



**UNIVERSIDAD CÉSAR VALLEJO**

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

**Machine Learning en la gestión de mantenimiento de maquinaria  
pesada en la empresa MEKATSU EQUIPOS S.R.L.**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:  
Ingeniero Mecánico Electricista**

**AUTORES:**

Blas Benites, Ruben Fredy (ORCID: [0000-0003-0487-3362](https://orcid.org/0000-0003-0487-3362))

Diaz Mayta, Enestor (ORCID: [0000-0002-5320-8708](https://orcid.org/0000-0002-5320-8708))

**ASESOR:**

Mg. Panta Carranza, Dante Omar (ORCID: [0000-0002-4731-263X](https://orcid.org/0000-0002-4731-263X))

**LÍNEA DE INVESTIGACIÓN:**

Sistemas y Planes de Mantenimiento

TRUJILLO – PERÚ

2021

## **Dedicatoria**

A mis amados padres que a través de sus enseñanzas forjaron en mí una persona de bien y que a pesar de los problemas que haya siempre salir adelante con mucha fe y fortaleza confiando en nuestro creador.

Así también dedico esta tesis a mis adoradas hijas y esposa quien con su amor incondicional y comprensión, me ayudaron para luchar día a día y con mucho esmero poder alcanzar uno de mis objetivos profesionales.

**Ruben F. Blas Benites**

A mi padre que ha sabido formarme con buenos sentimientos, hábitos y valores lo cual me ha ayudado a seguir adelante en los momentos difíciles

A mi madre que desde el cielo me ilumina para seguirá adelante con mis proyectos.

También dedico a mi hija valentina quién ha sido mi mayor motivación para nunca rendirme en los estudios y poder llegar a ser un ejemplo para ella.

**Enestor Diaz Mayta**

## **Agradecimiento**

En primer lugar dar gracias a Dios quien a pesar de las circunstancias que hoy en día atraviesa el mundo, él siempre está con su mano protectora cuidando y protegiendo de todo peligro.

Agradecer también a cada uno de nuestros familiares que han sido de vital importancia para llegar a este anhelado sueño de nuestras vidas.

Agradecer también a nuestra casa de estudios que ha sido durante estos años como es nuestra prestigiosa Universidad Cesar Vallejo.

También agradecimiento muy especial a nuestros docentes de la Universidad Cesar Vallejo, por todas las enseñanzas que nos brindaron en el transcurrir del tiempo de estudio y en especial al Ing. Panta Carranza Dante Omar y al Ing. Lujan López Jorge Eduardo, quienes han colaborado incansablemente para el desarrollo de esta investigación, agradecemos su comprensión y su infinita paciencia, pero sobre todo la rectitud y su dedicación como docentes.

Agradecemos también a cada uno de nuestros compañeros de esta prestigiosa Universidad que nos han brindado su amistad sincera y sobre todo el valor del compañerismo que más que eso nos consideramos una familia.

## **Los autores**

## Índice de contenidos

I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO .....	4
III.METODOLOGÍA.....	11
3.1 Tipo y Diseño de Investigación.....	11
3.2 Variables y operacionalización .....	11
3.3 Población (criterios de selección), muestra, muestreo y unidad de análisis .....	12
3.4 Técnicas de Recolección de Datos.....	13
3.5 Procedimientos.....	13
3.6 Método de análisis de datos .....	15
3.7 Aspectos éticos .....	15
IV. RESULTADOS.....	17
V. DISCUSIÓN.....	58
VI.CONCLUSIONES .....	62
VII.RECOMENDACIONES.....	63
ANEXOS .....	72

## Índice de tablas

Tabla 1: Población de la empresa MEKATSU .....	12
Tabla 2: Diagrama de flujo a través de la norma Asme .....	14
Tabla 3: Resumen del informe técnico de mayo a julio del 2021 .....	17
Tabla 4: Comparación de modelos.....	32
Tabla 5: Cuadro comparativo del cargador frontal.....	34
Tabla 6: Cuadro comparativo de la retroexcavadora.....	36
Tabla 7: Cuadro comparativo del tractor de oruga.....	37
Tabla 8: Cuadro comparativo de la excavadora.....	39
Tabla 9: Prueba de normalidad - Disponibilidad.....	41
Tabla 10: Estadísticas de muestras emparejadas .....	42
Tabla 11: Correlaciones de muestras emparejadas .....	42
Tabla 12: Prueba de muestras emparejadas.....	42
Tabla 13: Prueba de normalidad - Confiabilidad .....	43
Tabla 14: Estadísticas de muestras emparejadas .....	44
Tabla 15: Correlaciones de muestras emparejadas .....	44
Tabla 16: Prueba de muestras emparejadas.....	44
Tabla 17: Prueba de normalidad - Disponibilidad .....	45
Tabla 18: Estadísticas de muestras emparejadas .....	46
Tabla 19: Correlaciones de muestras emparejadas .....	46
Tabla 20: Prueba de muestras emparejadas.....	46
Tabla 21: Prueba de normalidad - Confiabilidad .....	47
Tabla 22: Estadísticas de muestras emparejadas .....	48
Tabla 23: Correlaciones de muestras emparejadas .....	48
Tabla 24: Prueba de muestras emparejadas.....	48
Tabla 25: Prueba de normalidad - Disponibilidad .....	49
Tabla 26: Estadísticas de muestras emparejadas .....	49
Tabla 27: Correlaciones de muestras emparejadas .....	50
Tabla 28: Prueba de muestras emparejadas.....	50
Tabla 29: Prueba de normalidad - Confiabilidad .....	50
Tabla 30: Estadísticas de muestras emparejadas .....	51
Tabla 31: Correlaciones de muestras emparejadas .....	51
Tabla 32: Prueba de muestras emparejadas.....	52
Tabla 33: Prueba de normalidad - Disponibilidad .....	52

Tabla 34: Estadísticas de muestras emparejadas .....	53
Tabla 35: Correlaciones de muestras emparejadas .....	53
Tabla 36: Prueba de muestras emparejadas.....	53
Tabla 37: Prueba de normalidad - Confiabilidad .....	54
Tabla 38: Contrastación de hipótesis específica 1.....	55
Tabla 39: Estadística de prueba Z- Incremento de conocimiento .....	56
Tabla 40: Resumen de hipótesis.....	56
Tabla 41: Matriz de consistencia.....	72
Tabla 42: Matriz de operacionalización de variable.....	75

## Índice de figuras

Figura 1: Fases de la metodología KDD.....	9
Figura 2: Disponibilidad inicial del cargador frontal.....	21
Figura 3: Disponibilidad inicial de la retroexcavadora .....	22
Figura 4: Disponibilidad inicial del tractor de oruga .....	23
Figura 5: Disponibilidad inicial de la excavadora .....	24
Figura 6: Confiabilidad inicial del cargador frontal .....	25
Figura 7: Confiabilidad inicial de la retroexcavadora .....	26
Figura 8: Confiabilidad inicial del tractor oruga.....	27
Figura 9: Confiabilidad inicial de la excavadora .....	28
Figura 10: Modelado de la predicción de fallas mecánicas (1ra parte) .....	29
Figura 11: Modelado de la predicción de fallas mecánicas (2a parte).....	29
Figura 12: Modelado de la predicción de fallas mecánicas (3ra parte) .....	29
Figura 13: Funcionamiento del modelo propuesto.....	29
Figura 14: Algoritmo-Árbol de decisión c5.0 .....	30
Figura 15: Algoritmo-Redes neuronales .....	30
Figura 16: Algoritmo-SVM.....	31
Figura 17: Algoritmo-Redes bayesianas.....	31
Figura 18: Algoritmo-Vecinos más cercanos .....	32
Figura 19: datos nuevos de cargador frontal .....	33
Figura 20: Modelo de predicción SVM .....	33
Figura 21: Datos predecidos de SVM .....	34
Figura 22: Comparación de disponibilidad del cargador frontal.....	35
Figura 23: Comparación de la confiabilidad del cargador frontal .....	35
Figura 24: Comparación de la disponibilidad de la retroexcavadora .....	36
Figura 25: Comparación de la confiabilidad de la retroexcavadora .....	37
Figura 26: Comparación de la disponibilidad del tractor de oruga .....	38
Figura 27: Comparación de la confiabilidad del tractor de oruga .....	38
Figura 28: Comparación de la disponibilidad de la excavadora .....	39
Figura 29: Comparación de la confiabilidad de la excavadora .....	40
Figura 30: Histograma de disponibilidad-cargador frontal .....	41
Figura 31: Histograma de confiabilidad-cargador frontal .....	43
Figura 32: Histograma de disponibilidad-retroexcavadora .....	45
Figura 33: Histograma de confiabilidad-retroexcavadora .....	47

Figura 34: Histograma de disponibilidad-tractor oruga.....	49
Figura 35: Histograma de confiabilidad-tractor oruga.....	51
Figura 36: Histograma de disponibilidad-excavadora.....	53
Figura 37: Histograma de confiabilidad-excavadora.....	55
Figura 38: Algoritmo-Árbol de decisión c5.0 .....	106
Figura 39: Algoritmo-Redes neuronales .....	107
Figura 40: Algoritmo-SVM.....	107
Figura 41: Algoritmo-Redes bayesianas.....	108
Figura 42: Algoritmo-Vecinos más cercanos .....	108
Figura 43: Registro y resumen de la carga frontal de la empresa MEKATSU S.R.L ..	109
Figura 44: Reparación de motor .....	110
Figura 45: Reparación de mangueras.....	110
Figura 46: Reparación de mangueras (Parte 2) .....	111
Figura 47: Pruebas correctivas .....	111
Figura 48: Pruebas correctivas (Parte 2).....	112
Figura 49: Pruebas por parte del personal de mantenimiento .....	112
Figura 50: Retroexcavadora .....	112
Figura 51: Esquema lógico del modelo.....	1123



## Resumen

La presente investigación tuvo por objetivo general, evaluar la influencia del Machine Learning en la gestión de mantenimiento de maquinaria pesada en la Empresa Mekatsu Equipos S.R.L. Se realizó una investigación de tipo aplicada, de diseño pre experimental, con un enfoque cuantitativo así mismo la población y la muestra del estudio, estuvo constituida por 4 maquinarias pesadas las cuales fueron el cargador frontal, retroexcavadora, tractor oruga y excavadora. Se aplicaron 5 modelos de Machine Learning entre ellas el SVM, Arboles de decisión, vecinos más cercanos, redes bayesianas y redes neuronales. La información recopilada, se procesó haciendo uso del programa Excel, obteniendo como resultados un incremento en el cargador frontal de 24.95% en la disponibilidad y 36,7% en la confiabilidad, con relación a la retroexcavadora se obtuvo un incremento del 25.48% en la disponibilidad y 35,24% en la confiabilidad, también se pudo apreciar con respecto al tractor oruga un incremento del 22.75% en la disponibilidad y 34.79% en la confiabilidad, con relación a la excavadora se obtuvo un incremento de 27.42% en la disponibilidad y 42.46% en la 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, generar grandes beneficios a la empresa y así como puede ser aplicado a otros tipos de empresas similares.

**Palabras clave:** Machine Learning, Gestión de Mantenimiento, Maquinaria pesada

## **Abstract**

The general objective of this research was to evaluate the influence of Machine Learning in the maintenance management of heavy machinery in the company Mekatsu Equipos SRL. An applied research was carried out, with a pre-experimental design, with a quantitative approach and the population and the sample of the study consisted of 4 heavy machinery which were the front loader, backhoe loader, crawler tractor and excavator. Five machine learning models were applied, including SVM, decision trees, nearest neighbors, Bayesian networks and neural networks. The information collected was processed using the Excel program, obtaining as results an increase of 24.95% in availability and 36.7% in reliability for the front loader, an increase of 25.48% in availability and 35.24% in reliability for the backhoe loader, an increase of 22.75% in availability and 34.79% in reliability for the crawler tractor, and an increase of 27.42% in availability and 42.46% in reliability for the excavator. 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 to the company and can be applied to other similar types of companies.

**Keywords:** Mobile Application, Knowledge, Motivation, Motivation, Satisfaction.

## I. INTRODUCCIÓN

En la actualidad, existen diversas entidades competidoras en el sector construcción buscan llevar una adecuada organización de recursos para perfeccionar la gestión de maquinarias pesadas. Por lo tanto, este tipo de máquina todavía juega un rol muy importante dentro de la sociedad moderna, puesto que reduce el tiempo y costo; antes de la integración de estas máquinas las operaciones en el sector construcción eran muy complicadas (Heaven32, 2019).

Por otra parte, uno de los problemas de las empresas de maquinaria pesada, son la falta de mantenimiento, este inconveniente se origina al no tomar acciones preventivas para el buen funcionamiento de la misma; existiendo en la mayoría una ausencia de programas de prevención que cumplan con los criterios de optimización (Guevara, Valera y Gómez Campos, 2016). En estos casos, cuando se evidencian problemas de disponibilidad y confiabilidad de equipos, puede llegar a formar marcas en la productividad y economía empresarial; además, son la principal causante de máquinas inoperativas (Tarrillo, 2020).

De acuerdo a Medina (2017) en un estudio realizado identificó la importancia que tiene la detección temprana de fallas, ya que esto se da mayormente en el sector construcción; al momento de generar disponibilidad y confiabilidad en sus maquinarias, ya que las fallas son un estado no deseado que hace que el elemento estructural no ejecute una función para la cual existe; es decir, es todo lo que detiene la operación de una máquina, buscando que en cualquier rareza se excluya completamente su causa.

En el Perú, la contraloría ha sido la encargada de advertir los riesgos de inoperatividad, debido a fallas mecánicas, en ese contexto, Perú21 (2020) menciona que en la ciudad de Moquegua se realizó una visita de inspección a las maquinarias pesadas, donde identificaron mantenimientos insuficientes. Asimismo, se constató que de las 39 máquinas y vehículos pesados, 19 estaban inactivos, entre ellos un camión, dos cargadores frontales, un clasificador de motor, 10 compresores, dos tractores de retroceso, un tractor de oruga y dos volquetes.

En el contexto local, la empresa MEKATSU EQUIPOS SRL, se encuentra ubicada en la Av. Sayacmarca Mz. 10 Lt. 16, Huanchaco, Trujillo., se dedica a

los servicios de mantenimiento preventivo, correctivo, predictivo y reparaciones en general. Para los servicios de reparación y mantenimiento de componentes, la empresa cuenta con instrumentos de medición, con personal técnico capacitado y un ambiente oleo hidráulico con banco de pruebas, las cuales garantizan calidad y precisión. En relación con la problemática, se ha podido evidenciar una serie de falencias, tales como: Desgaste prematuro de componentes internos de los sistemas, ejes de los engranajes dañados, desgaste de engranajes de transmisión, motores eléctricos dañados y exceso de trabajos correctivos, conllevando que la empresa no pueda suplir sus servicios de manera correcta; es decir que, a falta de herramientas tecnológicas, las actividades se retrasan, lo cual conlleva a generar sobrecostos y dar mala experiencia al cliente.

Es importante el mantenimiento oportuno, haciendo uso del ML la cual mediante el, se obtiene la información suficiente para predecir una falla, es por esto que en esta investigación se centra en ver en qué medida la implementación de la tecnología Machine Learning mejora la eficiencia de la gestión de mantenimiento de maquinaria pesada.

En base a lo detallado se formula la siguiente problemática: ¿En qué medida influye el Machine Learning en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L.? Y sus problemas específicos fueron: ¿Cómo es la gestión actual en la EMPRESA MEKATSU EQUIPOS S.R.L.?. ¿La propuesta de la implementación del Machine Learning ayudará a medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L.?. ¿Cómo se encuentra la gestión del mantenimiento con la implementación del Machine Learning en comparación con la situación anterior? La hipótesis de investigación fue la siguiente: El Machine Learning influye positivamente en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L. Además, Las hipótesis específicas fueron las siguientes: La gestión actual en la EMPRESA MEKATSU EQUIPOS S.R.L. se encuentra en pésimas condiciones. La propuesta de la implementación del Machine Learning ayuda a medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L. La gestión del mantenimiento con la implementación del Machine Learning mejora en comparación con la situación anterior.

Es así que la justificación de este proyecto estuvo fundamentada en el impacto teórico, ya que se logrará aumentar los conocimientos sobre nuevas tecnologías de información como Machine Learning en las empresas que utilizan maquinarias pesadas y la utilización KDD como metodología para la preparación de los datos que existen en el entorno de trabajo, cuyos resultados explicaran con gran relevancia la aplicación de Machine Learning para futuras investigaciones. Además, utilizar estos conocimientos para tener buena gestión de mantenimiento genera un impulso de confianza entre la empresa y el cliente. En la relevancia social, la investigación se justifica en la medida que pretende brindar una forma de escatimar recursos al momento de ejecutar los diagnósticos tempranos de fallas por parte del personal de mantenimiento. Esta investigación beneficiara a la empresa en la realización del recurso de gestión de mantenimiento, donde ellos puedan tener una mayor disponibilidad y confiabilidad con las obras y clientes. Asimismo, es fundamental ofrecer un apoyo y conseguir resultados más exactos que mejoren la gestión de mantenimiento generando así un apoyo económico favorable para los consultantes, además de constituirse como un beneficio laboral, social y tecnológico. Mientras tanto, en implicaciones prácticas, la implementación de Machine Learning ayudará a la sistematización de los reportes de fallas las cuales eran diagnosticadas fuera de tiempo. Para las cuales se usará un servicio de análisis de datos.

Como objetivo General se tuvo: Evaluar la influencia del Machine Learning en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L. Asimismo, los objetivos específicos fueron los siguientes: Determinar la gestión de mantenimiento actual en la EMPRESA MEKATSU EQUIPOS S.R.L. Elaborar la propuesta de la implementación del Machine Learning para medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L. Determinar la gestión del mantenimiento con la implementación del Machine Learning para comparar la situación anterior en la EMPRESA MEKATSU EQUIPOS S.R.L.

## II. MARCO TEÓRICO

Una vez establecida la realidad problemática se procedió a delimitar los antecedentes que sustentan el estudio, por tanto, se realizaron los hallazgos a nivel nacional e internacional:

Según Barroso (2018) efectuó un modelo predictivo basado en la tecnología Machine Learning en el área de mantenimiento de equipos mineros de la empresa BHP Minerals América. La metodología de desarrollo del proyecto fue el CRIPS-DM y el algoritmo utilizado fue el Gradient Boosting Tress, a través de ello se almacenaron los datos de órdenes, que posteriormente fueron clasificados en riesgos y no riesgosos. Para el recojo de información se tomó como población a todas las máquinas apropiable al área de mantenimiento de la compañía BHP Minerals Americas, los instrumentos aplicados fueron la entrevista y el cuestionario. En relación con los hallazgos reportados, el modelo GTB resulta con una precisión de 82,2 %. El estudio concluyó que la integración de esta herramienta predictiva es confiable, puesto que ayuda a automatizar el análisis de las órdenes de trabajo, permitiendo así a los planificadores orientar su trabajo sólo en OTs riesgosas y así mejorar su tiempo.

Por su parte, Castro y García (2020) elaboraron una automatización de información de fallas en equipos en una instalación minera del Perú. Para el desarrollo del estudio, se utilizó la metodología aplicada, descriptiva y longitudinal. Asimismo, se tomó como muestra y unidad de análisis a la máquina PC4000-6., lo cual se procedió a elaborar una data de entrenamiento con el registro de la falla de flota. A través del Machine Learning se pudo obtener un 85% de precisión respecto a las fallas presentadas por la máquina. En conclusión, la metodología Machine Learning ayuda a reducir el tiempo de clasificación de datos de fallas en equipos, así como también los tiempos muertos del personal.

Asimismo, Moscoso y Yarin (2019) usaron el Machine Learning con Matlab, para la mejora del mantenimiento predictivo, para que resulte más eficiente los camiones de la empresa la Compañía Minera Antapaccay – Cusco. El diseño fue pre-experimental, tomando, así como punto de análisis a los problemas, posteriormente los indicadores de gestión de mantenimiento fueron calculados KPI's. Finalmente, el estudio concluyó que el Machine Learning cumple un rol muy fundamental en la empresa, dado que en los camiones mineros se redujo el

tiempo de la clasificación de fallos, aumentando la mejora de en el desarrollo del mantenimiento de la flota en las máquinas.

De igual manera, Herrera (2019) estudiaron el impacto de las herramientas tecnológicas en la mejora de disponibilidad mecánica de equipos en la entidad CEMICON SA. Método de tipo descriptivo, de diseño experimental y corte longitudinal. Los resultados hallados indicaron que la disponibilidad mecánica pasó de 81.97% a 90.07%. En tal sentido, el estudio concluyó que las herramientas implementadas ayudan considerablemente la capacidad de programación del mantenimiento predictivo.

Clemente y Martinez (2020) realizaron un plan de mantenimiento preventivo para el aumento de confiabilidad y disponibilidad de maquinarias en la Empresa Grupo Señor de Pollamucay. Para ello tuvieron que conocer la disponibilidad y confiabilidad actual. La metodología fue aplicada. Asimismo, se utilizaron herramientas como el cuestionario y entrevista, como muestra se tomaron a 4 maquinarias pesadas críticas. Los resultados mostraron que la actual situación tuvo una confiabilidad inicial del 84%, y una disponibilidad de menor del 90, llegando así a concluir que tanto la confiabilidad y disponibilidad se encuentran en un rango bajo.

Así también, Del Pozo (2018) utilizaron tecnologías modernas para dar solución a inconvenientes mecánicos, y corregir la gestión del personal de mantenimiento en una empresa industrial de Valladolid. Las técnicas utilizadas fueron la regresión logística, redes neuronales y las máquinas de vectores soportes, fueron muy claves para la creación de un sistema predictivo. Los resultados fueron muy buenos ya que las precisiones de acierto fueron altísimas, en muchos casos del 100%, y los tiempos de computación fueron realmente bajos, con lo que su integración a nivel empresarial fue mucho más sencilla. Concluyó que la integración del software permitió mejorar la competitividad de la empresa.

Luna y Toledo (2019) implementaron un plan de mantenimiento preventivo para incrementar la confiabilidad en las maquinarias de la empresa OSIMIN S.R.L. El método fue aplicativo, de diseño pre-experimental, tomando como muestra a todas las maquinarias pesadas, el instrumento fue la encuesta. Se obtuvo como resultado que la implementación de un plan de mantenimiento preventivo incrementó la confiabilidad de las maquinarias pesadas con una confiabilidad general de 87% y disponibilidad general de 94%, en comparación de la

confiabilidad anterior de 78% y disponibilidad anterior de 89%. Luego se evaluó el diagnóstico el cual determinó que la confiabilidad inicial de las maquinarias pesadas en la empresa fue de 78%, el cual fue bajo y, por ende, no era confiable. Según De Los Ríos (2019) elaboró un sistema de mantenimiento predictivo de un motor eléctrico a través del uso de técnicas de inteligencia artificial en los equipos industriales del sistema SCADA - Ecuador. La metodología se basó en el enfoque cuantitativo y de diseño experimental; asimismo, la técnica empleada fue redes neuronales. Los resultados mostraron que el sistema de análisis tiene una probabilidad del 30% de poder tener un fallo, es decir que el 70% es capaz de soportar gran cantidad de información para poder integrar más elementos, logrando así poder predecir y hacer un análisis en tiempo real. Finalmente, se concluyó que el sistema estuvo apto para la predicción de fallas mecánicas llegando a mejorar la competitividad y experiencia del cliente.

Mientras tanto, Brasa (2019) desarrolló un modelo predictivo de mantenimiento para evitar futuras fallas mecánicas en equipos industriales de España. La metodología utilizada es el Machine Learning con los algoritmos Random Forest y XGBoost, tanto para la regresión como para la clasificación. Los datos con los que se trabajó constan en un principio de 28 variables. En conclusión, se pudo determinar que el sistema tiene un funcionamiento prometedor de 0.95% de precisión. Por tanto, el sistema ayudó a mejorar la gestión y mantenimiento del personal.

En paralelo, Inafuku (2020) desarrolló un sistema de robot móvil que hace diagnóstico en conjunto con inteligencia artificial en una planta industrial peruana, que permitan identificar fallas en equipo críticos como bombas y motores. La metodología fue aplicada, seguido de diseño experimental. Se utilizó la técnica de redes neuronales convolucionales. Finalmente, se concluyó que el modelo implementado tuvo un 100% de efectividad durante el entrenamiento y un 90% de efectividad durante la validación, lo cual quiere decir que cumple con todas las disposiciones aptas para el diagnóstico adecuado y preciso.

Según Cernuda Gonzáles (2019) elaboró una investigación sobre la detección de fallos y rodamientos haciendo uso del Machine Learning y Deep Learning en equipos de vibraciones en una empresa española. El método fue de tipo aplicada, y diseño experimental. Asimismo, se utilizaron los algoritmos de máquina de vectores, clasificadores Random Forest, KNN, MLP y XGBoost.



Llegando a la conclusión de que la detección de fallos en los rodamientos alcanzó una precisión del 100%, mientras que en la diagnosis no se logró eficientemente.

Finalmente, Luján (2020) aplicó el Machine Learning para la mejora de la productividad de la empresa Emcapsac, Lurín, en términos de eficiencia, medida en el uso de horas máquinas, y eficacia. La metodología empleada fue aplicada, de diseño experimental, asimismo, se tomó como población a la producción total de kg de cartón obtenida de la corrugadora. Los resultados obtenidos, muestran la existencia de un incremento del 22%, lo cual quiere decir que se realizó de manera correcta la implementación del mantenimiento preventivo.

Posteriormente, se procedió a definir las teorías relacionadas y enfoques conceptuales, que sustentan la investigación. El aprendizaje automático (ML) desprende como un subconjunto de la IA, que construye una guía matemática basado en datos de muestra, conocidos como "datos de entrenamiento", para hacer pronósticos sin estar programados necesariamente al momento de ejecutar la tarea (Zhang, 2020).

Por su parte, Yao y Liu (2013), lo definen como un subcampo muy activo de la inteligencia artificial relacionado con el desarrollo de modelos de aprendizaje por computadora, donde se centra en cómo una máquina puede engañar a un ser humano haciéndole creer que está frente a un individuo en lugar de una computadora. Además, el aprendizaje automático, brota de la inteligencia artificial como soporte al entrenamiento de modelos que respondan a la predicción de datos en diversos ámbitos de la ciencia actual (Baviera, 2017). Su estructura solicita el análisis de una variedad de algoritmos que faciliten la evaluación de un grupo de datos con el propósito de determinar los inconvenientes (Vite Cevallos, Carbajal Romero y Barrezueta Unda, 2020).

Las herramientas del Machine Learning fueron las siguientes: Weka, es una herramienta de visualización de distribución gratuita bajo la licencia GNU que resiste grandes labores estándar de la MD en específico tareas de proceso de datos (Dávila Hernández y Sanchez Corales, 2012). Por su parte Kotu Y Deshpande (2019), señalan que RapidMiner es una herramienta de software de código abierto y gratuito para la minería de datos y texto. Además, es compatible con los sistemas Macintosh, Linux y Unix. SPSS modeler, es una herramienta que se usa para la construcción de modelos predictivos y análisis estadístico de

manera sencilla (Alarcón y Mora, 2020). Software r, es un entorno de programación para el análisis estadísticos y gráficos, su sintaxis básica es sencilla e intuitiva, resultando en un aprendizaje rápido y cómodo (Avello Martínez y Seisdedo Losa, 2017). Finalmente, Knime, es una herramienta que orienta el proceso de descubrimiento del conocimiento de los datos mediante el diseño de flujo de trabajo permitiendo a diversos usuarios hacer uso del conocimiento (Izquierdo et al., 2015).

Asimismo, las organizaciones contienen grandes cantidades de datos de manera digital, entonces obtener patrones a raíz de esos datos se convierte en algo complicado para el individuo. Es así que, los algoritmos de Machine Learning toman gran relevancia, dado que permiten obtener los patrones de manera automática (Melgar Sasieta, 2019). El ML, hace uso de diversos algoritmos proyectados que recogen y estudian datos de entrada para la predicción de los valores de salida dentro de un rango no aceptable. Por tanto, se definieron los siguientes algoritmos: El algoritmo-Árbol de decisión, es una estructura de árbol parecido a un flujograma, donde un nodo interno encarna un atributo, mientras que la rama representa una regla de decisión, y los nodos de hojas son el resultado, por ende, esta representación gráfica, ayuda a la toma de decisiones (Sulla Torres, Gómez Campos y Cossio Bolaños, 2018). Mientras que regresión lineal ayuda pronosticar la conducta de una variable a partir de otra; por tanto, este algoritmo se utiliza para identificar las relaciones potencialmente causales o bien, cuando no hay dudas sobre su relación causal, para presagiar uno y otro (Dagnino, 2014). Redes neuronales, representa una familia de técnicas de procesamiento de información, inspirado en el procesamiento del sistema nervioso biológico del ser humano; siendo idóneos para el estudio de signos y la modelación de sistemas (Rivas y Mazón, 2017). Máquina de vectores, es una técnica que permite resolver problemas de clasificación, cuya finalidad es minimizar los riesgos estructurales, generando un límite de decisión en torno a la manipulación de datos (Betancourt, 2005). Los Bayesianos, son herramientas estadísticas adecuadas para las decisiones, cuando se encuentren en un escenario de incertidumbre, tomando en consideración el conocimiento difuso que tenemos sobre las variables incluidas en el problema de decisión (Ruiz-Ruano, López-Puga y Delgado-Morán, 2019).

En paralelo, se procedió a definir la metodología a utilizar: La metodología KDD. Gervilla-García et al. (2009), señalan que es un proceso que constituye una serie de fases, y a su vez es una de las más características, ya que se destinan diversas técnicas de modelado para descubrir patrones y asociaciones en los datos.




Figura 1: Fases de la metodología KDD

La metodología consta de 5 etapas: La primera etapa se procede a la selección de los datos sobre los que se trabajará. En la segunda etapa se realiza el Pre-procesamiento de los datos, para lo cual se efectúa un tratamiento de aquellos datos incorrectos y retirados. La tercera etapa se efectúa la transformación de datos, así como también la disminución de la dimensionalidad. En la penúltima etapa se procederá a la obtención de patrones de interés de acuerdo a las tareas ejecutadas. Finalmente, se efectúa la interpretación y evaluación del nuevo conocimiento obtenido en el dominio de aplicación.

De acuerdo a las teorías relacionadas de la segunda variable se encuentra gestión del mantenimiento. Mercado Verena (2016) indica que este término forma parte importante en lo que respecta la conservación de los activos empresariales, y de eficiencia en sus operaciones. A la vez Prando (2001) señala que la gestión de mantenimiento permite conseguir el rendimiento máximo requerido de los equipos y activos de una entidad logrando así llegar a las metas trazadas; con la máxima calidad, seguridad y a un mínimo costo.

En ese contexto, el mantenimiento es un conjunto de técnicas propuestas para mantener los equipos y herramientas en buen estado durante un tiempo largo, pudiendo así desarrollar la función esperada (Pérez Alegría y Supo Rojas, 2018). Por tanto, el mantenimiento, tiene como objetivo principal garantizar que las máquinas estén en perfectas condiciones para el óptimo funcionamiento de las mismas mediante programas de prevención y predicción de anomalías, reparación de componentes y mejoramiento permanente de sus condiciones operativas de cero defectos. Se determina, que los mantenimientos se clasifican

en tres tipos principales: Mantenimiento preventivo, predictivo y correctivo (Pérez Rondón, 2021).

Según Salgado et al. (2018), el mantenimiento preventivo representa las acciones previstas que tienen tiempos de realización ya establecidos que buscan aumentar la confiabilidad de las maquinarias. Para así evitar paradas inesperadas de los equipos, incluyen las tareas de limpieza, lubricación, inspección y ajuste (Cubas, 2018). Por otra parte, Herrera-Sánchez et al. (2020), mencionan que el mantenimiento predictivo se desarrolla con circuitos lógicos programables (PLC) para el cálculo y análisis de datos a través de sensores que ayuden a prever los grandes fallos de las máquinas productivas.

Además, los indicadores de Gestión de Mantenimiento son utilizados con el mismo valor, siendo estos eficaces al momento de medir el desempeño de los activos organizacionales y mostrando el esfuerzo que realizan para poder controlarlos y así incrementar su eficiencia (León, 2015). Según Fernández et al. (2018) mencionaron otros indicadores de mantenimiento:

a) Confiabilidad: Está asociada con la confianza que se le proporciona a una máquina, sistema o parte de ella. Por ende, para que se pueda ejecutar determinadas funciones, se requiere un tiempo determinado de evaluación pre-establecimiento, siempre con las condiciones adecuadas y estándares para la organización.

b) Disponibilidad: Es la capacidad de algún equipo o máquina para ser empleado cuando se necesite. La disponibilidad es la medida del rendimiento de un mantenimiento realizado, se calcula mediante la relación entre el tiempo de funcionamiento de la máquina y la diferencia entre estas medidas totales y el tiempo de ingeniería necesario para reparar la máquina. (Vega Acuña, 2017).

### III. METODOLOGÍA

#### 3.1 Tipo y Diseño de Investigación

El presente estudio fue de tipo aplicada, porque se pretendió dar solución a la problemática identificada en la investigación. Para Cabezas Mejía et al. (2018), este tipo de investigación interviene de manera inmediata en la solución de problemas prácticos; es decir que su objetivo principal es seleccionar y generar datos para profundizar nuestra comprensión de los problemas del mundo real. Asimismo, fue de alcance explicativo, porque van más allá de una descripción de fenómenos, sino que están orientados a dar respuestas a las causas de los eventos en general, en este estudio se explicará el porqué de las fallas en las maquinarias pesadas, y en qué condiciones se dio, logrando así solucionar este problema mediante una predicción temprana.

Por otra parte, el diseño de investigación fue pre-experimental, puesto que se analizó una variable única (Gestión de mantenimiento) y prácticamente no existió ningún tipo de control y ninguna manipulación alguna de la variable. Hernández, Fernández y Baptista (2014), refieren que este diseño busca la compilación de datos, a través de un solo grupo cuyo grado de control es mínimo. Generalmente es útil como primer acercamiento al problema de investigación en la realidad.

#### 3.2 Variables y operacionalización

**Variable independiente:** Machine Learning.

**Variable dependiente:** Gestión de mantenimiento.

**Definición conceptual:** la gestión de mantenimiento permite conseguir el rendimiento máximo requerido de los equipos y activos de una entidad logrando así llegar a las metas trazadas; con la máxima calidad, seguridad y a un mínimo costo. Asimismo, los mantenimientos se clasifican en tres tipos principales: Mantenimiento preventivo, predictivo y correctivo (Prando, 2001; Pérez Rondón, 2021).

**Definición operacional:** Se emplearon una ficha de registro Excel, y fichas de observación de métricas de precisión, que permitieron conocer la mejora en la gestión de mantenimiento de maquinarias pesadas de la empresa MEKATSU EQUIPOS S.R.L.

**Indicadores:** La dimensión de disponibilidad su indicador fue la siguiente fórmula  $D = \frac{T_o}{T_o+T_p}$ . De igual manera, para la dimensión confiabilidad su indicador

fue la siguiente fórmula  $(t) = e^{-\lambda t}$

**Escala de medición:** Razón

La matriz de operacionalización de variables se puede observar en la sección de anexos (N° 2)

### 3.3 Población (criterios de selección), muestra, muestreo y unidad de análisis

La población descrita en el presente estudio, estuvo compuesta por todas las maquinarias que posee la empresa MEKATSU EQUIPOS S.R.L. En ese sentido, Hernández, Fernández y Baptista (2014), señala que es la totalidad de elementos o individuos con rasgos similares, puestos como unidad de muestreo. En la siguiente tabla se detalla, la población definida:

**Tabla 1:** Población de la empresa MEKATSU EQUIPOS S.R.L.

		<b>REGISTRO Y CODIFICACIÓN DE LA MAQUINARIA</b>		
ITEM	DESCRIPCIÓN DE LA MAQUINARIA	NUMERO DE SERIE	CÓDIGO DEL EQUIPO	HOROMETRO
1	Cargador frontal Caterpillar 950H	M1G03575	MCF-01	7520
2	Retroexcavadora Caterpillar 420F	LTG00564	REC-03	2690
3	Motoniveladora Caterpillar 140 K	JPA00678	MNC-04	2740
4	Tractor de Orugas Caterpillar D6T-XL	GCT00940	TOC-05	5029

Fuente: Elaboración propia

Entre los criterios de selección se consideraron lo siguiente:

Criterios de inclusión:

- Todas las maquinarias propias de la empresa.

Criterios de exclusión:

- Todas las maquinarias que son alquiladas.

En congruencia, la muestra fue igual a la población, dado que el número es menor, por ende, se vio conveniente trabajar con una unidad de cada equipo.

Otzen y Manterola (2017), definen una muestra como parte de una población cuya representatividad permite extrapolar, por tanto, más allá de los resultados observados en ella, a una población accesible.

Por otra parte, el muestreo empleado fue no probabilístico, por conveniencia. Hernández y Carpio (2019), indagan que los muestreos no probabilísticos seleccionan a los individuos a investigación de acuerdo a los criterios de

inclusión. Mientras tanto, según su clasificación por conveniencia, se da, ya que cumplen con las características de interés, asimismo, la de seleccionar a los individuos de acuerdo al alcance y acceso.

De igual manera, se tuvo como unidad de análisis a 1 maquinaria existente dentro de la empresa MEKATSU EQUIPOS SRL.

### **3.4 Técnicas de Recolección de Datos**

Para la recolección de información, se tuvo que emplear la técnica de análisis documental, y observación. Dulzaides y Molina (2004), define al análisis documental como una forma de indagar e investigar, así como un conjunto de actividades intelectuales que buscan describir y representar documentos de una manera única y sistemática para ofrecer la posibilidad de su recuperación. Por otra parte, Castellanos (2017), refiere que la observación es una técnica que se basa en estudio de individuos, fenómenos, hechos, casos, situaciones, acciones, etc., con la finalidad de obtener información precisa y requerida para una investigación.
















En paralelo, el instrumento utilizado fue una ficha de registro, ficha de observación. Según Sánchez, Fernández y Díaz (2014) menciona que la ficha de observación ayuda a obtener registros de los procesos, frente al Pre-Test y Post-Test, luego de ello se ejecutan comparaciones siempre y cuando sea necesario la verificación del cumplimiento propuesto en la respectiva investigación.

### **3.5 Procedimientos**

Para desarrollar el estudio, se tuvieron que dar una serie de pasos. Lo primero que se efectuó fue una reunión con el director de la empresa, posteriormente se pasó a realizar las visitas necesarias sobre la identificación de la problemática que los aqueja respecto con sus maquinarias pesadas. En ese sentido, la tesis tuvo por finalidad, utilizar la metodología Machine Learning para predecir las fallas mecánicas de las maquinarias pesadas; para ello, se recopiló información a través de fuentes externas, tales como revistas, libros, tesis, tanto a nivel nacional como internacional. Posteriormente, se estableció la metodología científica a seguir, dentro de ello se determinaron las dimensiones e indicadores, para este caso se utilizaron las métricas de precisión. De igual manera, para la recolección de datos, se tomó como unidad de análisis a 1 maquinaria pesada pertenecientes de la empresa MEKATSU EQUIPOS S.R.L.

Después de realizar lo anterior, la ficha de observación pasó por revisión de expertos. Una vez obtenida la validación del instrumento, se pasó a su aplicación, estos permitieron la obtención de información clara y directa, mediante el registro de la precisión de los algoritmos utilizados en este estudio. Luego de la aplicación se recolectaron los datos para ser procesados en las herramientas estadísticas de SPSS Modeler. Asimismo, también se ejecutaron los análisis descriptivos e inferenciales mediante tablas y figuras. Y finalmente se desarrollaron las conclusiones y recomendaciones.

**Tabla 2:** Diagrama de flujo a través de la norma Asme

N°	ACTIVIDADES					DESCRIPCIÓN
						
	Operación	Desplazamiento	Inspección	Espera	Almacenamiento	
1						Inicialmente, se realizó una reunión con el director de la empresa.
2						Se esperó la autorización del Gerente.
3						Se recibió la autorización del Gerente general
4	 					Posteriormente se pasó a realizar las visitas necesarias para la identificación de la problemática
5						Luego se procedió a elaborar el título de investigación
6	 					Después se recopiló información a través de fuentes externas, tales como revistas, libros, tesis, tanto a nivel nacional como internacional
17						Se estableció la metodología científica a seguir, dentro de ello se determinaron las dimensiones e indicadores
8						Se tomaron como unidad de análisis a todas las maquinarias pertenecientes de la empresa MEKATSU EQUIPOS S.R.L. y al personal de mantenimiento.



9	○					Se han desarrollado herramientas de recolección de datos, como cuestionarios y hojas de observación.
10	○					Los instrumentos pasaron por revisión de expertos
11				▽		Recepción de la validación de instrumentos
12						Se procedió a obtener datos con las fichas de observación
13	○					Se pasaron a procesar en el programa SPSS Modeler
14	○					Se ejecutaron los análisis descriptivos e inferenciales mediante tablas y figuras.
15	○					Finalmente se desarrollaron las conclusiones y recomendaciones

Fuente: Elaboración propia.

### 3.6 Método de análisis de datos

Para el análisis de datos, se tuvo que basar en la estadística, descriptiva, predictiva e inferencial. Para la data recogida se tuvo que acceder a la ficha de los registros de la maquinaria pesada de cargador frontal que se encuentran en Excel (anexo n°11), a través de ello, se procedió a ejecutar la transformación de la variable fallas mecánicas de método cualitativo a cuantitativo, para después ser utilizada como un análisis predictivo haciendo uso de la herramienta spss modeler. Y sucesivamente demostrar la precisión respecto a las métricas utilizadas, tales como son: Accuracy (exactitud), sensibilidad y especificidad. Como también la disponibilidad y confiabilidad de las maquinarias.

### 3.7 Aspectos éticos

Para conservar la línea ética, se tomó en consideración varios principios jurídicos y éticos al momento de desarrollar el estudio. De acuerdo a la normativa establecida por la empresa MEKATSU EQUIPOS S.R.L., lugar donde fue realizado el estudio, se respetó el código de ética en investigación de la Universidad César Vallejo, en relación del artículo 3° se respetó la integridad y autonomía de los encuestados, así también en el artículo 4° se buscó el bienestar de las mismas y artículo 6° se prioriza la honestidad con la transparencia de la investigación. En ese sentido, todos los resultados

conseguidos no tuvieron manipulación alguna, puesto que se basó en el principio de la veracidad. De igual forma, se obtuvo el consentimiento de aplicación del proyecto por parte del dueño de la empresa. Asimismo, los derechos de autor estuvieron con sus respectivas citas y referencias de acuerdo al criterio ISO 690-2.

#### IV. RESULTADOS

Este capítulo presenta los resultados obtenidos durante la aplicación de las herramientas seleccionadas, en relación con los indicadores “Disponibilidad” y “Confiabilidad”, ejecutándose mediante el procesamiento de datos conseguido de las muestras con el software IBM SPSS Statistics v.25.

**3.1 Objetivo específico 1:** Determinar la gestión de mantenimiento actual en la EMPRESA MEKATSU EQUIPOS S.R.L.

El diagnóstico inicial de gravedad de maquinaria pesada empezó con la recopilación de datos, de todas las fallas de maquinaria pesada, durante un período de 3 meses (Mayo- Julio), teniendo en cuenta los días hábiles de trabajo en cada mes, permite determinar la severidad de la máquina e información sobre el daño, además, estos datos se recolectan a través de informes técnicos de Excel (Anexo n°11), instrumento donde se registraron las fallas ocurridas durante el periodo. En ese sentido, los detalles se pueden apreciar en la tabla n°3

**Tabla 3:** *Resumen del informe técnico de mayo a julio del 2021*

Familia	Me s	Hr. Nomi nal	Horas Deten ción	Horas Operat ivas	Nº Fall as	Hr. Deten ción por fallas	MTB F	MTT R	Dispo nibili dad	Confiabi lidad
Cargador frontal	Se m1- May	140	100	40	5	100	8.00	20.00	28.57	2.08
Cargador frontal	Se m2- May	140	73	67	4	63	16.75	15.75	51.54	15.71
Cargador frontal	Se m3- May	140	24	116	2	24	58.00	12.00	82.86	58.60
Cargador frontal	Se m4- May	180	123	57	6	95	9.50	15.83	37.50	3.83
Cargador frontal	Se m1- Jun	140	100	40	5	100	8.00	20.00	28.57	2.08
Cargador frontal	Se m2- Jun	140	58	82	3	49	27.33	16.33	62.60	32.17

Fuente: Empresa MEKATSU S.R.L.

<b>Cargador frontal</b>	Se m3- Jun	140	60	80	3	60	26.67	20.00	57.14	31.27
<b>Cargador frontal</b>	Se m4- Jun	180	104	76	5	96	15.20	19.20	44.19	13.01
<b>Cargador frontal</b>	Se m1- Jul	140	106	34	5	106	6.80	21.20	24.29	1.05
<b>Cargador frontal</b>	Se m2- Jul	140	50	90	2	40	45.00	20.00	69.23	50.21
<b>Cargador frontal</b>	Se m3- Jul	140	86	54	4	86	13.50	21.50	38.57	10.06
<b>Cargador frontal</b>	Se m4- Jul	180	66	114	3	56	38.00	18.67	67.06	44.23
<b>Retroexcavadora</b>	Se m1- May	140	75	65	4	75	16.25	18.75	46.43	14.84
<b>Retroexcavadora</b>	Se m2- May	140	70	70	3	60	23.33	20.00	53.85	26.49
<b>Retroexcavadora</b>	Se m3- May	140	80	60	3	60	20.00	20.00	50.00	21.22
<b>Retroexcavadora</b>	Se m4- May	180	100	80	4	80	20.00	20.00	50.00	21.22
<b>Retroexcavadora</b>	Se m1- Jun	140	100	40	5	100	8.00	20.00	28.57	2.08
<b>Retroexcavadora</b>	Se m2- Jun	140	80	60	3	60	20.00	20.00	50.00	21.22
<b>Retroexcavadora</b>	Se m3- Jun	140	57	83	3	57	27.67	19.00	59.29	32.61
<b>Retroexcavadora</b>	Se m4- Jun	180	97	83	5	88	16.60	17.60	48.54	15.45
<b>Retroexcavadora</b>	Se m1- Jul	140	82	58	4	106	14.50	26.50	35.37	11.79

<b>Retroexcavadora</b>	Se m2- Jul	140	82	58	4	40	14.50	10.00	59.18	11.79
<b>Retroexcavadora</b>	Se m3- Jul	140	81	59	3	86	19.67	28.67	40.69	20.67
<b>Retroexcavadora</b>	Se m4- Jul	180	96	84	4	56	21.00	14.00	60.00	22.85
<b>Tractor de Oruga</b>	Se m1- May	140	100	40	5	100	8.00	20.00	28.57	2.08
<b>Tractor de Oruga</b>	Se m2- May	140	60	80	3	45	26.67	15.00	64.00	31.27
<b>Tractor de Oruga</b>	Se m3- May	140	60	80	3	60	26.67	20.00	57.14	31.27
<b>Tractor de Oruga</b>	Se m4- May	180	101	79	5	89	15.80	17.80	47.02	14.06
<b>Tractor de Oruga</b>	Se m1- Jun	140	76	64	4	76	16.00	19.00	45.71	14.41
<b>Tractor de Oruga</b>	Se m2- Jun	140	50	90	2	40	45.00	20.00	69.23	50.21
<b>Tractor de Oruga</b>	Se m3- Jun	140	80	60	4	80	15.00	20.00	42.86	12.66
<b>Tractor de Oruga</b>	Se m4- Jun	180	86	94	4	76	23.50	19.00	55.29	26.74
<b>Tractor de Oruga</b>	Se m1- Jul	140	88	52	4	52	13.00	13.00	50.00	9.21
<b>Tractor de Oruga</b>	Se m2- Jul	140	38	102	2	32	51.00	16.00	76.12	54.45
<b>Tractor de Oruga</b>	Se m3- Jul	140	40	100	4	40	25.00	10.00	71.43	28.94
<b>Tractor de Oruga</b>	Se m4- Jul	180	152	28	6	130	4.67	21.67	17.72	0.13

<b>Excavador a</b>	Se m1- May	140	100	40	4	80	10.00	20.00	33.33	4.50
<b>Excavador a</b>	Se m2- May	140	38	102	3	38	34.00	12.67	72.86	40.18
<b>Excavador a</b>	Se m3- May	140	75	65	4	75	16.25	18.75	46.43	14.84
<b>Excavador a</b>	Se m4- May	180	118	62	7	118	8.86	16.86	34.44	3.02
<b>Excavador a</b>	Se m1- Jun	140	75	65	4	75	16.25	18.75	46.43	14.84
<b>Excavador a</b>	Se m2- Jun	140	50	90	2	40	45.00	20.00	69.23	50.21
<b>Excavador a</b>	Se m3- Jun	140	80	60	3	50	20.00	16.67	54.55	21.22
<b>Excavador a</b>	Se m4- Jun	180	130	50	6	120	8.33	20.00	29.41	2.42
<b>Excavador a</b>	Se m1- Jul	140	88	52	4	52	13.00	13.00	50.00	9.21
<b>Excavador a</b>	Se m2- Jul	140	38	102	2	44	51.00	22.00	69.86	54.45
<b>Excavador a</b>	Se m3- Jul	140	40	100	4	88	25.00	22.00	53.19	28.94
<b>Excavador a</b>	Se m4- Jul	180	115	65	5	106	13.00	21.20	38.01	9.21

En la tabla 3 se modela el resumen de los resultados de los indicadores de mantenimiento de todas las maquinarias por los 3 meses, donde vemos que la máquina cargadora frontal en la tercera semana del mes de mayo tuvo el mayor MTBF, fue 58 veces de probabilidad a fallar; y el MTTR fue de 12 veces, con una disponibilidad de 82.86 % y una confiabilidad de 58.60 %. Asimismo, el tractor de oruga tuvo un menor MTBF donde la cuarta semana de julio, fue de 4.67 veces a fallar; y el MTTR fue de 21.67 veces, con una disponibilidad de 17.72 %

y una confiabilidad de 0.13 %. En conclusión, se puede decir que la gestión de mantenimiento se encontraba en pésimas condiciones, porque cada vez los números de fallas eran mayores, también aumentaban los tiempos parados y de reparaciones.

### 3.1.1 Disponibilidad inicial del cargador frontal antes de aplicar el Machine Learning

En este marco, se calculó la disponibilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:




Figura 2: Disponibilidad inicial del cargador frontal

En la figura 2, se muestra un resumen de las calificaciones de disponibilidad del cargador frontal de 3 meses basado en registros de interrupciones muestra una alta disponibilidad en la tercera semana de mayo en 82.86% y baja disponibilidad en la primera semana de julio con un 24.29%. Sin embargo, al analizar los resultados obtenidos, se puede apreciar que no existe un mes en el que la disponibilidad máxima sea del 100%, lo que significa que el período de estadía y fijación afecta de manera permanente la probabilidad del equipo confiable en el tiempo requerido.

### 3.1.2 Disponibilidad inicial de la retroexcavadora antes de aplicar el Machine Learning

En este marco, se calculó la disponibilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:




Figura 3: Disponibilidad inicial de la retroexcavadora

Por otra parte, en relación con la disponibilidad de la maquinaria retroexcavadora. En la figura 3, se evidencia resultados donde la disponibilidad de la retroexcavadora, presenta una disponibilidad alta en la cuarta semana de julio fue del 60% y una disponibilidad baja en la primera semana de junio con un 28.57%. Sin embargo, al analizar los resultados obtenidos, se observó que ningún mes alcanzó la disponibilidad máxima del 100%, lo que significa que los intervalos de estadía y reparación inciden de manera permanente en la probabilidad de encajar.



### 3.1.3 Disponibilidad inicial del tractor de oruga antes de aplicar el Machine Learning

En este marco, se calculó la disponibilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:

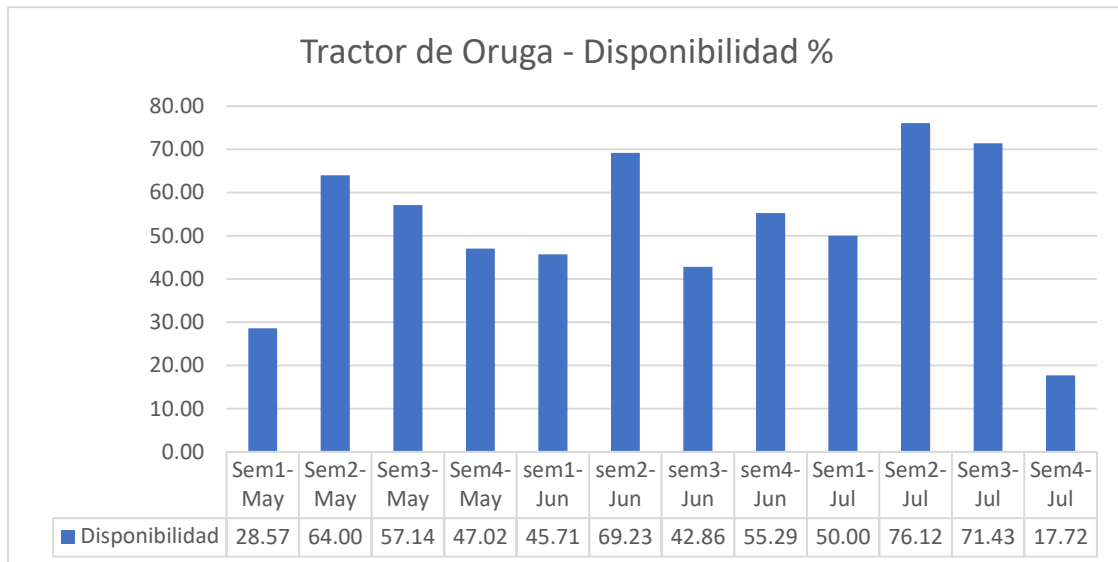


Figura 4: Disponibilidad inicial del tractor de oruga

Por otra parte, en relación con la disponibilidad de la maquinaria tractor de oruga. En la figura 4, presenta una disponibilidad alta en la segunda semana del mes de julio fue del 76.12% y una disponibilidad baja en la cuarta semana de julio con un 17.72%. Sin embargo, al analizar los resultados obtenidos, se observó que ningún mes alcanzó la disponibilidad máxima del 100%, lo que significa que los intervalos de estadía y reparación inciden de manera permanente en la probabilidad de encajar.

### 3.1.4 Disponibilidad inicial de la excavadora antes de aplicar el Machine Learning

En este marco, se calculó la disponibilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:

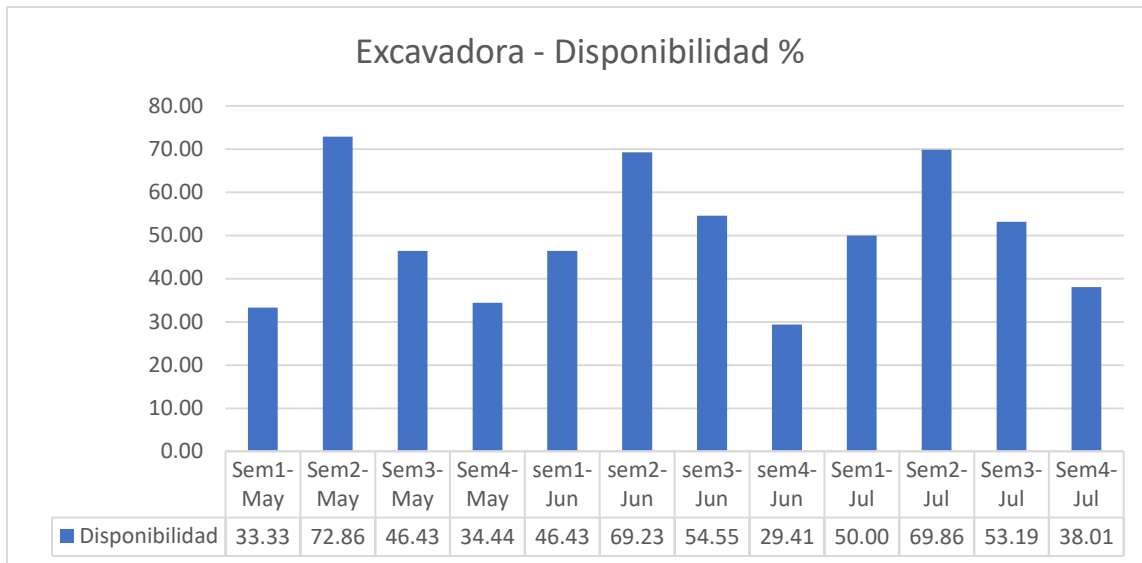



Figura 5: Disponibilidad inicial de la excavadora

Por otra parte, en relación con la disponibilidad de la maquinaria excavadora. En la figura 5, se presenta una disponibilidad alta en la segunda semana del mes de mayo fue del 72.86% y una disponibilidad baja en la cuarta semana del mes de junio con un 29.41%. Sin embargo, al analizar los resultados obtenidos, se observó que ningún mes alcanzó la disponibilidad máxima del 100%, lo que significa que los intervalos de estadía y reparación inciden de manera permanente en la probabilidad de encajar.

### 3.1.4 Confiabilidad inicial del cargador frontal antes de aplicar el Machine Learning

En este marco, se calculó la confiabilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:




*Figura 6: Confiabilidad inicial del cargador frontal*

En relación con la confiabilidad de la maquinaria cargador frontal. En la figura 6, se presenta una confiabilidad alta en la tercera semana del mes de mayo fue del 58.60% y una confiabilidad baja en la primera semana del mes de julio con un 1.05%. Sin embargo, al analizar los resultados obtenidos, se observó que ningún mes alcanzó la confiabilidad máxima del 100%, lo que significa que los intervalos de estadía y reparación inciden de manera permanente en la probabilidad de encajar.

### 3.1.5 Confiabilidad inicial de la retroexcavadora antes de aplicar el Machine Learning

En este marco, se calculó la confiabilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:




*Figura 7: Confiabilidad inicial de la retroexcavadora*

En relación con la confiabilidad de la maquinaria retroexcavadora. En la figura 7, presenta una confiabilidad alta en la tercera semana del mes de junio fue del 32.61% y una confiabilidad baja en la primera semana del mes de junio con un 2.08%, Sin embargo, al analizar los resultados obtenidos, se encontró que ningún mes alcanzó la confianza máxima del 100%, lo que significa que los intervalos de mantenimiento y reparación afectan continuamente la probabilidad configurada.

### 3.1.6 Confiabilidad inicial del tractor de oruga antes de aplicar el Machine Learning

En este marco, se calculó la confiabilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:



*Figura 8: Confiabilidad inicial del tractor oruga*

En relación con la confiabilidad de la maquinaria tractor de oruga. En la figura 8, se presenta una confiabilidad alta en la segunda semana del mes de julio fue del 54.45% y una confiabilidad baja en la cuarta semana del mes de julio con un 0.13%, Sin embargo, al analizar los resultados obtenidos, se encontró que ningún mes alcanzó el nivel máximo de confianza del 100%, lo que significa que los intervalos de mantenimiento y reparación afectan permanentemente la probabilidad configurada.

### 3.1.7 Confiabilidad inicial de la excavadora antes de aplicar el Machine Learning

En este marco, se calculó la confiabilidad de la maquinaria pesada de mayo a julio de 2021, como se muestra en la siguiente tabla:




Figura 9: Confiabilidad inicial de la excavadora

En relación con la confiabilidad de la maquinaria excavadora. En la figura 9, se presenta una confiabilidad alta en la cuarta semana del mes de junio fue del 54.45% y una confiabilidad baja en la cuarta semana de julio con un 2.42%, Sin embargo, al analizar los resultados obtenidos, se encontró que ningún mes alcanzó el nivel máximo de confianza del 100%, lo que significa que los intervalos de mantenimiento y reparación afectan permanentemente la probabilidad configurada.

**3.2 Objetivo específico 2:** Elaborar la propuesta de la implementación del Machine Learning para medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L.

Para el desarrollo del modelo se ha considerado en el ingreso de la data las variables: tiempo de parada, horómetro, código de trabajo, el tipo de mantenimiento y como variable de salida el tipo de falla. Luego estas variables han sido probadas en los algoritmos Máquina de Soporte vectorial (SVM), Árboles de decisión, Vecinos cercanos, redes bayesianas y redes neuronales con una cantidad de 137 datos, en la cual han realizado la predicción de las fallas, en donde se han obtenido los mejores resultados con los algoritmos de máquina de soporte vectorial y redes bayesianas con una precisión del 100%.

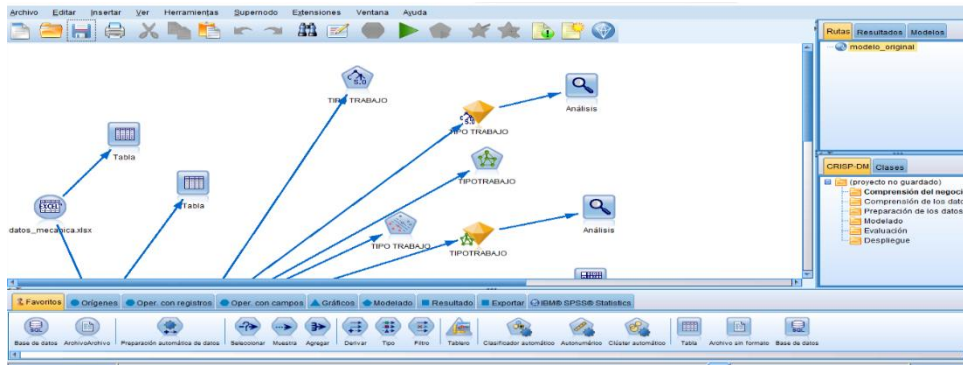


Figura 10: Modelado de la predicción de fallas mecánicas (1ra parte)

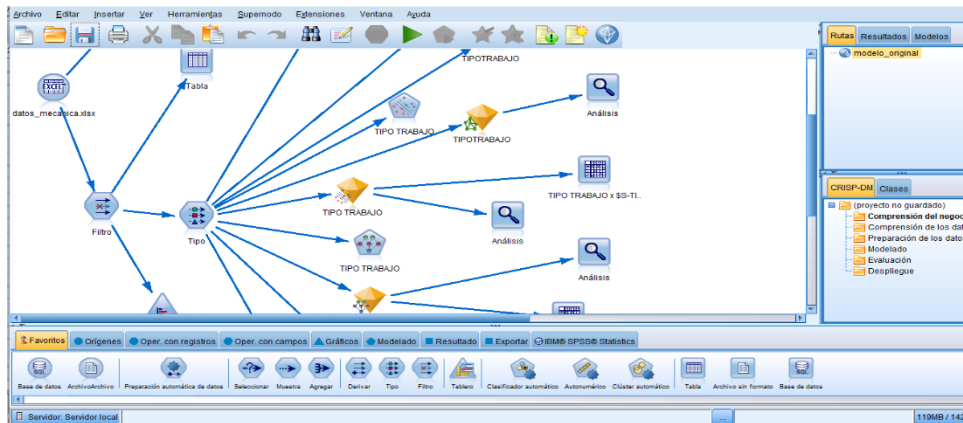


Figura 11: Modelado de la predicción de fallas mecánicas (2a parte)

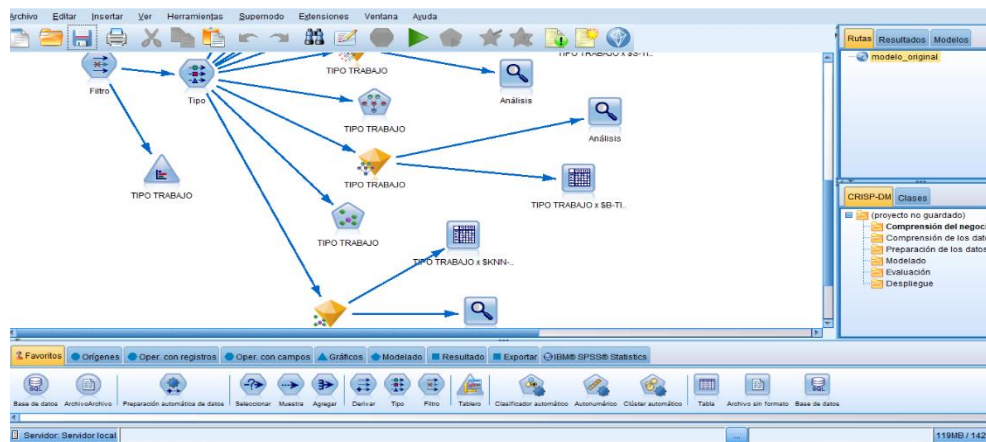


Figura 12: Modelado de la predicción de fallas mecánicas (3ra parte)

En la figura 10, 11 y 12 se puede apreciar que el modelado con respecto a la predicción de fallas mecánicas, que van ayudar al mantenimiento, preventivo y predictivo. En este modelo se usaron varios algoritmos entre los cuales tenemos: árbol de decisión c5.0, redes neuronales, redes bayesianas, svm, vecinos cercanos.

# Funcionamiento del modelo a través de un flujograma

A continuación, se detalla el funcionamiento de la propuesta en la siguiente figura:

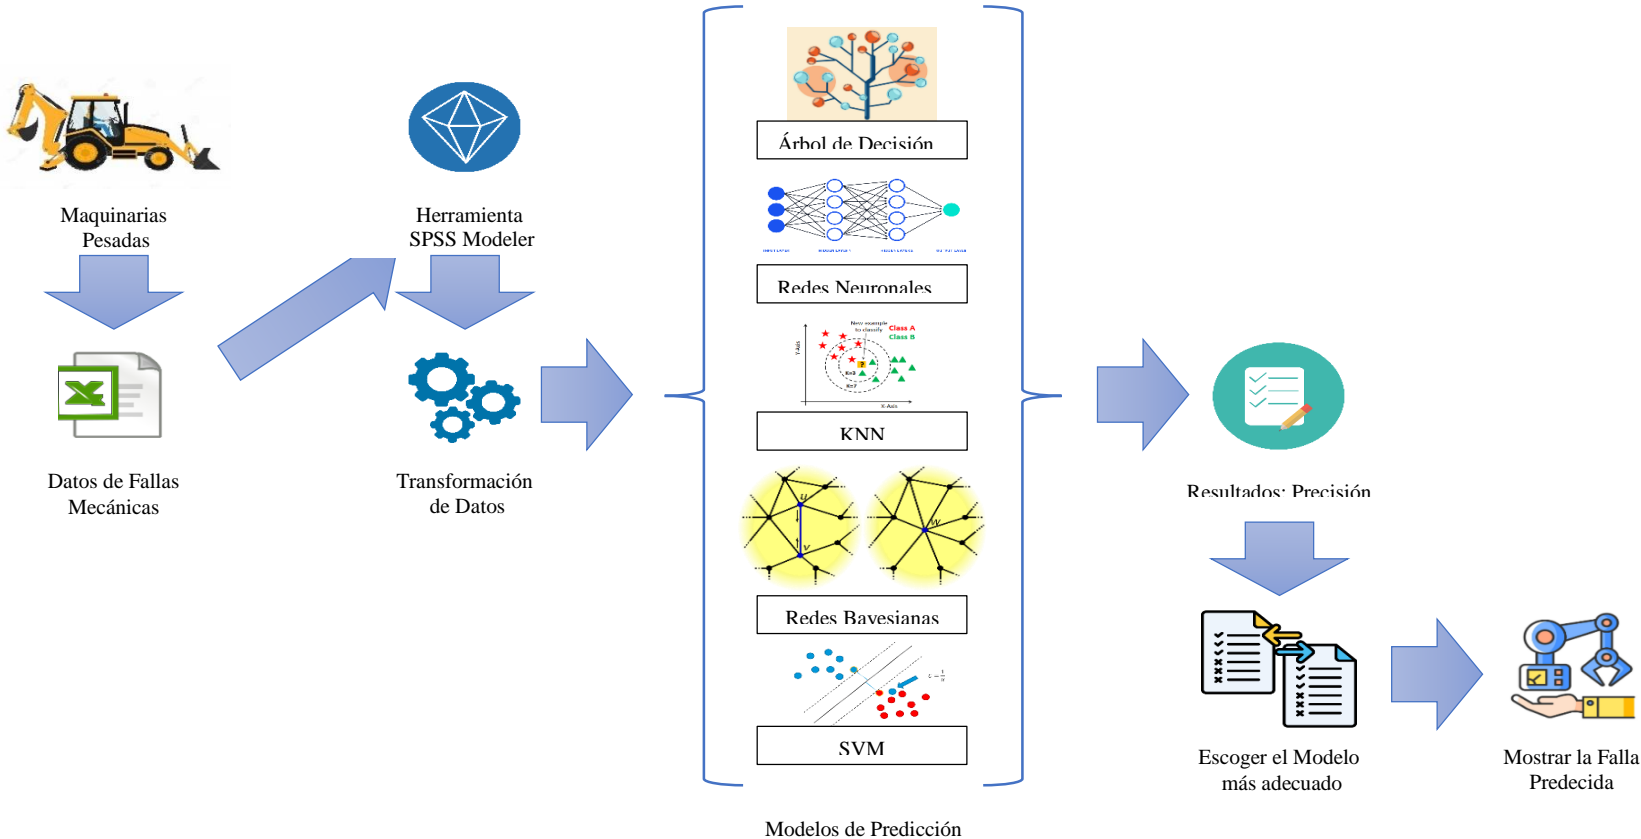


Figura 13: Funcionamiento del modelo propuesto



En la figura 13 se puede apreciar que las fuentes de datos provienen de la maquinaria pesada, para que luego estos datos que se encuentran en un archivo Excel sean transformados y los modelos puedan trabajar de manera adecuada. Luego los datos transformados con entrenados en 5 algoritmos, en la cual se obtiene la mejor precisión de todos los modelos y en la cual es usado para mostrar la predicción de fallas de la maquinaria.

En esta sección se presenta los resultados de precisión conseguidos por cada algoritmo referente a la aplicación del Machine Learning para mejorar la gestión del área de mantenimiento.

**Árbol de decisión c5.0 – Precisión:** con respecto al modelo se obtuvo una precisión del 76,64% que representa 105 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 32 datos que representan el 23,36%.

Resultados para el campo de resultado TIPO TRABAJO			
Comparando SC-TIPO TRABAJO con TIPO TRABAJO			
Correctos	105	76,64%	
Erróneos	32	23,36%	
Total	137		

Figura 14: Algoritmo-Árbol de decisión c5.0

**Redes neuronales – Precisión:** respecto al modelo se obtuvo una precisión del 53,28% que representa 73 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 64 datos que representan el 46,72%.

Resultados para el campo de resultado TIPO TRABAJO			
Comparando SN-TIPO TRABAJO con TIPO TRABAJO			
Correctos	73	53,28%	
Erróneos	64	46,72%	
Total	137		

Figura 15: Algoritmo-Redes neuronales

**Algoritmo SVM – Precisión:** respecto al modelo se obtuvo una precisión del 100% que representa 137 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 0 datos que representan el 0%.

Resultados para el campo de resultado TIPO TRABAJO		
Comparando SS-TIPO TRABAJO con TIPO TRABAJO		
Correctos	137	100%
Erróneos	0	0%
Total	137	

Figura 16: Algoritmo-SVM

**Redes bayesianas – Precisión:** respecto al modelo se obtuvo una precisión del 100% que representa 137 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 0 datos que representan el 0%.

Resultados para el campo de resultado TIPO TRABAJO		
Comparando SS-TIPO TRABAJO con TIPO TRABAJO		
Correctos	137	100%
Erróneos	0	0%
Total	137	

Figura 17: Algoritmo-Redes bayesianas

**Algoritmos vecinos más cercanos – Precisión:** respecto al modelo se obtuvo una precisión del 86.13% que representa 118 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 19 datos que representan el 19%.

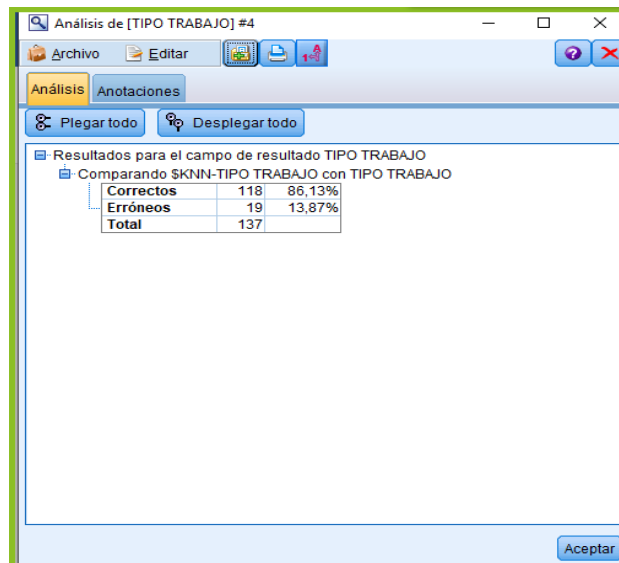


Figura 18: Algoritmo-Vecinos más cercanos

### **Análisis de comparación de resultados obtenidos de los 5 modelos predictivos.**

Tabla 4: Comparación de modelos

Nº	Modelo	precisión
1	Árbol de decisión	76.64%
2	Redes neuronales	53,28%
3	SVM	100%
4	Redes bayesianas	100%
5	Vecinos Cercanos	86.13%

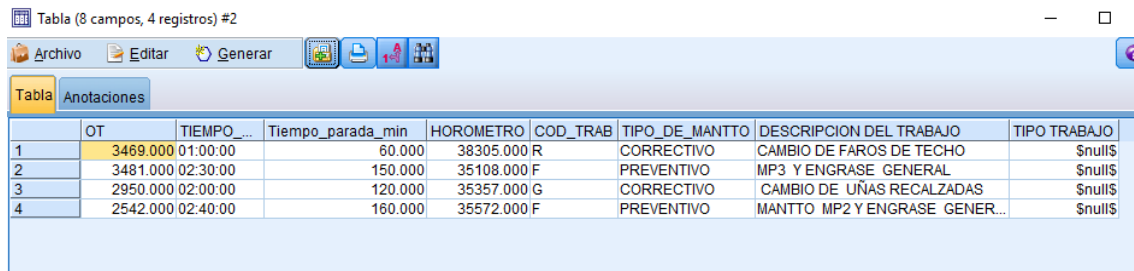
Fuente: elaboración propia

En la tabla 4 podemos apreciar que después de haber realizado los entrenamientos de los modelos predictivos, se han obtenidos una precisión para los árboles de decisión de 76,64%, redes neuronales de 53,28%, SVM una precisión de 100%, Redes bayesianas de 100%, así como una precisión de 86,13% en vecinos cercanos.

Por lo cual podemos concluir que el modelo más adecuado para la predicción con relación a las fallas mecánicas es el SVM y las redes bayesianas.

## Predicción de fallas con nuevos datos.

Ahora vamos a realiza la predicción de fallas de 4 cargadores frontales nuevas como se muestra en la figura 19, que no se han usado para el entrenamiento y de esta forma se realice el mantenimiento preventivo (antes de que empiece a fallar) de manera adecuado la cual permitirá que se incremente la confiabilidad y la disponibilidad de la maquinaria antes mencionada.



	OT	TIEMPO...	Tiempo_parada_min	HOROMETRO	COD_TRAB	TIPO_DE_MANTTO	DESCRIPCION DEL TRABAJO	TIPO TRABAJO
1	3469.000	01:00:00	60.000	38305.000	R	CORRECTIVO	CAMBIO DE FAROS DE TECHO	\$null\$
2	3481.000	02:30:00	150.000	35108.000	F	PREVENTIVO	MP3 Y ENGRASE GENERAL	\$null\$
3	2950.000	02:00:00	120.000	35357.000	G	CORRECTIVO	CAMBIO DE UÑAS RECALZADAS	\$null\$
4	2542.000	02:40:00	160.000	35572.000	F	PREVENTIVO	MANTTO MP2 Y ENGRASE GENER...	\$null\$

Figura 19: datos nuevos de cargador frontal

Como se puede apreciar en la figura 19, los datos de tipo de trabajo están vacíos debido a que el algoritmo, lo va a predecir con el modelo que se ha generado con los datos históricos.

Para lo cual ingresaremos los datos nuevos al modelo de máquina de soporte vectorial (SVM) como se muestra en la figura 20.

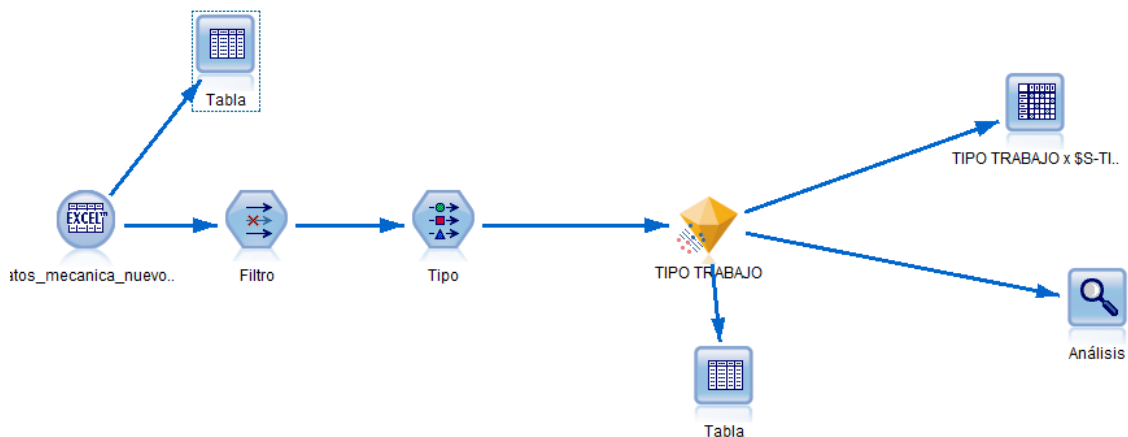


Figura 20: Modelo de predicción SVM

En la figura 20 se puede apreciar que se ingresa los datos en el nodo Excel, luego se hace el filtro de la información del tiempo, que no se va a usar debido a que ha sido transformado de horas minutos, luego en el nodo tipo se coloca las variables de ingreso y las variables de salida, posteriormente la información ingresa al modelo SVM, la cual hará la predicción de las fallas con los datos nuevos y se mostrará en la tabla como se muestra en la figura 21.

	Tiempo_parada_min	HOROMETRO	COD_TRAB	TIPO_DE_MANTTO	TIPO TRABAJO	\$\$-TIPO TRABAJO	\$\$P-TIPO TRABAJO
1	60.000	38305.000000	R	CORRECTIVO	\$null\$	Mecanico	0.859
2	150.000	35108.000000	F	PREVENTIVO	\$null\$	Mecanico	0.996
3	120.000	35357.000000	G	CORRECTIVO	\$null\$	Mecanico	0.974
4	160.000	35572.000000	F	PREVENTIVO	\$null\$	Mecanico	0.996

Figura 21: Datos predecidos de SVM

En la figura 21 se puede apreciar que con los datos que se ha ingresado al modelo, se ha predecido el tipo de falla de cada uno de ellos en donde se deben aplicar mantenimiento mecánico antes que empiecen a fallar las maquinarias.

**3.2 Objetivo específico 3:** Determinar la gestión del mantenimiento con la implementación del Machine Learning para comparar la situación anterior en la EMPRESA MEKATSU EQUIPOS S.R.L.


### 3.2.1 Demostración de la media del cargador frontal antes y después del Machine Learning

Tabla 5: Cuadro comparativo del cargador frontal

Familia	PRE-TEST		POST-TEST	
	Disponibilidad	Confiabilidad	Disponibilidad	Confiabilidad
Cargador frontal	28.57	2.08	55.71	30.35
Cargador frontal	51.54	15.71	71.54	51.34
Cargador frontal	82.86	58.60	72.14	54.13
Cargador frontal	37.50	3.83	89.53	81.77
Cargador frontal	28.57	2.08	68.57	52.42
Cargador frontal	62.60	32.17	69.23	50.21
Cargador frontal	57.14	31.27	72.86	54.45
Cargador frontal	44.19	13.01	93.02	82.39
Cargador frontal	24.29	1.05	57.14	31.27
Cargador frontal	69.23	50.21	83.08	75.05
Cargador frontal	38.57	10.06	84.29	76.90
Cargador frontal	67.06	44.23	74.42	61.61
<b>MEDIA</b>	<b>49.34</b>	<b>22.02</b>	<b>74.29</b>	<b>58.49</b>

Fuentes: Empresa MEKATSU S.R.L.


Posteriormente la data de disponibilidad se representó a través de una figura, lo cual ayudará a tener una comprensión más amplia y clara:



*Figura 22:* Comparación de disponibilidad del cargador frontal

En la figura 22 se puede apreciar que la maquinaria de cargador frontal en el pre-test tuvo una media en la disponibilidad del 49.34% y en el post-test una media del 74.29%; por lo tanto, se puede evidenciar que tras la aplicación del Machine Learning se obtuvo un incremento del 24.95% respecto a la disponibilidad del equipo.

Igualmente, para la confiabilidad fue necesario representarlo a través de una figura, para hacer más clara al momento de interpretarla:



*Figura 23:* Comparación de la confiabilidad del cargador frontal

En la figura 23 se puede apreciar que la maquinaria de cargador frontal en el pre-test tuvo una media en la confiabilidad del 22.02% y en el post-test una media del 58.49%; por lo tanto, se puede evidenciar que tras la aplicación del Machine Learning se obtuvo un incremento del 36.47% respecto a la confiabilidad del equipo.

### 3.2.2 Demostración de la media de la retroexcavadora antes y después del Machine Learning

Tabla 6: Cuadro comparativo de la retroexcavadora

Familia	PRE-TEST		POST-TEST	
	Disponibilidad	Confiabilidad	Disponibilidad	Confiabilidad
Retroexcavadora	46.43	14.84	69.15	38.53
Retroexcavadora	53.85	26.49	70.00	41.24
Retroexcavadora	50.00	21.22	65.22	35.58
Retroexcavadora	50.00	21.22	77.00	54.67
Retroexcavadora	28.57	2.08	75.00	55.41
Retroexcavadora	50.00	21.22	71.43	39.46
Retroexcavadora	59.29	32.61	83.21	75.25
Retroexcavadora	48.54	15.45	74.12	61.14
Retroexcavadora	35.37	11.79	60.71	33.48
Retroexcavadora	59.18	11.79	71.43	53.79
Retroexcavadora	40.69	20.67	83.33	75.44
Retroexcavadora	60.00	22.85	87.06	81.10
<b>MEDIA</b>	<b>48.49</b>	<b>18.52</b>	<b>73.97</b>	<b>53.76</b>

Fuentes: Empresa MEKATSU S.R.L.




Figura 24: Comparación de la disponibilidad de la retroexcavadora

En la figura 24 se puede apreciar que la maquinaria de retroexcavadora respecto a la disponibilidad, en el pre-test tuvo una media del 48.49% y en el post-test una media del 73.97%; por lo tanto, se puede evidenciar que tras la aplicación del

Machine Learning se obtuvo un incremento del 25.48% en relación con la disponibilidad del equipo.




Figura 25: Comparación de la confiabilidad de la retroexcavadora

En la figura 25 se puede estimar que la maquinaria retroexcavadora respecto a la confiabilidad, en el pre-test tuvo una media del 18.52% y en el post-test una media del 53.75%; por lo tanto, se puede evidenciar que tras la aplicación del Machine Learning se obtuvo un incremento del 35.24% en relación con la confiabilidad del equipo.

### 3.2.3 Demostración de la media del tractor oruga antes y después del Machine Learning


Tabla 7: Cuadro comparativo del tractor de oruga

Familia	PRE-TEST		POST-TEST	
	Disponibilidad	Confiabilidad	Disponibilidad	Confiabilidad
Tractor de Oruga	28.57	2.08	70.00	53.12
Tractor de Oruga	64.00	31.27	81.82	56.32
Tractor de Oruga	57.14	31.27	71.43	53.79
Tractor de Oruga	47.02	14.06	74.71	62.07
Tractor de Oruga	45.71	14.41	78.57	56.91
Tractor de Oruga	69.23	50.21	67.69	49.43
Tractor de Oruga	42.86	12.66	71.43	53.79
Tractor de Oruga	55.29	26.74	87.21	81.33
Tractor de Oruga	50.00	9.21	68.57	52.42
Tractor de Oruga	76.12	54.45	63.91	33.48
Tractor de Oruga	71.43	28.94	85.71	77.23




<b>Tractor de Oruga</b>	17.72	0.13	77.01	62.96
<b>MEDIA</b>	<b>52.09</b>	<b>22.95</b>	<b>74.84</b>	<b>57.74</b>

Fuente: Empresa MEKATSU S.R.L.



*Figura 26:* Comparación de la disponibilidad del tractor de oruga.

En la figura 26 se puede estimar que la maquinaria tractor de oruga respecto a la disponibilidad, en el pre-test tuvo una media del 52.09% y en el post-test una media del 74.84%; por lo tanto, se puede evidenciar que tras la aplicación del Machine Learning se obtuvo un incremento del 22.75% en relación con la disponibilidad del equipo.



*Figura 27:* Comparación de la confiabilidad de la retroexcavadora

En la figura 27 se puede estimar que la maquinaria tractor de oruga respecto a la confiabilidad, en el pre-test tuvo una media del 22.95% y en el post-test una media del 57.74%; por lo tanto, se puede evidenciar que tras la aplicación del

Machine Learning se obtuvo un incremento del 34.79% en relación con la confiabilidad del equipo.

### 3.2.4 Demostración de la media de la excavadora antes y después del Machine Learning

Tabla 8: Cuadro comparativo de la excavadora

Familia	PRE-TEST		POST-TEST	
	Disponibilidad	Confiabilidad	Disponibilidad	Confiabilidad
Excavadora	33.33	4.50	66.10	45.16
Excavadora	72.86	40.18	83.58	75.82
Excavadora	46.43	14.84	94.29	79.07
Excavadora	34.44	3.02	62.57	41.93
Excavadora	46.43	14.84	68.57	52.42
Excavadora	69.23	50.21	83.33	75.44
Excavadora	54.55	21.22	68.57	52.42
Excavadora	29.41	2.42	87.06	81.10
Excavadora	50.00	9.21	71.43	53.79
Excavadora	69.86	54.45	70.77	50.97
Excavadora	53.19	28.94	83.33	73.34
Excavadora	38.01	9.21	87.13	81.22
<b>MEDIA</b>	<b>49.81</b>	<b>21.09</b>	<b>77.23</b>	<b>63.56</b>

Fuente: Empresa MEKATSU S.R.L.





Figura 28: Comparación de la confiabilidad de la excavadora

En la figura 28 se puede estimar que la maquinaria excavadora respecto a la disponibilidad, en el pre-test tuvo una media del 49.81% y en el post-test una

media del 77.23%; por lo tanto, se puede evidenciar que tras la aplicación del Machine Learning se obtuvo un incremento del 27.42% en relación con la disponibilidad del equipo.



*Figura 29:* Comparación de la confiabilidad de la excavadora

En la figura 29 se puede estimar que la maquinaria excavadora respecto a la confiabilidad, en el pre-test obtuvo una media del 21.09% y en el post-test una media del 63.56%; por lo tanto, se puede evidenciar que tras la aplicación del Machine Learning se obtuvo un incremento del 42.47% en relación con la confiabilidad del equipo.

Finalmente, se puede concluir que el Machine Learning resultó ser una herramienta eficaz, puesto que los resultados que mostraron los gráficos fueron positivos, teniendo así incrementos significativos. Es decir, que gracias al Machine Learning la empresa se encuentra más actualizado en relación con las fallas mecánicas de todas las maquinarias en general.

### **3.3.5 Demostración estadística de las maquinarias “cargador frontal”**

#### **3.3.5.1 Disponibilidad del cargador frontal**

Para tener una comprensión más clara, se realizó el análisis inferencial acerca de la maquinaria cargador frontal, para lo cual fue necesario conocer su efecto en del Machine Learning en la disponibilidad y confiabilidad del mismo. Para comprobar si la distribución de la muestra es normal o no, se usó las pruebas de Kolmogorov-Smirnov y Shapiro-Wilk para una muestra.

Al elaborar la prueba de normalidad en este estudio, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores

“disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “disponibilidad”

**Tabla 9:** Prueba de normalidad - Disponibilidad

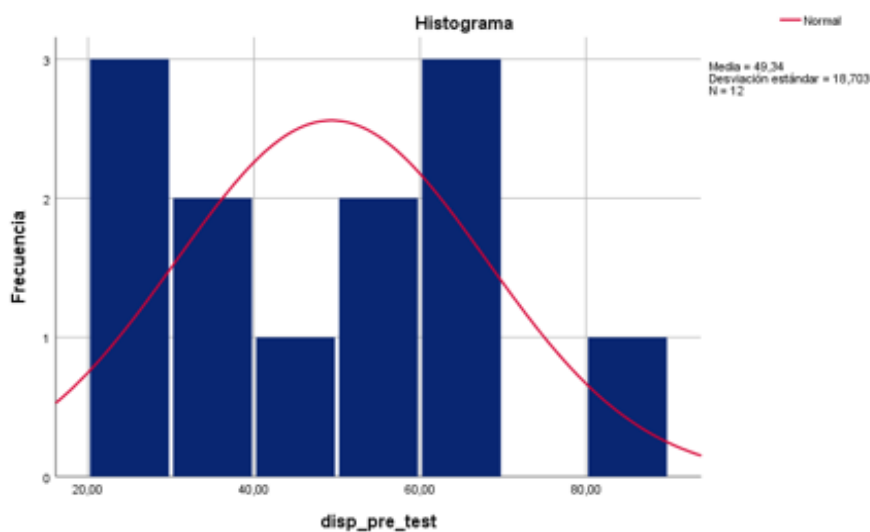
Shapiro Wilk			
	Estadístico	gl	Sig.
Pre-Test	,953	12	,674
Post-Test	,949	12	,618

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 9, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,674, el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,618, lo cual hace que se convierta en prueba paramétrico.

En la figura 30 se puede observar la media obtenida en el pre-test, que fue del 49.34, seguido de una desviación estándar del 18.703.



**Figura 30:** Histograma de disponibilidad-cargador frontal

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada cargador frontal en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la disponibilidad de la maquinaria pesada cargador frontal en la empresa MEKATSU EQUIPOS S.R.L.

**Tabla 10:** Estadísticas de muestras emparejadas

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	74,2942	12	11,56893	3,33966
	Post-Test	49,3433	12	18,70269	5,39900

Fuente: IBM SPSS estadístico v.25

**Tabla 11:** Correlaciones de muestras emparejadas

Correlaciones de muestras emparejadas				
		N	Correlación	Sig
Par 1	Pre-Test & Post-Test	12	,240	,453

Fuente: IBM SPSS estadístico v.25

**Tabla 12:** Prueba de muestras emparejadas

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de la 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 SPSS estadístico v.25

En base a los resultados conseguidos de las pruebas de disponibilidad del cargador frontal entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,001 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada cargador frontal en la empresa MEKATSU EQUIPOS S.R.L.

### 3.3.5.2 Confiabilidad de la cargadora frontal

Al elaborar la prueba de normalidad en este estudio, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores “disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “confiabilidad”

**Tabla 13:** Prueba de normalidad - Confiabilidad


	Shapiro Wilk		
	Estadístico	gl	Sig.
Pre-Test	,880	12	,088
Post-Test	,912	12	,224

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 13, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,088, el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,224, lo cual hace que se convierta en prueba paramétrico.

En la figura 31 se puede observar la media obtenida en el pre-test, que fue del 22.03, seguido de una desviación estándar del 20.548.



*Figura 31:* Histograma de confiabilidad-cargador frontal

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada cargador frontal en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la confiabilidad de la maquinaria pesada cargador frontal en la empresa MEKATSU EQUIPOS S.R.L.

**Tabla 14:** Estadísticas de muestras emparejadas

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	58,4908	12	17,73725	5,12030
	Post-Test	22,0250	12	20,54818	5,93175

Fuente: IBM SPSS estadístico v.25

**Tabla 15:** Correlaciones de muestras emparejadas

Correlaciones de muestras emparejadas				
		N	Correlación	Sig
Par 1	Pre-Test & Post-Test	12	,173	,590

Fuente: IBM SPSS estadístico v.25

**Tabla 16:** Prueba de muestras emparejadas

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de la 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 SPSS estadístico v.25

En base a los resultados conseguidos de las pruebas de confiabilidad del cargador frontal entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,000 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada cargador frontal en la empresa MEKATSU EQUIPOS S.R.L.

### 3.3.6 Demostración estadística de la maquinaria “retroexcavadora”

#### 3.3.6.1 Disponibilidad de la retroexcavadora

Al elaborar la prueba de normalidad en esta sección, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores

“disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “disponibilidad”

**Tabla 17: Prueba de normalidad - Disponibilidad**

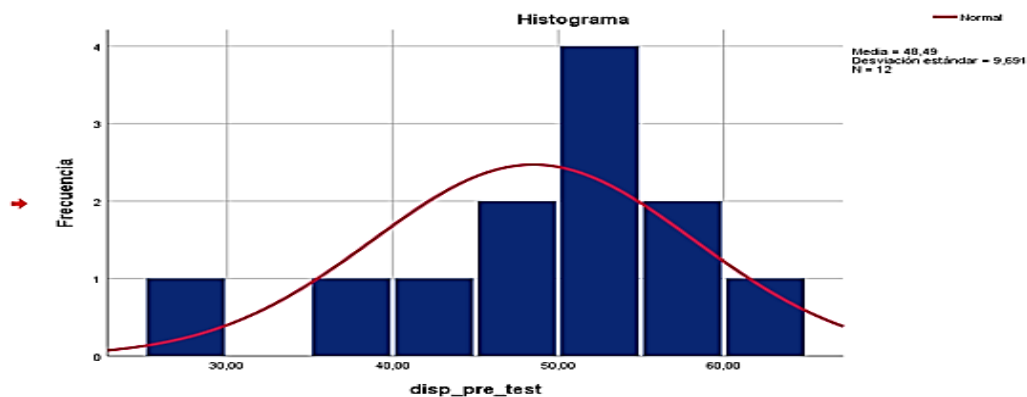
Shapiro Wilk			
	Estadístico	gl	Sig.
Pre-Test	,919	12	,278
Post-Test	,969	12	,901

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la Tabla 17, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,278 el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,901 lo cual hace que se convierta en prueba paramétrico.

En la figura 32 se puede observar la media obtenida en el pre-test, que fue de 48.49, seguido de una desviación estándar del 9.691.



**Figura 32: Histograma de disponibilidad-retroexcavadora**

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada retroexcavadora en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la disponibilidad de la maquinaria pesada retroexcavadora en la empresa MEKATSU EQUIPOS S.R.L.



**Tabla 18: Estadísticas de muestras emparejadas**

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	73,9717	12	7,73943	2,23418
	Post-Test	48,4933	12	9,69064	2,79745

Fuente: IBM SPSS estadístico v.25

**Tabla 19: Correlaciones de muestras emparejadas**

Correlaciones de muestras emparejadas				
		N	Correlación	Sig
Par 1	Pre-Test & Post-Test	12	,339	,281

Fuente: IBM SPSS estadístico v.25

**Tabla 20: Prueba de muestras emparejadas**

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de la 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 SPSS estadístico v.25

En base a los resultados conseguidos de las pruebas de disponibilidad de la retroexcavadora entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,000 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que El Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada retroexcavadora en la empresa MEKATSU EQUIPOS SR.L.

### 3.3.6.2 Confiabilidad de la retroexcavadora

Al elaborar la prueba de normalidad en este estudio, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores “disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “confiabilidad”

**Tabla 21: Prueba de normalidad - Confiabilidad**


Shapiro Wilk			
	Estadístico	gl	Sig.
Pre-Test	,960	12	,785
Post-Test	,905	12	,182

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 21, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,785 el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,182 lo cual hace que se convierta en prueba paramétrico.

En la figura 33 se puede observar la media obtenida en el pre-test, que fue de 18.52, seguido de una desviación estándar del 7.926.



**Figura 33:** Histograma de confiabilidad-retroexcavadora

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada retroexcavadora en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la confiabilidad de la maquinaria pesada retroexcavadora en la empresa MEKATSU EQUIPOS S.R.L.

**Tabla 22: Estadísticas de muestras emparejadas**

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	53,7575	12	16,71232	4,82443
	Post-Test	18,5192	12	7,92646	2,28817

Fuente: IBM SPSS estadístico v.25

**Tabla 23: Correlaciones de muestras emparejadas**

Correlaciones de muestras emparejadas				
		N	Correlación	Sig
Par 1	Pre-Test & Post-Test	12	,292	,357

Fuente: IBM SPSS estadístico v.25

**Tabla 24: Prueba de muestras emparejadas**

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de la 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 SPSS estadístico v.25

En base a los resultados conseguidos de las pruebas de confiabilidad de la retroexcavadora entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,000 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada retroexcavadora en la empresa MEKATSU EQUIPOS S.R.L.

### 3.3.7 Demostración estadística de la maquinaria “tractor de oruga”

#### 3.3.7.1 Disponibilidad del tractor de oruga

Al elaborar la prueba de normalidad en esta sección, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores “disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “disponibilidad”

**Tabla 25:** Prueba de normalidad - Disponibilidad

	Shapiro Wilk		
	Estadístico	gl	Sig.
Pre-Test	,960	12	,790
Post-Test	,954	12	,702

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 25, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,790 el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,702 lo cual hace que se convierta en prueba paramétrica.

En la figura 34 se puede observar la media obtenida en el pre-test, que fue de 52.09, seguido de una desviación estándar del 17.355.




Figura 34: Histograma de disponibilidad-tractor oruga

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada tractor de oruga en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la disponibilidad de la maquinaria pesada tractor de oruga en la empresa MEKATSU EQUIPOS S.R.L.

**Tabla 26:** Estadísticas de muestras emparejadas

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	74,8383	12	7,35536	2,12331

Post-Test	52,0908	12	17,35539	5,01007
-----------	---------	----	----------	---------

Fuente: IBM SPSS estadístico v.25

**Tabla 27:** *Correlaciones de muestras emparejadas*

Correlaciones de muestras emparejadas				
		N	Correlación	Sig
Par 1	Pre-Test & Post-Test	12	-,006	,985

Fuente: IBM SPSS estadístico v.25

**Tabla 28:** *Prueba de muestras emparejadas*

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de la 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 SPSS estadístico v.25

En base a los resultados conseguidos de las pruebas de disponibilidad del tractor de oruga entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,002 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada tractor de oruga en la empresa MEKATSU EQUIPOS S.R.L.

### 3.3.7.2 Confiabilidad del tractor de oruga

Al elaborar la prueba de normalidad en este estudio, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores “disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “confiabilidad”

**Tabla 29:** *Prueba de normalidad - Confiabilidad*

Shapiro Wilk			
	Estadístico	gl	Sig.
Pre-Test	,930	12	,380
Post-Test	,914	12	,243

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 29, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,380 el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,243 lo cual hace que se convierta en prueba paramétrico.

En la figura 35 se puede observar la media obtenida en el pre-test, que fue de 22.95, seguido de una desviación estándar del 17.391.

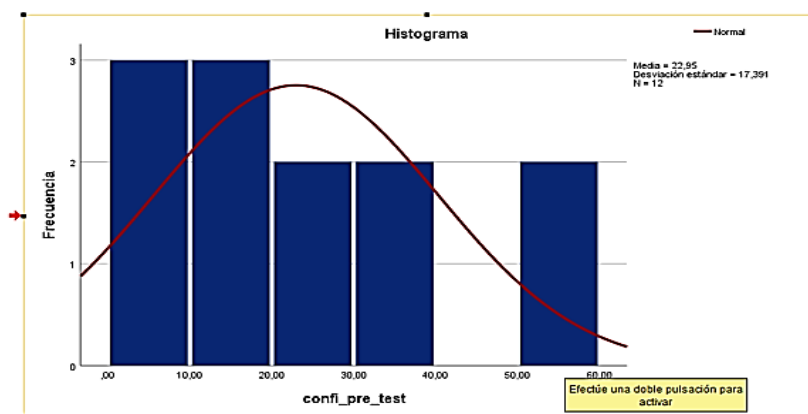


Figura 35: Histograma de confiabilidad-tractor oruga

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada tractor de oruga en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la confiabilidad de la maquinaria pesada tractor de oruga en la empresa MEKATSU EQUIPOS S.R.L.

Tabla 30: Estadísticas de muestras emparejadas

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	57,7375	12	12,51728	3,61343
	Post-Test	22,9525	12	17,39120	5,02041

Fuente: IBM SPSS estadístico v.25

Tabla 31: Correlaciones de muestras emparejadas

Correlaciones de muestras emparejadas			
		N	Sig
		Correlación	

<b>Par 1</b>	Pre-Test & Post-Test	12		-,321	,308
--------------	----------------------	----	--	-------	------

Fuente: IBM SPSS estadístico v.25

**Tabla 32:** Prueba de muestras emparejadas

Prueba de muestras emparejadas									
Diferencias emparejadas									
95% de intervalo de confianza de la 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 SPSS estadístico v.25

En base a los resultados conseguidos de las pruebas de confiabilidad del tractor de oruga entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,000 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada tractor de oruga en la empresa MEKATSU EQUIPOS SRL.

### 3.3.8 Demostración estadística de la maquinaria “excavadora”

#### 3.3.8.1 Disponibilidad de la excavadora

Al elaborar la prueba de normalidad en esta sección, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores “disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “disponibilidad”

**Tabla 33:** Prueba de normalidad - Disponibilidad

Shapiro Wilk			
	Estadístico	gl	Sig.
Pre-Test	,927	12	,345
Post-Test	,913	12	,231

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 33, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,345 el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-

test el nivel de significancia fue de ,231 lo cual hace que se convierta en prueba paramétrico.

En la figura 36 se puede observar la media obtenida en el pre-test, que fue de 48. 81, seguido de una desviación estándar del 14.864.

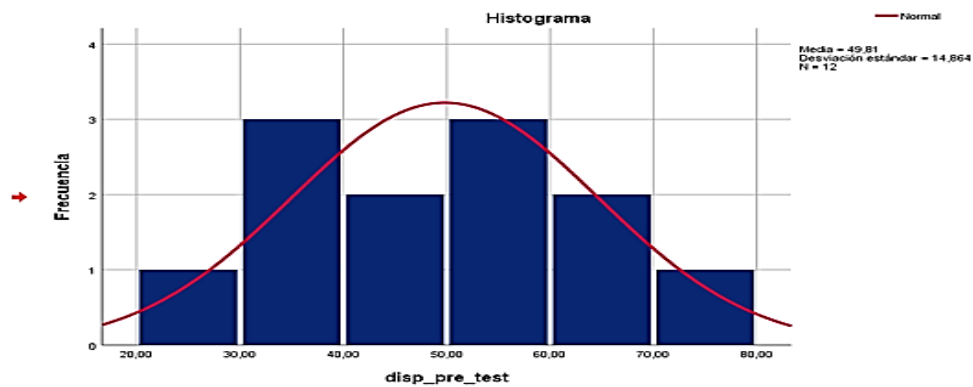


Figura 36: Histograma de disponibilidad-excavadora

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue paramétrico. Por lo cual, la prueba estadística empleada fue el T de Student. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada excavadora en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la disponibilidad de la maquinaria pesada excavadora en la empresa MEKATSU EQUIPOS S.R.L.

Tabla 34: Estadísticas de muestras emparejadas

Estadísticas de muestras emparejadas					
		Media	N	Desv. Desviación	Desv. Error promedio
Par 1	Pre-Test	77,2275	12	10,28936	2,97028
	Post-Test	49,8117	12	14,86437	4,29097

Fuente: IBM SPSS estadístico v.25

Tabla 35: Correlaciones de muestras emparejadas

Correlaciones de muestras emparejadas					
		N	Correlación	Sig	
Par 1	Pre-Test & Post-Test	12	,105	,985	

Fuente: IBM SPSS estadístico v.25

Tabla 36: Prueba de muestras emparejadas

### Prueba de muestras emparejadas



		Diferencias emparejadas							
		95% de intervalo de confianza de la 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 SPSS estadistic v.25

En base a los resultados conseguidos de las pruebas de disponibilidad de la excavadora entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez realizada la aplicación de la prueba de T de Student, el nivel de significancia fue ,000 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la disponibilidad de la maquinaria pesada excavadora en la empresa MEKATSU EQUIPOS SRL.

### 3.3.8.2 Confiabilidad de la maquinaria “excavadora”

Al elaborar la prueba de normalidad en este estudio, se hizo uso del Shapiro-Wilk, puesto que los datos son  $< 50$ ; asimismo, para los indicadores “disponibilidad” y “confiabilidad”. A continuación, se realizará la prueba de normalidad del indicador “confiabilidad”

**Tabla 37:** Prueba de normalidad - Confiabilidad

	Shapiro Wilk		
	Estadístico	gl	Sig.
Pre-Test	,872	12	,070
Post-Test	,846	12	,032

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors.

De acuerdo a la tabla 37, se pudo demostrar que en el pre-test se obtuvo un nivel de significancia del ,070 el cual siendo mayor a 0.05, la variable persiguió una distribución normal y por tanto es paramétrico. Asimismo, en la prueba del post-test el nivel de significancia fue de ,032 lo cual hace que se convierta en prueba no paramétrico.

En la figura 37 se puede observar la media obtenida en el pre-test, que fue de 21.09, seguido de una desviación estándar del 18.334.

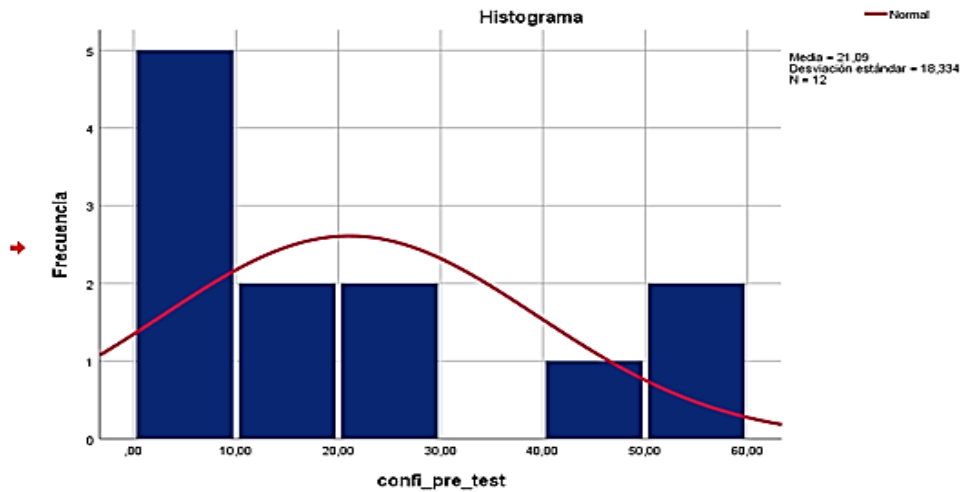


Figura 37: Histograma de confiabilidad-excavadora

### Prueba de hipótesis

De acuerdo con la tabla anterior, se pudo demostrar que el Pre-Test y Post-Test fue no paramétrico. Por lo cual, la prueba estadística empleada fue Wilcoxon. Consecutivamente, se revelaron la hipótesis tanto alterna como la nula:

**H0:** El Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada excavadora en la empresa MEKATSU EQUIPOS S.R.L.

**H1:** El Machine Learning no ayuda a mejorar la confiabilidad de la maquinaria pesada excavadora en la empresa MEKATSU EQUIPOS S.R.L.

### Prueba de Wilcoxon

Tabla 38: Contrastación de hipótesis específica 1

		N	Rango promedio	Suma de rangos
<b>Confi pre_test</b>	Rangos negativos	11 <sup>a</sup>	7.00	77.00
<b>- Confi post_test</b>	Rangos positivos	1 <sup>b</sup>	1.00	1.00
	Empates	0 <sup>c</sup>		
	Total	12		

a) Confi pre-test < Confi post-test

b) Confi pre-test > Confi post-test

c) Confi pre-test = Confi post-test

En la tabla 39 se muestra los resultados de la prueba Z referente al incremento de conocimiento.

**Tabla 39:** Estadística de prueba Z- Incremento de conocimiento

	Confi pre_test - Confi post_test
<b>Z</b>	-2.981 <sup>b</sup>
<b>Sig. asin. (bilateral)</b>	0.03

- a) Prueba de rangos con signo de Wilcoxon
- b) Se basa en rangos positivos

En base a los resultados conseguidos de las pruebas de confiabilidad de la excavadora entre el antes y después de la aplicación del Machine Learning, se ha logrado evidenciar que una vez aplicada la prueba wilcoxon, el nivel de significancia fue ,03 (menor a 0.05) por lo que se acepta la hipótesis de investigación, pudiendo contrastar que el Machine Learning ayuda a mejorar la confiabilidad de la maquinaria pesada excavadora en la empresa MEKATSU EQUIPOS S.R.L.

**3.4.1 Objetivo general:** Evaluar la influencia del Machine Learning en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L.

En base a los resultados conseguidos, se aceptaron condiciones de las hipótesis específicas 1, 2 y 3; entonces, se aceptó la hipótesis general “El Machine Learning influye positivamente en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L”

#### 3.4.1.1 Resumen

A continuación, en la tabla 16 se muestra un resumen de las comprobaciones realizadas en las hipótesis de la investigación:

**Tabla 40:** Resumen de hipótesis

<b>Hipótesis</b>	<b>Resultado (Aceptada o rechazada)</b>
HE1: La gestión actual en la EMPRESA MEKATSU EQUIPOS S.R.L. se encuentra en pésimas condiciones.	Aceptada

---

HE2: La propuesta de la implementación del Machine Learning ayuda a medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L. Aceptada

---

HE3: La gestión del mantenimiento con la implementación del Machine Learning mejoró en comparación con la situación anterior. Aceptada

---

HG: El Machine Learning influye positivamente en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L. Aceptada

---

Fuente: propia

## V. DISCUSIÓN

En esta sección se procedió a realizar la discusión de cada objetivo, sintetizando con los principales resultados que hay dentro del informe; asimismo, se apoyó y comparó los resultados encontrados con las teorías y literatura científica actual. Resaltando su valor porcentual y su relevancia final.

Por ello, las necesidades de la industria hacen del mantenimiento preventivo una parte importante de los esfuerzos de planificación, cuyo objetivo es maximizar la disponibilidad y el valor económico de la máquina desde el momento de la compra.

Según Rodríguez (2007) los análisis de fallas son estimados como una parte relevante dentro del diagnóstico de estos problemas fortuitos, inclusive el mantenimiento preventivo es clave para la operación correcta y progreso de las plantas industriales. Además, el transporte en general, incluida la maquinaria pesada, está sujeto a importantes cambios tecnológicos ya que los componentes necesarios para su crecimiento se encuentran a su vez con graves daños a equipos y maquinaria, todo ello materializado económicamente.

Este trabajo de investigación se efectuó en la EMPRESA MEKATSU EQUIPOS S.R.L., lugar que se encarga al mantenimiento y servicios relacionados a la mecánica de maquinarias pesadas, la mayoría de los trabajadores han manifestado tener problemas de sobrecostos y averías imprevistas en las maquinarias, siendo esto uno de los grandes problemas que afronta el establecimiento.

Respecto al objetivo específico 1, el diagnóstico del estado inicial de la gestión del mantenimiento actual con respecto a la confiabilidad y disponibilidad de las maquinarias pesadas en general de la EMPRESA MEKATSU EQUIPOS S.R.L., se logró demostrar un nivel de confiabilidad promedio inicial de las maquinarias pesadas de 21.15% el cual fue bajo y en la disponibilidad fue de un nivel promedio general del 49.93% antes de usar el Machine Learning, que también fue considerado bajo, puesto que se encuentra en el rango menor del 90%. Esto es contrastado con el estudio de Clemente y Martínez (2020) donde los resultados mostraron que la actual situación tuvo una confiabilidad inicial del 84%, y una disponibilidad de menor del 94%, llegando así a concluir que tanto la confiabilidad y disponibilidad se encuentran en un rango menor. De igual manera esta información es corroborado por el trabajo previo de Luna y Toledo (2019),

consiguieron un incremento de confiabilidad del 8%, a comparación previa el incremento fue del 9%. Esto revela lo significativo que fue contar con un plan de mantenimiento preventivo, ya que conjuntamente de aumentar el porcentaje de confiabilidad de las maquinarias también se alcanzó reducir el número de deterioros y optimizar la disponibilidad para que puedan efectuar sus funciones activas. Según Fernández et al. (2018) Confiabilidad está asociada con la confianza que se le proporciona a una máquina, sistema o parte de ella. Por ende, para que se pueda ejecutar determinadas funciones, se requiere un tiempo determinado de evaluación pre-establecimiento, siempre con las condiciones adecuadas y estándares para la organización. Asimismo, también es definida como la posibilidad que un activo pueda realizar su tarea bajo reglas establecidas en determinado tiempo. Y disponibilidad es la capacidad de algún equipo o máquina para ser empleado cuando se necesite. La disponibilidad es la medida del rendimiento de un mantenimiento realizado (Vega Acuña, 2017).

En relación con el objetivo específico 2, se logró elaborar la propuesta a través de un modelado, mediante ello permitió identificar y medir los diferentes tipos de fallas que ocurren en los equipos, mejorando así el nivel de conocimiento del personal técnico. Es contrastado con el estudio de De Los Ríos (2019) donde realizaron un modelamiento de mantenimiento predictivo de un motor eléctrico a través del uso de técnicas de inteligencia artificial en los equipos industriales del sistema SCADA – Ecuador, llegando a la conclusión de que el sistema se encontró apto para la predicción de fallas mecánicas, por ende, esto mejoró la competitividad de la empresa, así también la experiencia del cliente. Asimismo, Herrera (2019), elaboró un estudio sobre el impacto de las herramientas tecnológicas en la mejora de disponibilidad mecánica de equipos en la entidad CEMICON SA. El estudio concluyó que las herramientas implementadas ayudan considerablemente la capacidad de programación del mantenimiento predictivo, es decir, permite anticipar, evitar y minimizar el tiempo de intervención de posibles fallas.

De acuerdo al objetivo específico 3, Para la implementación del Machine Learning en la gestión de mantenimiento se realizó la demostración en donde se evidenció que la disponibilidad del equipo de cargador frontal tras la aplicación del ML obtuvo un incremento del 24.95% ya que anteriormente contaba con una disponibilidad del 49.34%, de la misma manera en cuanto a la confiabilidad del

equipo se obtuvo un incremento del 36.47, relacionado con la maquinaria retroexcavadora tuvo un incremento del 25.48% en su disponibilidad después de aplicarse el Machine Learning, que puede ser corroborado en la figura 15, en cuanto a la figura 16 muestra que la confiabilidad de la maquinaria retroexcavadora aumento un 35.24% después de aplicarse el Machine Learning, la maquinaria tractor de oruga aumentó su disponibilidad a 22.75% después de aplicarse el Machine Learning, la confiabilidad de la maquinaria aumentó un 34.79%. Asimismo, la maquinaria excavadora aumentó su disponibilidad a un 27.42% después de haberse aplicado el Machine Learning contando con una confiabilidad aumentada al 42.47%. Estos resultados son contrastados con el estudio de Barroso (2018) sobre un modelo predictivo basado en la tecnología Machine Learning, en el área de mantenimiento de equipos mineros. En la cual llegó a concluir un incremento promedio que fue de 85 % entre el antes y después en la disponibilidad y confiabilidad de maquinarias.

Por otro lado, también es corroborado por el estudio de Luján (2020), donde los resultados obtenidos, muestran la existencia de un incremento del 22%, lo cual quiere decir que se realizó de manera correcta la implementación del mantenimiento preventivo. Por ende, se concluyó que esto mejoró significativamente la competitividad empresarial, en conjunto con el ahorro de gastos. Asimismo, Moscoso y Yarin (2019) de acuerdo a sus resultados de su estudio concluyó que el Machine Learning cumple un rol muy fundamental en la empresa, dado que en los camiones mineros se redujo el tiempo de la clasificación de fallos, generando así rápida atención por parte del personal técnico, asimismo, aumentando la mejora de en el desarrollo del mantenimiento de la flota en las máquinas.

Finalmente, en relación con el objetivo general, evaluar la influencia del Machine Learning en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L. En las demostraciones estadísticas se pudo evidenciar que todas las hipótesis de investigación han sido aceptadas, lo que implica la influencia positiva del Machine Learning en la mejora de la disponibilidad y confiabilidad de las maquinarias pesadas. Esto es corroborado con el estudio de Castro y García (2020), donde concluyeron que la metodología y herramienta de Machine Learning ayuda a reducir el tiempo de clasificación de datos de fallas en equipos, así como también los tiempos muertos del personal,

por tanto, esta herramienta representa la eficiencia. De igual manera, en el estudio de Herrera (2019), donde concluyó que las herramientas implementadas de Machine Learning ayudan considerablemente la capacidad de programación del mantenimiento predictivo, es decir, permite anticipar, evitar o minimizar el tiempo de intervención de posibles fallas. Además, el aprendizaje automático (ML) desprende como un subconjunto de la IA, que construye una guía matemática basado en datos de muestra, conocidos como "datos de entrenamiento", para hacer pronósticos sin estar programados necesariamente al momento de ejecutar la tarea (Zhang, 2020).



## VI. CONCLUSIONES

1. Respecto al objetivo específico 1, el diagnóstico del estado inicial de la gestión del mantenimiento actual con respecto a la confiabilidad de las maquinarias pesadas de la EMPRESA MEKATSU EQUIPOS S.R.L., se logró evidenciar un nivel de confiabilidad promedio inicial de las maquinarias pesadas de 21.15% el cual fue bajo y en la disponibilidad fue de un nivel promedio general del 49.93% también bajo, ya que en el rango menor del 90% y entonces no fue confiable viéndose afectada su disponibilidad en la cantidad de horas de reparación en conjunto con el número de fallas.
2. En relación con el objetivo específico 2, se logró elaborar la propuesta a través de un modelado haciendo uso de diferentes algoritmos, a través de ello permitió identificar y medir los diferentes modos de falla que ocurren en el cargador frontal, reduciendo errores, tiempo de inactividad y bajando el costo del dinero; Por otro lado, este modelo permitió elevar el nivel de conocimiento de los empleados para actuar en situaciones de este tipo.
3. Respecto al objetivo específico 3, se logró evidenciar que tras la aplicación del ML, el cargador frontal obtuvo un incremento del 24.95% de la misma manera en cuanto a la confiabilidad del equipo se obtuvo un incremento del 36.47%, relacionado con la maquinaria retroexcavadora tuvo un incremento del 25.48% en su disponibilidad después de aplicarse el Machine Learning, mientras que la confiabilidad de la maquinaria retroexcavadora aumento un 35.24% después de aplicarse el Machine Learning, la maquinaria tractor de oruga aumentó su disponibilidad a 22.75% después de aplicarse el Machine Learning, la confiabilidad de la maquinaria aumentó un 34.79%. Asimismo, la maquinaria excavadora aumentó su disponibilidad a un 27.42% después de haberse aplicado el Machine Learning contando con una confiabilidad aumentada al 42.47%.
4. Finalmente, en relación con el objetivo general, se pudo evidenciar que el machine influyó significativamente en la gestión de mantenimiento, puesto que esta herramienta ayudó a predecir los fallos, averías de las maquinarias (cargador frontal, retroexcavadora, tractor de oruga y excavadora), permitiendo así a la empresa tomar decisiones en base a datos empíricos, de manera más ágil e inteligente.

## **VII. Recomendaciones**

1. Se recomienda aplicar otros algoritmos de aprendizaje automático a los datos históricos de las maquinarias pesadas con el fin de ampliar el panorama de predicción, ya que actualmente el modelo ha sido entrenado con escasa data obtenida a través de una sola máquina.
2. Se recomienda realizar estudios en entidades particulares y nacionales con relación a la gestión de mantenimiento para comprender mejor la situación de los equipos durante su operatividad.
3. Se recomienda realizar el correspondiente seguimiento e inspección periódica, utilizando herramientas de mantenimiento predictivo para optimizar el desempeño de las tareas de mantenimiento y lograr los resultados esperados, tendiendo a reducir los tiempos de inactividad, las pérdidas de tiempo, las cuales están directamente relacionadas con los mayores costos de cambio / reparación mayor y componentes costosos.
4. Se recomienda crear un modelo predictivo empleando más factores relacionados a la gestión de mantenimiento, como por ejemplo partes del equipo, años de uso.
5. Se recomienda hacer estudios sobre la utilización de algoritmos combinados diferentes al usado como por ejemplo cascading, stacking, con la finalidad de mejorar el modelo creado en base a solo un algoritmo.
6. Se recomienda crear un software inteligente que permita predecir las fallas de manera individual o por grupo de maquinarias y equipos.
7. Se recomienda la capacitación al personal con respecto al modelo construido, consiguiendo el compromiso de todos para fomentar el liderazgo y las habilidades del personal se traduce en la disponibilidad de todos los equipos, donde los beneficios económicos y rentables de tener una cantidad de máquinas en funcionamiento, más allá de eso, consideran tener una amplia gama de repuestos y accesorios esenciales.

## REFERENCIAS

- ALARCÓN, E., y MORA, B. J. *Modelo para la evaluación del riesgo crediticio para los clientes de las microfinancieras del Perú* [En línea]. C.F. Díaz Sánchez, dir. Tesis de pregrado. Universidad Peruana de Ciencias Aplicadas, 2020 [Consulta: 21 de setiembre de 2021]. Disponible en: [https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/650407/Alarc%C3%B3n\\_ME.pdf?sequence=1&isAllowed=y](https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/650407/Alarc%C3%B3n_ME.pdf?sequence=1&isAllowed=y).
- AVELLO MARTINEZ, R., y SEISDEDRO LOSA, A. El procesamiento estadístico con R en la investigación científica. *Medisur* [En línea]. Cuba: Universidad de Cienfuegos, 2017, **15**(5), pp. 583-586 [Consulta: 21 de setiembre de 2021]. ISSN 1727-897X. Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1727-897X2017000500001&lng=es&nrm=iso](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1727-897X2017000500001&lng=es&nrm=iso).
- BARROSO, J. *Modelo predictivo basado en machine learning de órdenes de trabajo riesgosas para mantenimiento de equipos mineros* [En línea]. I.A. Calisto Leyva, dir. Tesis de pregrado. Universidad de Chile, 2018 [Consulta: 20 de setiembre de 2021]. Disponible en: <http://repositorio.uchile.cl/handle/2250/170038>.
- BAVIERA, T. Técnicas para el Análisis de Sentimiento en Twitter: Aprendizaje Automático Supervisado y SentiStrength. *Revista DÍGITOS* [En línea]. España: Universidad de Valencia, 2017. **1**(3), pp.35-50 [Consulta: 21 de setiembre de 2021]. ISSN 2444-0132. Disponible en: <https://revistadigitos.com/index.php/digitos/article/view/74/39>.
- BETANCOURT, G. Las máquinas de soporte vectorial (SVMs). *Scientia Et Technica* [En línea]. Colombia: Universidad Tecnológica de Pereira, 2005. **11**(27), pp. 67-72 [Consulta: 21 de setiembre de 2021]. ISSN 0122-1701. Disponible en: [https://www.researchgate.net/publication/49588125\\_LAS\\_MAQUINAS\\_DE\\_SOPORTE\\_VECTORIAL\\_SVMs](https://www.researchgate.net/publication/49588125_LAS_MAQUINAS_DE_SOPORTE_VECTORIAL_SVMs).
- BRASA, P. *Análisis estadístico de datos para el mantenimiento predictivo de maquinaria industrial* [En línea]. J. Roca Pardiñas, dir. Tesis de maestría. Universidad de Vigo, 2019 [Consulta: 20 de setiembre de 2021]. Disponible en: [http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto\\_1564.pdf](http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_1564.pdf).

CABEZAS MEJÍA, E., NARANJO, A., y TORRES SANTAMARÍA, J. *Introducción a la metodología de la investigación científica* [En línea]. Ecuador: Universidad de las Fuerzas Armadas ESPE, 2018, pp. 1-38. [Consulta: 21 de setiembre de 2021]. ISBN 978-9942-765-44-4. Disponible en: <http://repositorio.espe.edu.ec/jspui/bitstream/21000/15424/1/Introduccion%20a%20la%20Metodologia%20de%20la%20investigacion%20cientifica.pdf>.

CASTELLANOS, L. *Técnica de Observación* [En línea]. Lc metodología investigación, 02 de marzo de 2017. [Consulta: 21 de setiembre de 2021]. Disponible en: <https://lcmetodologiainvestigacion.wordpress.com/2017/03/02/tecnica-de-observacion/>.

CASTRO, R., y GARCÍA, O. *Desarrollo de un sistema inteligente para la adecuada gestión de mantenimiento en una flota de máquinas PC4000-6* [En línea]. J.A. Yasektig Castillo, dir. Tesis de pregrado. Universidad de Piura, 2020 [Consulta: 20 de setiembre de 2021]. Disponible en: <https://pirhua.udep.edu.pe/handle/11042/4681>.

CERNUDA GONZÁLES, P. *Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada* [En línea]. E. Caro Huertas, dir. Tesis de maestría. Universidad Politécnica de Madrid, 2019 [Consulta: 20 de setiembre de 2021]. Disponible en: [https://oa.upm.es/65400/1/TFM\\_PAULA\\_CERNUDA\\_GONZALEZ.pdf](https://oa.upm.es/65400/1/TFM_PAULA_CERNUDA_GONZALEZ.pdf).

CLEMENTE, M., y MARTINEZ, J. *Plan de mantenimiento preventivo para incrementar la confiabilidad de las maquinarias pesadas en la empresa Grupo Señor de Pomallucay S.R.L., Huaraz – 2020* [En línea]. F. Vega Huincho, dir. Tesis de pregrado. Universidad César Vallejo, 2020. Consulta: 20 de setiembre de 2021]. Disponible en: <https://repositorio.ucv.edu.pe/handle/20.500.12692/57945>.

CUBA, C. *Propuesta de mejora para incrementar la disponibilidad de los equipos en el proceso de teñido, a través de un plan de mantenimiento en una empresa textil peruana* [En línea]. V.H. Núñez Ponce, dir. Tesis de pregrado. Universidad Peruana Ciencias Aplicadas, 2018 [Consulta: 27 de setiembre de 2021]. Disponible en: [https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/625854/Cuba\\_nc.pdf?sequence=3&isAllowed=y](https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/625854/Cuba_nc.pdf?sequence=3&isAllowed=y).

DAGNINO, J. Regresión lineal. *Rev. chil. anes* [En línea]. Chile: Pontificia Universidad Católica de Chile, 2014, **43**(2), pp. 143-149 [Consulta: 21 de setiembre de 2021]. ISSN 0719-6792. Disponible en: <https://revistachilenadeanestesia.cl/regresion-lineal/>.

DE LOS RÍOS, G. *Mantenimiento predictivo para la supervisión de motores eléctricos aplicando técnicas de inteligencia artificial* [En línea]. E.V. Mendoza Merchán, dir. Tesis de pregrado. Universidad Católica de Santiago de Guayaquil, 2019 [Consulta: 20 de setiembre de 2021]. Disponible en: <http://repositorio.ucsg.edu.ec/bitstream/3317/12635/1/T-UCSG-PRE-TEC-IECA-93.pdf>.

DEL POZO, C. *Mantenimiento predictivo en motores de inducción aplicando técnicas de inteligencia artificial y teoría de desequilibrios electromagnéticos* [En línea]. O. Duque Pérez, dir. Tesis de maestría. Universidad de Valladolid, 2018 [Consulta: 20 de setiembre de 2021]. Disponible en: <https://uvadoc.uva.es/handle/10324/32462>.

DULZAIDES, M., y MOLINA, A. Análisis documental y de información: dos componentes de un mismo proceso. *ACIMED* [En línea]. La Habana: Scielo, 2004. **4**(2), pp. 1-1 [Consulta: 21 de setiembre de 2021]. ISSN 1024-9435. Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1024-94352004000200011](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1024-94352004000200011).

GUEVARA, W., VALERA CÁRDENAS, A., Y GÓMEZ CAMPOS, J.A. Metodología para evaluar el factor confiabilidad en la gestión de proyectos de diseño de equipos industriales. *Tecnura* [En línea]. Colombia: Universidad Distrital Francisco José de Caldas, 2016, **19**, pp. 129-141. [Consulta: 20 de setiembre de 2021]. ISSN 2248-7638. Disponible en: <https://revistas.udistrital.edu.co/index.php/Tecnura/article/view/10379>.

HEAVEN32. *La importancia de la maquinaria pesada en la sociedad actual*. [En línea] Heaven32, 19 de octubre de 2019. [Consulta: 20 de setiembre de 2021]. Disponible en: <https://www.heaven32.com/estilo-vida/la-importancia-de-la-maquinaria-pesada-en-la-sociedad-actual/>.

HERNÁNDEZ, C., y CARPIO, N. Introducción a los tipos de muestreo. *Revista ALERTA*. El Salvador: Scielo, 2019. **2**(1): pp. 76-79. ISSN 2617-5274.

HERNÁNDEZ, R., FERNÁNDEZ, C., y BAPTISTA, M. *Metodología de la investigación* [En línea]. México: McGRAW-HILL Education, 2014, pp. 1-634.

[Consulta: 21 de setiembre de 2021]. ISBN 978-1-4562-2396-0. Disponible en:  
<http://observatorio.epacartagena.gov.co/wp-content/uploads/2017/08/metodologia-de-la-investigacion-sexta-edicion.compressed.pdf>.

HERRERA, W. *Impacto de las herramientas tecnológicas de gestión de equipos en la mejora de la disponibilidad mecánica de maquinaria pesada. Caso: CEMICON S.A.C* [En línea]. J. Ramos Quispe, dir. Tesis de maestría. Universidad Nacional de San Agustín De Arequipa, 2019 [Consulta: 20 de setiembre de 2021]. Disponible en:  
<http://repositorio.unsa.edu.pe/handle/UNSA/10830>.

HERRERA SÁNCHEZ, G., MORÁN BRAVO, L., GALLARDO NAVARRO, J., y SILVA JUÁREZ, A. Gestión del mantenimiento y la industria 4.0. *Revista de Ingeniería Innovativa*. Perú: Ecorfan, 2020. **4**(15), pp. 18-28. ISSN 2523-6873.

INAKUFU, A. *Diseño e Implementación de un Sistema de Diagnóstico de Fallas para la Inspección y Detección de Fallas en Componentes de Procesos Industriales utilizando un Robot Móvil y Algoritmos de Inteligencia Artificial* [En línea]. C.G. Pérez Zuñiga, dir. Tesis de maestría. Pontificia Universidad Católica del Perú, 2020 [Consulta: 20 de setiembre de 2021]. Disponible en:  
[https://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/17779/INAKUFU\\_YOSHIDA\\_ALBERTO\\_%20DISE%C3%91O\\_IMPLEMENTACI%C3%93N\\_SISTEMA.pdf?sequence=1&isAllowed=y](https://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/17779/INAKUFU_YOSHIDA_ALBERTO_%20DISE%C3%91O_IMPLEMENTACI%C3%93N_SISTEMA.pdf?sequence=1&isAllowed=y).

IZQUIERDO, A., BRAVO, L., CERUTO, T., y MARTÍN, D. Nuevos plugins para la herramienta Knime para el uso de sus flujos de trabajo desde otras aplicaciones. *Ciencias de la Información* [En línea]. La Habana: Instituto de Información Científica y Tecnológica, 2015, **46**(1), pp. 47-52 [Consulta: 21 de setiembre de 2021]. ISSN 0864-4659. Disponible en:  
<https://www.re.dalyc.org/pdf/1814/181439409007.pdf>.

KOTU, V., y DESHPANDE, B. (2019). Getting Started with RapidMiner. *En: Data Science. Concepts and Practice*. 2.<sup>a</sup> ed. 491–521. Elsevier, 2019. pp. 491-521. ISBN 978-0-12-814761-0.

LUJAN, J.C. *Aplicación del mantenimiento preventivo para mejorar laproductividad de la empresa Emcapsac, Lurín 2020* [En línea]. M.L. Delgado Montes, dir. Tesis de pregrado. Universidad César Vallejo, 2020 [Consulta: 20 de setiembre de 2021]. Disponible en:

[https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/55219/Lujan\\_MJC-SD.pdf?sequence=1&isAllowed=y](https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/55219/Lujan_MJC-SD.pdf?sequence=1&isAllowed=y).

LUNA, A.; TOLEDO, A. *Implementación de un plan de mantenimiento preventivo para incrementar la confiabilidad en las maquinarias de la empresa OSIMIN S.R.L. Huaraz – 2019* [En línea]. F. Vega Huincho, dir. Tesis de pregrado. Universidad Cesar Vallejo, 2019. Disponible en <http://repositorio.ucv.edu.pe/handle/UCV/26125?locale-attribute=es>

MEDINA, E. Análisis de fallas mecánicas en turbo cargadores. *Revista Venezolana de ciencia y tecnología*. Venezuela: Universidad Rafael Beloso Chacín, 2017, 7(2): pp. 14-30. ISSN 1856-4194.

MERCADO VERENA, J. B. Modelo de gestión de mantenimiento enfocado en la eficiencia y optimización de la energía eléctrica. *Saber. Revista Multidisciplinaria del Consejo de Investigación de la Universidad de Oriente* [en línea]. Cumaná: Universidad de Oriente, 2016, 28(1), pp. 99-105 [Consulta: 27 de septiembre de 2021]. ISSN 1315-0162. Disponible en: <https://www.redalyc.org/articulo.oa?id=427746276011>

OTZEN, T., y MANTEROLA, C. Técnicas de Muestreo sobre una Población a Estudio. *Int. J. Morphol* [En línea]. Chile: Scielo, 2017. 35(1), pp. 227-232 [Consulta: 21 de setiembre de 2021]. ISSN 0717-9502. Disponible en: [http://www.scielo.cl/scielo.php?script=sci\\_arttext&pid=S0717-95022017000100037&lng=es&nrm=iso](http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0717-95022017000100037&lng=es&nrm=iso).

PÉREZ RONDON, F.A. *Conceptos generales en la gestión del mantenimiento industrial* [En línea]. Bucaramanga: Universidad Santo Tomás, 2021, pp. 1-112. [Consulta: 21 de setiembre de 2021]. ISBN 978-958-8477-92-3. Disponible en: <https://repository.usta.edu.co/bitstream/handle/11634/33276/9789588477923.pdf?sequence=4&isAllowed=y>.

PÉREZ ALEGRÍA, J., y SUPO ROJAS. Gestión de mantenimiento para reducir costos en el área de electromecánica en el hospital regional Lambayeque. *Revista científica. Ing: ciencia, tecnología e innovación*. Lambayeque: Universidad de Sipán, 2018. 5(1), pp. 1-11. ISSN 2313-1926.

PERÚ21. 2020. *Contraloría advierte riesgo de inoperatividad en maquinaria para la ejecución de obras en Moquegua* [En línea] Redacción Perú21, 09 de diciembre de 2020. [Consulta el: 20 de setiembre de 2021]. Disponible en:

<https://peru21.pe/peru/moquegua-contraloria-advierte-riesgo-de-inoperatividad-en-maquinaria-para-la-ejecucion-de-obras-nnpp-noticia/?ref=p21r>.

PRANDO, R. *Manual de Gestión de Mantenimiento a la Medida*. San Salvador: Piedra Santa. 2001. 99pp. ISBN: 8483773996.

RIVAS, W., y MAZÓN, B. *Redes neuronales artificiales aplicadas al reconocimiento de patrones* [En línea]. Machala: UTMACH, 2017, [Consulta: 21 de setiembre de 2021]. ISBN: 978-9942-24-100-9. Disponible en: [https://www.researchgate.net/profile/Bertha-Mazon-Olivo/publication/327703478\\_Capitulo\\_1\\_Generalidades\\_de\\_las\\_redes\\_neuronales\\_artificiales/links/5b9fe3c0299bf13e6038a1d8/Capitulo-1-Generalidades-de-las-redes-neuronales-artificiales.pdf](https://www.researchgate.net/profile/Bertha-Mazon-Olivo/publication/327703478_Capitulo_1_Generalidades_de_las_redes_neuronales_artificiales/links/5b9fe3c0299bf13e6038a1d8/Capitulo-1-Generalidades-de-las-redes-neuronales-artificiales.pdf).

RODRÍGUEZ, C. *Análisis de Modos y Efectos de Falla para el mantenimiento de la flota de servicio pesado en empresa minera* [En línea]. Tesis de pregrado. Universidad del Zulia, 2007 [Consulta: 20 de setiembre de 2021]. Disponible en: <http://ojs.urbe.edu/index.php/revecitec/article/view/3022/4130>.

ROMERO BRACO, G., MACGLUF, A., ESPINOZA, J., y SUÁREZ, A. Aplicación de Machine Learning en la industria 4.0 en tiempos de pandemia. *Interconectando Saberes*. México: Universidad Veracruzana, 2021. 6(11): pp. 1-7. ISSN 2448-8704.

RUIZ RUANO, A., LÓPEZ PUGA, J., y DELGADO-MORÁN, J. El componente social de la amenaza híbrida y su detección con modelos bayesianos. *URVIO, Revista Latinoamericana de Estudios de Seguridad*. España: Universidad Católica de Murcia, 2019. (25): pp. 57-69. ISSN 1390-4299.

SALGADO, Y., MARTÍNEZ, A., y SANTOS, A. Programación del mantenimiento preventivo de generadores de sistemas de potencia con presencia eólica. *Ingeniería Energética* [En línea]. La Habana: Instituto Superior Politécnico José A. Echeverría. Cujae, 2018. 34, pp. 157-167 [Consulta: 27 de setiembre de 2021]. ISSN 1815-5901. Disponible en: <https://www.redalyc.org/journal/3291/329158816003/html/>.

SÁNCHEZ BRACHO, M., FERNÁNDEZ, M., y DÍAZ, J. Técnicas e instrumentos de recolección de información: análisis y procesamiento realizado por el investigador cualitativa. *Revista Científica UISRAEL*. Ecuador: Universidad Tecnológica Israel, 2021. 8(1): pp. 107-121. ISSN 2631-2786.



SULLA-TORRES, J.; GOMEZ-CAMPOS, R. y COSSIO-BOLANOS, M.A. Aplicación de un árbol de decisión difusa con clasificación de ambigüedad para determinar el exceso de peso en escolares. *Rev. mex. ing. Bioméd.* La Habana: Instituto de Información Científica y Tecnológica, 2021. **39**(2): pp.128-143. ISSN 0864-4659.

VEGA ACUÑA, A. *Implementación del Mantenimiento Preventivo para mejorar la disponibilidad de la maquinaria en la Empresa Grúas América S.A.C. Santa Anita, 2017* [En línea]. C.E. Céspedes Blanco, dir. Tesis de pregrado. Universidad César Vallejo, 2017 [Consulta: 20 de setiembre de 2021]. Disponible en: <https://hdl.handle.net/20.500.12692/1978>.

VITE CEVALLOS, H., CARVAJAL ROMERO, H., y BARREZUETA UNDA, S. Aplicación de algoritmos de aprendizaje automático para clasificar la fertilidad de un suelo bananero. *Conrado* [En línea]. Cuba: Universo Sur, 2020. **16**(72), pp.15-19 [Consulta: 21 de setiembre de 2021]. ISSN 2519-7320. Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1990-86442020000100015&lng=es&nrm=iso](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442020000100015&lng=es&nrm=iso).

YAO, X., y LIU, Y. *Aprendizaje automático. Metodologías de búsqueda* [En línea]. Boston: Springer, 2014, pp. 477-517. [Consulta: 20 de setiembre de 2021]. ISBN 978-1-4614-6940-7. Disponible en: [https://link.springer.com/chapter/10.1007/978-1-4614-6940-7\\_17#citeas](https://link.springer.com/chapter/10.1007/978-1-4614-6940-7_17#citeas).

ZHANG, X-D. *Aprendizaje automático. En: Un enfoque de álgebra matricial para la inteligencia artificial* [En línea]. Singapur: Springer, 2020, pp. 223-440. [Consulta: 20 de setiembre de 2021]. ISBN 978-981-15-2770-8. Disponible en: [https://link.springer.com/chapter/10.1007/978-981-15-2770-8\\_6#citeas](https://link.springer.com/chapter/10.1007/978-981-15-2770-8_6#citeas)

## ANEXOS

### ANEXO N° 1: MATRIZ DE CONSISTENCIA

**Tabla 41: Matriz de consistencia**

Título	Problema	Objetivos	Hipótesis	Variable	Definición conceptual	Definición operacional	Indicadores	Escala de medición
Machine Learning en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L."	<b>General</b>	<b>General</b>	<b>General</b>	<b>Independiente</b>				
	¿Cómo influye el Machine Learning en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L.?	Evaluar la influencia del Machine Learning en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU S.R.L.	El Machine Learning influye positivamente en la gestión de mantenimiento de maquinaria pesada en la EMPRESA MEKATSU EQUIPOS S.R.L.					
	<b>Específicos</b>	<b>Específicos</b>	<b>Específicos</b>	<b>Dependiente</b>				

Fuente: Elaboración propia.

¿Cómo es la gestión actual en la EMPRESA MEKATSU EQUIPOS S.R.L.? ¿La propuesta de la implementación del Machine Learning ayudará a medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L.? ¿Cómo se encuentra la gestión del mantenimiento con la implementación del Machine Learning en comparación	Determinar la gestión de mantenimiento actual en la EMPRESA MEKATSU EQUIPOS S.R.L. Elaborar la propuesta de la implementación del Machine Learning para medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS SRL. Determinar la gestión del mantenimiento con la implementación del Machine Learning para comparar la situación anterior en la EMPRESA MEKATSU EQUIPOS S.R.L.	La gestión actual en la EMPRESA MEKATSU EQUIPOS S.R.L. se encuentra en pésimas condiciones. La propuesta de la implementación del Machine Learning ayuda a medir la gestión del mantenimiento en la EMPRESA MEKATSU EQUIPOS S.R.L. La gestión del mantenimiento con la implementación del Machine Learning mejoró en comparación con la situación anterior	Gestión de mantenimiento	La gestión de mantenimiento permite conseguir el rendimiento máximo requerido de los equipos y activos de una entidad logrando así llegar a las metas trazadas; con la máxima calidad, seguridad y a un mínimo costo. Asimismo, los mantenimientos se clasifican en tres tipos principales: Mantenimiento preventivo, predictivo y correctivo (Prando, 2001; Pérez Rondón, 2021).	Se emplearon una ficha de registro Excel, y fichas de observación de métricas de precisión, que permitieron conocer la mejora en la gestión de mantenimiento de maquinarias de la empresa MEKATSU EQUIPOS S.R.L.	Razón
					$D = \frac{MTBF - MTT}{MTBF} \times 100$	
					$(t) = e^{-\lambda t}$	

---

con la situación  
anterior?

---

## ANEXO N° 2: OPERACIONALIZACIÓN DE VARIABLES

**Tabla 42:** *Matriz de operacionalización de variable*

Variable	Definición conceptual	Definición Operacional	Indicadores	Escala de medición
<p><b>Independiente:</b></p> <p>Machine Learning</p>	<p>El aprendizaje automático (ML) es un subconjunto de la inteligencia artificial, que construye un modelo matemático basado en datos de muestra, conocidos como "datos de entrenamiento", para hacer predicciones o decisiones sin estar programados explícitamente para realizar la tarea (Zhang, 2020).</p>			
<p><b>Dependiente:</b></p> <p>Gestión de mantenimiento</p>	<p>La gestión de mantenimiento permite conseguir el rendimiento máximo requerido de los equipos y activos de una entidad logrando así llegar a las metas trazadas; con la máxima calidad, seguridad y a un mínimo costo. Asimismo, los mantenimientos se clasifican en tres tipos principales: Mantenimiento preventivo, predictivo y correctivo (Prando, 2001; Pérez Rondón, 2021).</p>	<p>Se emplearon una ficha de registro Excel, y fichas de observación de métricas de precisión, que permitieron conocer la mejora en la gestión de mantenimiento de</p>	$D = \frac{T_o}{T_o + T_p}$  $(t) = e^{-\lambda t}$	<p>Razón</p>

---

maquinarias de la empresa  
MEKATSU EQUIPOS S.R.L.

---

Fuente: Elaboración propia.







## VALIDACION DE INSTRUMENTO

### EXPERTO 1

**Apellidos y Nombre del experto:** Daza Vergaray Alfredo

**Título y/o grado:** Dr. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					98
Objetividad	Esta expresado en conducta observable.					98
Actualidad	Es adecuado al avance de la ciencia.					98
Organización	Existe una organización lógica					98
Suficiencia	Comprende los aspectos de cantidad y calidad.					98
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					98
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					98
Pertinencia	El instrumento es adecuado al tipo de investigación.					98

Promedio de Validación					98
------------------------	--	--	--	--	----

Promedio de valoración: 98

Observaciones: Ninguna



FIRMA

## EXPERTO 2

**Apellidos y Nombre del experto:** Lavado Canchachi Rodolfo Adán

**Título y/o grado:** Ing. Mecánico

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

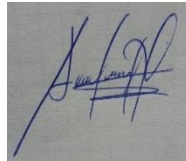
**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					96
Objetividad	Esta expresado en conducta observable.					96
Actualidad	Es adecuado al avance de la ciencia.					96
Organización	Existe una organización lógica					96
Suficiencia	Comprende los aspectos de cantidad y calidad.					96
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					96
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
Coherencia	Está basado en aspectos teóricos, científicos					96

	acordes a la tecnología educativa.					
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					96
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					96
<b>Promedio de Validación</b>						96

Promedio de valoración: 96

Observaciones: Ninguna



FIRMA

### EXPERTO 3

**Apellidos y Nombre del experto:** Suárez Rebaza, Camilo Ernesto

**Título y/o grado:** Mg. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51-70%	Muy Bueno 71-80%	Excelente 81-100%
<b>Claridad</b>	Promedio de Validación					97
<b>Objetividad</b>	Esta expresado en conducta observable.					97
<b>Actualidad</b>	Es adecuado al avance de la ciencia.					97

<b>Organización</b>	Existe una organización lógica					97
<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					97
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					97
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					97
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					97
<b>Promedio de Validación</b>						97

Promedio de valoración: 97

Observaciones: Ninguna



FIRMA

## ANEXO N° 4: INSTRUMENTO DE OBSERVACIÓN PARA EL ALGORITMO SVM - FICHA DE REGISTRO

Tipo de Prueba	Post Test
Empresa Investigada	
Investigador	
Fecha de inicio	

Algoritmo	SVM
-----------	-----

Matriz de confusión:

		Predicción	
		Positive	Negative
Observación	Positive	(TP) True Positive	(FN) False Negative
	Negative	(FP) False Positive	(TN) True Negative

Métricas a Evaluar:

Ítem	Indicador	Medida	Fórmula	Precisión
1	Precisión (exactitud)	Razón	Accuracy = $(TP+TN/TP+TN+FP+FN)$ * 100	
2	Especificidad	Razón	Especificidad = $(TN/TN+FP)$ * 100	
3	Sensibilidad	Razón	Sensibilidad = $(TP/TP+FN)$ * 100	

Otras Métricas:

Ítem	Indicador	Medida	Fórmula	Precisión
1	F 1 SCORE	Razón	$2 * (\text{Recall} * \text{Precisión}) / (\text{Recall} + \text{Precisión})$	

**ANEXO N° 5: VALIDACIÓN DE INSTRUMENTOS**  
**EXPERTO 1**

**Apellidos y Nombre del experto:** Daza Vergaray Alfredo

**Título y/o grado:** Dr. Ing. de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					98
Objetividad	Esta expresado en conducta observable.					98
Actualidad	Es adecuado al avance de la ciencia.					98
Organización	Existe una organización lógica					98
Suficiencia	Comprende los aspectos de cantidad y calidad.					98
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					98
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					98

<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					98
<b>Promedio de Validación</b>						98

Promedio de valoración: 98

Observaciones: Ninguna



FIRMA

**EXPERTO 2**

**Apellidos y Nombre del experto:** Lavado Canchachi Rodolfo Adán

**Título y/o grado:** Ing. Mecánico.

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

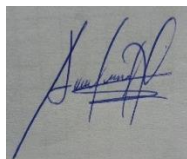
**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51-70%	Muy Bueno 71-80%	Excelente 81-100%
<b>Claridad</b>	Promedio de Validación					96
<b>Objetividad</b>	Esta expresado en conducta observable.					96
<b>Actualidad</b>	Es adecuado al avance de la ciencia.					96
<b>Organización</b>	Existe una organización lógica					96
<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					96
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					96
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos					96

	acordes a la tecnología educativa.					
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					96
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					96
<b>Promedio de Validación</b>						96

Promedio de valoración: 96

Observaciones: Ninguna



FIRMA

### EXPERTO 3

**Apellidos y Nombre del experto:** Suárez Rebaza, Camilo Ernesto

**Título y/o grado:** Mg. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51-70%	Muy Bueno 71-80%	Excelente 81-100%
<b>Claridad</b>	Promedio de Validación					97
<b>Objetividad</b>	Esta expresado en conducta observable.					97
<b>Actualidad</b>	Es adecuado al avance de la ciencia.					97



<b>Organización</b>	Existe una organización lógica					97
<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					97
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					97
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					97
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					97
<b>Promedio de Validación</b>						97

Promedio de valoración: 97

Observaciones: Ninguna



\_\_\_\_\_  
FIRMA

### **ANEXO N° 6: INSTRUMENTO DE OBSERVACIÓN PARA EL ALGORITMO ÁRBOL DE DECISIÓN - FICHA DE REGISTRO**

Tipo de Prueba	Post Test
Empresa Investigada	
Investigador	
Fecha de inicio	

Algoritmo	Árbol de decisión
-----------	-------------------

Matriz de confusión:

		Predicción	
		Positive	Negative
Observación	Positive	(TP) True Positive	(FN) False Negative
	Negative	(FP) False Positive	(TN) True Negative

Métricas a Evaluar:

Ítem	Indicador	Medida	Fórmula	Precisión
1	Precisión (exactitud)	Razón	Accuracy = $(TP+TN/TP+TN+FP+FN)$ * 100	
2	Especificidad	Razón	Especificidad = $(TN/TN+FP)$ * 100	
3	Sensibilidad	Razón	Sensibilidad = $(TP/TP+FN)$ * 100	

## ANEXO N° 7: VALIDACIÓN DE INSTRUMENTOS

### Experto 1

**Apellidos y Nombre del experto:** Daza Vergaray Alfredo

**Título y/o grado:** Dr. Ing. de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					98
Objetividad	Esta expresado en conducta observable.					98
Actualidad	Es adecuado al avance de la ciencia.					98
Organización	Existe una organización lógica					98
Suficiencia	Comprende los aspectos de cantidad y calidad.					98
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					98
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					98
Pertinencia	El instrumento es adecuado al tipo de investigación.					98

Promedio de Validación					98
------------------------	--	--	--	--	----

Promedio de valoración: 98

Observaciones: Ninguna



FIRMA

### Experto 2

**Apellidos y Nombre del experto:** Lavado Canchachi Adan

**Título y/o grado:** Ing. Mecánico.

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

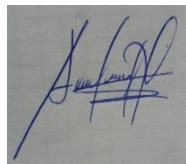
**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					96
Objetividad	Esta expresado en conducta observable.					96
Actualidad	Es adecuado al avance de la ciencia.					96
Organización	Existe una organización lógica					96
Suficiencia	Comprende los aspectos de cantidad y calidad.					96
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					96
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96

<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					96
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					96
<b>Promedio de Validación</b>						96

Promedio de valoración: 96

Observaciones: Ninguna



FIRMA

### Experto 3

**Apellidos y Nombre del experto:** Suárez Rebaza, Camilo Ernesto

**Título y/o grado:** Mg. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
<b>Claridad</b>	Promedio de Validación					97
<b>Objetividad</b>	Esta expresado en conducta observable.					97
<b>Actualidad</b>	Es adecuado al avance de la ciencia.					97
<b>Organización</b>	Existe una organización lógica					97

<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					97
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					97
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					97
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					97
<b>Promedio de Validación</b>						97

Promedio de valoración: 97

Observaciones: Ninguna



\_\_\_\_\_  
FIRMA

### ANEXO N° 8: INSTRUMENTO DE OBSERVACIÓN PARA EL ALGORITMO KNN - FICHA DE REGISTRO

Tipo de Prueba	Post Test
Empresa Investigada	
Investigador	
Fecha de inicio	

Algoritmo	K-NN
-----------	------

Matriz de confusión:

		Predicción	
		Positive	Negative
Observación	Positive	(TP) True Positive	(FN) False Negative
	Negative	(FP) False Positive	(TN) True Negative

Métricas a Evaluar:

Ítem	Indicador	Medida	Fórmula	Precisión
1	Precisión (exactitud)	Razón	Accuracy = $(TP+TN/TP+TN+FP+FN)$ * 100	
2	Especificidad	Razón	Especificidad = $(TN/TN+FP)$ * 100	
3	Sensibilidad	Razón	Sensibilidad = $(TP/TP+FN)$ * 100	

## ANEXO N° 9: VALIDACIÓN DE INSTRUMENTO

### Experto 1

**Apellidos y Nombre del experto:** Daza Vergaray Alfredo

**Título y/o grado:** Dr. Ing de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					98
Objetividad	Esta expresado en conducta observable.					98
Actualidad	Es adecuado al avance de la ciencia.					98
Organización	Existe una organización lógica					98

<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					98
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					98
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					98
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					98
<b>Promedio de Validación</b>						98

Promedio de valoración: 98

Observaciones: Ninguna



FIRMA

## Experto 2

**Apellidos y Nombre del experto:** Lavado Canchachi Rodolfo Adán

**Título y/o grado:** Ing. Mecánico.

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

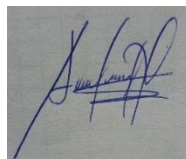
**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.



INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					96
Objetividad	Esta expresado en conducta observable.					96
Actualidad	Es adecuado al avance de la ciencia.					96
Organización	Existe una organización lógica					96
Suficiencia	Comprende los aspectos de cantidad y calidad.					96
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					96
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					96
Pertinencia	El instrumento es adecuado al tipo de investigación.					96
<b>Promedio de Validación</b>						96

Promedio de valoración: 96

Observaciones: Ninguna



FIRMA

**Experto 3**

**Apellidos y Nombre del experto:** Suárez Rebaza, Camilo Ernesto

**Título y/o grado:** Mg. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					97
Objetividad	Esta expresado en conducta observable.					97
Actualidad	Es adecuado al avance de la ciencia.					97
Organización	Existe una organización lógica					97
Suficiencia	Comprende los aspectos de cantidad y calidad.					97
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					97
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					97
Pertinencia	El instrumento es adecuado al tipo de investigación.					97
<b>Promedio de Validación</b>						97

Promedio de valoración: 97

Observaciones: Ninguna



FIRMA

**ANEXO N° 10: INSTRUMENTO DE OBSERVACIÓN PARA EL ALGORITMO  
Redes Bayesianas - FICHA DE REGISTRO**

Tipo de Prueba	Post Test
Empresa Investigada	
Investigador	
Fecha de inicio	

Algoritmo	K-NN
-----------	------

Matriz de confusión:

		Predicción	
		Positive	Negative
Observación	Positive	(TP) True Positive	(FN) False Negative
	Negative	(FP) False Positive	(TN) True Negative

Métricas a Evaluar:

Ítem	Indicador	Medida	Fórmula	Precisión
1	Precisión (exactitud)	Razón	$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} * 100$	
2	Especificidad	Razón	$Especificidad = \frac{TN}{TN+FP} * 100$	
3	Sensibilidad	Razón	$Sensibilidad = \frac{TP}{TP+FN} * 100$	

## ANEXO N° 11: VALIDACIÓN DE INSTRUMENTO

### Experto 1

**Apellidos y Nombre del experto:** Daza Vergaray Alfredo

**Título y/o grado:** Dr. Ing de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					98
Objetividad	Esta expresado en conducta observable.					98
Actualidad	Es adecuado al avance de la ciencia.					98
Organización	Existe una organización lógica					98
Suficiencia	Comprende los aspectos de cantidad y calidad.					98
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					98
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					98
Pertinencia	El instrumento es adecuado al tipo de investigación.					98

Promedio de Validación					98
------------------------	--	--	--	--	----

Promedio de valoración: 98

Observaciones: Ninguna



Firma

### Experto 2

**Apellidos y Nombre del experto:** Lavado Canchachi Rodolfo Adán

**Título y/o grado:** Ing. Mecánico

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

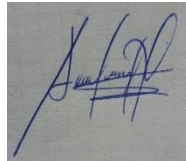
**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					96
Objetividad	Esta expresado en conducta observable.					96
Actualidad	Es adecuado al avance de la ciencia.					96
Organización	Existe una organización lógica					96
Suficiencia	Comprende los aspectos de cantidad y calidad.					96
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					96
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
Coherencia	Está basado en aspectos teóricos, científicos					96

	acordes a la tecnología educativa.					
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					96
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					96
<b>Promedio de Validación</b>						96

Promedio de valoración: 96

Observaciones: Ninguna



—  
Firma

**Experto 3**

**Apellidos y Nombre del experto:** Suárez Rebaza, Camilo Ernesto

**Título y/o grado:** Mg. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
<b>Claridad</b>	Promedio de Validación					97
<b>Objetividad</b>	Esta expresado en conducta observable.					97
<b>Actualidad</b>	Es adecuado al avance de la ciencia.					97
<b>Organización</b>	Existe una organización lógica					97
<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					97

<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					97
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					97
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					97
<b>Promedio de Validación</b>						97

Promedio de valoración: 97

Observaciones: Ninguna



\_\_\_\_\_  
Firma

## ANEXO N° 12: INSTRUMENTO DE OBSERVACIÓN PARA EL ALGORITMO Redes Neuronales - FICHA DE REGISTRO

Tipo de Prueba	Post Test
Empresa Investigada	
Investigador	
Fecha de inicio	

Algoritmo	K-NN
-----------	------

Matriz de confusión:

		Predicción
--	--	------------

		Positive	Negative
Observación	Positive	(TP) True Positive	(FN) False Negative
	Negative	(FP) False Positive	(TN) True Negative

Métricas a Evaluar:

Ítem	Indicador	Medida	Fórmula	Precisión
1	Precisión (exactitud)	Razón	Accuracy = $(TP+TN/TP+TN+FP+FN)$ * 100	
2	Especificidad	Razón	Especificidad = $(TN/TN+FP)$ * 100	
3	Sensibilidad	Razón	Sensibilidad = $(TP/TP+FN)$ * 100	

## ANEXO N° 13: VALIDACIÓN DE INSTRUMENTO

### Experto 1

**Apellidos y Nombre del experto:** Daza Vergaray Alfredo

**Título y/o grado:** Dr. Ing Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					98
Objetividad	Esta expresado en conducta observable.					98
Actualidad	Es adecuado al avance de la ciencia.					98
Organización	Existe una organización lógica					98



<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					98
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					98
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					98
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					98
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					98
<b>Promedio de Validación</b>						98

Promedio de valoración: 98

Observaciones:



Firma

### Experto 2

**Apellidos y Nombre del experto:** Lavado Canchachi Rodolfo Adán

**Título y/o grado:** Ing. Mecánico

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

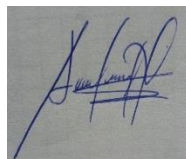
**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

INDICADORES	CRITERIOS	Deficiente 0-20%	Regular 21-50%	Bueno 51- 70%	Muy Bueno 71-80%	Excelente 81-100%
Claridad	Promedio de Validación					96
Objetividad	Esta expresado en conducta observable.					96
Actualidad	Es adecuado al avance de la ciencia.					96
Organización	Existe una organización lógica					96
Suficiencia	Comprende los aspectos de cantidad y calidad.					96
Intencionalidad	Adecuado para valorar aspectos del sistema metodológico y científico					96
Consistencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
Coherencia	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					96
Metodología	Responde al propósito del trabajo bajo los objetivos a lograr					96
Pertinencia	El instrumento es adecuado al tipo de investigación.					96
<b>Promedio de Validación</b>						96

Promedio de valoración: 96

Observaciones:



\_\_\_\_\_  
Firma

**Experto 3**

**Apellidos y Nombre del experto:** Suárez Rebaza, Camilo Ernesto

**Título y/o grado:** Mg. Ingeniería de Sistemas

**Fecha:**

**Nombre del instrumento:** Ficha de Registro

**Autor:**

**Título de investigación:** Machine Learning para la mejora en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.

<b>INDICADORES</b>	<b>CRITERIOS</b>	<b>Deficiente 0-20%</b>	<b>Regular 21-50%</b>	<b>Bueno 51- 70%</b>	<b>Muy Bueno 71-80%</b>	<b>Excelente 81-100%</b>
<b>Claridad</b>	Promedio de Validación					97
<b>Objetividad</b>	Esta expresado en conducta observable.					97
<b>Actualidad</b>	Es adecuado al avance de la ciencia.					97
<b>Organización</b>	Existe una organización lógica					97
<b>Suficiencia</b>	Comprende los aspectos de cantidad y calidad.					97
<b>Intencionalidad</b>	Adecuado para valorar aspectos del sistema metodológico y científico					97
<b>Consistencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Coherencia</b>	Está basado en aspectos teóricos, científicos acordes a la tecnología educativa.					97
<b>Metodología</b>	Responde al propósito del trabajo bajo los objetivos a lograr					97
<b>Pertinencia</b>	El instrumento es adecuado al tipo de investigación.					97
<b>Promedio de Validación</b>						97

Promedio de valoración: 97

Observaciones:

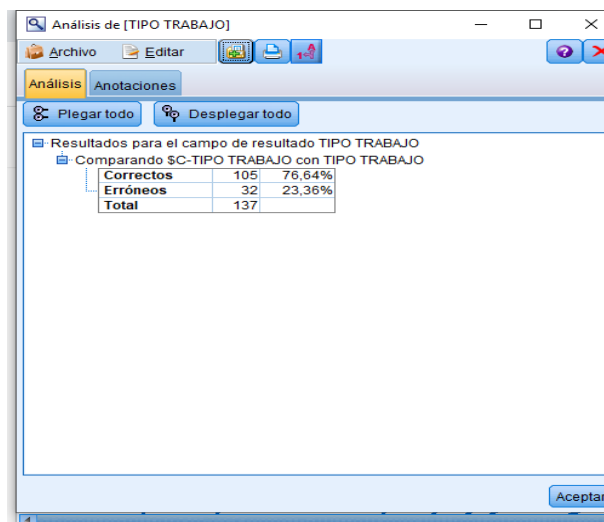


Firma

## ANEXO N° 14: RESULTADOS DE LOS ALGORITMOS UTILIZADOS EN EL MODELO

En esta sección se presenta los resultados de precisión conseguidos por cada algoritmo referente a la aplicación del Machine Learning para mejorar la gestión del área de mantenimiento.

**Árbol de decisión c5.0 – Precisión:** con respecto al modelo se obtuvo una precisión del 76,64% que representa 105 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 32 datos que representan el 23,36%.



Resultados para el campo de resultado TIPO TRABAJO		
Comparando SC-TIPO TRABAJO con TIPO TRABAJO		
Correctos	105	76,64%
Erróneos	32	23,36%
Total	137	

Figura 38: Algoritmo-Árbol de decisión c5.0

**Redes neuronales – Precisión:** respecto al modelo se obtuvo una precisión del 53,28% que representa 73 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 64 datos que representan el 46,72%.

Resultados para el campo de resultado TIPO TRABAJO		
Comparando SN-TIPO TRABAJO con TIPO TRABAJO		
Correctos	73	53,28%
Erróneos	64	46,72%
Total	137	

Figura 39: Algoritmo-Redes neuronales

**Algoritmo SVM – Precisión:** respecto al modelo se obtuvo una precisión del 100% que representa 137 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 0 datos que representan el 0%.

Resultados para el campo de resultado TIPO TRABAJO		
Comparando SS-TIPO TRABAJO con TIPO TRABAJO		
Correctos	137	100%
Erróneos	0	0%
Total	137	

Figura 40: Algoritmo-SVM

**Redes bayesianas – Precisión:** respecto al modelo se obtuvo una precisión del 100% que representa 137 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 0 datos que representan el 0%.

Resultados para el campo de resultado TIPO TRABAJO		
Comparando \$S-TIPO TRABAJO con TIPO TRABAJO		
Correctos	137	100%
Erróneos	0	0%
<b>Total</b>	<b>137</b>	

Figura 41: Algoritmo-Redes bayesianas

**Algoritmos vecinos más cercanos – Precisión:** respecto al modelo se obtuvo una precisión del 86.13% que representa 118 datos, en la cual se identifica de manera correcta las fallas mecánicas, así mismo el error fue de 19 datos que representan el 19%.

Resultados para el campo de resultado TIPO TRABAJO		
Comparando \$KNN-TIPO TRABAJO con TIPO TRABAJO		
Correctos	118	86.13%
Erróneos	19	13.87%
<b>Total</b>	<b>137</b>	

Figura 42: Algoritmo-Vecinos más cercanos

## ANEXO N° 15: FICHA DE REGISTRO DE LA EMPRESA MEKATSU S.R.L

En esta sección se presenta el registro a detalle los datos de la máquina cargadora frontal, tales como: El modelo, meses, número de fallas, horas periodo, horas operadas, MTBF, MTRR, disponibilidad y confiabilidad.

Figura 43: Registro y resumen de la carga frontal de la empresa MEKATSU S.R.L.

REPORTE DIARIO 2021 MEKATSU disponibilidad-confiabilidad\_antes\_despues\_modificado [Modo de compatibilidad] - Excel


	A	B	C	D	E	F	G	H	I	J	K	L	M
1	Antes de la implementacion del machine learning												
2													
3													
4	<b>Familia</b>	<b>Modelo</b>	<b>Meses</b>	<b>Horas correctivas</b>	<b># fallas</b>	<b>Horas periodo</b>	<b>Horas operadas</b>	<b>MTBF</b>	<b>MTTR</b>	<b>Disponibilidad (%)</b>	<b>Confiabilidad (%)</b>		
5	cargador frontal	966H	Sem1-May	210	30	600	390	13	7	65	62		
6	cargador frontal	966H	Sem2-May	288	48	600	312	7	6	52	55		
7	cargador frontal	966H	Sem3-May	275	55	600	325	6	5	54	56		
8	cargador frontal	966H	Sem4-May	250	60	600	350	6	4	58	59		
9	cargador frontal	966H	Sem1-Jun	240	68	600	360	5	4	60	60		
10	cargador frontal	966H	Sem2-Jun	400	70	600	200	3	6	33	39		
11	cargador frontal	966H	Sem3-Jun	360	66	600	240	4	5	40	46		
12	cargador frontal	966H	Sem4-Jun	240	53	600	360	7	5	60	60		
13	cargador frontal	966H	Sem1-Jul	300	49	600	300	6	6	50	54		
14	cargador frontal	966H	Sem2-Jul	240	57	600	360	6	4	60	60		
15	cargador frontal	966H	Sem3-Jul	240	66	600	360	5	4	60	60		
16	cargador frontal	966H	Sem4-Jul	240	60	600	360	6	4	60	60		
17													
18	Despues de la implementacion del machine learning												

## ANEXO N° 16: MAQUINA DE LA EMPRESA MEKATSU S.R.L

En este anexo, se muestran las fotos y evidencias de la cargadora frontal. El cargador frontal es un equipo tractor, montado en orugas o en ruedas, que tiene una cuchara de gran tamaño en su extremo frontal., asimismo, se puede visualizar que el personal técnico está en plena reparación, originada por las fallas frecuentes de lubricación, fallas de encendido (motores), mangueras agrietadas, fugas de fluidos, etc.



*Figura 44: Reparación de motor*



*Figura 45: Reparación de mangueras*





*Figura 46: Reparación de mangueras (Parte 2)*



*Figura 47: Pruebas correctivas*



*Figura 48: Pruebas correctivas (Parte 2)*



*Figura 49: Pruebas por parte del personal de mantenimiento*



*Figura 50: Retroexcavadora*

## ANEXO N° 17: ESQUEMA LÓGICO DE LA PREDICCIÓN DEL MACHINE LEARNING

En este anexo, se muestra el esquema lógico de la predicción del Machine Learning, después de seleccionar la relación de equipos, el programa realiza la data de entrenamiento con los datos históricos recopilados de todos los sistema de los equipos independientemente para luego ser procesado con apoyo del modelo de algoritmo y posteriormente realizar la combinación y clasificación de los datos para que al final nos de la predicción de falla.

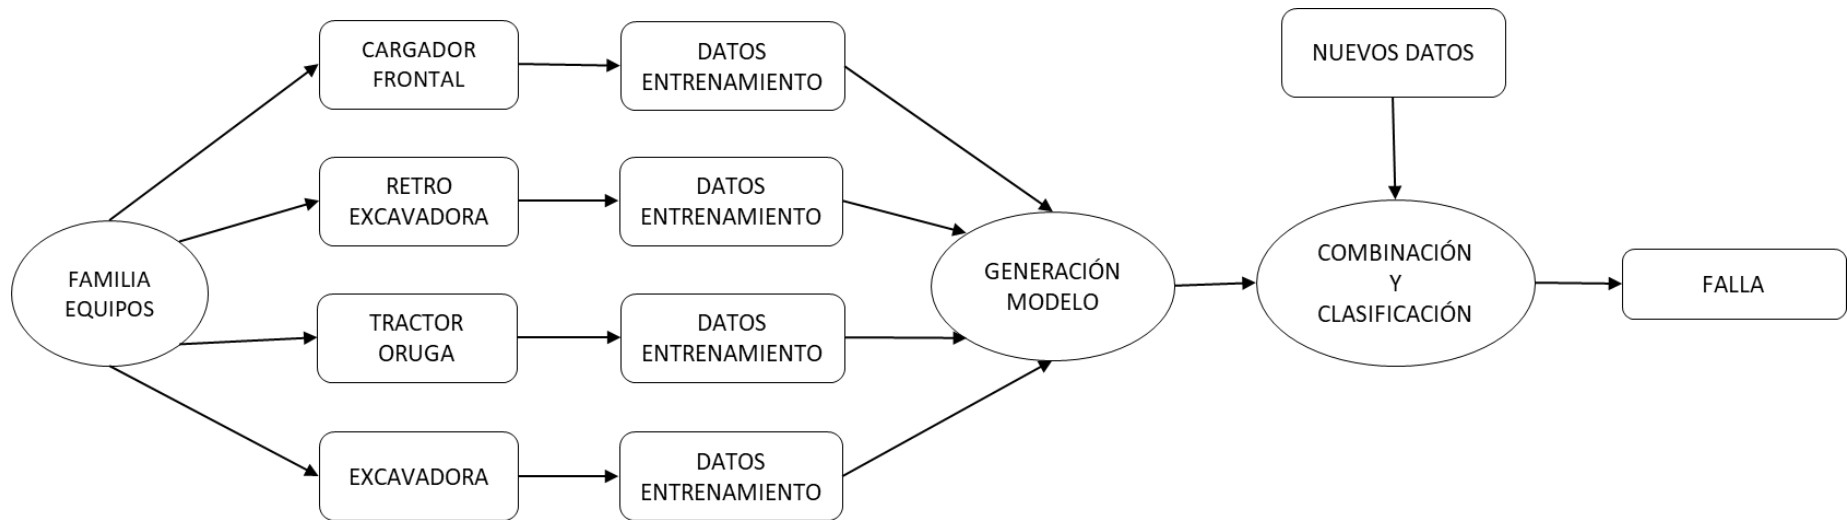


Figura 511: Esquema lógico del modelo

## ANEXO N° 18: CARTA DE AUTORIZACIÓN

Trujillo, 15 de noviembre del 2021

Señor (a):  
**CARGO: Gerente general**  
**NOMBRE DE LA EMPRESA MEKATSU EQUIPOS SRL.**  
Presente.-

Es grato dirigirme a usted para saludarlo, y a la vez manifestarle que dentro de mi formación académica en la experiencia curricular de investigación del x. ciclo, se contempla la realización de una investigación con fines de obtención de mi título profesional al finalizar mi carrera.

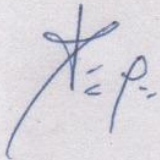
En tal sentido, considerando la relevancia de su organización, solicito su colaboración, para que pueda realizar mi investigación en su representada y obtener la información necesaria para poder desarrollar la investigación titulada: "Machine Learning en la gestión de mantenimiento de maquinaria pesada en la empresa MEKATSU EQUIPOS S.R.L.". En dicha investigación me comprometo a mantener en reserva el nombre o cualquier distintivo de la empresa, salvo que se crea a bien su socialización.

Se adjunta la carta de autorización de uso de información en caso que se considere la aceptación de esta solicitud para ser llenada por el representante de la empresa.

Agradeciéndole anticipadamente por vuestro apoyo en favor de mi formación profesional, hago propicia la oportunidad para expresar las muestras de mi especial consideración.

Atentamente,

Alumno.  
**Enestor Diaz Mayta**  
**DNI 43959016**



CDR 60



44549724

+Trujillo 15 Nov 2021

## ANEXO N° 19: AUTORIZACIÓN DE USO DE INFORMACIÓN

### AUTORIZACIÓN DE USO DE INFORMACIÓN DE EMPRESA

Yo : José Robert Paz Beltrán  
(Nombre del representante legal o persona facultada en permitir el uso de datos)

Identificado con DN 44549724 en mi calidad del área de Gerente General...  
(Nombre del área de la empresa)

de la empresa **MEKATSU EQUIPOS SR.** con R.U.C N°, 20602810683 ubicada en : Av Sayacmarca M10Lt 16A\_ Villa Prg Huanchaco\_Trujillo.

#### OTORGO LA AUTORIZACIÓN,

Al señor(s): Díaz Mayta Enestor, Identificado con DNI N°43959016,  
Blas Benites Rubén Fredy Identificado(s) con DNI N°44266766 de la universidad cesar vallejo, Carrera profesional Ingeniería Mecánica Eléctrica, para que utilice la siguiente información de la empresa:

..... uso de base de datos de mantenimientos de las maquinarias línea amarilla y nombre de la empresa para proyecto de investigación con máquinas de aprendizaje para predecir las fallas que permitirá ayudar a la reducción de costos en la institución  
(Detallar la información a entregar)

con la finalidad de que pueda desarrollar su ( x)Trabajo de Investigación, ( x)Tesis, para optar al grado de ( x )Bachiller, o ( x )Título Profesional.

- ( ) Mantener en Reserva el nombre o cualquier distintivo de la empresa; o  
( ) Mencionar el nombre de la empresa.

  
Firma y sello del Representante Legal

DNI: 44549724

El Estudiante declara que los datos emitidos en esta carta y en el Trabajo de Investigación, en la Tesis son auténticos. En caso de comprobarse la falsedad de datos, el Estudiante será sometido al inicio del procedimiento disciplinario correspondiente; asimismo, asumirá toda la responsabilidad ante posibles acciones legales que la empresa, otorgante de información, pueda ejecutar.

Firma del Estudiante

DNI: 43959016

Firma del Estudiante

DNI: 44266766

