibilidad, confiabilidad, gestión de flota vehicular.

Abstract

The general objective of the research was to analyze the impact of implementing machine learning to achieve availability and reliability of a vehicle fleet (Calera). An applied type of research was carried out, of a pre-experimental design, with a quantitative approach, likewise the population and the study sample, consisted of 4 heavy machineries which were the front loader, skid steer loader, backhoe loader and excavator. Different Machine Learning models were applied, including SVM, Decision Trees, and neural networks. The information collected was processed using the Excel program, obtaining as results an increase in the front loader of 24.95% in availability and 36.7% in reliability, in relation to the backhoe loader an increase of 25.48% was obtained in the availability and 35.24% in reliability, an increase of 22.75% in availability and 34.79% in reliability could also be seen with respect to the skid steer loader, in relation to the excavator an increase of 27.42% was obtained in availability and 42.46% in reliability. Finally, it was concluded that Machine Learning improves the maintenance management of heavy machinery, since having a technological tool that predicts failures, generates great benefits for the company and can be applied to other types of similar companies.

Keywords: Machine Learning, availability, reliability, vehicle fleet management.

I. INTRODUCCIÓN

El machine learning permitió que las computadoras aprendan a mejorar su desempeño en lo que se les encomienda, esto se realiza a través de tareas sin necesidad de ser programadas directamente (Ruiz-Sarmiento et al. 2020), sin embargo, no se tiene definido el límite ante estos programas de aprendizaje automático y los enfoques estadísticos, resaltando regularmente la precisión predictiva en base a hipótesis, considerándose grandes datos y dimensiones (Bi et al. 2019).

El mantenimiento tiene varios conceptos en base a su aplicación durante los últimos años, se simplifica en una herramienta de autoayuda para una mejor calidad de producción y mantenibilidad de los equipos industriales o maquinarias pesadas, generando indirectamente un mayor tiempo de la seguridad y vida útil, garantizando su operatividad, funcionalidad en los equipos o máquinas.(DAYAM, 2021).

Debido a ello, se ha trazado investigaciones en el campo informático, buscando lograr que las máquinas sean cada vez más inteligentes, puesto que; no solamente el aprendizaje es parte del comportamiento de los seres humanos, (Mitchell 2018) sino que ha sido convertido en un importante aspecto de vital importancia en las máquinas; siendo los algoritmos tradicionales una fuente para el machine learning en diversas áreas (Shinde y Shah 2018).

A su vez, el crecimiento tanto en el potencial informático como en los avances algorítmicos han logrado que las técnicas sobre el machine learning sean las herramientas claves para encontrar modelos de datos (Vorobeychik y Kantarcioglu 2018), determinándose que; es más razonable el hacer uso de computadoras cuánticas en lugar de las clásicas, puesto que cuentan con un software cuántico que funciona más rápido con su base de datos; a pesar de los desafíos considerables que presentan el hardware y software (Biamonte et al. 2017).

No obstante, las aplicaciones pueden verse vulnerables frente al uso malintencionado que se le den, provocando accidentes y congestiones en su sistema, logrando incluso que se simulen situaciones inusuales en su predicción,

por tanto, el machine learning estudia y plantea el uso de nuevos enfoques en el desarrollo de técnicas que logren un aprendizaje sólido frente a una manipulación contradictoria (Vorobeychik y Kantarcioglu 2018).

En la actualidad, las industrias a menudo se ven restringidas para cumplir sus objetivos en relación con la productividad; esto se debe a diversas complejidades y capacidades como desarrollos tecnológicos y digitalización, baja productividad y capacidad (Abderrahim et al. 2020) ya que, la mayoría de los sistemas existentes para la gestión y control de vehículos se caracterizan por tener dos problemas generales y son: muy rudimentarios utilizando tecnologías totalmente desfasadas, no son alcanzables por pequeñas y medianas empresas, por los sobrecostos que les supone un sistema de estas características. (ATO, 2013)(SUFERI, 2021)

En la actualidad la calera, no tiene una planificación adecuada que nos permita llevar un verdadero autocontrol de diversos sucesos ocurridos en cada máquina para generar un mejor mantenimiento, estas unidades no tienen un plan de mantenimiento preventivo puesto que; presentan un sin número de averías o fallas imprevistas, cuyas causas generan: retraso en las actividades programadas, paradas imprevistas y fortuitas en diferentes puntos de las áreas de trabajo, mayores costos en reparación de averías producidas fuera del taller de mantenimiento de la empresa. (Biteus y Lindgren 2018).

Las consecuencias o síntomas generados con anterioridad son; la gran pérdida de tiempo y fuera de servicio de la unidad vehicular, en el almacén no existe registro sobre los repuestos para aplicar al mantenimiento y/o reparación del equipo, ausencia de rutinas de mantenimiento e inspección a falta de tiempo del personal encargado del mantenimiento, no se cuenta con historial de fallas, base de datos, capacitación para conductores y técnicos de mantenimiento. (Gavilán 2019) Por ende, genera ciertas molestias en los operadores de las unidades, así como también del personal técnico de mantenimiento, paralización temporal de actividades programadas y las no programadas por correctivos emergentes en el proceso laboral.

A la vez se justificó, una propuesta sobre la mejora de mantenimiento con la implementación del machine learning, brindando de tal forma un producto de calidad en mejor tiempo de mantenibilidad y minimizando los defectos. (Iberdrola 2022) En lo económico, con la implementación de una propuesta de un mantenimiento en donde mejoramos la disponibilidad y confiabilidad de las máquinas usando machine learning, se visualiza reducir aquellos costos que generan desviaciones en la calera sobre el control del mantenimiento.

Así mismo; se describe las preguntas de rigor: ¿Cuál es el impacto que causa la implementación de machine learning en la disponibilidad y confiabilidad de la flota vehicular de una calera? Generando las siguientes preguntas frente a este suceso; ¿Cuál es la disponibilidad y confiabilidad de la flota vehicular de una calera?, ¿Cómo implementar machine learning en el mantenimiento de la flota vehicular de una calera?, ¿Cuál sería la disponibilidad y confiabilidad de la flota vehicular de una calera posterior a la implementación de machine learning?, ¿Cuál sería el costo beneficio de implementar machine learning en el mantenimiento de la flota vehicular de una calera?

Por lo tanto, se deducen ciertos objetivos que ayudaran a la claridad y mejora del proyecto desarrollado, como tal se plantea el objetivo general: Analizar el impacto al implementar el machine learning para lograr una disponibilidad y confiabilidad de una flota vehicular (Calera), así mismo; los objetivos específicos resaltarán dicha información de resultados como: determinar la disponibilidad y confiabilidad de la flota vehicular de una calera, elaborar un modelo de machine learning para pronosticar la disponibilidad y confiabilidad de la flota vehicular de la calera, determinar la confiabilidad y disponibilidad pronosticada de la flota vehicular de una calera posterior a la implementación de machine learning, determinar el costo beneficio del machine learning implementado en el mantenimiento de la flota vehicular de una calera.

II. MARCO TEÓRICO

Se proponen investigaciones orientadas a la investigación planteada con fines de comparación de datos y darle la relevancia entorno al mantenimiento mediante el uso de machine learning.

(Ren 2021a), Atlanta; En el artículo planteó como objetivo reducir y optimizar las tareas mediante una distribución, aplicando un registro de mantenimiento predictivo, haciendo uso de un método aplicativo, con un mecanismo experimental. Los resultados mostraron una mejora de la ejecución en un mejor intervalo de tiempo, siendo 0,48% más efectivo, reduciendo los costos hasta un 5,43%, en tanto; la energía es mejorada en un 28,10%, esto se acredita en que el uso del machine learning fue eficiente y útil en la mejora para la empresa. En la prueba y utilidad de este modelo de predicción fue un 95.1% y 94.5% más eficiente; su mantenimiento está basado en una regresión logística, son dos registros usados en tiempo real mediante una base de datos, el algoritmo genético ocasionó una mejor gestión de los recursos, todo ello generado con el machine learning para una mejora calidad de mantenimiento predictivo.

(Barroso Salgado 2018) Chile; Desarrolló un diseño predictivo enfocado en el desarrollo del machine learning sobre la zona de mantenimiento de maquinarias mineras en la organización BHP Minerales de América, sin embargo; se plantearon diversos estudios metodológicos, siendo uno de ellos el CRIPS-DM y como algoritmo desarrollado fue el Gradient Boosting Trees, los mismos que en conjunto lograron un mejor almacenamiento de las órdenes de trabajo, los instrumentos para consolidar dicha información fue la entrevista dirigida a los operarios y la ficha de registro de cada máquina. El resultado obtenido fue reportado con gran efectividad de la aplicación, mostrando una precisión de 82,2%, esto concluye que la disponibilidad e integración del software de programación (machine learning) como herramienta predictiva es de grado confiable, ayudando a mejorar la calidad y producción de las maquinarias mediante una buena automatización de las tareas de trabajo, gestionando mejor accesibilidad a los operarios y planificadores de los trabajos programados, con mejora del tiempo y disminución del riesgo laboral.

(Paolanti et al. 2018) Finlandia, Se logra establecer como objetivo un enfoque en base al machine learning para una mejor gestión del mantenimiento predictivo dirigida a la industria 4.0, utilizando un método aplicativo con diseño no experimental. En tanto, se utiliza la base de datos como instrumento para el análisis con el machine learning, los resultados probaron que el mecanismo de programación utilizado brinda una mejor visión de la calidad del mantenimiento predictivo de las máquinas programadas. La conclusión generó que el monitoreo o auditoría en conjunto, lograsen una mejor eficiencia y operatividad de los motores eléctricos mediante el mantenimiento predictivo, cuya probabilidad se resuelve en la ganancia empresarial con la aplicación de este software, a su vez la rentabilidad generada anualmente por las fallas ocasionadas de forma inesperada de los motores.

(Ruiz-Sarmiento et al. 2020) España; Desarrolló como objetivo principal un modelo predictivo con la finalidad de analizar el rendimiento de una máquina industrial, aplicando el machine learning con un método aplicado, a los datos y registro de la máquina en cuestión a la operatividad y mantenimiento. Los resultados son favorables ya que, se fusionan de manera iterativa el modelo propuesto, mostrando un conocimiento más centrado, preciso y eficaz a la hora de tener alguna falla o mantenimiento en tiempo real, sin embargo, de forma indirecta abarca los métodos de laminación en calor ejecutados en la fábrica con un sistema predictivo, esto se debe a la evaluación que se requiere lograr con la información real si la máquina produce 118Kg/d. Concluye que, las técnicas de vanguardia integradas en machine learning para la productividad genera un 85.8% más eficiente a las veces anteriores, esto produce una profunda y compleja revolución industrial, puesto que, puede aplicarse en diferentes circunstancias y áreas.

(Marín Vilca y Pinedo Torres 2019) Perú; Plantea una predicción de caudal del efluente o descarga siendo este minimizado por una concentración de esfuerzos, situado en la represa de Blanca Aguada, el objetivo radica en la inserción de redes con memoria de largo y corto plazo, estas redes son llamadas (LSTM) en nombre del inglés Long Short Term Memory, los cuales analizarán y evaluarán la predicción y toma de decisiones del Sistema de Alerta Temprana (SAT), se propuso un sistema para un desarrollo metodológico en la implementación y

programación de la Red LSTM, el cual analizará, tomará decisiones y trabajará con una forma preventiva o segura sobre el caudal del efluente en distintos niveles o rangos de alertas. La red neuronal LSTM, está sujeta a diversos registros o datos de sensores, los cuales son característicos por su volumen de agua en el efluente (caudal de desfogue). Los resultados obtenidos como forma métrica tienen un 1.30 de error cuadrático medio (RMSE) conseguido en las primeras pruebas siendo eficiente y aceptable en la toma de decisiones, esto se deduce en la confiabilidad para una siguiente descarga de caudal predictivo.

(Pozo Gallego 2018) España; Manipularon tecnologías modernas con la finalidad de generar una solución a los inconvenientes o fallas mecánicas, detectando, analizando y corrigiendo la gestión sobre los trabajadores de la zona de mantenimiento de la corporación industrial de Valladolid. Los instrumentos usados de forma básica son las redes neuronales, máquinas y regresión logística, siendo claves en un desarrollo de sistema predictivo. Los resultados son sustentables puesto que la precisión al implementar el machine learning fue de un 82.1% logrando una altísima escala durante los últimos años en la empresa. En conclusión, el empleo del software gestionó y simplificó mejorar la calidad y producción en la empresa.

(Agüero et al. 2021) Perú; Desarrolló un análisis de programación con mayor confiabilidad y tiempo aplicado usando el software de machine learning en el área de producción de la industria REDONDO, dedicada a la producción de lácteos y mermeladas, el objetivo está enfocado en descifrar la manera más correcta en como el machine learning mejorará el proceso en la producción de mermelada en la empresa. La investigación está compuesta por el tipo y diseño a utilizar, siendo estos de forma aplicada y cuasi experimental respectivamente. Tomó como población 70 observaciones en estratificado y 70 operaciones comerciales; los resultados fueron muy favorables con la aplicación del machine learning pues mejora y ayuda con gran efectividad en la reducción de fallas o inconvenientes en el proceso de producción desde un 33.72% hasta un 91.44%, del mismo sentido ayudó a mejorar dicha eficiencia y control en la gestión de solicitudes atendidas en horas de descanso en un rango del 66.28% hasta el 8.56% disminuidos. En conclusión, el índice de control sobre las operaciones fue del 43.04% hasta el 82.70% de operaciones comerciales.

2.1. Marco Conceptual

Machine learning, es el estudio de los algoritmos computarizados que mejoran y generan un rendimiento automático gracias a su data compleja, usando una media de rendimiento, para mejorar las tareas y el desempeño del estudio a investigar. (Mitchell 2018)

La empleabilidad del machine learning descifra ciertas preguntas a resolver: ¿de qué manera, se puede construir sistemas informáticos que ayuden de forma automática con buen sustento en el ámbito de gestionar y, qué leyes serían fundamentales en los procesos que rigen una buena funcionalidad? (Gavilán 2019)

Machine learning, se efectúa con principios básicos los cuales brindan un mejor procedimiento a la respuesta de problemas operativos y estadísticos. (Vorobeychik y Kantarcioglu 2018) Un mecanismo de machine learning no solo se concentra en solo una forma o modelo aplicativo, sino también como un proyecto sustentable y aplicativo en los últimos años, pues este software consta de diversas etapas que son accesibles al incremento de las probabilidades de mejora continua, el cual como resultado es exitoso. (Maisueche Cuadrado 2019) Se comentan los siguientes niveles genéricos:

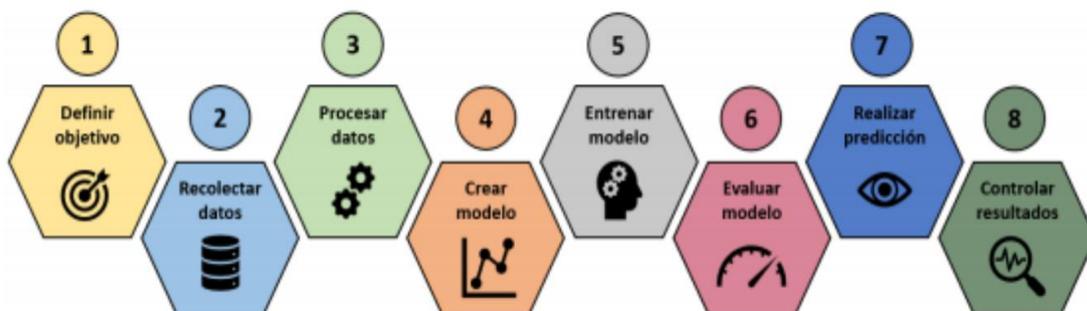


Figura 1: Etapas genéricas para el planteamiento de un proyecto con M.L.

Fuente: (Maisueche Cuadrado 2019)

Es la tecnología que desarrolla sucesiones que resultan ser automáticas en las operaciones industriales con la finalidad de minimizar la mano de obra humana, esto genera una suposición sobre las ventajas sobresalientes en el tiempo de crear y controlar una cantidad de información de forma más eficiente y efectiva. (APD 2019)

Proceso del desarrollo del modelo Machine Learning.

Para el desarrollo del modelo es impulsado por tratar de satisfacer una incertidumbre del negocio. Una vez que se identifican los objetivos del negocio, se recopilan los datos apropiados para el desarrollo de un nuevo modelo (o se modifica un modelo existente). (Ren 2021b; Biamonte et al. 2017)

Para el desarrollo de un modelo de machine learning, este se tiene que apoyar en una metodología orientada al análisis de datos, para el presente trabajo se aplicará el método CRISP-DM que son las siglas de Cross-Industry Standard Process for Data Mining, método que orienta los trabajos en una minería con datos orientados al machine learning. (Nadarajah et al. 2018)

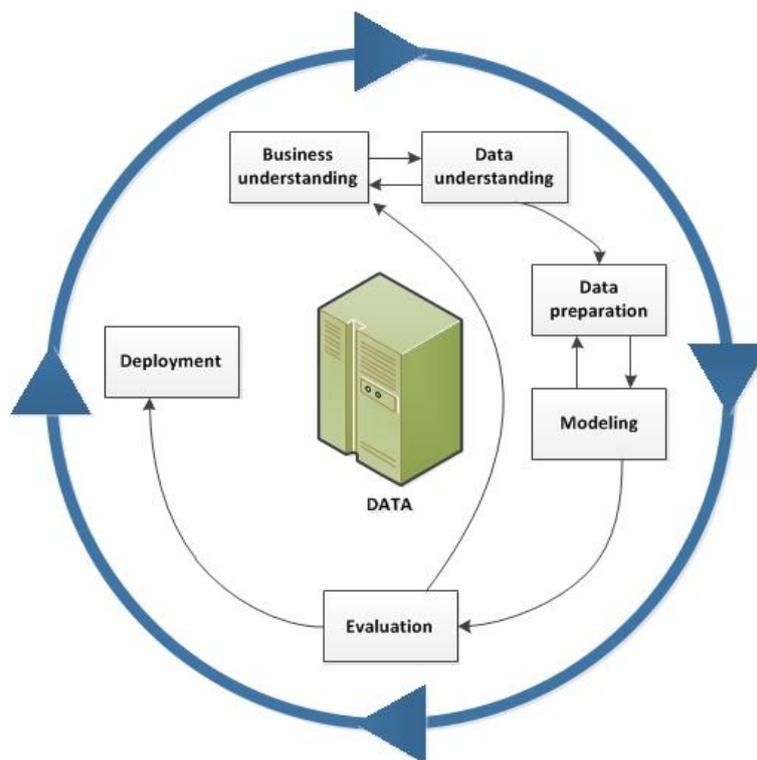


Figura 2: Ciclo de vida de minería de datos

Fuente: (IBM 2017)

Su ciclo de vida en el modelo tiene la característica de contener seis fases direccionadas hacia indicadores dependientes, frecuentes e importantes entre las fases. Su secuencia consta de un rasgo no estricto en sus fases, pero si es requisito indispensable para el estudio. (Maisueche Cuadrado 2019)

Conocimiento y preparación de los datos

Para la aplicación del machine learning se obtuvo información con respecto a las horas de trabajo y mantenimiento de las máquinas, como son las siguientes:

Tabla 1: *Variables, descripción y datos.*

Variables	Descripción	Renombre
Hora nominal	Horas reales intervalo de tiempo	var_X1
hora detención	Horas de parada de equipos	var_X2
Hora operativa	Horas trabajadas de equipos	var_X3
Numero de fallas	Número de paradas del equipo	var_X4
Hora detección fallas	Horas para detección de fallas	var_X5
MTB_F	Tiempo medio entre fallas	var_X6
MTT_R	Tiempo medio para reparar	var_X7
Disponibilidad	Disponibilidad de los equipos	var_Y1
Confiabilidad	Confiabilidad de los equipos	var_Y2

Fuente: Elaboración Propia

Modelamiento

(Markudova et al. 2021) Al tener los objetivos indicados, de saber cuál es la disponibilidad y confiabilidad, el modelamiento se realizará por cada variable objetivo, para ello seguiremos ciertos procesos para la aplicación:

Modelos aplicar

Al ser las variables objetivas cuantitativas de tipo numérico se evaluará tres modelos de machine learning para saber cuál de estas nos dan mejor precisión al momento de pronosticar la disponibilidad y confiabilidad de la máquina, para el presente estudio aplicaremos tres algoritmos de machine learning que nos permita tener la mejor predicción, los cuales son:

- ✓ Regresión lineal múltiple
- ✓ Random Forest (Modelo de árboles aleatorios)
- ✓ Aumento de gradiente XGBOOST

La disponibilidad. Es la tecnología que desarrolla sucesiones que resultan ser automáticas en las operaciones industriales con la finalidad de minimizar la mano de obra humana, esto genera una suposición sobre las ventajas sobresalientes a la hora de crear y controlar una cantidad de información de forma más eficiente

y efectiva.(Emerson 2017)

$$\textit{Disponibilidad} = \frac{\textit{Tiempo de producción real}}{\textit{Tiempo de producción posible}} \times 100\%$$

Es la capacidad reflejada en los elementos para encontrar un estado más conciso y desarrollado mediante una función en condiciones bajas, el cual serán determinadas rápidamente o cuando se aplica el software durante un intervalo de tiempo, teniendo como resultado recursos externos(UNE 2018)

$$D = \frac{MUT}{MUT + MTTR}$$

MUT: Tiempo medio de actividad MTTR: Tiempo de reparación

Capacidad que tiene un componente o activo en estado operativo para encontrar una función donde debajo se centra en un solo intervalo de tiempo o durante, siendo los recursos necesarios divididos de forma equitativa(Sobrino Zimmermann 2017)

$$D = \frac{Td - Pp}{Td}$$

TC: Tiempo calendario TD: Tiempo disponible PP: Paradas programadas

La confiabilidad se conceptualiza en una posibilidad que conlleva un componente, artículo, equipo, sistema o máquina, donde determina una función aplicada dentro de un proyecto en condiciones de operación por un periodo mejor definido.(Alberti 2020)

$$\textit{Confiabilidad} = \frac{1}{\textit{Tiempo promedio entre fallas}}$$

Es la probabilidad de un componente, producto, dispositivo, sistema o proceso, en donde su función es determinar con exactitud dichos tiempos o periodos de tiempo más específicos donde sea un resultado mayor específico con menor tiempo, en condiciones favorables. (Luko 2021)

La confiabilidad consta en utilizar un rango de fórmulas, para detallar dicho análisis de cálculo, mediante una variabilidad del error en medición y el sujeto; generando diversos resultados en diversos tiempos o escenarios, poblaciones o momentos aplicables a las mismas circunstancias. (Frontera Temuco y Manterola Delgado 2018)

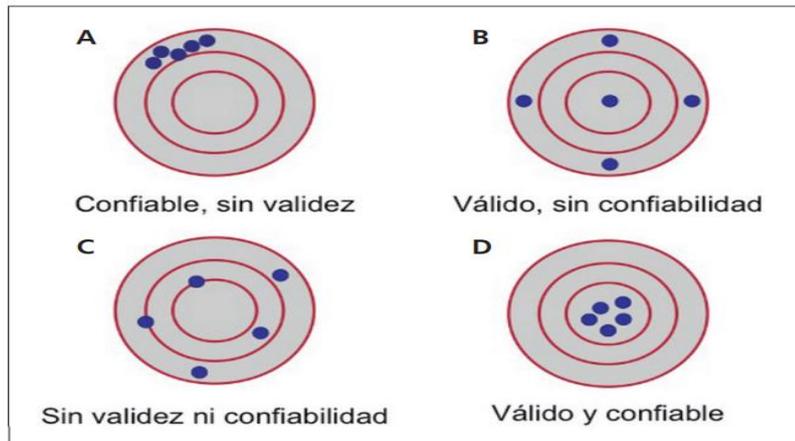


Figura 3: Escenarios de confiabilidad

Fuente: (Frontera Temuco y Manterola Delgado 2018)

Gestión de una flota vehicular: Es el uso en conjunto de unidades vehiculares con un objetivo determinado, el cual se rige a ofrecer servicios para realizar actividades dentro o fuera de una organización, con una forma eficaz y eficiente mediante un coste y nivel de servicio determinado. (Fernandez Gomez 2016)

La flota vehicular es el grupo de maquinarias o unidades vehiculares que cuenta una empresa para ofrecer un servicio o utilidad personal hacer un sector privado o personal. (Beetrack 2016)

Una flota de vehículos: Es un conjunto de unidades móviles que disponen las empresas o los mismos propietarios para fines de lucro, los vehículos industriales en este caso las maquinarias son usadas para un manejo logístico o comercial, el contrato de una flota vehicular se gestiona mediante los proveedores, siendo una mejor alternativa a realizar operaciones o minimizar preocupaciones dentro de una entidad. (Quadis 2016)

III. METODOLOGÍA

3.1. Tipo y diseño de investigación

3.1.1. Tipo de investigación

- **Aplicada:** se hará uso de los datos y fichas de registros de aquellos vehículos que necesitamos analizar en mejora de los procesos en su productividad y desarrollo para el sustento dentro de la Calera a fines de una mejora continua. (Marín Vilca y Pinedo Torres 2019)

3.1.2. Diseño de investigación

- **Diseño:** Se basa en una forma pre experimental, esta investigación describe criterios o causas de una deficiente y mala gestión sobre el mantenimiento u operatividad de una flota vehicular de una empresa, usando el machine learning como software de programación para el desarrollo de la confiabilidad, disponibilidad y mantenibilidad de una calera. (Moritzer, Heiderich y Geisler 2019)

Esta forma **pre experimental** manipulará la variable dependiente en la producción de algún efecto sobre la variable independiente, donde los individuos, objetos, mecanismos entre más, pueden ser medidos de manera aleatoria. (Ansolabehere et al. 2019)

Es de nivel **explicativo**, pues propone una relación formal entre ambas variables. (Ansolabehere et al. 2019)

3.2. Variables y operacionalización

Variable Independiente

VI: Machine Learning: Es el campo de inteligencia artificial que propone algoritmos mediante una data de la población que se desea estudiar, potencia a los ordenadores a mejorar e identificar los patrones de datos masivos o planificar predicciones a largo plazo con una confiabilidad muy buena. Este proceso de programación se desarrolla de forma fiable y compatible, desde el inicio al final con mejora en el tiempo de su ejecución. (Iberdrola 2022).

Variable Dependiente

VD: Confiabilidad: Es aquel término colectivo que sirve para describir los factores que influyen como la mantenibilidad, logística y fiabilidad; así mismo precisa mantener dicho grado de disponibilidad en lo más alto para un mejor sustento. Su probabilidad dentro del equipo o sistema opera de tal manera, que es mínimo las fallas en un periodo de tiempo, bajo criterios operacionales constantes y definidos. (AEC 2019).

VD: Disponibilidad: Es la capacidad que permite que un elemento encuentre su centro de equilibrio estadístico, mediante una función propuesta bajo estándares determinados, asumiendo que se requiere y se proveen recursos externos necesarios. La disponibilidad es aquel término de probabilidad necesario y exclusivo entre los equipos que serán reparados. (Fuenmayor 2018)

3.3. Población, muestra, muestreo y unidad de análisis

3.3.1. Población: Está sujeta a la calera, donde se consideró un grupo límite de la empresa, de manera definida y accesible donde se toma 36 unidades como muestra, donde se detallarán los criterios que se plantea investigar en la empresa calera. (Calizas y Minerales) (Carpio, Hernández y Carpio 2019)

Criterios de inclusión: Maquinarias usadas en la calera

Criterios de exclusión: Maquinarias alquiladas en la CALERA.

Tabla 2: *Total de maquinarias*

Descripción de maquinaria	Total
Cargador frontal	12
Minicargador	8
Excavadora	7
Retro excavadora	9
Total	36

Fuente: Elaboración propia

3.3.2. Muestra: son los equipos automotrices que contiene la calera, en mejora de su confiabilidad y disponibilidad para disminuir las paradas por fallas, mantenimiento y sustentabilidad en el autoconsumo de la empresa.

3.3.3. Muestreo: Por conveniencia, No probabilístico.

(Hernández y Carpio 2019) Comenta que el realizar muestreos no probabilísticos hacia las personas, son de carácter inclusivo. En tanto; su clasificación es por conveniencia, esto cumple ciertas características de interés, así mismo; una selección de los individuos en base al acceso y alcance.

3.3.1. Unidad de análisis: Datos de cada equipo.

3.4. Técnicas e instrumentos de recolección de datos

Las **técnicas** que sirven para la recolección de datos comprenden el análisis documental (reportes de mantenimiento correctivo y preventivo de las máquinas); se emplea la ficha de registro para poder enfocarse a ciertos parámetros de análisis y toma de decisiones de la investigación. En tanto, se usa una guía de observación, que es el registro de apuntes sobre las características de las necesidades en desarrollo.

Tabla 3: *Instrumentos y técnicas de medición*

Técnicas	Uso	Instrumentos
Análisis documental.	Recopilación de información de fuentes confiables.	Ficha de registro.
Entrevista	Recoger la base de datos de las máquinas de empresa la CALERA.	Cuestionario.

Fuente: Elaboración propia

3.5. Procedimientos

Se diagnostica una situación actual dentro de una calera, donde analizaremos la confiabilidad y disponibilidad de las maquinarias, estableciendo criterios mediante el uso del machine learning con R (Software con un soporte de alcance y análisis estático). A su vez, se realizará el uso de una carta de aceptación sobre el estudio y manipulación de datos a la jefatura de la entidad, para la medición de indicadores con la finalidad de proponer una mejor gestión de mantenimiento de las maqunarias de la empresa calera.

3.6. Método de análisis de datos

El método para analizar los datos requeridos en la investigación es el análisis descriptivo, usando el Microsoft Excel y el empleo del software SPSS 22.0, para establecer las frecuencias, tabulación gráfica, en donde se obtendrá la información más concisa con respecto a las variables.

3.7. Aspectos éticos

En la investigación se plantea una autorización de la empresa Calera para toma de datos para recopilar información de forma transparente en el desarrollo de los objetivos propuestos, respetando la confiabilidad y las normas establecidas en la recopilación de datos administrativos.

Este análisis es de carácter privado, pues se presenta con originalidad el desarrollo a sustentar, por consecuencia; no da soporte a la copia o plagio en la ejecución del proyecto. Por lo tanto; se plantea datos verídicos en este estudio, con el compromiso y responsabilidad del estudiante que, prohíbe que las personas puedan tener accesibilidad a la información ejecutada con fines académicos.

IV. RESULTADOS

4.1. Determinar la disponibilidad y confiabilidad de la flota vehicular de una calera.

Se muestra resultados basados en la aplicación de la herramienta propuesta, dirigidos a los indicadores de Confiabilidad y Disponibilidad, se concluye las soluciones propuestas mediante el procesamiento de datos, donde usé el software IBM SPSS Statistics v.22. en el siguiente planteamiento:

Tabla 4: *Informe técnico desde mayo hasta el mes de julio del año 2022*

Familia	Mes	Hr. Nominal	Horas Detención	Horas Operativas	Nº Fallas	Hr. Detención por Fallas	MTBF	MTTR	Disponibilidad	Confiabilidad
Cargadorfrontal	S.1 Mayo	140	100	40	5	100	8.00	20.00	28.57	2.08
Cargadorfrontal	S.2 Mayo	140	73	67	4	63	16.75	15.75	51.54	15.71
Cargadorfrontal	S.3 Mayo	140	24	116	2	24	58.00	12.00	82.86	58.60
Cargadorfrontal	S.4 Mayo	180	123	57	6	95	9.50	15.83	37.50	3.83
Cargadorfrontal	S.1 Junio	140	100	40	5	100	8.00	20.00	28.57	2.08

Cargador frontal	S.2 Junio	140	58	82	3	49	27.33	16.33	62.60	32.17
Cargador frontal	S.3 Junio	140	60	80	3	60	26.67	20.00	57.14	31.27
Cargador frontal	S.4 Junio	180	104	76	5	96	15.20	19.20	44.19	13.01
Cargador frontal	S.1 Julio	140	106	34	5	106	6.80	21.20	24.29	1.05
Cargador frontal	S.2 Julio	140	50	90	2	40	45.00	20.00	69.23	50.21
Cargador frontal	S.3 Julio	140	86	54	4	86	13.50	21.50	38.57	10.06
Cargador frontal	S.4 Julio	180	66	114	3	56	38.00	18.67	67.06	44.23
retroexcavadora	S.1 Mayo	140	75	65	4	75	16.25	18.75	46.43	14.84
retroexcavadora	S.2 Mayo	140	70	70	3	60	23.33	20.00	53.85	26.49
retroexcavadora	S.3 Mayo	140	80	60	3	60	20.00	20.00	50.00	21.22
retroexcavadora	S.4 Mayo	180	100	80	4	80	20.00	20.00	50.00	21.22

retroexcavadora	S.1 Junio	140	100	40	5	100	8.00	20.00	28.57	2.08
retroexcavadora	S.2 Junio	140	80	60	3	60	20.00	20.00	50.00	21.22
retroexcavadora	S.3 Junio	140	57	83	3	57	27.67	19.00	59.29	32.61
retroexcavadora	S.4 Junio	180	97	83	5	88	16.60	17.60	48.54	15.45
retroexcavadora	S.1 Julio	140	82	58	4	106	14.50	26.50	35.37	11.79
excavadora	S.2 Julio	140	82	58	4	40	14.50	10.00	59.18	11.79
excavadora	S.3 Julio	140	81	59	3	86	19.67	28.67	40.69	20.67
excavadora	S.4 Julio	180	96	84	4	56	21.00	14.00	60.00	22.85
excavadora	S.1 Mayo	140	100	40	5	100	8.00	20.00	28.57	2.08
excavadora	S.2 Mayo	140	60	80	3	45	26.67	15.00	64.00	31.27
excavadora	S.3 Mayo	140	60	80	3	60	26.67	20.00	57.14	31.27

excavadora	S.4 Mayo	180	101	79	5	89	15.80	17.80	47.02	14.06
Mini Cargador	S.1 Junio	140	76	64	4	76	16.00	19.00	45.71	14.41
Mini Cargador	S.2 Junio	140	50	90	2	40	45.00	20.00	69.23	50.21
Mini Cargador	S.3 Junio	140	80	60	4	80	15.00	20.00	42.86	12.66
Mini Cargador	S.4 Junio	180	86	94	4	76	23.50	19.00	55.29	26.74
Mini Cargador	S.1 Julio	140	88	52	4	52	13.00	13.00	50.00	9.21
Mini Cargador	S.2 Julio	140	38	102	2	32	51.00	16.00	76.12	54.45
Mini Cargador	S.3 Julio	140	40	100	4	40	25.00	10.00	71.43	28.94
Mini Cargador	S.4Julio	180	152	28	6	130	4.67	21.67	17.72	0.13

Fuente: Registro de datos de la calera

Se realiza el modelamiento de los resultados resumidos de las maquinarias en los 3 meses, se muestra que la maquinaria de la cargadora frontal en la semana 3, tuvo el mayor MTBF, teniendo una probabilidad de 58 veces en las que presuntamente fallaría, y por otra parte el MTTR se dio en 12 veces, su confiabilidad es de 58.60% y la disponibilidad un 82.86%. Por otro lado, el minicargador género menor MTBF sucedido a finales del mes de julio, tuvo un 4.46 veces que este podía generar una falla, su MTTR tiene 21.67 veces; la confiabilidad fue de 0.13% y la disponibilidad de un 17.72%. La conclusión deduce que una gestión para el mantenimiento se encuentra en pésimas condiciones, porque las fallas con el pasar de los días aumenta, tanto en las reparaciones como en los tiempos detenidos.

4.4.1. Disponibilidad del cargador frontal antes del software de programación aplicativo.

En este gráfico se planteó una máquina pesada para un análisis de su disponibilidad, desde mayo a julio del 2022, se analiza lo siguiente:

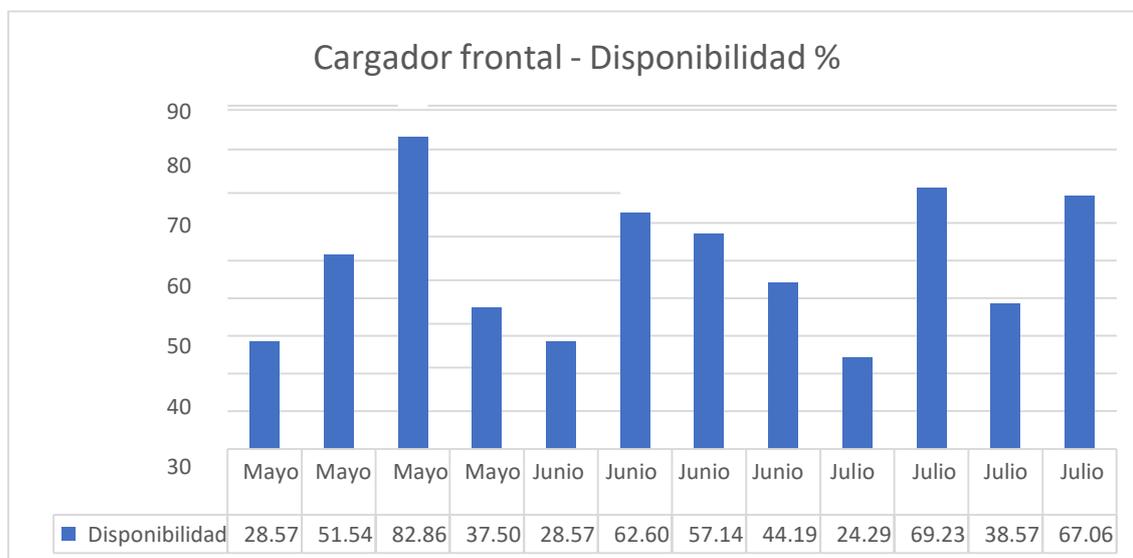


Figura 4: Disponibilidad del cargador frontal

Fuente: Elaboración Propia

En el gráfico, se representa los datos sobre la disponibilidad del cargador frontal en el rango de los 3 meses, donde se detalla la elevada disponibilidad sucedido en la semana 3 del mes de mayo, contando con un 82.86% y una inferior disponibilidad a comienzos de la primera semana de julio teniendo un 46.29%. No obstante; los resultados analizados demuestran que no hay dicha disponibilidad al 100%, esto significa que contiene un periodo de fijación y estadía que afectaría de forma permanente la confiabilidad de la máquina en el tiempo disponible.

4.4.2. Disponibilidad de la retro excavadora antes del software de programación

En este gráfico se planteó una máquina pesada para un análisis de su disponibilidad, desde mayo a julio del 2022, se analiza lo siguiente:

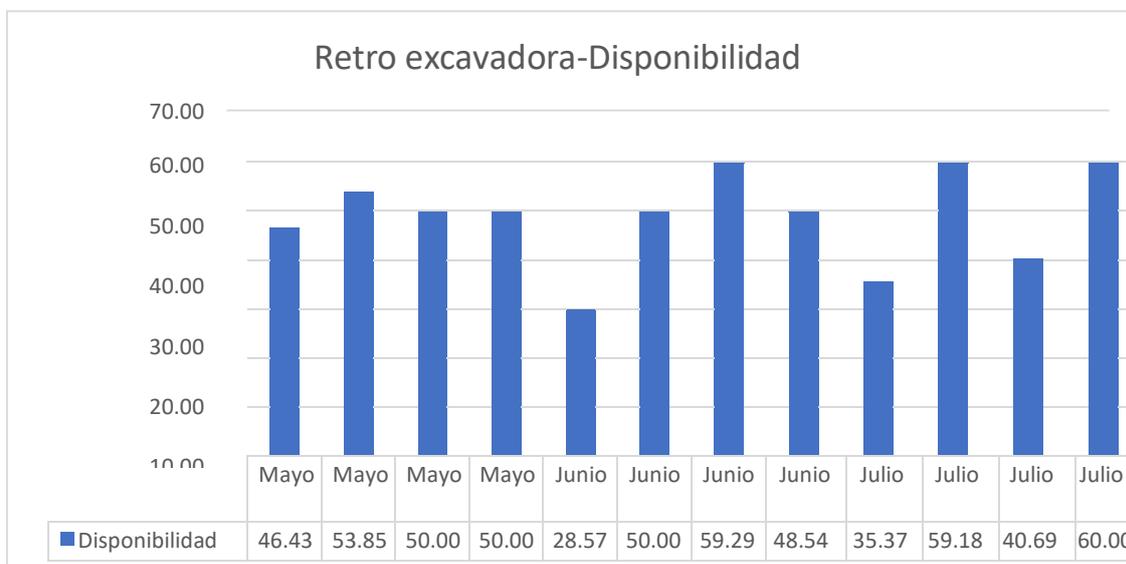


Figura 5: Disponibilidad de la retro excavadora

Fuente: Elaboración Propia

En tanto, la disponibilidad de la retro excavadora en el gráfico demuestra que su disponibilidad es muy alta, desde de la semana 4 en el mes de julio, donde fue un 60% y la disponibilidad fue desde la primera semana del mes de junio con un 28.57%. Por ende, al concluir dichos resultados ninguno llego a una disponibilidad del 100%, lo que generó una discrepancia entre la reparación y la estadía pues, inciden de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.4.3. Disponibilidad del minicargador antes del software de programación.

En este gráfico se planteó una máquina pesada para un análisis de su disponibilidad, desde mayo a julio del 2022, se analiza lo siguiente:

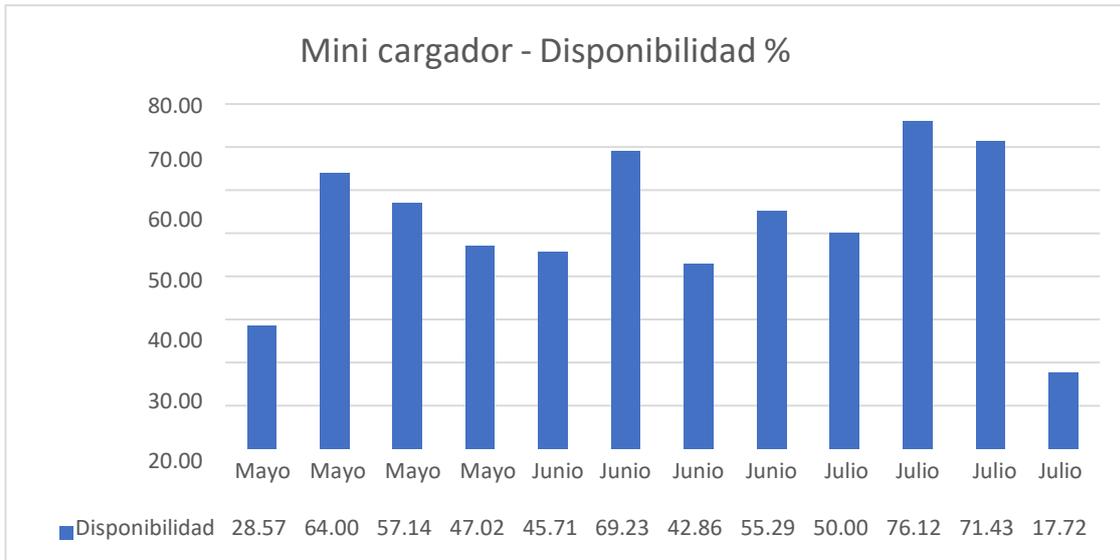


Figura 6: Disponibilidad del mini cargador

Fuente: Elaboración Propia

En otro contexto, existe una relación de disponibilidad en la máquina minicargador, donde en la figura, muestra una elevada disponibilidad en su semana dos en el mes de julio, el cual tuvo un 76.12% y una baja disponibilidad de 17.72% en la semana cuatro. A su vez; ninguno de ellos alcanzó una disponibilidad del 100%, esto se concreta en los intervalos de reparación y estadía que inciden de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.4.4. Disponibilidad de la excavadora antes del software de programación aplicativo

En este gráfico se planteó una máquina pesada para un análisis de su disponibilidad, desde mayo a julio del 2022, se analiza lo siguiente:

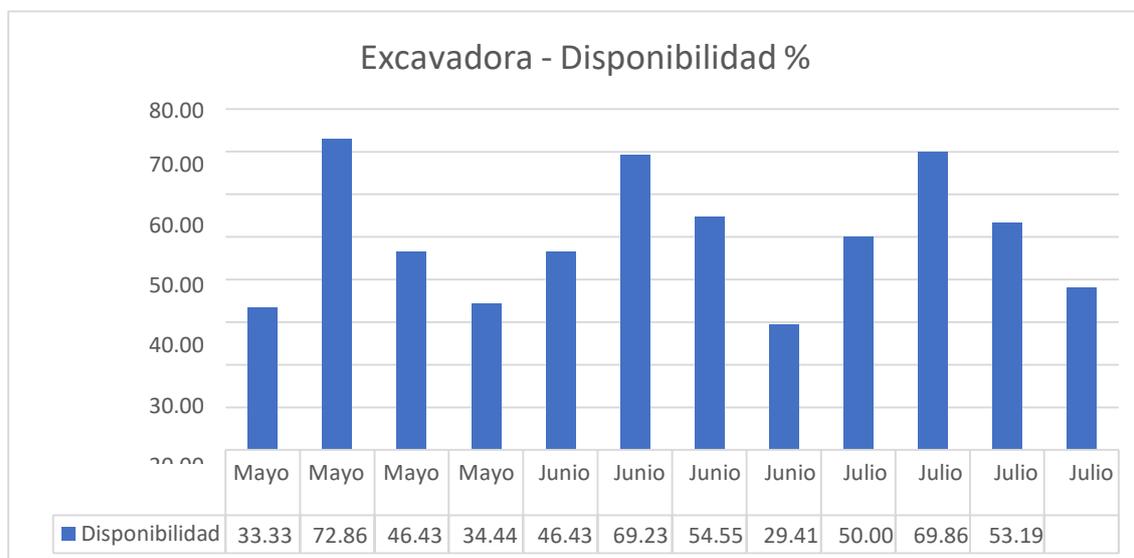


Figura 7: Disponibilidad de la excavadora

Fuente: Elaboración Propia

En otra máquina se plantea dicha estadística descriptiva sobre la disponibilidad en una excavadora; la disponibilidad se presentó en la semana dos del mes de mayo con un 72.86% y su disponibilidad más baja fue un 29.41% en la semana cuatro del mes de junio. A su vez; ninguno de ellos alcanzó una disponibilidad del 100%, esto tiene como conclusión que, el intervalo de reparación y estadía coinciden de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.4.5. Confiabilidad del cargador frontal antes del software de programación aplicativo

En este gráfico se planteó una máquina pesada para un análisis de su disponibilidad, desde mayo a julio del 2022, se analiza lo siguiente:

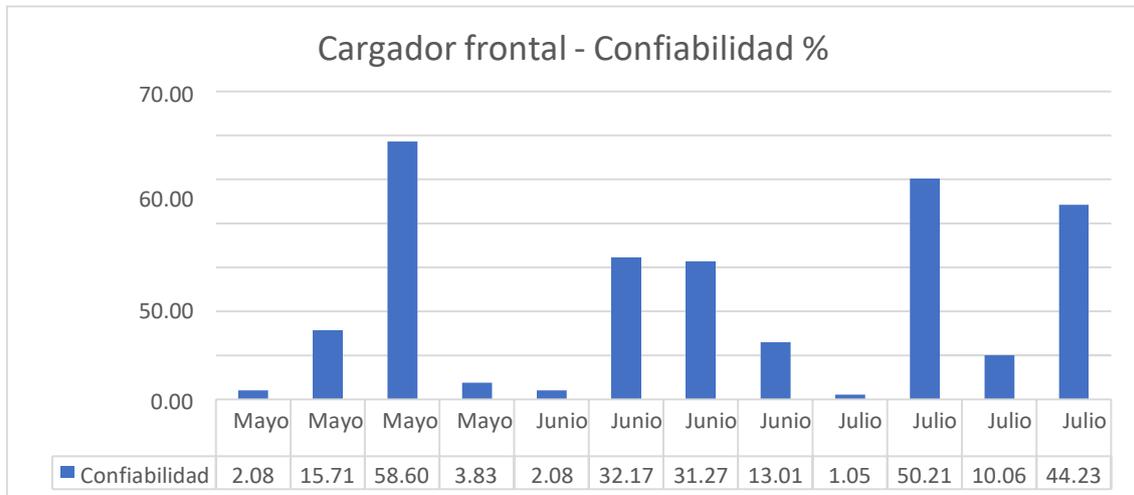


Figura 8: Confiabilidad del cargador frontal

Fuente: Elaboración Propia

En otro contexto, existe una relación de confiabilidad en el cargador frontal, en la figura se muestra la elevada confiabilidad en mayo en su semana tres, el cual obtuvo un 64.6% y una baja confiabilidad de 1.05% en la semana uno del mes de julio. A su vez; ninguno de ellos alcanzo una confiabilidad del 100%, esto demuestra la coincidencia de los intervalos de reparación y estadía inciden de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.4.6. Confiabilidad de la retroexcavadora antes del software de programación aplicativo.

En este gráfico se planteó una máquina pesada para un análisis de su confiabilidad, desde mayo a julio del 2022, se analiza lo siguiente:

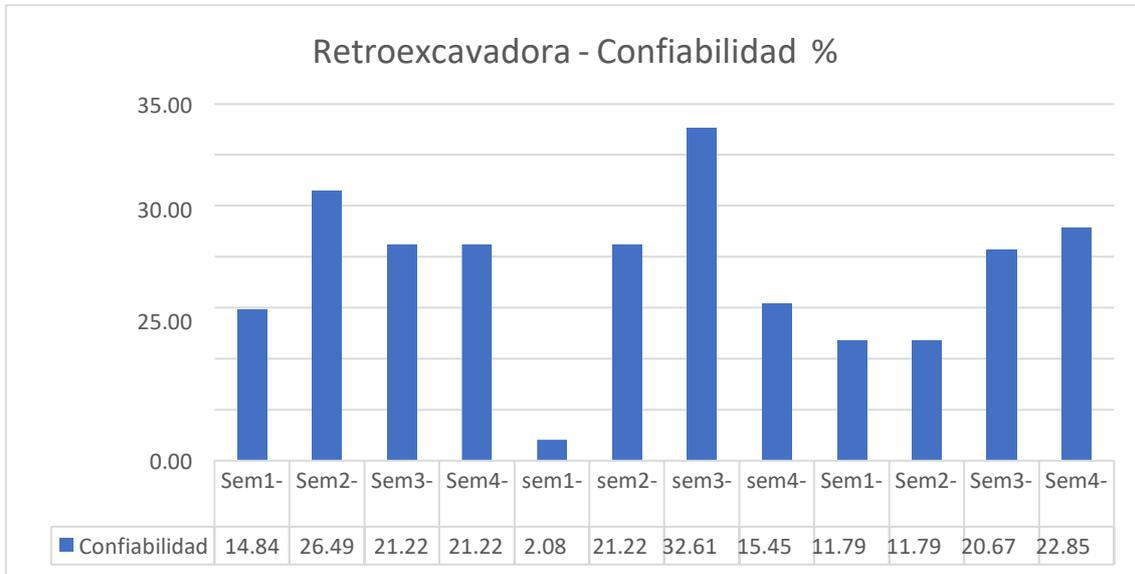


Figura 9: Confiabilidad de la retroexcavadora

Fuente: Elaboración Propia

En otra máquina se plantea dicha estadística descriptiva sobre la confiabilidad de la retroexcavadora, en la figura denota que; la confiabilidad se presentó en la tercera semana de junio con 32.61% y la baja confiabilidad de 2.08% en la semana uno del mes de junio. A su vez; ninguno de ellos alcanzo una confiabilidad del 100%, esto se simplifica en que el intervalo de reparación y mantenimiento inciden de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.4.7. Confiabilidad del minicargador antes del software de programación aplicativo

En este gráfico se planteó una máquina pesada para un análisis de su confiabilidad, desde mayo a julio del 2022, se analiza lo siguiente:

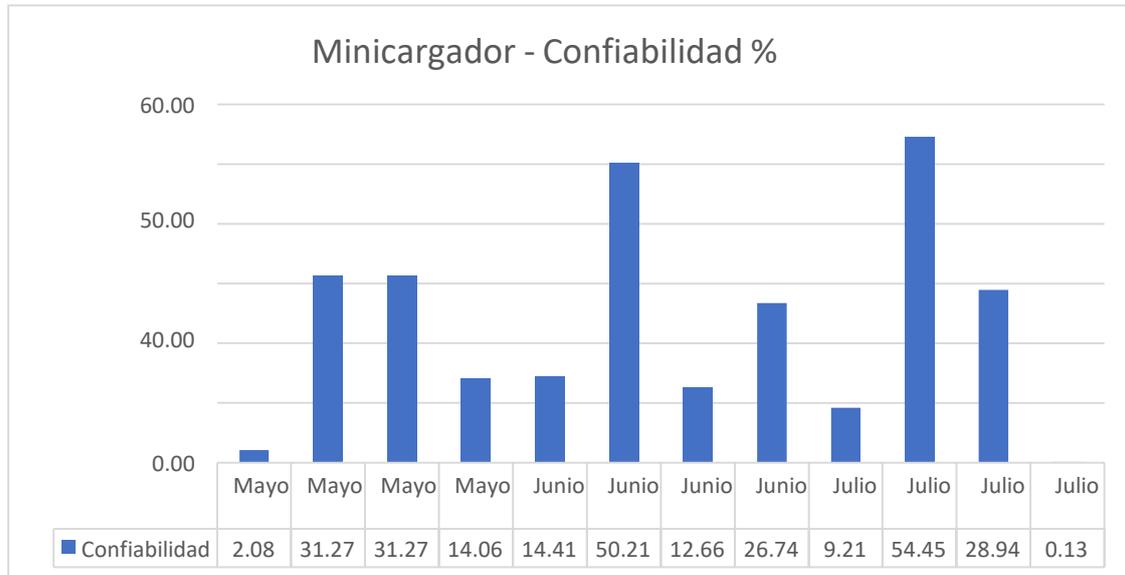


Figura 10: Confiabilidad del minicargador

Fuente: Elaboración Propia

En otro contexto, existe una relación de confiabilidad en la máquina minicargador donde se muestra confiabilidad alta en la semana dos del mes de julio, el cual obtuvo un 54.4% y una confiabilidad mínima de 0.13% en la semana cuatro del mes de julio. A su vez; ninguno de ellos alcanzó una confiabilidad del 100%, esto concluye que dichos intervalos (reparación y mantenimiento) coincidan de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.4.8. Confiabilidad de la excavadora antes del software de programación aplicativo

En este gráfico se planteó una máquina pesada para un análisis de su confiabilidad, desde mayo a julio del 2022, se analiza lo siguiente:

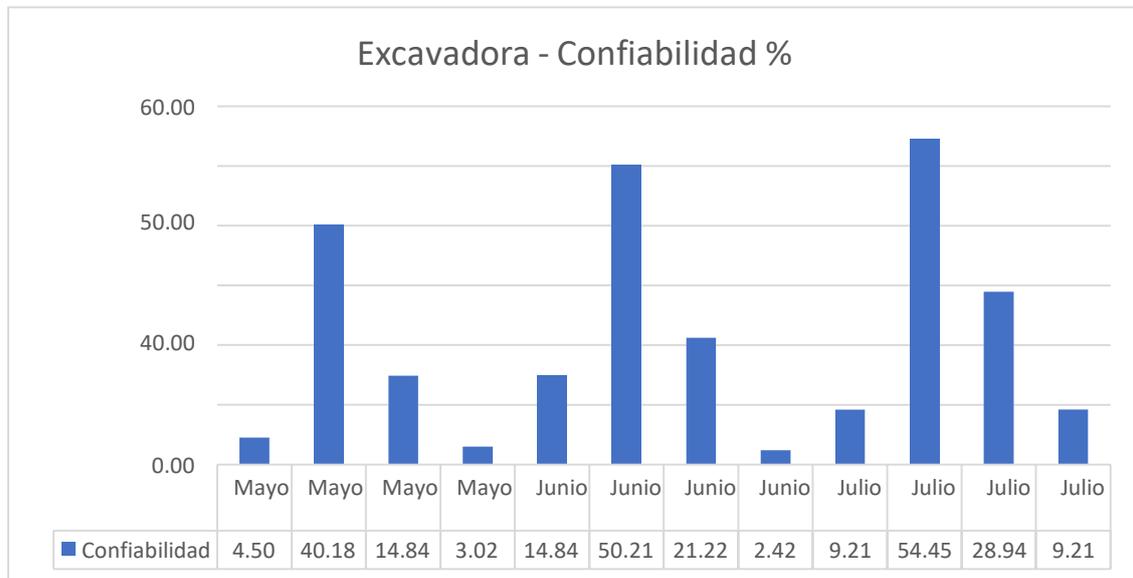


Figura 11: Confiabilidad de la excavadora

Fuente: Elaboración propia

En otro contexto, existe una relación de confiabilidad en la máquina excavadora, la figura 11, muestra elevada confiabilidad en la semana dos en julio, el cual obtuvo 56.45% y una mínima confiabilidad de 2.42% a fines del mes de junio. A su vez; ninguno de ellos alcanzó una confiabilidad del 100%, esto concluye que dichos intervalos (reparación y mantenimiento) coincidan de forma permanente al mostrar una probabilidad para un mejor encuadre.

4.2. Desarrollar un modelo de machine learning para pronosticar la disponibilidad y confiabilidad de la flota vehicular de la calera.

4.2.1. Modelamiento

En esta parte aplicaremos los modelos de machine learning para determinar si estos algoritmos nos ayudan a predecir de manera satisfactoria la disponibilidad y confiabilidad de las máquinas.

El modelo de machine learning nos ayudará a predecir la disponibilidad de la máquina.

Se sigue una serie de procesos escalonados hasta obtener los resultados que esperamos:

4.2.2. Selección de variables

Para el modelo con dos variables dependientes no deben presentar una correlación mayor al 60 %, si cumple esa condición se selecciona ambas variables como candidatas. Pero si ambas superaban el 60% se debe descartar las variables correlacionadas entre sí, evita problemas de multi-co-linealidad en el modelo final.

Para ello se aplica el coeficiente de correlación de Spearman

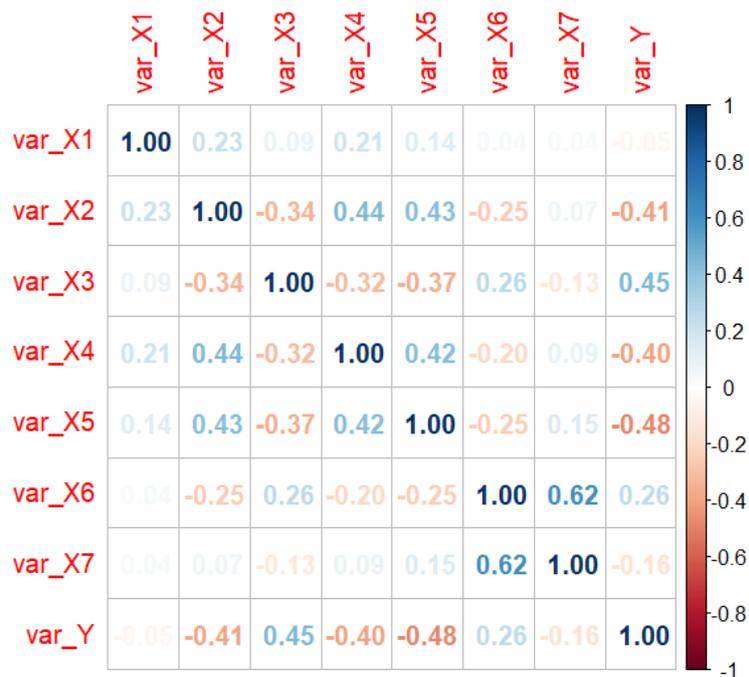


Figura 12: Matriz de correlación de Spearman

Fuente: (Juárez Villatoro 2017)

Como se visualiza en la figura N° 12, la matriz no presenta correlación entre

ellas, a excepción de las variables X6 y X7, estas dos variables se encuentran correlacionadas entre sí, por lo que se incluirá la variable X6 ya que cuenta con mayor correlación ante la variable objetivo.

Una vez analizado la correlación de las variables, se aplicó la técnica de Random Forest para analizar la importancia de variables. Esta es una herramienta de Machine Learning que nos permite identificar las principales variables a través de los árboles decisión que minimizan el error cuadrático de predicción de la utilidad.

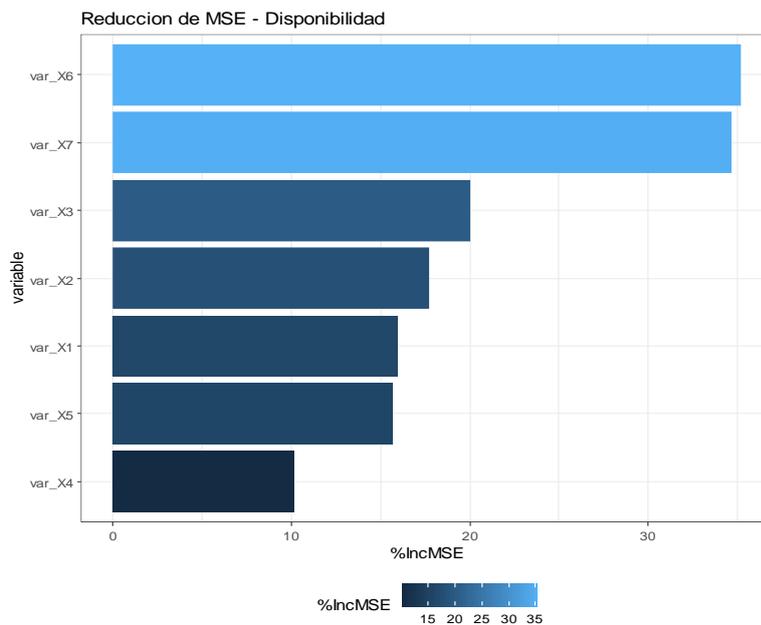


Figura 13: Selección de variables por Random Forest

Fuente: Elaboración Propia

En la figura N°13 se observa que la variable X6 es la que más aportará a reducir el error al momento de generar el algoritmo, por otro lado, la variable X4 su aporte no es muy significativo para incluirlo en el modelo.

De este análisis las variables a ser incluidas en el modelo de disponibilidad de las máquinas serían:

Tabla 5: *Análisis de variables*

Variabes	
Hora_nominal	var_X1
hora_detencion	var_X2
Hora_operativa	var_X3
Hora_deteccion_fallas	var_X5
MTB_F	var_X6
Disponibilidad	var_Y1

Fuente: Elaboración propia

a. Estimación del modelo

El modelo para la disponibilidad será de la siguiente manera:

$$var_{Y1} = var_{X1} + var_{X2} + var_{X3} + var_{X5} + var_{X6}$$

Al aplicar los algoritmos de machine learning en la data de entrenamiento obtuvimos los siguientes resultados:

1. Regresión lineal múltiple:

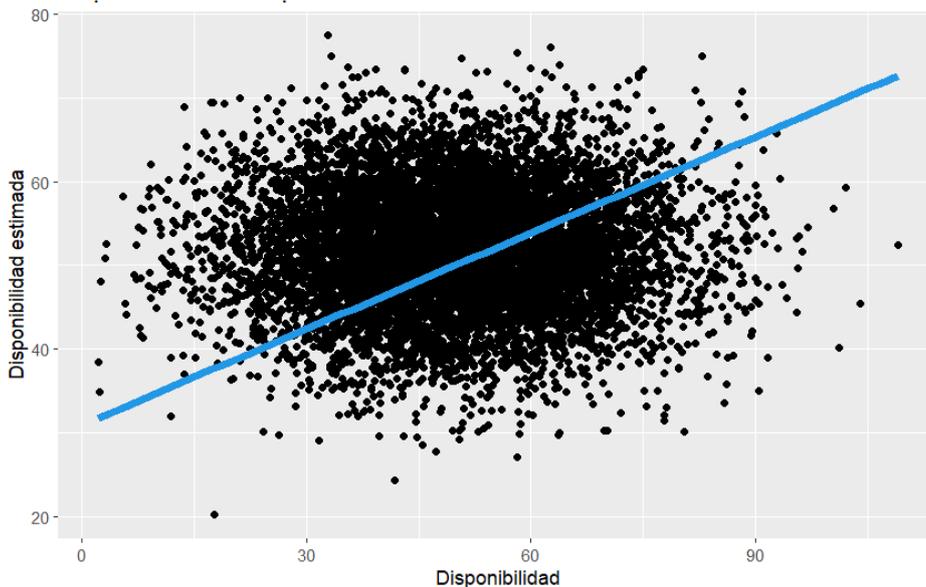


Figura 14: Disponibilidad vs Disponibilidad estimada (RLM)

Fuente: Elaboración Propia

Al aplicar el algoritmo de regresión lineal múltiple, considerado un algoritmo de machine learning clásico obtuvimos un R-cuadrado de 0.3357, indicando que este modelo no es bueno ya que su predicción es muy baja. Así mismo se puede

observar que la nube de puntos de la disponibilidad estimada no se ajusta a la recta de los datos de la disponibilidad.

2. Random Forest

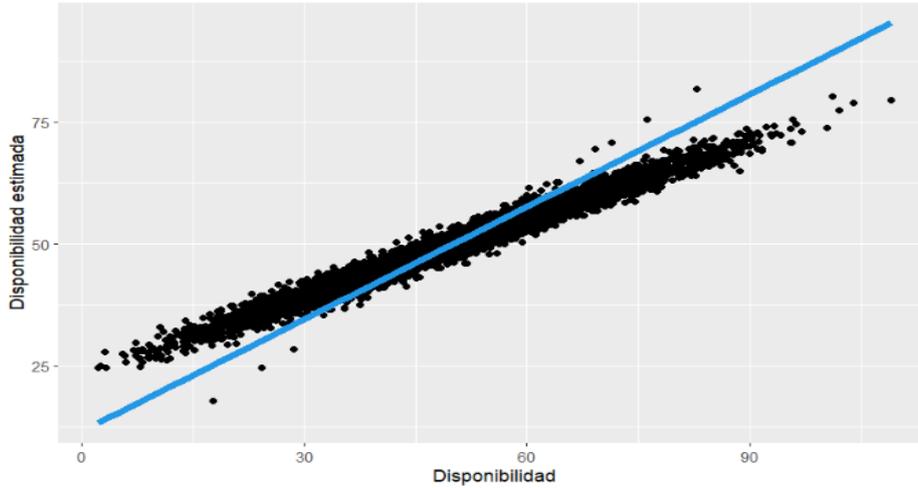


Figura 15: Disponibilidad vs Disponibilidad estimada (RF)

Fuente: Elaboración Propia

Al aplicar el algoritmo de random forest, considerado un algoritmo de machine contemporáneo obtuvimos un R-cuadrado de 0.8921, indicando que este modelo es bueno ya que su predicción es muy alta. Así mismo se puede observar que la nube de puntos de la disponibilidad estimada se ajusta mejor a la recta de los datos de la disponibilidad.

3. Xgboost:

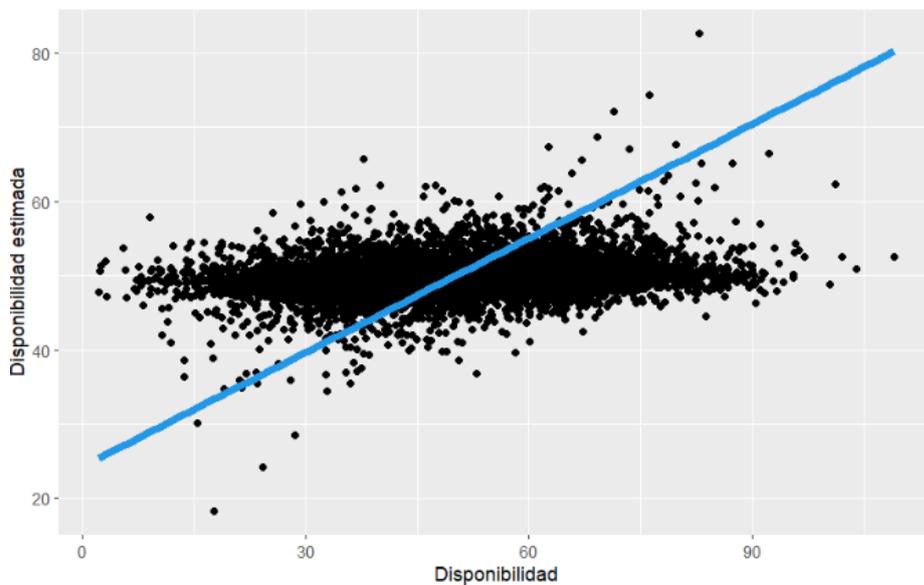


Figura 16: Disponibilidad vs Disponibilidad estimada (Xgboost)

Fuente: Elaboración Propia

Al aplicar el algoritmo de Xgboost, considerado un algoritmo de machine contemporáneo obtuvimos un R-cuadrado de 0. 5286, indicando que este modelo es bueno pero el resultado obtenido con el R-cuadrado es regular. Así mismo se puede observar que la nube de puntos de la disponibilidad estimada no se ajusta a la recta de los datos de la disponibilidad.

Discusión

Tabla 6: *Resultados por modelo*

Modelo	MSE	RMSE	R - cuadrado
Regresion lineal múltiple	0.1346	12.2373	0.3357
Random Forest	0.0001	4.9322	0.8921
Xgboost	0.0002	10.3081	0.5286

Fuente: Elaboración Propia

Al aplicar los modelos de machine learning para predecir la disponibilidad de la máquina, el algoritmo de Random Forest nos dio los mejores indicadores, obteniendo un R- cuadrado cercano a uno, lo que nos indica que su predicción es de las mejores a comparación de los demás algoritmos, así mismo el valor de la raíz cuadrada del error cuadrático medio (RMSE) fue de 4.9322, lo cual nos indica que este modelo es que menor error nos muestra al momento de estimar la disponibilidad. Por ello podemos concluir que un modelo machine learning nos brinda una buena estimación de la disponibilidad de la máquina a utilizar.

4.2.1. El modelo de machine learning nos ayudara a predecir la confiabilidad de la máquina.

Se sigue una serie de procesos escalonados hasta obtener los resultados esperados:

a. Selección de variables

Para el modelo dos variables dependientes no deben presentar una correlación mayor al 60 %, si cumple esa condición se selecciona ambas variables como candidatas. Pero si ambas superaban el 60% se descartar las variables correlacionadas entre sí, evita problemas de multicolinealidad en el modelo final. Para ello se aplica el coeficiente de correlación de Spearman

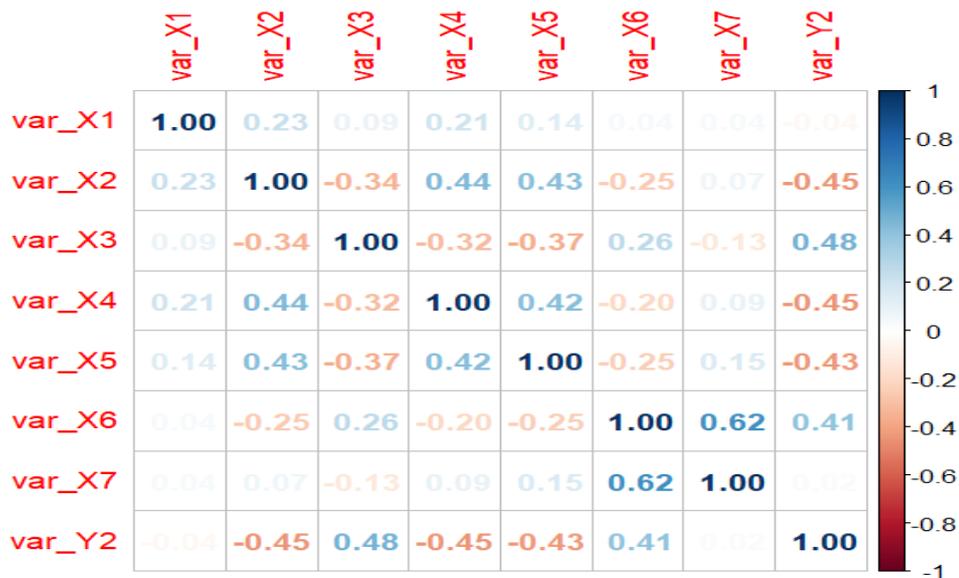


Figura 17: Matriz de correlación de Spearman

Fuente: (Juárez Villatoro 2017)

Como se puede apreciar en la figura N° 17, la matriz no presenta correlación entre ellas, a excepción de las variables X6 y X7, estas dos variables se encuentran correlacionadas entre sí, por lo que se incluirá la variable X6 ya que cuenta con mayor correlación ante la variable objetivo.

Una vez analizado la correlación de variables, se aplica la técnica de Random Forest para analizar la importancia de variables. Esta es una herramienta de Machine Learning que nos permite identificar las principales variables a través de los árboles decisión que minimizan el error cuadrático de predicción de la utilidad.

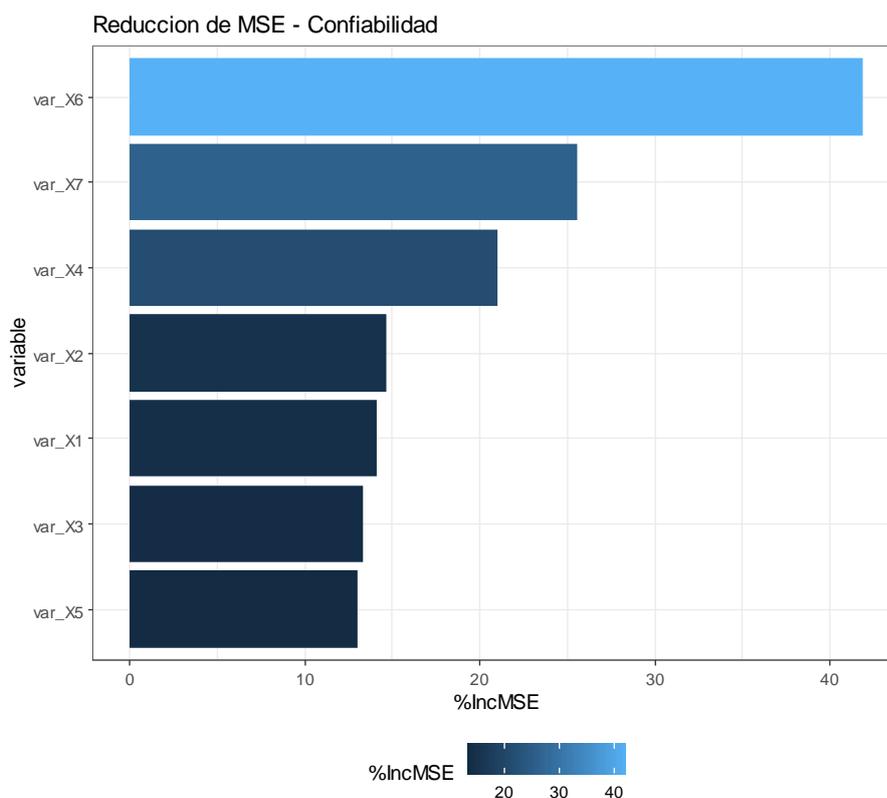


Figura 18: Selección de variables por Random Forest

Fuente: Elaboración Propia

La figura N°18 se observa que la variable X6 es la que más aportará a reducir el error al momento de generar el algoritmo, a comparación del modelo aplicado en la disponibilidad, en la confiabilidad la variable X4 si aporta a esta variable.

De este análisis las variables a ser incluidos en el modelo de disponibilidad de las máquinas serian:

Tabla 7: Variables del modelo de disponibilidad

Variables	
Hora nominal	var_X1
hora detención	var_X2
Hora operativa	var_X3
Numero fallas	var_X4
Hora detección fallas	var_X5
MTB_F	var_X6
Confiabilidad	var_Y2

Fuente: Elaboración Propia

b. Estimación del modelo

El modelo para la confiabilidad será de la siguiente manera:

$$\rightarrow var_{Y_2} = var_{X_1} + var_{X_2} + var_{X_3} + var_{X_4} + var_{X_5} + var_{X_6}$$

Al aplicar los algoritmos de machine learning en la data de entrenamiento obtuvimos los siguientes resultados:

- **Regresión lineal múltiple:**

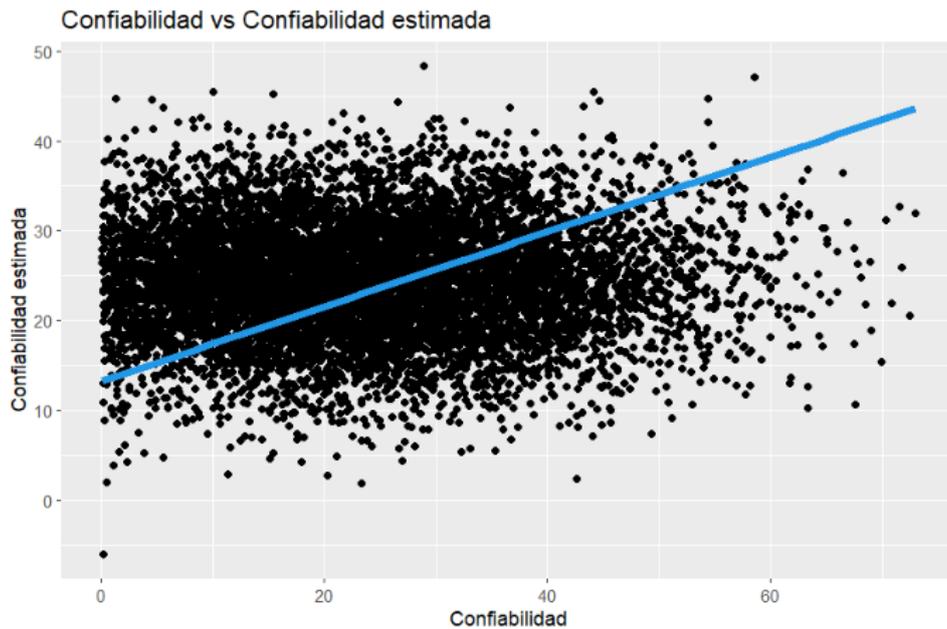


Figura 19: Confiabilidad vs Confiabilidad estimada (RLM)

Fuente: Elaboración Propia

Al aplicar el algoritmo de regresión lineal múltiple, considerado un algoritmo de machine learning clásico obtuvimos un R-cuadrado de 0.4155, indicando que este modelo no es bueno ya que su predicción es muy baja. Así mismo se puede observar que la nube de puntos de la confiabilidad estimada no se ajusta a la recta de los datos de la confiabilidad.

- Random Forest:

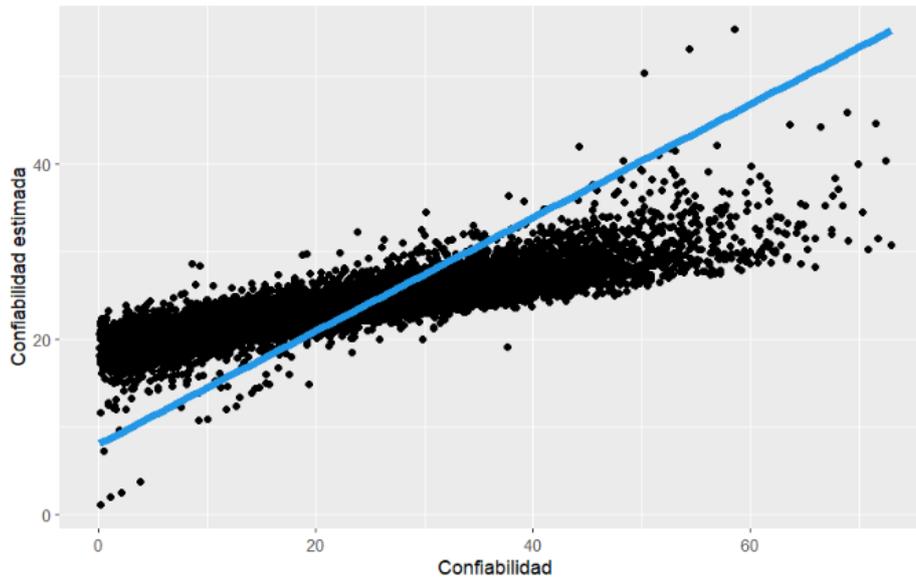


Figura 20: Confiabilidad vs Confiabilidad estimada (RF)

Fuente: Elaboración Propia

Al aplicar el algoritmo de random forest, considerado un algoritmo de machine contemporáneo obtuvimos un R-cuadrado de 0.7311, indicando que este modelo es bueno ya que su predicción es muy alta. Así mismo se puede observar que la nube de puntos de la confiabilidad estimada se ajusta mejor a la recta de los datos de la confiabilidad.

- Xgboost:

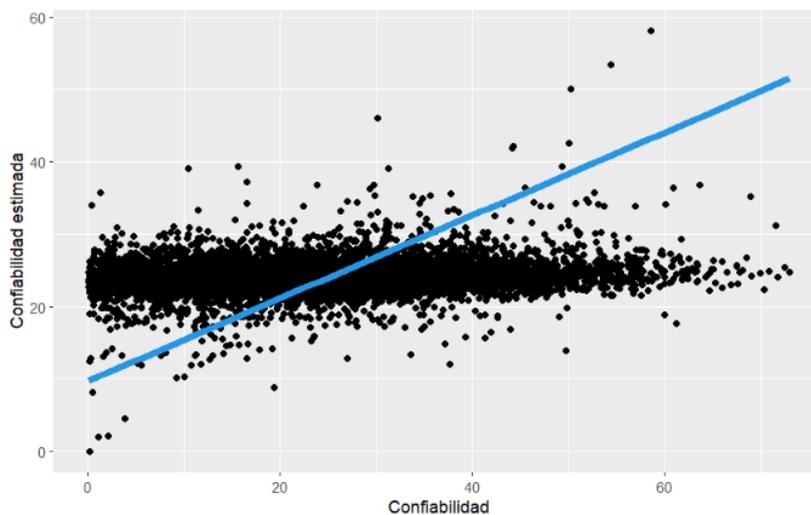


Figura 21: Confiabilidad en Xgboost

Fuente: Elaboración propia

Al aplicar el algoritmo de Xgboost, considerado un algoritmo de machine contemporáneo obtuvimos un R-cuadrado de 0.5827, indicando que este

modelo es bueno pero el resultado obtenido con el R-cuadrado es regular. Así mismo se puede observar que la nube de puntos de la confiabilidad estimada no se ajusta a la recta de los datos de la confiabilidad.

- **Discusión**

Tabla 8: *Resultados por modelo*

Modelo	MSE	RMSE	R - cuadrado
Regresión lineal múltiple	0.0000	11.2321	0.4155
Random Forest	-0.0051	7.6189	0.7311
Xgboost	-0.0001	9.4913	0.5827

Fuente: Elaboración propia

Al aplicar los modelos de machine learning para predecir la confiabilidad de la máquina, el algoritmo de Random Forest nos dio los mejores indicadores, obteniendo un R- cuadrado cercano a uno, lo que nos indica que su predicción es de las mejores a comparación de los demás algoritmos, así mismo el valor de la raíz cuadrada del error cuadrático medio (RMSE) fue de 7.6189, lo cual nos indica que este modelo es que menor error nos muestra al momento de estimar la confiabilidad. Por ello, podemos concluir que un modelo machine learning nos brinda una buena estimación de la confiabilidad de la máquina a utilizar. (Biamonte et al. 2017)

4.3. Determinar la disponibilidad y confiabilidad pronosticada de la flota vehicular de una calera posterior a la implementación de machine learning.

4.3.1. Performance del modelo en la disponibilidad

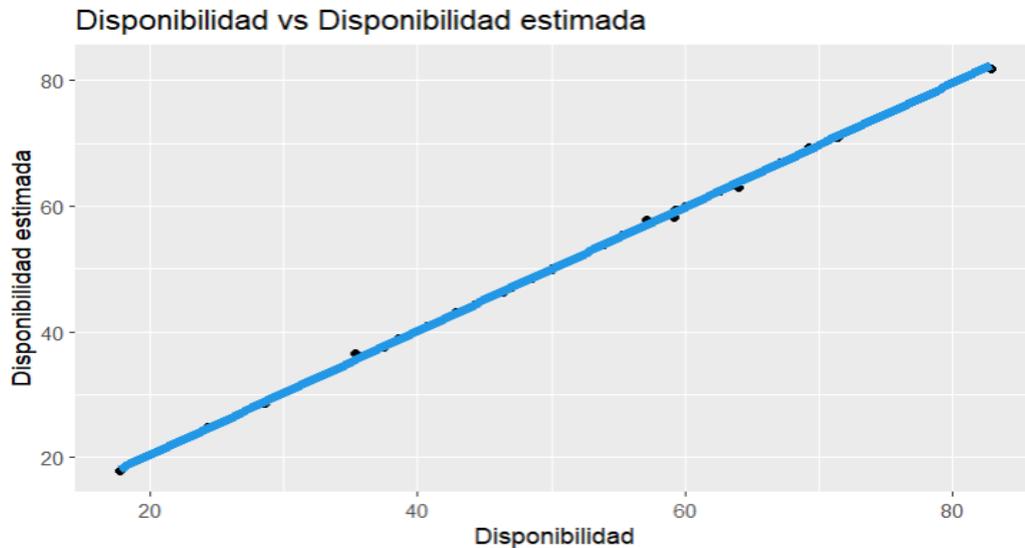


Figura 22: Disponibilidad vs Disponibilidad estimada

Fuente: Elaboración propia

- ✓ Al aplicar el algoritmo de Random forest en la implementación obtuvimos un R-cuadrado de 0.9992, indicando que este modelo predice bien en la implementación, incluso se obtuvo un mejor resultado que en la data de entrenamiento. Así mismo se puede observar que la nube de puntos de la disponibilidad estimada se ajusta a la recta de los datos reales de la disponibilidad.

Discusión

Tabla 9: Resultados por modelo

Modelo	MSE	RMSE	R - cuadrado
Data de entrenamiento	0.0001	4.9322	0.8921
Data de implementación	0.0053	0.4263	0.9992

Fuente: Elaboración propia

Al aplicar los modelos de machine learning para predecir la disponibilidad de la máquina en la data de implementación, el algoritmo de Random Forest nos sigue dando buenos indicadores, obteniendo un R- cuadrado cercano a uno, lo que nos indica que su predicción sigue siendo acertada.

4.3.2. Performance del modelo en la confiabilidad

Confiabilidad vs Confiabilidad estimada

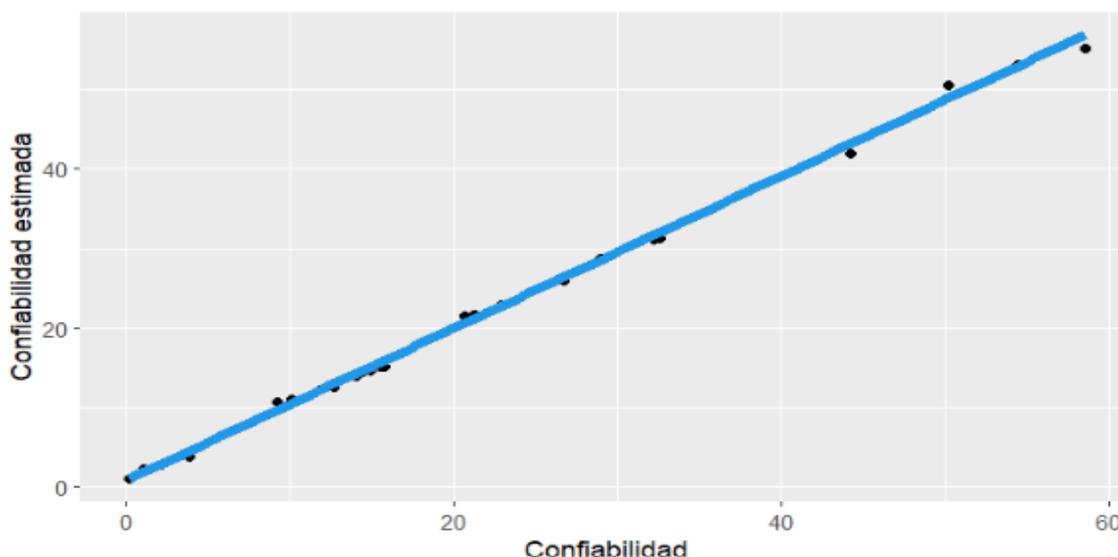


Figura 23: Confiabilidad vs Confiabilidad estimada

Fuente: Elaboración propia

- ✓ Al aplicar el algoritmo de Random forest en la implementación obtuvimos un R-cuadrado de 0.9962, indicando que este modelo predice bien en la implementación, incluso se obtuvo un mejor resultado que en la data de entrenamiento. Así mismo se puede observar que la nube de puntos de la disponibilidad estimada se ajusta a la recta de los datos reales de la confiabilidad.

Discusión

Tabla 10: Resultados por modelo

Modelo	MSE	RMSE	R - cuadrado
Data de entrenamiento	-0.0051	7.6189	0.7311
Data de implementación	0.0641	0.9595	0.9962

Fuente: Elaboración propia

Al aplicar los modelos de machine learning para predecir la confiabilidad de la máquina en la data de implementación, el algoritmo de Random Forest nos sigue dando buenos indicadores, obteniendo un R- cuadrado cercano a uno, lo que nos indica que su predicción sigue siendo acertada.

- **Disponibilidad del cargador frontal**

Tabla 11: *Disponibilidad y prueba de muestras*

		Prueba de muestras emparejadas							
		Diferencias emparejadas							
		intervalo de confianza al 95% de diferencia							
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par 1	Pre & Post-Test	24,95083	19,49118	5,62662	12,56673	37,33494	4,434	11	,001

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para disponibilidad de la maquinaria del cargador frontal antes y después de que se aplicara el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.001 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Confiabilidad de la cargadora frontal**

Tabla 12: *Confiabilidad y prueba de muestras*

		Prueba de muestras emparejadas							
		Diferencias emparejadas							
		intervalo de confianza al 95% de diferencia							
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par 1	Pre & Post-Test	36,46583	24,71034	7,13326	20,76563	52,76563	5,112	11	,000

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para confiabilidad de la maquinaria del cargador frontal antes y después de que se aplicará el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.000 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Disponibilidad de la retroexcavadora**

Tabla 13: *Disponibilidad y prueba de muestras*

		Prueba de muestras emparejadas							
		Diferencias emparejadas							
		intervalo de confianza al 95% de diferencia							
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par 1	Pre & Post-Test	25,47833	10,14445	2,92845	19,03286	31,92381	8,700	11	,000

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para disponibilidad de la maquinaria retroexcavadora antes y después de que se aplicará el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.000 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Confiabilidad de la retroexcavadora**

Tabla 14: *Confiabilidad y prueba de muestras*

		Prueba de muestras emparejadas							
		Diferencias emparejadas							
		intervalo de confianza al 95% de diferencia							
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par 1	Pre & Post-Test	35,23833	16,27271	4,69753	24,89915	45,577	7,501	11	,000

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para confiabilidad de la maquinaria de la retroexcavadora antes y después de que se aplicará el machine learning, se

consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.000 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Disponibilidad del minicargador**

Tabla 15: *Disponibilidad y prueba de muestras*

		Prueba de muestras emparejadas							
		Diferencias emparejadas							
		intervalo de confianza al 95% de diferencia							
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par 1	Pre & Post-Test	22,74750	18,89201	5,45365	10,74409	34,75091	4,171	11	,002

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para disponibilidad de la maquinaria del minicargador antes y después de que se aplicará el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.002 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Confiabilidad del minicargador**

Tabla 16: *Confiabilidad y prueba de muestras*

		Prueba de muestras emparejadas							
		Diferencias emparejadas							
		intervalo de confianza al 95% de diferencia							
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par 1	Pre & Post-Test	34,78500	24,47582	7,06556	19,23381	50,33619	4,923	11	,000

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para confiabilidad de la maquinaria del minicargador antes y después de que se aplicará el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.000 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Disponibilidad de la excavadora**

Tabla 17: *Disponibilidad y prueba de muestras*

Prueba de muestras emparejadas									
Diferencias emparejadas									
intervalo de confianza al 95% de diferencia									
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par	Pre & Post-Test	27,41583	17,16623	4,95546	16,50893	38,32273	5,532	11	,000

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para disponibilidad de la maquinaria excavadora antes y después de que se aplicará el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.000 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

- **Confiabilidad de la excavadora**

Tabla 18: *Confiabilidad y prueba de muestras*

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de ladiferencia									
		Media	Desv.	Desv. Error	Inferior	Superior	t	gl	Sig (bilateral)
Par	Pre & Post-Test	21,09734	18,33452	4,95546	27,39201	53,54382	5,843	11	,000

Fuente: (IBM 2017) Elaboración propia

Los resultados logrados sobre la prueba para confiabilidad de la maquinaria excavadora antes y después de que se aplicará el machine learning, se consiguió evidenciar la prueba T de Student, donde su nivel fue de 0.000 (inferior a 0.05), por lo que se consigna con aceptabilidad la hipótesis de la investigación.

Resultados comparativos

- **Disponibilidad**

El valor promedio real obtenido de la disponibilidad de las máquinas en el ejercicio de agosto fue de 49.976% y del estimado 49.970%

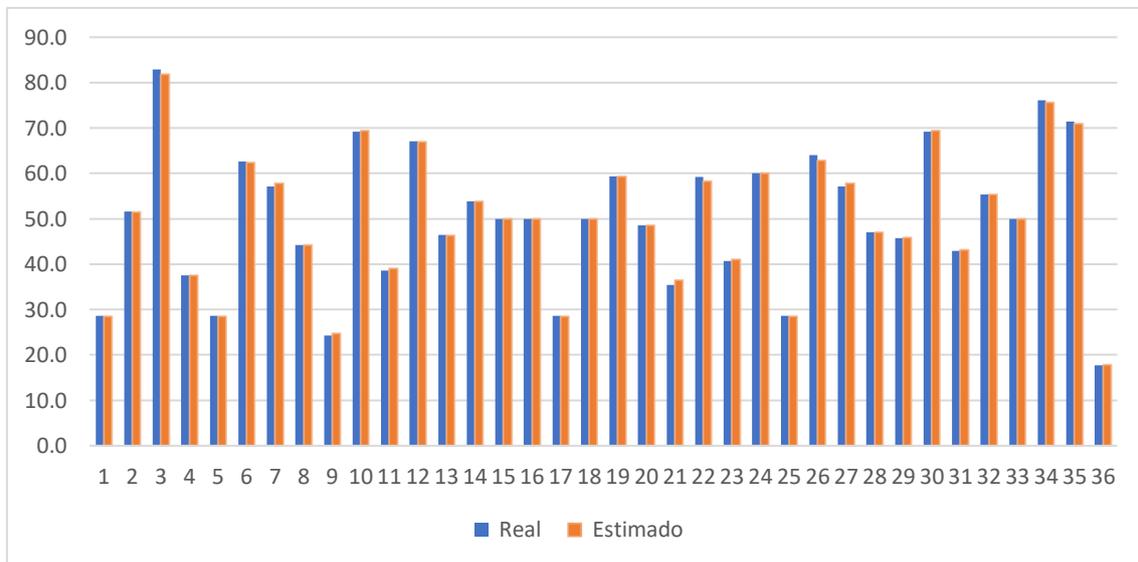


Figura 24: Valor promedio en disponibilidad
Fuente: Elaboración propia

- **Confiabilidad**

El valor promedio real obtenido de la confiabilidad de las máquinas en el ejercicio de agosto fue de 21.166 % y del estimado 21.101%

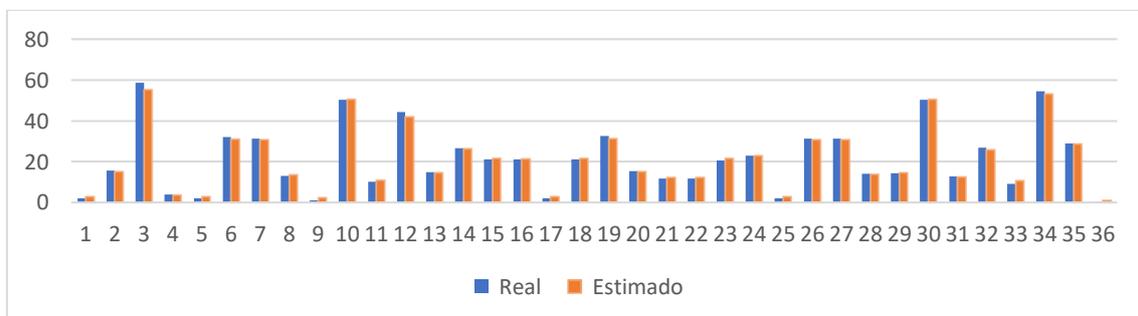


Figura 25: Valor promedio en confiabilidad
Fuente: Elaboración propia

La descripción de los equipos que aparecen en las figuras 24 y 25 de disponibilidad y confiabilidad se detallan en la siguiente tabla:

Tabla 19: Listado de equipos de la empresa calera

Equipo	Flota	Código
1	Cargador frontal	CF-E0001
2	Cargador frontal	CF-E0002
3	Cargador frontal	CF-E0003
4	Cargador frontal	CF-E0004
5	Cargador frontal	CF-E0005
6	Cargador frontal	CF-E0006
7	Cargador frontal	CF-E0007
8	Cargador frontal	CF-E0008
9	Cargador frontal	CF-E0009
10	Cargador frontal	CF-E0010
11	Cargador frontal	CF-E0011
12	Cargador frontal	CF-E0012
13	Minicargador	MC-E0001
14	Minicargador	MC-E0002
15	Minicargador	MC-E0003
16	Minicargador	MC-E0004
17	Minicargador	MC-E0005
18	Minicargador	MC-E0006
19	Minicargador	MC-E0007
20	Minicargador	MC-E0008
21	Excavadora	EX-E0001
22	Excavadora	EX-E0002
23	Excavadora	EX-E0003
24	Excavadora	EX-E0004
25	Excavadora	EX-E0005
26	Excavadora	EX-E0006
27	Excavadora	EX-E0007
28	Retroexcavadora	RE-E0001
29	Retroexcavadora	RE-E0002
30	Retroexcavadora	RE-E0003
31	Retroexcavadora	RE-E0004
32	Retroexcavadora	RE-E0005
33	Retroexcavadora	RE-E0006
34	Retroexcavadora	RE-E0007
35	Retroexcavadora	RE-E0008
36	Retroexcavadora	RE-E0009

Fuente: Elaboración propia

4.4. Determinar el costo beneficio al implementar el machine learning en el mantenimiento de la flota vehicular de una calera.

La información analizada enmarca dos situaciones distintas las cuales serán comparadas, antes y después de la implementación (se practicaba mucho el mantenimiento correctivo que en algunas circunstancias no permitía mejorar la disponibilidad de las máquinas, gestionando una pérdida de tiempo laborable y productiva basado en fallas electromecánicas. Para el estudio del costo sobre la implementación y el costo que indujo a su factibilidad, no se consideraron las actividades de forma mensual. (Beetrack 2016)

Inversión en la implementación del machine learning con el software R; así mismo se planteó dichos componentes en el desarrollo del proyecto con el que se indica cada inversión monetaria y el beneficio de este; se denota en la siguiente tabla:

Tabla 20: Costo invertido en el software de aplicación predictiva

Descripción	Importe
Software	
Software IBM SPSS 0.2	S/250.00
Software R	S/550.00
Hardware	
Laptop	S/1,650.00
Impresora	S/500.00
Servicios	
Servicio de internet	S/240.00
Servicio de telefonía	S/50.00
Total	S/3,240.00

Fuente: Elaboración propia

➤ Indicadores económicos

El Banco de Crédito del Perú, muestra una tasa de 12%, usándose en el valor para el cálculo del VAN, teniendo como inversión inicial S/3,240.00 en la aplicación del modelo predictivo de machine learning.

Tabla 21: Indicadores VAN y TIR

Indicador	Valor
VAN	S/ 2852.13
TIR	32.65%

Fuente: Elaboración propia

Al hacer análisis de costo/beneficio de una inversión de S/3,240.00; en donde se obtuvo un VAN de S/. 2852.13 y con un TIR de 32.65%; el cual será recuperado en el segundo mes posterior a la implementación, es una resultante bastante favorable en la aplicación del software sobre la gestión de mantenimiento predictivo de la empresa calera.

V. DISCUSIÓN

(Ren 2021a) planteó una optimización y reducción de tareas teniendo criterios sobre una buena distribución aplicando conceptos y diseños de mantenimiento predictivo, en donde su reducción se hizo un 0.48% más eficiente mejorando su costo hasta un 5,43% y su energía en 28,10% estos datos se lograron al aplicar el machine learning; así mismo, el modelo resultante en su utilidad y prueba generó un 95,1% de manera predictiva y un 94,5% eficiente, este algoritmo está planteado en una regresión logística en donde se toma dos registros en un tiempo real desde un informe o base de datos de los sucesos a mejorar.

En el primer objetivo específico de mi investigación para determinar la disponibilidad y confiabilidad de la flota vehicular de una calera se realizó el análisis de la gestión de mantenimiento de la flota vehicular de la calera para mejorar la disponibilidad y confiabilidad de las maquinarias que incluye la flota de cargador frontal, minicargador, retroexcavadora y excavadora de orugas, mediante el uso de una base de datos y registro de máquinas que actualmente utiliza la empresa, de donde se obtuvo la información necesaria para procesarla con los software Excel y SPSS y obtener de forma gráfica el escenario actual y real de las maquinarias de la empresa calera para analizar las disponibilidades y confiabilidades alcanzadas de la flota de equipos cargador frontal, minicargador, retroexcavadora y excavadora de orugas. Los datos tomados para la aplicación del presente estudio fueron dentro de un rango de los tres últimos meses; siendo los meses de mayo, junio y julio, y en base a los resultados obtenidos en estos meses de toma de datos de la calera, fue de suma importancia para la aplicación del modelamiento del algoritmo obtenido con la aplicación del software R de machine learning en el cuarto mes, mes de agosto, donde como resultado de la aplicación del software R de machine learning se logró pronosticar o predecir la disponibilidad y confiabilidad que se iba a alcanzar en el mes de agosto, por lo que al conocer esta información, los responsables del área de mantenimiento de la empresa ejecutaron las acciones necesarias para mejorar la disponibilidad y confiabilidad pronosticadas.

(Barroso Salgado 2018) desarrolló un método predictivo enfocado en la aplicación del machine learning en la zona de mantenimiento de maquinarias mineras, enfocado en diversas metodologías, entre los que están el CRIPS-DM un sistema de programación para encontrar o desarrollar el algoritmo llamado Gradient Boosting Trees, la unión de estos lograron concretar una mejor distribución y gestión para el almacenamiento sobre las ordenes de trabajo, el resultado para su efectividad fue de un 82,2%, concretando que el software de machine learning es muy eficaz en cuanto a su modo predictivo con un grado de confiabilidad muy alto.

Se planteó como segundo objetivo específico de mi investigación elaborar un modelo de machine learning para pronosticar la disponibilidad y confiabilidad de la flota vehicular de la calera, por lo que se afirma lo indicado en la referencia; ya que, en el planteamiento para el desarrollo del software R de aprendizaje automático realizado en la empresa calera, también usar la metodología orientada al análisis de datos conocido como el método CRIPS-DM (Cross-Industry Standard Process for Data Mining) y el LSTM (Long Short Term Memory) para el modelamiento de un algoritmo para predecir la disponibilidad y confiabilidad con el uso de modelos convencionales como el de regresión lineal múltiple y contemporáneos como los modelos Random Forest (Modelo de árboles aleatorios) y aumento de gradiente XGBOOST de machine learning. Al aplicar los modelos de machine learning para predecir la disponibilidad de la máquina, el modelo de Random Forest nos dio los mejores indicadores, obteniendo un R- cuadrado cercano a uno, lo que nos indica que su predicción es de las mejores a comparación de los demás algoritmos, así mismo el (RMSE) fue de 4.9322, lo cual nos indica que este modelo es que menor error nos muestra al momento de estimar la disponibilidad. Por ello, puedo concluir que un modelo machine learning nos brinda una buena estimación de la disponibilidad de la máquina a utilizar. Por otro lado, al aplicar los modelos de machine learning para predecir la confiabilidad de la máquina, el algoritmo de Random Forest nos dio los mejores indicadores, obteniendo un R- cuadrado cercano a uno, lo que nos indica que su predicción es de las mejores a comparación de los demás algoritmos, así mismo el (RMSE) fue de 7.6189, lo cual nos indica que este modelo es que menor error nos muestra al momento de estimar la confiabilidad.

(Paolanti et al. 2018) Logró proponer un enfoque de calidad usando el machine learning en la gestión de mantenimiento predictivo sobre industria 4.0, sus resultados fueron que el software de programación planteado brindó una mejor calidad del mantenimiento predictivo hacia las máquinas programadas; lograron una mejor eficiencia y operatividad de los motores eléctricos con esta programación, generando ganancias en la empresa de forma muy eficaz y rentable con la aplicación del software.

En el tercer objetivo específico de mi investigación para determinar la confiabilidad y disponibilidad pronosticada de la flota vehicular de una calera posterior a la implementación de machine learning, se buscó pronosticar la mejora del rendimiento de la flota vehicular de una empresa calera para así mejorar la disponibilidad y confiabilidad de los equipos, mediante el uso de una base de datos y registro de máquinas que utiliza la calera en sus operaciones, donde la resultante de mejora fue un 49.976% en la disponibilidad de equipos y su confiabilidad logro alcanzar 21.166%. El valor promedio real obtenido de la disponibilidad de las máquinas en el mes de agosto fue de 49.976% y del estimado 49.970%. Y para el caso de la confiabilidad, el valor promedio real obtenido de la confiabilidad de las máquinas en el mes de agosto fue de 21.166% y del estimado 21.101%.

(Ruiz-Sarmiento et al. 2020) propusieron un modelo predictivo para analizar el rendimiento de una máquina industrial, aplicando machine learning donde los datos y registro de la máquina fueron propuestos por la empresa para analizar su operatividad y mantenimiento. Dieron como resultado un conocimiento más centrado, preciso y eficaz para minimizar una falla o mantenimiento en tiempo real, la técnica de programación machine learning en su productividad generó un 85.8% de eficiencia en comparación a la post-implementación, teniendo relevancia en diferentes circunstancias y áreas.

Al analizar los resultados del primer, segundo, tercer y cuarto objetivo específico de mi investigación, del planteamiento realizado en la calera, la aplicación de aprendizaje automático mediante el uso del software R; así como la investigación de (Ruiz-Sarmiento et al. 2020), también se generó grandes impactos en la utilidad de la flota vehicular de la empresa calera, mejorando la rentabilidad,

eficiencia en el uso de los recursos, disponibilidad y confiabilidad de la flota de equipos en un 49.976% y 21.166% respectivamente. Haciendo sumamente indispensable usar el aprendizaje automático en su función de pronosticar la disponibilidad y confiabilidad de la flota de equipos, lo que permite a la jefatura y responsables del área de mantenimiento de la empresa, tomar decisiones que permitirán desarrollar e implementar estrategias para el corto, mediano y largo plazo para reducir la incidencia de fallas y mantenimientos correctivos en cualquier flota de la empresa. Ante lo indicado debo precisar, que el uso del machine learning tiene un alto potencial de ser eficiente en la gestión de mantenimiento de grandes y pequeños equipos, donde la debilidad de la metodología es que, a mayor cantidad de equipos a analizar, la eficiencia del pronósticos será ligeramente menor, y a menor cantidad de equipos su fortaleza considerando la eficiencia en el pronóstico será mayor.

VI. CONCLUSIONES

1. Se realizó análisis estadístico de la información recopilada de las maquinarias en los 3 meses de estudio, se muestra que la maquinaria de la cargadora frontal en la semana 3, tuvo el mayor MTBF, teniendo una probabilidad de 58 veces en las que presuntamente fallaría, y por otra parte el MTTR se dio en 12 veces, su confiabilidad es de 58.60% y la disponibilidad un 82.86%. Por otro lado, el minicargador generó menor MTBF sucedido a finales del mes de julio, tuvo un 4.46 veces que este podía generar una falla, su MTTR tiene 21.67 veces; la confiabilidad fue de 0.13% y la disponibilidad de un 17.72%.
2. Con el software R de machine learning, se analizó la correlación de las variables con la aplicación del coeficiente de correlación de Spearman, al aplicar el modelo de random forest, considerado un algoritmo de machine contemporáneo obtuvimos un R-cuadrado de 0.7311, indicando que este modelo es bueno ya que su acierto en la predicción es muy alta. Así mismo se puede observar que la nube de puntos de la confiabilidad estimada se ajusta mejor a la recta de los datos de la confiabilidad.
3. Se determinó la disponibilidad y confiabilidad de las maquinaria en donde se aplicaron diferentes patrones de estudio sobre el machine learning en las cuales se tiene a los árboles de decisión, SVM y redes neuronales; la información recopilada se analizó con el software Excel, esto transcurre en los resultados de forma favorable en donde se logró un alza de disponibilidad de 24.9% y confiabilidad de 36.5 en la maquinaria del cargador frontal; la retroexcavadora tuvo una gran mejora en su disponibilidad con un 25.4% y la confiabilidad tuvo un 35.2%; por otro lado el minicargador en su disponibilidad logró un 22.7% y en su confiabilidad un 34.7%; para finalizar la excavadora en la disponibilidad logró un 27.4% donde su confiabilidad género como resultado un 42.4%.
4. Respecto de la inversión para implementación del machine learning con el software R; se determinó que es viable al obtener un VAN de S/2852.13 y un TIR del 32.65% con una inversión de S/3,240.00.

VII. RECOMENDACIONES

Concientizar a la jefatura y responsables en toma de decisiones, uso constante del machine learning no solo cuando haya fallas o malas gestiones que no permitan alcanzar la productividad esperada, sino que el uso constante sea para lograr tener un mecanismo más fiable y confiable para pronosticar el rendimiento de los equipos; como resultado mejorar la precisión del software para lograr una gestión de mantenimiento más tecnológico y preciso.

Organizar equipos de trabajo para la capacitación y difusión del machine learning a través del uso del software R y los beneficios que esta tecnología aporta para mejorar los procesos de mantenimiento en los equipos.

Brindar esta investigación sin fines de lucro hacia futuros investigadores, que requieran indagar y conocer el uso del Machine Learning, con el uso de la metodología del CRISP-DM, al generar e implementar dicha metodología con el uso de software de machine learning se reducirán los costos y aumentará la disponibilidad y confiabilidad de las máquinas o equipos.

REFERENCIAS

- ABDERRAHIM, M., BEKRAR, A., TRENTESAUX, D., AISSANI, N. y BOUAMRANE, K., 2020. Manufacturing 4.0 operations scheduling with AGV battery management constraints. *Energies*, vol. 13, no. 18. ISSN 19961073. DOI 10.3390/EN13184948.
- AEC, 2019. Disponibilidad. *Asociación Española para la Calidad* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.aec.es/web/guest/centro-conocimiento/disponibilidad>.
- AGÜERO, V., MARTIN, J., HUARCAYA, S. y GLORIA, J., 2021. Machine Learning en la mejora del proceso de operaciones comerciales en la empresa Redondos, Lima - 2020. *Repositorio Institucional - UCV* [en línea], [Consulta: 23 septiembre 2022]. Disponible en: <https://repositorio.ucv.edu.pe/handle/20.500.12692/63573>.
- ALBERTI, A., 2020. ¿Qué es la confiabilidad en el mantenimiento? *ALS Global* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.alsglobal.com/%2Fes-co%2Fnews%2Farticulos%2F2020%2F05%2Fqu-es-la-confiabilidad-en-el-mantenimiento>.
- ANSOLABEHERE, K., CORTÉS, F., MARTÍNEZ, L. y ZAREMBERG, G., 2019. Estudio introductorio. *Diseños de investigación*, pp. 7-48. DOI 10.2307/J.CTVB1HT6X.3.
- APD, 2019. Qué es Machine Learning, cómo funciona y a qué se aplica . *Madrid* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.apd.es/que-es-machine-learning/>.
- BARROSO SALGADO, J.A., 2018. Modelo predictivo basado en machine learning de ordenes de trabajo riesgosas para mantenimiento de equipos mineros. [en línea], [Consulta: 23 septiembre 2022]. Disponible en: <https://repositorio.uchile.cl/handle/2250/170038>.
- BEETRACK, 2016. La importancia de la flota vehicular en el sector logístico. [en línea], [Consulta: 27 junio 2022]. Disponible en:

<https://www.beetrack.com/es/blog/flota-vehicular>.

- BI, Q., GOODMAN, K.E., KAMINSKY, J. y LESSLER, J., 2019. What is machine learning? A primer for the epidemiologist. *American Journal of Epidemiology*, vol. 188, no. 12, pp. 2222-2239. ISSN 14766256. DOI 10.1093/AJE/KWZ189.
- BIAMONTE, J., WITTEK, P., PANCOTTI, N., REBENTROST, P., WIEBE, N. y LLOYD, S., 2017. Quantum machine learning. *Nature* 2017 549:7671, vol. 549, no. 7671, pp. 195-202. ISSN 1476-4687. DOI 10.1038/nature23474.
- BITEUS, J. y LINDGREN, T., 2018. Planning Flexible Maintenance for Heavy Trucks using Machine Learning Models, Constraint Programming, and Route Optimization. *SAE International Journal of Materials and Manufacturing*, vol. 10, no. 3, pp. 306-315. ISSN 19463987. DOI 10.4271/2017-01-0237.
- CARPIO, atalia, HERNÁNDEZ, C.E. y CARPIO, N., 2019. Introducción a los tipos de muestreo. *Alerta, Revista científica del Instituto Nacional de Salud* [en línea], vol. 2, no. 1 (enero-junio), pp. 75-79. [Consulta: 23 septiembre 2022]. ISSN 2617-5274. DOI 10.5377/ALERTA.V2I1.7535. Disponible en: <https://www.lamjol.info/index.php/alerta/article/view/7535>.
- CASTRO GALÁN, E., 2015. Aplicación de la Metodología CRISP-DM a un Proyecto de Minería de Datos en el Entorno Universitario. ,
- EMERSON, 2017. Disponibilidad- Generalidades. *Bus Sch-OEE102* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.emerson.com/documents/automation/training-bussch-oe-102es-es-41724.pdf>.
- FERNANDEZ GOMEZ, J.M., 2016. Introducción a la gestión de flotas de vehículos Advance Fleet Management Consulting. [en línea], [Consulta: 27 junio 2022]. Disponible en: <https://www.researchgate.net/publication/303864416>.
- FRONTERA TEMUCO, L. y MANTEROLA DELGADO, C., 2018. Laboratorio e Infectología. *Chilena Infecto* [en línea], [Consulta: 23 junio 2022].

Disponible en: www.sochinf.cl.

FUENMAYOR, E., 2018. Analisis de Confiabilidad, Disponibilidad y Mantenibilidad de un Sistema de Bombeo. | LinkedIn. *LinkedIn* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.linkedin.com/pulse/analisis-de-confiabilidad-disponibilidad-y-un-sistema-edgar/?originalSubdomain=es>.

GAVILÁN, I.G.R., 2019. Cinco definiciones de machine learning . *Tema The7 de Dream-Theme* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://ignaciogavilan.com/cinco-definiciones-de-machine-learning/>.

HERNÁNDEZ, C.E. y CARPIO, N., 2019. Introducción a los tipos de muestreo. *ALERTA Revista Científica del Instituto Nacional de Salud*, vol. 2, no. 1, pp. 75-79. DOI 10.5377/ALERTA.V2I1.7535.

IBERDROLA, 2022. Machine Learning: definición, tipos y aplicaciones prácticas. *Innovación* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>.

IBM, 2017. SPSS Modeler CRISP-DM. ,

JUÁREZ VILLATORO, 2017. Coeficiente de asociación de Spearman. ,

LUKO, S.N., 2021. ¿Qué es la confiabilidad? *ASTM Standardization News: Espanol* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://sn.astm.org/spanish/?q=data-points/¿qué-es-la-confiabilidad-jf18.html>.

MAISUECHE CUADRADO, A., 2019. Utilización del Machine Learning en la industria 4.0. [en línea], [Consulta: 23 septiembre 2022]. Disponible en: <https://uvadoc.uva.es/handle/10324/37908>.

MARÍN VILCA, D.G. y PINEDO TORRES, I.A., 2019. Modelo predictivo Machine Learning aplicado a análisis de datos Hidrometeorológicos para un SAT en Represas. *Universidad Tecnológica del Perú* [en línea], [Consulta: 23 septiembre 2022]. Disponible en:

https://repositorio.utp.edu.pe/bitstream/handle/20.500.12867/3300/Darwin_Marin_Ian_Pineda_Tesis_Titulo_Profesional_2019.pdf?sequence=1.

MARKUDOVA, D., MISHRA, S., CAGLIERO, L., VASSIO, L., MELLIA, M., BARALIS, E., SALVATORI, L. y LOTI, R., 2021. Preventive maintenance for heterogeneous industrial vehicles with incomplete usage data. *Computers in Industry*, vol. 130. ISSN 01663615. DOI 10.1016/J.COMPIND.2021.103468.

MITCHELL, T., 2018. ¿Qué es el aprendizaje automático o machine learning? *Machine learning para todos* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://machinelearningparatodos.com/que-es-el-aprendizaje-automatico-o-machine-learning/>.

MORITZER, E., HEIDERICH, G. y GEISLER, C., 2019. Investigation on the fiber compounding with a new type of compounding machine. *AIP Conference Proceedings*, vol. 2065. ISSN 15517616. DOI 10.1063/1.5088291.

NADARAJAH, N., SHAMDANI, A., HARDY, G., CHIU, W. y WIDYASTUTI, H., 2018. Prediction of Railway Vehicles' Dynamic Behavior with Machine Learning Algorithms-Web of Science Core Collection. *ELECTRONIC JOURNAL OF STRUCTURAL ENGINEERING* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.webofscience.com/wos/woscc/full-record/WOS:000457986400008>.

PAOLANTI, M., ROMEO, L., FELICETTI, A., MANCINI, A., FRONTONI, E. y LONCARSKI, J., 2018. Machine Learning approach for Predictive Maintenance in Industry 4.0. *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications, MESA 2018*, DOI 10.1109/MESA.2018.8449150.

POZO GALLEGO, C. del, 2018. Mantenimiento predictivo en motores de inducción aplicando técnicas de inteligencia artificial y teoría de desequilibrios electromagnéticos. [en línea], [Consulta: 23 septiembre 2022]. Disponible en: <https://uvadoc.uva.es/handle/10324/32462>.

- QUADIS, 2016. ¿Qué son las flotas de vehículos? [en línea], [Consulta: 27 junio 2022]. Disponible en: <https://www.quadis.es/articulos/que-son-las-flotas-de-vehiculos-/106615>.
- REN, Y., 2021a. Optimizing Predictive Maintenance with Machine Learning for Reliability Improvement. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering*, vol. 7, no. 3. ISSN 23329025. DOI 10.1115/1.4049525.
- REN, Y., 2021b. Optimizing Predictive Maintenance with Machine Learning for Reliability Improvement. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering* [en línea], vol. 7, no. 3. [Consulta: 23 septiembre 2022]. ISSN 23329025. DOI 10.1115/1.4049525/1094081. Disponible en: <https://asmedigitalcollection.asme.org/risk/article/7/3/030801/1094081/Optimizing-Predictive-Maintenance-With-Machine>.
- RUIZ-SARMIENTO, J.R., MONROY, J., MORENO, F.A., GALINDO, C., BONELO, J.M. y GONZALEZ-JIMENEZ, J., 2020. A predictive model for the maintenance of industrial machinery in the context of industry 4.0. *Engineering Applications of Artificial Intelligence*, vol. 87, pp. 103289. ISSN 0952-1976. DOI 10.1016/J.ENGAPPAL.2019.103289.
- SHINDE, P.P. y SHAH, S., 2018. A Review of Machine Learning and Deep Learning Applications. *Proceedings - 2018 4th International Conference on Computing, Communication Control and Automation, ICCUBEA 2018*, DOI 10.1109/ICCUBEA.2018.8697857.
- SOBRINO ZIMMERMANN, J., 2017. CONFIABILIDAD VERSUS DISPONIBILIDAD. *Alpha Manufacturas* [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.alphamanufacturas.com/confiabilidad-versus-disponibilidad/>.
- UNE, 2018. Mantenimiento. *Terminología del mantenimiento*. [en línea], [Consulta: 23 junio 2022]. Disponible en: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0060338>.

VALUEKEEP, 2020. ¿Qué son el MTTR y MTBF? . [en línea], [Consulta: 24 noviembre 2022]. Disponible en: <https://valuekeep.com/es/recursos/mttr-y-mtbf/>.

VOROBAYCHIK, Y. y KANTARCIOGLU, M., 2018. Adversarial machine learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, vol. 12, no. 3, pp. 1-169. ISSN 19394616. DOI 10.2200/S00861ED1V01Y201806AIM039.

ANEXOS

Anexo 1: Proceso del modelado:

Cargando la data

```
#####
# ANALISIS PARA LA CONFIABILIDAD
#####

library(data.table)
library(RODBC)
library(party)
library(pROC)
library(lattice) ## tabla formato latex
library(xtable) ## tabla formato latex
library(corrplot)
library(caret) ##
library(reshape)
library(dplyr)
library(earth) ## grafica para la monotonia de los betas
library(readxl)
library(sqldf)
library(randomForest)
library(tidyverse)
library(xgboost)
library(ggpubr)
library(RandomForest)

#####
# I -- CARGANDO LA DATA
#####

#Ruta
setwd('C:/Users/.....')

data_confi <- read_excel("Datos_maquinaria_4.xlsx")
```

Analizando la data

```
# seleccionando variables
#-----

data_confi<-sqldf("select
                    Hora_nominal           as var_X1,
                    hora_detencion         as var_X2,
                    Hora_operativa         as var_X3,
                    Num_fallas              as var_X4,
                    Hora_deteccion_fallas  as var_X5,
                    MTB_F                   as var_X6,
                    MTT_R                   as var_X7,
                    Confiabilidad           as var_Y2
                    from data_confi")

summary(data_confi)

#####
# II -- SELECCION DE VARIABLES
#####

# CORRELACION DE VARIABLES
M <- cor(data_confi,
         method = "spearman",
         use = "pairwise.complete.obs")
corrplot(M, method = "number") ## > 60% se descartan
corrplot.mixed(M, order = 'AOE') ## > 60% se descartan
set.seed(7514)

# SELECCION DE VARIABLES RANDOM FOREST
modelo_randomfores1 <- randomForest(var_Y2 ~ ., data = data_confi,
                                   mtry = 5, ntree = 100, nodesize = 3, importance = TRUE)

# GRAFICO
importancia_pred <- as.data.frame(importance(modelo_randomfores1, scale = TRUE))
importancia_pred <- rownames_to_column(importancia_pred, var = "variable")
p1 <- ggplot(data = importancia_pred, aes(x = reorder(variable, `-%IncMSE`),
                                         y = `-%IncMSE`,
                                         fill = `-%IncMSE`)) +
  labs(x = "variable", title = "Reduccion de MSE - Confiabilidad") +
  geom_col() +
  coord_flip() +
  theme_bw() +
  theme(legend.position = "bottom")
x11()
ggarrange(p1)
```

Modelamiento de la data

Evaluación

```
# B -- MODELO 02: Random Forest
#####-----
## Semilla
set.seed(18562)

modelo_02<-randomForest(var_Y2 ~ var_X1+var_X2+var_X4+var_X6
                        ,data= data_conf1
                        ,ntree = 500, nodesize = 3, importance = TRUE)

summary(modelo_02)

# B.1 - Prediciendo
data_conf1$estimacion_ML2 <- predict(modelo_02, newdata=data_conf1,type="response")

# B.2 - Medición
corr2 <- cor(data_conf1$estimacion_ML2, data_conf1$var_Y, method = c("pearson")) # Correlacion
rmse2 <- sqrt(mean((data_conf1$estimacion_ML2 - data_conf1$var_Y)^2)) # Error (raiz cuadrada del error cuadraic

# B.3 - Grafico Lineal

qplot(x = var_Y2, y = estimacion_ML2,data = data_conf1,
      main = "Confiabilidad vs Confiabilidad estimada", ylab = "Confiabilidad estimada",
      xlab = "Confiabilidad", geom = c("point"),
      method = "lm") +
  geom_smooth(method=lm,se=FALSE,fullrange=TRUE,lwd = 2, color = 4)

# C -- MODELO 03: xgboost
#####-----
## Semilla
set.seed(18562)

modelo_03<-train(var_Y2 ~ var_X1+var_X2+var_X4+var_X6
                 ,data= data_conf1
                 ,method = "xgbTree",
                 trControl = trainControl("cv", number = 10))

summary(modelo_03)

# C.1 - Prediciendo
data_conf1$estimacion_ML3 <- predict(modelo_03, newdata=data_conf1,type="raw")

# C.2 - Medición
corr3 <- cor(data_conf1$estimacion_ML3, data_conf1$var_Y, method = c("pearson")) # Correlacion
rmse3 <- sqrt(mean((data_conf1$estimacion_ML3 - data_conf1$var_Y)^2)) # Error (raiz cuadrada del error cuadraic

# c.3 - Grafico Lineal

qplot(x = var_Y2, y = estimacion_ML3,data = data_conf1,
      main = "Confiabilidad vs Confiabilidad estimada", ylab = "Confiabilidad estimada",
      xlab = "Confiabilidad", geom = c("point"),
      method = "lm") +
  geom_smooth(method=lm,se=FALSE,fullrange=TRUE,lwd = 2, color = 4)

# D -- RESUMEN DE INDICADORES ( MEJOR MODELO)
#####-----

# Estadisticos (MSE, RMSE, R-CUADRADO)
accuracy(data_conf1$estimacion_ML1, data_conf1$var_Y2)
accuracy(data_conf1$estimacion_ML2, data_conf1$var_Y2)
accuracy(data_conf1$estimacion_ML3, data_conf1$var_Y2)
```

Implementación

```
#####
# IV -- IMPLEMENTACIÓN DATA DE IMPLEMENTACION
#####

# 4.1 -- CARGANDO LA DATA
#####

setwd('C:/Users/.....')

data_confi_test <- read_excel("Datos_maquinaria_4.xlsx")

str(data_confi)

# Transformando variables
#-----

data_confi_test<-sqldf("select
                        Hora_nominal      as var_X1,
                        hora_detencion     as var_X2,
                        Hora_operativa     as var_X3,
                        Num_fallas         as var_X4,
                        Hora_deteccion_fallas as var_X5,
                        MTB_F              as var_X6,
                        MTT_R              as var_X7,
                        Confiabilidad      as var_Y2
                        from data_confi")

# 4.2 -- APLICACION DEL MODELO( Random Forest)
#####-----

# A - PREDICIENDO LA CONFIABILIDAD ( modelo_02 )
data_confi_test$estimacion_ML2 <- predict(modelo_02, newdata=data_confi_test,type="response")

# B - MEDICION
accuracy(data_confi_test$estimacion_ML2, data_confi_test$var_Y2)

# C - Grafico:

qplot(x = var_Y2, y = estimacion_ML2,data = data_confi_test,
      main = "Confiabilidad vs Confiabilidad estimada", ylab = "Confiabilidad estimada",
      xlab = "Confiabilidad", geom = c("point"),
      method = "lm") +
  geom_smooth(method=lm,se=FALSE,fullrange=TRUE,lwd = 2, color = 4)
```

Anexo 2: Operacionalización de variables

Variables	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Escala de medición
VI: Machine Learning	Es una disciplina del campo de la Inteligencia Artificial, que mediante el uso de algoritmos, dota a los ordenadores la capacidad de identificar patrones en datos masivos y elaborar predicciones. (Iberdrola 2022)	Es una metodología muy presente en las tecnologías introducidas en la industria por la Revolución 4.0.	Machine Learning	Ficha de revisión Técnica	Ordinal
				Frecuencia de incidencia de fallas	Ordinal
VD: Confiabilidad	Es un término usado para describir la disponibilidad y los factores de influencia: como son fiabilidad, mantenibilidad y logística de mantenimiento. (AEC 2019)	Es la probabilidad de que un equipo opere sin fallar durante un periodo de tiempo determinado bajo condiciones operacionales definidas y constantes.	Estabilidad		Ordinal
			Coeficiente Alfa de Cronbach		Ordinal
VD: Disponibilidad	Es la capacidad de un elemento de encontrarse en estado para desarrollar una función requerida bajo unas condiciones determinadas en un instante dado, asumiendo que se proveen los recursos externos requeridos. (AEC 2019)	Es un término exclusivo de los “equipos reparables” que se define como la probabilidad de que el equipo esté operando.	Fiabilidad	Tiempo medio entre fallos (MTBF)	Ordinal
			Mantenibilidad	Tiempo medio de reparación (MTTR)	Ordinal

ANEXO 3: INSTRUMENTO – FICHA DE REGISTRO

Ficha de registro	
<i>Equipo</i>	
<i>Área de trabajo del equipo</i>	
<i>Horómetro</i>	
<i>Responsable</i>	
<i>Comentarios</i>	

N°	Fecha	PRE-TEST								POST-TEST							
		Horas correctivas	#fallas	Horas periodo	Horas operadas	MTBF	MTTR	Disponibilidad	Confiabilidad	Horas correctivas	#fallas	Horas periodo	Horas operadas	MTBF	MTTR	Disponibilidad	Confiabilidad
1																	
2																	
3																	
4																	
5																	
6																	
7																	
8																	
9																	

Fuente: Elaboración propia

Anexo 4: Ubicación de la Empresa Calera



La empresa calera EL ZASAL EIRL está localizada en Cajamarca, provincia Hualgayoc y distrito Bambamarca, su dirección es carretera Bambamarca a Cajamarca Km 8 en el caserío comunidad Apan Bajo. El rubro de su sector es fabricación de cemento, cal y yeso.



UNIVERSIDAD CÉSAR VALLEJO

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

Declaratoria de Autenticidad del Asesor

Yo, SIALER DIAZ CESAR DANY, 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: "Machine learning en la disponibilidad y confiabilidad de la flota vehicular de una calera", cuyo autor es RONDON CHAVEZ RONALD EDWIN, constato que la investigación tiene un índice de similitud de 8.00%, 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, 07 de Diciembre del 2022

Apellidos y Nombres del Asesor:	Firma
SIALER DIAZ CESAR DANY DNI: 16731363 ORCID: 0000-0002-7430-9524	Firmado electrónicamente por: SIALERDC el 20-12- 2022 16:38:52

Código documento Trilce: TRI - 0477606