



UNIVERSIDAD CÉSAR VALLEJO

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

Machine learning para mejorar la gestión de mantenimiento de
maquinas industriales

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

AUTOR:

Rojas Bances Dagner Paul (ORCID: [0000-0001-9325-9019](https://orcid.org/0000-0001-9325-9019))

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

CHICLAYO – PERÚ

2021

Dedicatoria

Le dedico a mi madre, que es el eje fundamental en mi vida, sin ella, jamás hubieras logrado conseguir lo que hasta ahora soy. Su sacrificio insaciable ha hecho de mí el gran ejemplo a seguir, no solo para mí sino también para mi hermano.

Dagner

Agradecimiento

Agradezco en primer lugar a Dios por ser mi guía incondicional por iluminarme por permitirme seguir luchando por mi sueño. También agradezco a mi madre por el apoyo moral por sus buenos consejos, a mis hermanos por estar conmigo en las buenas y malas, a todos mis compañeros que hemos compartido conocimientos.

El autor

Índice de contenidos

Dedicatoria	ii
Agradecimiento	iii
Índice de contenidos	iv
Índice de tablas	v
Índice de figuras	vi
Resumen	vii
Abstract	viii
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO.....	3
III. METODOLOGÍA	10
3.1. Tipo y diseño de investigación	10
3.2. Variables y operacionalización.....	10
3.3. Población, muestra y muestreo.....	12
3.4. Técnicas e instrumentos de recolección de datos	12
3.5. Procedimientos	13
3.6. Métodos de análisis de datos.....	13
3.7. Aspectos éticos.....	13
IV. RESULTADOS.....	14
V. DISCUSIÓN.....	43
VI. CONCLUSIONES.....	47
VII. RECOMENDACIONES	48
REFERENCIAS.....	49
ANEXOS	56

Índice de tablas

Tabla 1. Total de maquinarias	12
Tabla 2. Análisis de criticidad de las maquinaria.....	14
Tabla 3. Promedio de análisis de criticidad por áreas	19
Tabla 4. Análisis de modo y efecto de fallas del área de extrusión y bobinado ...	20
Tabla 5. Resumen del análisis de modo potencial de fallos y efectos (AMEF)	23
Tabla 6. Evaluación del mantenimiento preventivo por áreas Octubre 2020 – Setiembre 2021	23
Tabla 7. Evaluación del mantenimiento correctivo por áreas Octubre 2020 – Setiembre 2021	24
Tabla 8. Evaluación del mantenimiento de lubricación por áreas Octubre 2020 – Setiembre 2021	24
Tabla 9. Resumen de evaluación del mantenimiento en la empresa Octubre 2020 – Setiembre 2021	25
Tabla 10. Evaluación de la disponibilidad de las maquinarias	25
Tabla 11. Requerimiento funcionales por módulos a desarrollar.....	28
Tabla 12. Control de pruebas por módulos a desarrollar	28
Tabla 13. Cronograma de ejecución de la implementación.....	28
Tabla 14. Presupuesto de recursos.....	29
Tabla 15. Presupuesto por software.....	29
Tabla 16. Presupuesto de Hardware	29
Tabla 17. Estimación de la mejora de la disponibilidad de las maquinarias	39
Tabla 18. Producción de Enero – Diciembre 2020	39
Tabla 19. Análisis del beneficio obtenido en horas	40
Tabla 20. Análisis del beneficio obtenido de la propuesta en S/.	40
Tabla 21. Evaluación económica.....	41

Índice de figuras

Figura 1. Programación clásica frente al Machine Learning.....	6
<i>Figura 2.</i> Etapas genéricas para realizar un Proyecto de Machine Learning	7
Figura 3. Resumen del análisis de modo potencial de fallos y efectos (AMEF) ...	23
Figura 4. Evaluación de la disponibilidad de las maquinarias	26
Figura 5. Evaluación de la mantenibilidad y confiabilidad de las maquinarias	26
Figura 6. Infraestructura tecnológica	30
Figura 7. Diagrama de flujo de adquisición de datos	31
Figura 8. Algoritmo puro de confiabilidad	32
Figura 9. Ejecutando algoritmo de confiabilidad, conectando con sistema	32
Figura 10. Algoritmo puro de mantenibilidad.....	33
Figura 11. Ejecutando algoritmo de mantenibilidad, conectando con sistema	33
Figura 12. Algoritmo puro de disponibilidad	34
Figura 13. Ejecutando algoritmo de disponibilidad, conectando con sistema	34
Figura 14. Algoritmo general para la propuesta	35
Figura 15. Prueba 1 de los algoritmos	36
Figura 16. Prueba 2 de los algoritmo	37
Figura 17. Prueba final comprobada de los algoritmos	38

Resumen

La presente investigación se trazó como objetivo, evaluar la factibilidad de la implementación del machine learning para mejorar la eficiencia de la gestión de mantenimiento de máquinas industriales, empleando una metodología de tipo aplicada de nivel descriptivo con diseño no experimental, considerando una muestra de 125 máquinas industriales de la fábrica de sacos de polipropileno Atlántica S.R.L. Entre sus resultados, demostró que con la implementación de la propuesta de machine learning se logrará incrementar la disponibilidad de la maquina principal extrusora de 56% a 90%, mantenibilidad de 0,51 a 0,10, confiabilidad de 1,96 a 9,89, mientras que la embobinadora de 62% a 85%, mantenibilidad 0,22 a 0,04 y confiabilidad 4,65 a 23,72. Llegando a la conclusión, que con la propuesta de machine learning, se tiene un VAN de S/. 320.266,991 soles, demostrándose que genera beneficios después de haber logrado cubrir todos los costos, asimismo con un TIR de 56% siendo mayor que el costo del capital del 15%, finalmente un b/c de 2,34 afirmando que por cada sol invertido, se obtiene un beneficio de 2,34.

Palabras clave. Machine Learning, máquinas industriales, gestión de mantenimiento

Abstract

The objective of this research was to evaluate the feasibility of the implementation of machine learning to improve the efficiency of the maintenance management of industrial machines, using an applied type methodology of descriptive level with non-experimental design, considering a sample of 125 machines. industrials of the polypropylene bag factory Atlántica SRL Among its results, it showed that with the implementation of the machine learning proposal it will be possible to increase the availability of the main extruder machine from 56% to 90%, maintainability from 0.51 to 0, 10, reliability from 1.96 to 9.89, while the winder from 62% to 85%, maintainability 0.22 to 0.04 and reliability 4.65 to 23.72. Reaching the conclusion that with the machine learning proposal, there is a NPV of S /. 320,266,991 soles, showing that it generates profits after having managed to cover all costs, also with an IRR of 56% being greater than the cost of capital of 15%, finally a b / c of 2.34 stating that for each sol invested, you get a profit of 2.34.

Keywords. Machine Learning, industrial machines, maintenance management

I. INTRODUCCIÓN

En la actualidad, la industria 4.0, se considera como la cuarta revolución industrial, en la que las formas de producción hacen uso de sistemas físicos cibernéticos para crear una industria más flexible y de carácter reconfigurable, es decir la estructura de una fábrica puede cambiar para lograr producir diferentes productos (Luna et al., 2019)

Para Romero y Rincón (2020), manifiesta que una de las preocupaciones en la industria, es el incremento de conexión entre máquina y la nube por la reglamentación de los procedimientos de la información, que establece parámetros de seguridad que pueden ser vulnerados por medio de múltiples métodos de hacking, considerando en cuenta que los datos industriales ya sean instrucciones, métodos, datos y secretos industriales son uno de los recursos más vitales para muchas industrias.

El mantenimiento industrial, enfrenta un cambio y desarrollo tanto en lo económico como en lo tecnológico, el mantenimiento bien diseñado es primordial en las industrias, porque es genera una mayor eficiencia en su producción, evitando paros de equipos no deseados, mayor eficiencia en el consumo de energía (Contreras, 2020).

Los sistemas de producción complejos, logran contar con miles de piezas y componentes, que están sujetos a múltiples conexiones e interdependencias físicas y lógicas los problemas de mantenimiento se complican, indicando que el enfoque tradicional de mantenimiento no es válido. Ante ello, el nuevo paradigma de industria 4.0 representa un cambio en la forma de producción en las factorías actuales y es por ello que levanta mucho interés entre académicos y profesionales (Guerrero, y otros, 2019).

El progresivo avance tecnológico en los procesos en la industria, causo el reemplazo del trabajo del hombre por equipos; donde con el pasar del tiempo empezaron a presentar fallas, ameritando la intervención del hombre para arreglarla, para así de esta manera continuar la producción (Yali, 2021). La gestión de machine learning, permite garantizar la integridad y continuidad de las operaciones, así como la seguridad de los trabajadores, reduciendo casi el 25% de los fallos de las maquinarias, mejorando el coste de mantenimiento en al menos un

15% e incrementando la productividad en más de un 35% reduciendo accidentes y riesgos operacionales (Fracttal, 2021).

La presente investigación, se desarrolló en la fábrica de sacos de polipropileno, ubicado en Lambayeque. A través de una supervisión realizada en las instalaciones de la empresa, se determinó que, en la labor diaria, existen paradas constantes en la maquina extrusora, demostrándose que el rendimiento se encuentra en un 56%, ocasionando a insatisfacción de los clientes potenciales debido que presentan quejas por la mala calidad del producto, así como la entrega inoportuna (Atlántica, 2021).

La información que registra la empresa, se evidencia constantes paradas de las maquinarias, generando una pérdida del 20% del producto terminado, siendo factor primordial, que se pretende proponer una propuesta de gestión a partir de machine learning para mejorar la eficiencia del mantenimiento de máquinas industriales. Por tal razón, la investigación respondió a la siguiente formulación ¿Cómo mejora la eficiencia de la gestión de mantenimiento máquinas industriales con la implementación del Machine Learning?

A la vez se justificó, porque con la propuesta de gestión a partir de machine learning, se pretende brindar un producto de calidad, cero defectos y en el tiempo previsto. En lo Ambiental, debido que se evitará los procesos de mantenimiento descontrolado, dado que las maquinarias industriales manipulan sustancias, que suelen ser nocivas para el medio ambiente y las personas que lo utilizan. En lo económico, debido que con la propuesta de gestión a partir de machine learning, se pretenderá reducir los gastos por el ineficiente control del mantenimiento.

Para brindar una solución al problema planteado, se establece como objetivo general, evaluar la factibilidad de la implementación del machine learning para mejorar la eficiencia de la gestión de mantenimiento de máquinas industriales; con objetivos específicos, evaluar la eficiencia actual de la gestión de mantenimiento de máquinas industriales para comparar posteriormente con la eficiencia estimada implementando machine learning; elaborar la propuesta de implementación de machine learning para estimar la eficiencia de la gestión de mantenimiento de máquinas industriales; evaluar el costo – beneficio de la implementación de machine learning para estimar la factibilidad económica.

II. MARCO TEÓRICO

Yyi et al. (2021), en su artículo titulado, se trazó como objetivo optimizar las distribuciones de las tareas y el modelo de mantenimiento predictivo, empleando la metodología de tipo aplicada, con diseño no experimental. Entre sus resultados, indicó que en la evaluación del tiempo de ejecución es un 0,48% más rápido, un 5,43% más bajo costos, así como el uso de energía es 28,10%, siendo bajo en comparación con los segundos mejores resultados, para la precisión de entrenamiento y prueba del modelo de predicción es del 95,1%, asimismo el 94,5% respectivamente. Concluyeron, el modelo de mantenimiento se basa en la regresión logística, de dos clases mediante un conjunto de datos en tiempos reales, tales como la gestión de recursos basada en algoritmo genético, que se integra con el aprendizaje automático para el mantenimiento predictivo en computación de niebla. Mohan et al. (2021), en su artículo titulado, se trazó como objetivo predecir la avería futura antes del enfoque de mantenimiento propuesta que se implementa en una máquina del modelo de arena hidráulica en alta presión en una fundición de fabricación, empleando una metodología de tipo descriptivo con diseño no experimental. Entre sus resultados, que se desglosan en minutos por mes, así como el número de averías en un mes, debido a los fenómenos que se analizaron posterior de aplicar el enfoque propuesta, donde el sistema incrementó el tiempo medio entre fallos en un 800% y por lo tanto logró un tiempo de inactividad cero en las industrias. Concluyeron, que las averías imprevistas en cualquier planta industrial allanan, el camino para enormes pérdidas para la industria en términos de producción y beneficios.

Susto (2021), en su artículo titulado, se trazó como objetivo demostrar que mediante el aprendizaje automático a partir del mantenimiento predictivo se demuestre el enfoque de varios clasificadores, empleando una metodología de tipo aplicada con diseño no experimental. Entre sus resultados se demostró que la capacitación de múltiples módulos de clasificación con diferentes horizontes de predicción para proporcionar diferentes compensaciones de rendimientos. Concluyó, que la eficacia de la metodología se demuestro empleando un simulado a un problema de mantenimiento de fabricación en semiconductores de referencia.

Ameeth y Cuerdo (2017), en su artículo titulado, se trazó como objetivo determinar el uso de la previsión de media móvil integrada autorregresiva (ARIMA) en los datos de serie temporales recopilado de varios sensores de una máquina de corte para predecir los posibles fallos y defectos de calidad, considerando una metodología de tipo descriptivo con diseño no experimental. Entre sus resultados, que con el uso del machine learning, se demuestra un componente vital en el IIoT, teniendo casos mejorando el proceso de fabricación en general. Concluyeron, que con el uso de tecnologías de internet de las cosas (IoT) en la fabricación que aprovecha, los datos de la máquina generados por distintos sensores, para aplicar varios análisis sobre ellos para obtener información útil.

Paolanti (2018) se trazó como objetivo establecer el enfoque de aprendizaje automática para el mantenimiento predictivo en la industria 4.0, empleando la metodología de tipo aplicada con diseño no experimental. Entre sus resultados, se probó el sistema como claro ejemplo de la industria, a través del desarrollo del análisis del sistema de datos, empleando el enfoque de aprendizaje automático. Concluyó, que el monitoreo de la condición junto con el mantenimiento predictivo de los motores eléctricos, con otros equipos empleados por la industria, evitando grandes pérdidas económicas graves resultantes de fallas inesperadas del motor.

Ruiz et al. (2019) se trazó como objetivo establecer un modelo predictivo para el rendimiento de maquinaria industrial, en el contexto de la industria 4.0; empleando la metodología de tipo aplicada. Entre sus resultados, que el modelo propuesto se fusiona de forma iterativa, el conocimiento experto con la información en tiempo real procedente de los procesos de laminación en caliente realizados en la fábrica, donde el modelo predictivo ha sido ajustado, con la finalidad de evaluar datos reales de procesos 118 k, demostrando sus virtudes para impulsar la era de la industria 4.0. Concluyeron, que, con la integración de las técnicas de vanguardia, implica una revolución profunda y compleja, que suele ser cambiante los procesos programados a procesos inteligentes, que cambios los programados a procesos inteligentes reactivos, debiendo aplicarse a fondo en diferentes niveles.

Ullah et al. (2017) se trazó como objetivo determinar como la aplicación de la termografía infrarroja impacta en el mantenimiento predictivo de equipos en subestaciones eléctrica mediante un enfoque de aprendizaje automático, empleando una metodología de tipo aplicado, no experimental. Entre sus

resultados, se demostró el rendimiento de MLP, una precisión inicial de 79,78% incrementa el MLP, con el corte del gráfico para incrementar la precisión al 84%, donde el desarrollo de la implementación fue exitoso para un nuevo sistema. Concluyeron, que las imágenes térmicas se toman a través de cámaras infrarrojas, sin perturbar las operaciones de funcionamiento de las subestaciones eléctricas.

En su investigación, Dueñas et al. (2020) se trazó como objetivo analizar los casos de éxito en la implementación del mantenimiento a través del uso de tecnologías de la industria 4.0 en empresas colombianas, considerando una metodología documental y cualitativa. Entre sus resultados, demostraron que dos empresas colombianas de gran relevancia en el país en la implementación de tecnologías de la industria 4.0 en los procesos de mantenimiento predictivo. Concluyeron que determinaron de forma correcta cada variable crítica del proceso, mediante la realización de un análisis de datos, donde su estructuración.

Una vez establecido los antecedentes, referidos a las variables de estudio, se mencionan las teorías de relaciones, estableciendo que las máquinas industriales en los sectores de automotriz, energética, electrónica, fundición, textilera, minera empaquetados, farmacéuticas, entre otras que desarrollan sus procesos con maquinarias industriales probadas. Este tipo de maquinarias, han ido evolucionando al ritmo, que indica la innovación tecnológica, cumpliendo parámetros estandarizados, así como las exigencias de la economía de escala, diferenciándose de las máquinas domésticas (Gonzales, 2021). Las máquinas industriales, se clasifican de la siguiente manera.

La maquinaria industrial liviana, que son artefactos destinados a laborar con componentes pequeños, como es el claro ejemplo al momento de soldar, agujerear, además permitirá fabricar recambios específicos de las maquinarias. La maquinaria industrial pesada, está compuesta por los artefactos que tienen como finalidad laborar en actividades, donde no necesita una aplicación compleja de la fuerza (Gonzales, 2021). A su vez, existen diferentes tipos de maquinarias industriales: eléctricas, hidráulicas, térmicas y brazo robótico.

El Machine Learning, forma parte de la inteligencia artificial, donde la manera de pensar da a entender, en vez de realizar alguna actividad por instinto, que se emplea en el cerebro, al momento de considerar un cuestionamiento. Entre los fundamentos de la metodología, se considera el aprendizaje por error y los procesos

para el ajuste, seguido de las etapas de un proyecto de Machine Learning (Friedrich et al., 2016).

Entre ellos, se encuentra la programación clásica, que es el conjunto de reglas que se encuentran diseñadas por una persona, para lograr obtener respuestas que permitan cumplir dichos procedimientos a partir de una información de entrada, donde el machine learning, se encarga de generar un conjunto de reglas efectivas que están relacionadas a la misma de información de entrada, con las respuestas que uno espera, para obtener a través de aprendizajes. Las ventajas de la metodología, consta de una serie de reglas que se aplican a diferentes datos de entrada, para reproducir respuestas donde se generan de forma automática (Gesing et al., 2018).



Figura 1. Programación clásica frente al Machine Learning
(Gesing et al., 2018)

Por otra parte, el error y los problemas de ajuste, se cuentan con la precisión con la capacidad de generalizar el aspecto clave, en la hora de realizar un modelo de Machine Learning, donde es imposible conseguir un modelo que esté libre de errores, pero completo (Friedrich et al., 2016).

Lo referido a las etapas en un proyecto de Machine Learning, se encuentra relacionado a principios básicos, que concierne al procedimiento que brinda una solución a los problemas reales. Un proyecto de Machine Learning, no se centra solo en seleccionar un modelo para posterior ser entrenado, sino más bien como todo proyecto, cuenta con una serie de etapas, que les permite el incremento de sus probabilidades de éxito (Friedrich et al., 2016). En la siguiente figura, se describen las etapas genéricas:




Figura 2. Etapas genéricas para realizar un Proyecto de Machine Learning

Fuente. (Friedrich et al., 2016)

La primera etapa, consta en entender el problema que se pretende resolver, debido que la mayoría de las decisiones tomadas a lo largo del proyecto, dependiendo de lo que se haya comprendido. La segunda etapa, se refiere a la cantidad, así como el tipo de información, donde la calidad de información que se alimenta la máquina, teniendo un impacto directo en el funcionamiento del modelo. La tercera etapa, se procesa la información que cumple la función de visualizar, para analizar cuáles son las variables más representativas (Friedrich et al., 2016).

La cuarta etapa, se establece el modelo que más se ajusta al problema, regresión lineal, árboles de decisión, red neuronal, k-vecinos más cercanos. La quinta etapa, consta del entrenamiento del modelo, que a través de la información se ajusta a los parámetros de forma automática por el algoritmo seleccionado a medida, que se entrena el modelo. En la sexta etapa, se verifica la precisión del modelo, mediante la introducción de la información de test (Friedrich et al., 2016).

En la séptima etapa, logra ser la unión entre la simulación con el mundo actual, haciendo referencia la implementación de un modelo en un sistema real, con el que se pretende comunicar. La última etapa, se refiere en monitorización de los resultados, que asegura el modelo aporte un alto valor predictivo, como es de importancia que se cumpla con los objetivos marcados en la primera etapa (Friedrich et al., 2016).

La gestión del mantenimiento, es primordial para garantizar la continuidad del trabajo productivo evitando interrupciones del programa debido a fallas de la maquina (García, 2013). El mantenimiento, así como todas las actividades son necesarias para mantener las máquinas e instalaciones en condiciones adecuadas que logren las funciones establecidas que mejoran la producción, así como buscan la correcta disponibilidad y confiabilidad de los equipos (Amendola, 2012).

El mantenimiento, optimiza la disponibilidad de las maquinarias, con el objetivo de reducir los costos incurridos en las paradas de producción, que son ocasionadas por la deficiencia del mantenimiento de las maquinarias, a través de la ejecución de una determinada cantidad de mantenimiento en el momento establecido (García, 2013).

Los tipos de mantenimientos, tales como el rutinario, que carga la responsabilidad en el propio personal que opera las maquinarias, estableciendo la relación sobre los mantenimientos correctivos generados de muy fácil resolución, mientras que el preventivo es de nivel básico. El mantenimiento preventivo, desarrolla supervisiones periódica sobre las maquinarias, considerando que en todas las partes de un mecanismo se desgastan de manera desigual (García, 2016).

La disponibilidad, es el tiempo medio entre fallas (TPEF) y los intervalos de falla deben calcularse para que la máquina esté en buenas condiciones, se use durante el tiempo requerido y para estimar los cálculos de disponibilidad. Reparación (TPPR). El tiempo medio entre fallas es el tiempo transcurrido desde el inicio de la máquina hasta que ocurre una falla. A mayor resultado, mayor índice de disponibilidad del dispositivo (Sánchez, 2017). La siguiente fórmula se utiliza para calcular el TPEF

$$TPEF = \sum \frac{TEF}{N^{\circ}fallas} \left(\frac{Horas}{fallas} \right)$$

El TPPR, el tiempo promedio para reparar

$$TPPR = \sum \frac{TPR}{N^{\circ}fallas} \left(\frac{Horas}{fallas} \right)$$

En el cálculo de la disponibilidad, se emplea la siguiente

$$Disponibilidad = \frac{Tiempo\ promedio\ entre\ fallas\ PEF}{Tiempo\ promedio\ entre\ fallas + tiempo\ promedio\ para\ reparación} \times 100\%$$

La confiabilidad se refiere a la posibilidad de que el equipo realice sus funciones requeridas sin fallas durante un cierto período de operación en condiciones ambientales. Al calcular la confiabilidad se utiliza el tiempo medio entre fallas de cada dispositivo a analizar (Sánchez, 2017). La fórmula es la siguiente:

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

La mantenibilidad se considera la capacidad del equipo para ser reparado dentro del tiempo especificado después de la falla y volver al funcionamiento normal (Sánchez, 2017). La preocupación es que cuanto menos tiempo dedique a trabajos de mantenimiento y reparación, mayor será el nivel de mantenimiento. La fórmula es:

$$\text{Mantenibilidad} = \frac{\text{Tiempo total de mantenimiento}}{\text{Número de reparaciones}}$$

Análisis de criticidad, permite identificar los activos de una instalación sobre los cuales es necesario y vale la pena dirigir nuestros recursos humanos, económicos y tecnológicos. Es necesario, tomar en cuenta criterios de flexibilidad operacional, impacto a la producción, costos de mantenimiento, impacto a la seguridad y frecuencia de falla (Mejía, 2017). Ante ello, se considera los factores ponderados para el análisis de criticidad, donde:

Frecuencia de falla, frecuente 4, promedio 3, bueno 2; Impacto a la producción, pérdidas de producción superiores al 75% (10), pérdidas de producción entre el 50% y el 74% (7), pérdidas de producción entre el 25% y 49% (5), pérdidas de producción entre el 10% y el 24% (3), pérdidas de producción menor al 10% (1). Flexibilidad operacional, no cuenta con reserva para cubrir la producción (4), cuenta con reserva para cubrir la producción (2), cuenta con unidades de reserva en línea (1). Costo de mantenimiento, costos de reparación, materiales y mano de obra superiores a 3000 (2), costos de reparación, materiales y mano de obra entre 1 a 3000 (1). Impacto a seguridad y medio ambiente, riesgo alto de pérdida de la vida (8), riesgo medio de pérdida de la vida (6), riesgo mínimo (3) no existe ningún riesgo (1) (Mejía, 2017).

A la vez, el número de prioridad de riesgo, es el riesgo que se prioriza la evaluación de acciones preventivas disminuyen el impacto de los defectos identificados, donde el valor del riesgo se obtiene mediante la evaluación y ponderación de la severidad, la ocurrencia y detectabilidad, conforme con el tipo de fallas que existen en el proceso (Socconini, 2018). La severidad, es el nivel que ocasiona el efecto del modo de falla con respecto a los materiales y equipos dentro del proceso, en lo cual el efecto extremo (10), crítico (9), muy alto (8), alto (7), moderado (6), bajo (5), muy bajo (4), menor (3), significativamente menor (2) y ninguno (1) (Meneses, 2016)..

La Ocurrencia, número de veces en que se repiten las fallas en el proceso, este valor es obtenido de acuerdo a la frecuencia, en que se presentan y son identificadas. Muy alto (10 - 9) , Alto (8 – 7), moderado (6 – 5), (bimensualmente) 4, bajo (3 – 2), remoto (1) (Meneses, 2016).

III. METODOLOGÍA

3.1. Tipo y diseño de investigación

La presente investigación es de tipo aplicada, debido que con la teoría referencia sobre Machine Learning, permitió desarrollar una gestión para la mejora de la eficiencia del mantenimiento de máquinas industriales.

Es de nivel explicativo, por lo que se proponen someter a prueba una relación causal entre variables (Ansolabehere, y otros, 2018). Esta investigación, se describió las causas de la deficiente gestión de mantenimiento de las máquinas industriales en un fábrica de sacos de polipropileno que a través de Machine Learning se pretende mejorar la disponibilidad, mantenibilidad y confiabilidad.

Respecto es de enfoque cuantitativo, porque se efectuó la recolección de información, con el fin de responder los cuestionamientos de la investigación, que, mediante el análisis estadístico, se comprobó la hipótesis de la investigación (Arias, 2012). Esta investigación, se demostró que con la gestión a partir de Machine Learning, mejora la eficiencia del mantenimiento de máquinas industriales.

Además, es de diseño pre experimental, es aquel en el cual se manipula la variable independiente para producir algún efecto sobre otra variable y donde los individuos entre los que se realiza la medición son elegidos de forma aleatoria (Ansolabehere, y otros, 2018), dado que se inicio realizando la recopilación de información de de las maquinarias industriales de la fábrica de sacos, lo cual permitió identificar aquellos factores que influyen en la disponibilidad, confiabilidad, mantenibilidad, donde servirán como referencia para elaborar la propuesta de gestión a partir de Machine Learning. La presente investigación, tiene una dimensión transversal, debido que la información de las variables, se relacionan para analizar durante un período determinado (Hernández et al, 2016). El diseño, sigue el siguiente esquema:

O1 X O 2

Donde: X, variable independiente; O1, medición pre experimental de la variable independiente; O2, medición post experimental

3.2. Variables y operacionalización

Variable independiente. Machine Learning

Conjunto de operaciones con el objetivo de garantizar la continuidad de la actividad operativa, evitando atrasos en el proceso por averías de máquinas y equipos (Gonzales, 2019).

Para Lawson et al. (2019) sostuvo que el aprendizaje automático, es una sub disciplina de la inteligencia artificial, que intenta emular cómo un cerebro humano comprende e interactúa con el mundo.

El Machine Learning, se emplea para predecir un resultado, que es necesario analizarlo, para observar si los valores que produce durante el entrenamiento se comparan con algunos valores objetivos, de este modo el aprendiz recibe retroalimentación (Amendola, 2012).

La definición operacional, el machine Learning, tendrá que demostrarse que tan fiable, compatible es, asimismo su tiempo de ejecución. Los indicadores, referente al machine learning, se encuentra fiabilidad, compatibilidad y el tiempo de ejecución.

Variable dependiente. Gestión del mantenimiento

Es la capacidad de lograr los objetivos y metas programadas con los recursos disponibles en un tiempo predeterminado (Hoyos, 2020).

La gestión de mantenimiento, evalúa el estado inicial en el que se encuentra dicha área, con el propósito de analizar los cambios favorables o no, donde la medición se debe realizar mediante indicadores (Camisón et al., 2016).

Por otra parte, es el proceso de mantenimiento de los activos y recursos de una empresa que tiene como principales objetivos controlar los costos, los tiempos, los recursos y asegurar el cumplimiento de la normativa (Sánchez, 2017)

La definición operacional, se tiene que la gestión del mantenimiento de las maquinarias industriales, se evaluó la confiabilidad, disponibilidad y mantenibilidad.

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

$$Mantenibilidad = \frac{Tiempo\ total\ de\ mantenimiento}{Número\ de\ reparaciones}$$

Disponibilidad

$$= \frac{Tiempo\ promedio\ entre\ fallas\ PEF}{Tiempo\ promedio\ entre\ fallas + tiempo\ promedio\ para\ reparación} \times 100\%$$

Matriz de operacionalización (Ver Anexo 01).

3.3. Población, muestra y muestreo

La población de una investigación, se consideró un grupo de sucesos limitados, accesible y definidos que conforman la parte relativa, para elegir la muestra, donde se realice una serie de criterios preestablecidos (Gómez y otros, 2016). En este caso, como parte de la población se consideró a las 125 máquinas industriales de la fábrica de sacos de polipropileno Atlántica S.R.L.

Tabla 1. Total de maquinarias

Área	Total
Extrusora	3
Bobinadora	4
Multifilamento	1
Telares Circulares	77
Telar Plano	1
Impresión	3
Laminación	1
Conversión	7
Bastas	14
Enrolladora	1
Reciclado	2
Prensa	2
Chiller	3
Compresor Aire	2
Ablandador	1
Máquina De Clises	1
Montacarga	1
Torno Lineal	1
Total	125

Fuente. Elaboración propia

La muestra, es una fracción de la población en la que se realiza la investigación, existiendo una serie de sucesos, que consigue la cantidad de los componentes (López, 2017). En la presente investigación, se consideró como muestra a toda la población por ser mínima, donde es un total de 125 máquinas industriales de la fábrica de sacos de polipropileno Atlántica S.R.L.

3.4. Técnicas e instrumentos de recolección de datos

Las técnicas de la recolección de datos, para la presente investigación, estuvieron conformadas por el análisis documental, tales como reporte de los distintos tipos de mantenimiento preventivo y correctivo de las maquinarias. Además, la observación que se consideró es la acción de visualizar todo el recorrido del proceso productivo con la finalidad de identificar los problemas.

Entre los instrumentos de recolección de información, se empleó la ficha de registro, registro establecido para poder analizar la información obtenida por la empresa. Además, se empleó, la guía de observación, que es aquel registro abierto donde se anotó puntos considerables, desde el inicio hasta el término de la producción.

3.5. Procedimientos

En la presente investigación, se empleó el siguiente procedimiento, donde se presentó una carta de aceptación en las instalaciones de la fábrica de sacos. Posterior fue aceptado por parte de la jefatura de mantenimiento, recién se realizó un análisis de la eficiencia actual del mantenimiento, midiendo los indicadores de la disponibilidad, confiabilidad y mantenibilidad de la maquinaria, con la finalidad de mapear los indicadores, para así proponer una gestión a partir de Machine Learning, posterior estimar que tan eficiente será el mantenimiento.

3.6. Métodos de análisis de datos

El método de análisis de datos, que se empleó para la investigación es el análisis descriptivo, es decir se logró ingresar la información obtenida al programa Microsoft Excel, a su vez se empleó el software estadístico SPSS 22, con la finalidad que se establezcan las frecuencias, tabulaciones gráficas, permitiendo comprender la información arrojada para el cumplimiento de las variables.

3.7. Aspectos éticos

Los aspectos éticos, considerados para la recolección de información, fue necesario solicitar la autorización en la empresa, para así garantizar la transparencia en el desarrollo de los objetivos. Se respetó, la confiabilidad de la información brindada de la fábrica de sacos, de ser necesario y/o requerido por los administrativos.

En lo que respecta, a los autores referenciados se respetó la autoría, citando a cada uno de ellos, sin incurrir en plagio, del mismo modo fue sometido al software anti plagio Turnitin. El procedimiento de la recolección de la información, se desarrolló atendiendo los principios éticos del autor, el cual se reflejó únicamente la realidad observada, sin alterar para así garantizar que el trabajo sea original, permitiendo que sea de gran utilidad para una nueva fuente de información.

El desarrollo de la investigación, se realizó con el estricto sentido de protección de la información confiada por parte de la fábrica de sacos, utilizado para único fin de esta investigación, sin fomentar la divulgación para otros intereses.

IV. RESULTADOS

4.1. Evaluación de la gestión del mantenimiento de las máquinas industriales

Con el propósito de realizar la evaluación de la gestión del mantenimiento de las máquinas industriales, se empleó el análisis de criticidad para las máquinas, donde se consideró los esfuerzos y recursos con el fin de mejorar su disponibilidad. Para lo cual se consideró, el fundamento teórico de Mejía (2017) que establece criterios para el análisis de criticidad de las maquinarias, tales como riesgo de lesión, el impacto de la producción, frecuencias de fallas, impacto ambiental, mientras que la importancia que es la ponderación.

Tabla 2. Análisis de criticidad de las maquinaria

ITEM	AREA	CODIGO DE LA MAQUINARIA	RIESGO DE LESIÓN (RL)	IMPORTANCIA (I)	IMPACTO EN LA PRODUCCIÓN (IP)	IMPORTANCIA (I)	FRECUENCIA DE FALLAS (FF)	IMPORTANCIA (I)	IMPACTO AMBIENTAL (IA)	IMPORTANCIA (I)	PUNTAJE DE CRITICIDAD PONDERADO (RL*I)+(IP*I)+(FF*I)+(IA*I)
1	Extrusora	EL -800	5	0.4	3	0.3	3	0.2	2	0.1	3.7
2		EY - 1500	5	0.4	4	0.3	4	0.2	3	0.1	4.3
3		ES - 1400	5	0.4	3	0.3	3	0.2	3	0.1	3.8
4	Bobinadora	EL-BA-LS200HS	4	0.4	4	0.3	4	0.2	2	0.1	3.8
5		EL-BM	5	0.4	5	0.3	3	0.2	3	0.1	4.4
6		EY-BA	5	0.4	4	0.3	2	0.2	3	0.1	3.9
7		ES-BA-SF200XE	4	0.4	4	0.3	4	0.2	2	0.1	3.8
8	Multifilamento	ML40/4-01	2	0.4	3	0.3	2	0.2	2	0.1	2.3
9	Telares circulares	TSA6-01	5	0.4	4	0.3	4	0.2	3	0.1	4.3
10		TSA6-02	3	0.4	3	0.3	2	0.2	2	0.1	2.7
11		TSA6-03	4	0.4	3	0.3	3	0.2	1	0.1	3.2
12		TSA6-04	3	0.4	4	0.3	2	0.2	3	0.1	3.1
13		TSA6-05	4	0.4	2	0.3	3	0.2	2	0.1	3
14		TSA6-06	4	0.4	3	0.3	2	0.2	3	0.1	3.2
15		TSA6-07	2	0.4	2	0.3	3	0.2	2	0.1	2.2
16		TSA6-08	3	0.4	2	0.3	3	0.2	2	0.1	2.6
17		TSA6-09	3	0.4	4	0.3	2	0.2	3	0.1	3.1
18		TSA6-10	3	0.4	1	0.3	2	0.2	2	0.1	2.1
19		TSA6-11	4	0.4	3	0.3	1	0.2	1	0.1	2.8

ITEM	AREA	CODIGO DE LA MAQUINARIA	RIESGO DE LESIÓN (RL)	IMPORTANCIA (I)	IMPACTO EN LA PRODUCCIÓN (IP)	IMPORTANCIA (I)	FRECUENCIA DE FALLAS (FF)	IMPORTANCIA (I)	IMPACTO AMBIENTAL (IA)	IMPORTANCIA (I)	PUNTAJE DE CRITICIDAD PONDERADO (RL*I)+(IP*I)+(FF*I)+(IA*I)
20		TSA6-12	3	0.4	3	0.3	1	0.2	1	0.1	2.4
21		TSA6-13	4	0.4	3	0.3	3	0.2	2	0.1	3.3
22		TSA6-14	4	0.4	3	0.3	3	0.2	2	0.1	3.3
23		TSA6-15	3	0.4	3	0.3	2	0.2	3	0.1	2.8
24		TSA6-16	2	0.4	3	0.3	1	0.2	1	0.1	2
25		TSA6-17	3	0.4	2	0.3	2	0.2	1	0.1	2.3
26		TSA6-18	3	0.4	3	0.3	2	0.2	1	0.1	2.6
27		TSA6-19	3	0.4	3	0.3	2	0.2	1	0.1	2.6
28		TSA6-20	4	0.4	4	0.3	2	0.2	1	0.1	3.3
29		TLLSL6-01	3	0.4	3	0.3	2	0.2	1	0.1	2.6
30		TLLSL6-02	3	0.4	2	0.3	3	0.2	1	0.1	2.5
31		TLLSL6-03	4	0.4	2	0.3	3	0.2	1	0.1	2.9
32		TLLSL6-04	5	0.4	3	0.3	2	0.2	1	0.1	3.4
33		TLLSL6-05	4	0.4	3	0.3	2	0.2	1	0.1	3
34		TLLSL6-06	4	0.4	2	0.3	3	0.2	1	0.1	2.9
35		TLLSL6-07	3	0.4	2	0.3	2	0.2	2	0.1	2.4
36		TLLSL6-08	4	0.4	3	0.3	2	0.2	2	0.1	3.1
37		TYSBY800-6S-01	3	0.4	3	0.3	2	0.2	2	0.1	2.7
38		TYSBY800-6S-02	3	0.4	2	0.3	2	0.2	3	0.1	2.5
39		TYSBY800-6S-03	2	0.4	4	0.3	2	0.2	2	0.1	2.6
40		TYSBY800-6S-04	3	0.4	4	0.3	2	0.2	2	0.1	3
41		TYSBY800-6S-05	3	0.4	3	0.3	1	0.2	3	0.1	2.6
42		TYSBY800-6S-06	3	0.4	2	0.3	1	0.2	2	0.1	2.2
43		TYSBY800-6S-07	2	0.4	3	0.3	2	0.2	1	0.1	2.2
44		TYSBY800-6S-08	2	0.4	2	0.3	1	0.2	1	0.1	1.7
45		TYSBY800-6S-09	2	0.4	3	0.3	2	0.2	1	0.1	2.2
46		TYSBY800-6S-10	2	0.4	2	0.3	1	0.2	2	0.1	1.8
47		TYSBY800-6S-11	2	0.4	4	0.3	2	0.2	1	0.1	2.5
48		TYSBY800-6S-12	3	0.4	2	0.3	2	0.2	1	0.1	2.3
49		TYSBY800-6S-13	3	0.4	2	0.3	2	0.2	1	0.1	2.3
50		TYSBY800-6S-14	3	0.4	3	0.3	2	0.2	1	0.1	2.6
51		TYSBY800-6S-15	3	0.4	2	0.3	2	0.2	2	0.1	2.4
52		TYSBY800-6S-16	3	0.4	3	0.3	1	0.2	2	0.1	2.5
53		TYSBY800-6S-17	2	0.4	2	0.3	1	0.2	2	0.1	1.8
54		TYSBY800-6S-18	2	0.4	2	0.3	1	0.2	1	0.1	1.7
55		TYSBY800-6S-19	2	0.4	2	0.3	2	0.2	2	0.1	2

ITEM	AREA	CODIGO DE LA MAQUINARIA	RIESGO DE LESIÓN (RL)	IMPORTANCIA (I)	IMPACTO EN LA PRODUCCIÓN (IP)	IMPORTANCIA (I)	FRECUENCIA DE FALLAS (FF)	IMPORTANCIA (I)	IMPACTO AMBIENTAL (IA)	IMPORTANCIA (I)	PUNTAJE DE CRITICIDAD PONDERADO (RL*I)+(IP*I)+(FF*I)+(IA*I)
56		TYSBY800-6S-20	2	0.4	2	0.3	2	0.2	1	0.1	1.9
57		TSL4-01	1	0.4	4	0.3	1	0.2	2	0.1	2
58		TSL4-02	2	0.4	3	0.3	2	0.2	1	0.1	2.2
59		TLL4-01	3	0.4	3	0.3	2	0.2	2	0.1	2.7
60		TLL4-02	2	0.4	2	0.3	2	0.2	1	0.1	1.9
61		TLL4-03	3	0.4	2	0.3	2	0.2	2	0.1	2.4
62		TLL4-04	3	0.4	2	0.3	1	0.2	1	0.1	2.1
63		TLL4-05	4	0.4	2	0.3	1	0.2	2	0.1	2.6
64		TLL4-06	2	0.4	4	0.3	2	0.2	2	0.1	2.6
65		TLNV-01	5	0.4	2	0.3	1	0.2	1	0.1	2.9
66		TLL4-05	6	0.4	3	0.3	2	0.2	2	0.1	3.9
67		TLL4-06	2	0.4	2	0.3	1	0.2	1	0.1	1.7
68		TLL4-07	3	0.4	4	0.3	2	0.2	2	0.1	3
69		TLL4-08	2	0.4	2	0.3	3	0.2	2	0.1	2.2
70		TLL4-09	4	0.4	2	0.3	1	0.2	1	0.1	2.5
71		TLL4-10	2	0.4	2	0.3	2	0.2	1	0.1	1.9
72		TLL4-11	3	0.4	3	0.3	1	0.2	2	0.1	2.5
73		TLL4-12	4	0.4	2	0.3	2	0.2	1	0.1	2.7
74		TLL4-13	2	0.4	2	0.3	1	0.2	2	0.1	1.8
75		TLL4-14	3	0.4	3	0.3	1	0.2	1	0.1	2.4
76		TLL4-15	4	0.4	2	0.3	2	0.2	2	0.1	2.8
77		TLL4-16	5	0.4	2	0.3	4	0.2	2	0.1	3.6
78		TYLLSL620-1.5M-01	3	0.4	2	0.3	1	0.2	1	0.1	2.1
79		TYLLSL620-1.5M-02	6	0.4	1	0.3	2	0.2	1	0.1	3.2
80		TYSSL8-2M-01	2	0.4	2	0.3	2	0.2	1	0.1	1.9
81		TYSSL8-2M-02	1	0.4	1	0.3	1	0.2	1	0.1	1
82		TYYSBY2.2M-6S-01	2	0.4	1	0.3	2	0.2	1	0.1	1.6
83		TYYSBY2.2M-6S-02	3	0.4	2	0.3	3	0.2	1	0.1	2.5
84		TYCH-3M-01	4	0.4	3	0.3	2	0.2	1	0.1	3
85		TYCH-3M-02	2	0.4	2	0.3	2	0.2	1	0.1	1.9
86	Telar plano	TM-01	3	0.4	3	0.3	2	0.2	1	0.1	2.6
87		IFMSBY3-1.2M-01	2	0.4	2	0.3	1	0.2	1	0.1	1.7
88	Impresión	IFANRP-8C-01	1	0.4	2	0.3	2	0.2	1	0.1	1.5
89			1	0.4	2	0.3	1	0.2	2	0.1	1.4
90	Laminación		1	0.4	1	0.3	1	0.2	1	0.1	1

ITEM	AREA	CODIGO DE LA MAQUINARIA	RIESGO DE LESIÓN (RL)	IMPORTANCIA (I)	IMPACTO EN LA PRODUCCIÓN (IP)	IMPORTANCIA (I)	FRECUENCIA DE FALLAS (FF)	IMPORTANCIA (I)	IMPACTO AMBIENTAL (IA)	IMPORTANCIA (I)	PUNTAJE DE CRITICIDAD PONDERADO (RL*I)+(IP*I)+(FF*I)+(IA*I)
91	Conversión	CABCS-2002-1.6M-01	1	0.4	2	0.3	2	0.2	1	0.1	1.5
92		CABCS-2002-1.4M-02	1	0.4	2	0.3	1	0.2	2	0.1	1.4
93		CABCS-2002-1.4M-03	2	0.4	2	0.3	1	0.2	1	0.1	1.7
94		CABCS-2012-1.4M-04	3	0.4	3	0.3	1	0.2	2	0.1	2.5
95		CASGSM-1.5M-01	3	0.4	2	0.3	1	0.2	1	0.1	2.1
96		CONVERTEX	2	0.4	3	0.3	1	0.2	1	0.1	2
97		SLITEX	3	0.4	2	0.3	1	0.2	1	0.1	2.1
98	Bastas	MCN-DN-2HS-1	2	0.4	2	0.3	1	0.2	1	0.1	1.7
99		MCN-DN-2HS-2	3	0.4	2	0.3	2	0.2	2	0.1	2.4
100		MCN-DN-2HS-3	2	0.4	1	0.3	2	0.2	1	0.1	1.6
101		MCN-DN-2HS-4	2	0.4	1	0.3	2	0.2	1	0.1	1.6
102		MCN-DN-2HS-5	1	0.4	2	0.3	2	0.2	1	0.1	1.5
103		MCN-DN-2HS-6	2	0.4	1	0.3	3	0.2	1	0.1	1.8
104		MCN-DN-2HS-7	2	0.4	1	0.3	2	0.2	1	0.1	1.6
105		MCN-DN-2HS-8	3	0.4	1	0.3	2	0.2	2	0.1	2.1
106		MCN-DN-2HS-9	1	0.4	2	0.3	1	0.2	3	0.1	1.5
107		MCN-DN-DKN- 3BP-10	1	0.4	2	0.3	2	0.2	1	0.1	1.5
108		MCN-DN-DKN- 3BP-11	1	0.4	1	0.3	2	0.2	2	0.1	1.3
109		MCN-DN-DKN- 3BP-12	2	0.4	2	0.3	1	0.2	1	0.1	1.7
110		MCN-DN-2HS-9	3	0.4	2	0.3	2	0.2	2	0.1	2.4
111		MCN-DN-2HS-9	2	0.4	1	0.3	1	0.2	1	0.1	1.4
112	Enrolladora	EM-01	2	0.4	2	0.3	2	0.2	2	0.1	2
113	Reciclado	PY-01	1	0.4	2	0.3	2	0.2	1	0.1	1.5
114		MT-01	2	0.4	2	0.3	1	0.2	1	0.1	1.7
115	Prensa	PHCH-01	3	0.4	2	0.3	1	0.2	2	0.1	2.2
116		PHP-02	3	0.4	3	0.3	2	0.2	1	0.1	2.6
117	Chiller	CHC-30RAP-060-01	2	0.4	2	0.3	3	0.2	1	0.1	2.1
118		CHHB-25TR-01	2	0.4	2	0.3	2	0.2	1	0.1	1.9
119		CHPCH900S-01	2	0.4	2	0.3	2	0.2	1	0.1	1.9
120	Compresor aire	CTC-L55-01	2	0.4	2	0.3	1	0.2	2	0.1	1.8
121		CTI-UP6-40-01	3	0.4	2	0.3	2	0.2	1	0.1	2.3
122	Ablandador	AA -01	2	0.4	2	0.3	3	0.2	3	0.1	2.3

ITEM	AREA	CODIGO DE LA MAQUINARIA	RIESGO DE LESIÓN (RL)	IMPORTANCIA (I)	IMPACTO EN LA PRODUCCIÓN (IP)	IMPORTANCIA (I)	FRECUENCIA DE FALLAS (FF)	IMPORTANCIA (I)	IMPACTO AMBIENTAL (IA)	IMPORTANCIA (I)	PUNTAJE DE CRITICIDAD PONDERADO (RL*I)+(IP*I)+(FF*I)+(IA*I)
123	Máquina De Clises		3	0.4	3	0.3	1	0.2	1	0.1	2.4
124	Almacén	MCAT-GP2.5T-01	2	0.4	1	0.3	1	0.2	1	0.1	1.4
125	Mantenimiento	TP.1.5M - 01	3	0.4	3	0.3	1	0.2	1	0.1	2.4

Fuente. Elaboración propia

Una vez realizado el análisis de criticidad por cada máquina, se promedia el total del puntaje de criticidad ponderado, por la cantidad de maquinarias por áreas, resaltándose si no aplicamos un correcto mantenimiento en dichas maquinarias, esto puede ocasionar graves accidentes, paras de producción, así como altos costos de mantenimiento correctivo. Ante ello, se representa un resumen por áreas (Tabla 3).

Tabla 3. Promedio de análisis de criticidad por áreas

Área	Puntaje de criticidad Ponderado
Bobinadora	3.98
Extrusora	3.93
Telar plano	2.60
Telares circulares	2.53
Prensa	2.40
Máquina de Clises	2.40
Mantenimiento	2.40
Ablandador	2.30
Multifilamento	2.30
Compresor de aire	2.05
Enrolladora	2.00
Chiller	1.97
Conversión.	1.90
Bastas	1.72
Reciclado	1.60
Impresión	1.40
Almacén	1.40
Total	38.88

Fuente. Elaboración propia

El resumen de análisis de criticidad por las áreas de producción de la empresa, se tiene que en el proceso de investigación, se centrará en las áreas de Bobinadora (4 máquinas), Extrusora (3 máquinas), Telar Plano (1 máquina) y Telares Circulares (77 máquina).

En el análisis de modo y efecto de fallas del área de extrusión y bobinado, se realizó tomando el fundamento teórico de Meneses (2016) que establece, que se debe realizar en base de los niveles de severidad, ocurrencia y detectabilidad, para así encontrar el nivel potencial de riesgo que es la multiplicación de dichos factores.

Tabla 4. Análisis de modo y efecto de fallas del área de extrusión y bobinado

PR- AMEF -01		Proceso: Extrusión y bobinado					Encargado		Dagner Rojas Bances	
		CONDICIONES EXISTENTES								
Etapa del proceso	Modos potenciales de fallas	Efecto potencial de la falla	Severidad	Causas potenciales de las fallas	Ocurrencia	Control actual del proceso	Detectabilidad	NPR	Acciones recomendadas	
Descarga de la materia prima e insumos en la tolda dosificadora.	Dosificación inadecuada de la Materia Prima	Color de cinta no requerido	5	Desconocimiento del operador de extrusión sobre las especificaciones establecidas.	8	Se tiene especificación técnica disponible, pero los operadores lo desconocen.	10	400	Dar a conocer la especificación técnica, brindando la capacitación adecuada a los operadores.	
				Deficiente regulación del material.	6	Se inspecciona la calidad de dosificación, antes de iniciar el proceso.	1	30		
				Carece de calibración la balanza para el pesado de la materia prima	3	Programa de Mantenimiento y calibración de equipos de medición.	1	15		
				Falta de stock de materia prima	3	Reporte diario de Stock.	4	60		
	Materia prima húmeda	Agujeros en la lámina	7	Carece de inspección de la materia prima por parte de control de calidad.	2	Controles establecidos en el Plan de Calidad.	2	28		
				Condiciones inadecuadas del almacén de Materia Prima	3	Inspección inopinada de calidad.	2	42		
Falta de inspección del operador de extrusión				6	Capacitación al puesto en que laboran.	8	336	Diseñar un programa de capacitación.		
Extrusión de la materia prima para la obtención de la mezcla fundida.	Inadecuado parámetros de máquina (Temperatura de tornillo, filtro, velocidad, amperaje del motor).	Materia prima no fundida correctamente.	7	Desconocimiento del índice de fluidez (Cantidad de material que fluye mediante el orificio de un dado capilar).	8	Controles establecidos en el plan de calidad.	6	336	Mejorar la producción de valores de índice de fluidez.	
				Falta de estandarización de los perfiles de temprano (Tornillo y filtro), referente al índice de fluidez.	9	No cuenta con algún control.	8	504	Establecer por máquina, especificación técnica.	
				Desconocimiento de las partes principales motor, caja reductora, tornillo, bomba de	9	Capacitación en las labores que realiza.	7	441		

				fusión, etc.) y limpieza adecuada.					
				Desconocimiento del panel de control para asegurar un mayor monitoreo del sistema.	7	Capacitación en las labores que realiza.	8	392	
				Desconocimiento del estado del tornillo extrusor.	8	Enumerar las actividades del mantenimiento preventivo, identificando los repuestos críticos.	1	56	Enumerar las actividades del mantenimiento preventivo, identificando los repuestos críticos.
				Falta de mantenimiento preventivo del tornillo de extrusión, caja del motor y caja reductora.	6	No cumple las actividades programadas de mantenimiento.	7	294	
	Falla del sistema de las extrusoras	Caída de línea.	9	Corte de energía eléctrica	5	Reporta al proveedor de energía eléctrica.	5	225	
				Desgaste de las partes primordiales.	7	Identificación durante el mantenimiento preventivo	2	126	
Paso de la mezcla fundida por el cabezal y obtención de la lámina	Temperatura de cabezal inadecuado.	Denier no requerido	8	Falta de estandarización de los perfiles de temperatura (Cabeza), según el indicador de fluidez del polipropileno.	8	No existe	10	640	Establecer cada máquina una especificación técnica de perfiles de temperatura vs indicador de fluidez.
	Calibración inadecuada del cabezal			Desconocimiento del operador de extrusión sobre el proceso de calización del cabezal.	8	Capacitación en el puesto de trabajo.	9	576	
				Zonas no identificadas del cabezal.	8	En el cabezal está escrito con plumón	6	384	
				Herramienta inadecuada para la calibración.	4	No existe Check List de Herramientas	5	160	Elaborar Check List de herramientas
				Limpieza inadecuada del cabezal.	8	Capacitación en el puesto de trabajo.	8	512	
Enfriamiento y secado de la lámina	Parámetro de maquina inadecuado	Lámina con agua (Cinta deformada)	5	Falta de conocimiento sobre los parámetros de máquina..	8	Se tiene disponible en la red, pero los operadores no logran	10	400	Colocar la especificación técnica en el panel del operador.
	Inadecuada limpieza de tubos sopladores y rodillo calandria.			Desconocimiento del funcionamiento del sistema calandria y sus partes principales	6	No existe	10	300	Incluir el tema en el Programa de mejora.
				Desconocimiento de la correcta limpieza.	6	Capacitación en el puesto de trabajo.	8	240	
Corte de la lámina en cintas	Equipo de corte inadecuado	Ancho de cinta fuera de especificación.	4	Desconocimiento del operador de extrusión sobre los equipos de corte inicial a utilizar según el	8	Se tiene especificación técnica disponible en la red, pero los	10	320	Colocar la especificación técnica en el panel del operador.

				tipo de cinta, previamente establecidas.		operadores no pueden acceder		
	Mal estado de las cuchillas			Carece de conocimiento del estado óptimo de las cuchillas de corte.	4	Check List	10	160
				Falta de stock de cuchillas para reposición.	3	No existe	7	84
	Inadecuado del cambio de equipo de corte	Accidente de los operadores.	9	Desconocimiento del proceso de cambio de los equipos de corte.	2	Capacitación	8	144
Calentamiento, estiramiento y enfriamiento (contracción de las cintas).	Parámetros de máquina inadecuado (T° de horno, ratio de estiramiento templado).	Elongación y tenacidad fuera de especificación	7	Falta de estandarización de parámetros: T° de hornos 2 y 3 (línea).	7	No existe	10	490
				Desconocimiento de las partes principales del sistema de contracción –estiramiento.	7	Capacitación en el puesto de trabajo.	8	392
	Caída de línea.	9	Desconocimiento del flujo de aire que ingresa al horno..	5	No existe	10	450	
Embobinado de las cintas en bobinas	Mal estado de las canastillas	Embobinado inadecuado	6	Falta de inspección de las canillas.	8	No existe	9	432
				Falta de stock disponibles	3	No existe	4	72
	Desconocimiento del estado correcto de las canillas.			2	Capacitación en el puesto de trabajo.	8	96	
	Desconocimientos de las partes principales de las embobinadoras .			8	Capacitación en el puesto de trabajo.	8	384	
	Posición inadecuada de las guías cintas.			8	No existe	9	432	
Proceso inadecuado del embobinado	Accidente del operador	9	Desconocimiento del personal.	7	Capacitación	7	441	
				Alta rotación de los operarios o ausencia de bobinas	7	Programa de incentivos	6	378

Fuente. Elaboración propia

En el análisis de modo y efecto de fallas en el área de extrusión y bobinado, se determinó los modos potenciales de fallas, dosificación inadecuada de la materia prima, materia prima húmeda, inadecuado parámetros de máquina, falla del sistema de las extrusora, calibración inadecuada del cabeza, parámetro de maquina inadecuado, inadecuada limpieza de tubos sopladores y rodillo calandria, equipo de corte inadecuado, mal estado de las cuchillas, proceso inadecuado del cambio de equipo de corte, falta de inspección de los controles y proceso inadecuado del embobinado.

Tabla 5. Resumen del análisis de modo potencial de fallos y efectos (AMEF)

NPR	Clasificación	Extrusión y Bobinadora	%
0-100	Bajo	9	24%
100-200	Moderado	4	11%
200-300	Alto	3	8%
300-1000	Extremo	21	57%
Total		37	100%

Fuente. Elaboración propia

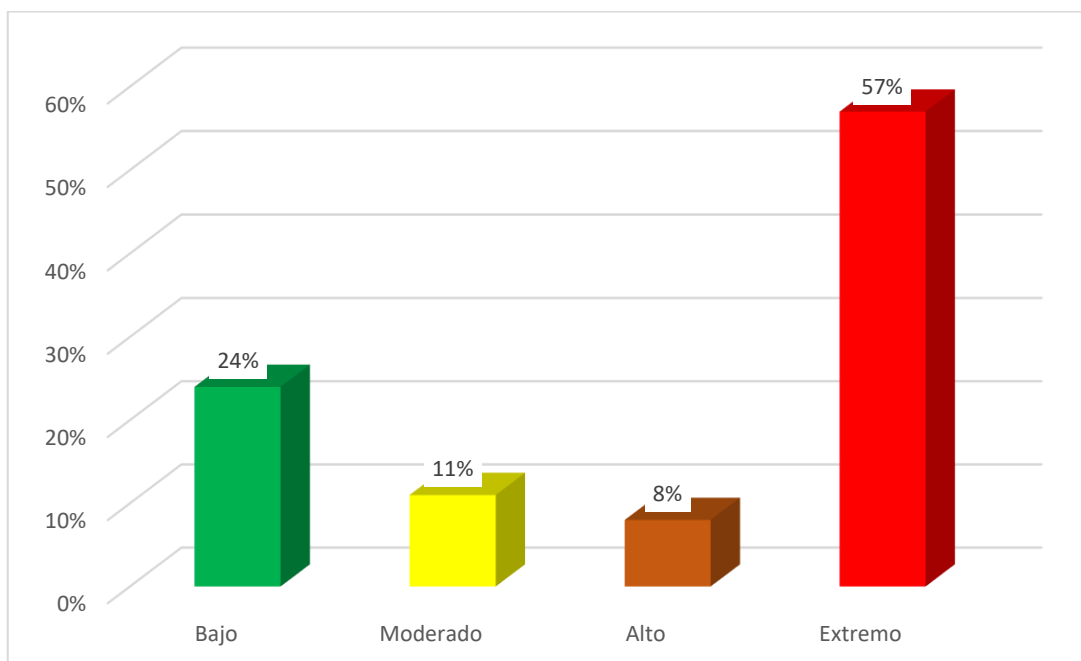


Figura 3. Resumen del análisis de modo potencial de fallos y efectos (AMEF)

Fuente. Elaboración propia

En el análisis de modo potencial de fallos y efecto (AMEF) de las máquinas, de las áreas con mayor riesgo de criticidad de la fábrica de sacos, se tiene como resultante de potencial entre la ocurrencia, severidad y detectabilidad que existe un número de prioridad de riesgo extrema en el área de extrusión, con 21 riesgos.

Tabla 6. Evaluación del mantenimiento preventivo por áreas Octubre 2020 – Setiembre 2021

Área	Total de horas de mantenimiento preventivo	Total de horas de mantenimiento Global	Indicador
Extrusión	41.17	286.79	14%
Impresión	3	450.75	1%
Laminación	0	96.13	0%
Conversión	5	560.3	1%
Multifilamento	29.25	88.75	33%
Recicladora	0.67	61.83	1%

Telares	551.36	2513.82	22%
Prensa	0	30.51	0%
Trensadora	0	1.5	0%
Promedio	70.05	454.49	8%

Fuente. Elaboración propia

En la Tabla 6, se encuentra la evaluación del mantenimiento preventivo por áreas, indicando que el área de laminación, es considerado como parte importante en el proceso productivo no se realiza mantenimiento preventivo al igual que el área de prensa y trenzadora, además, las horas dedicadas en el área de impresión y conversión es de 1%, indicando que no se está prestando la debida atención a áreas fundamentales dentro del proceso productivo, pues una parada en alguna máquina de estas, pudiendo ocasionar retraso e incluso incumplimiento de los pedidos. Por lo tanto, ante ello se obtuvo un indicador promedio del mantenimiento en las áreas de 8%.

Tabla 7. Evaluación del mantenimiento correctivo por áreas Octubre 2020 – Setiembre 2021

Área	Total de horas de mantenimiento correctivo	Total de horas de mantenimiento Global	Indicador
Extrusión	148.5	286.79	52%
Impresión	408.55	450.75	91%
Laminación	91.8	96.13	95%
Conversión	502.8	560.3	90%
Multifilamento	40.5	88.75	46%
Recicladora	60.83	61.83	98%
Telares	1962.46	2513.82	78%
Prensa	30.51	30.51	100%
Trensadora	0	1.5	0%
Total	3245.95	454.49	72%

Fuente. Elaboración propia

En la Tabla 7, se encuentra la evaluación del mantenimiento correctivo por áreas, indicando que el área de reciclaje es la que presenta mayores fallas, debido a que la máquina recicladora ya alcanzó su vida útil. El área de laminación, también presenta fallas frecuentes con un 95,5%, esto se debe a que no se le dedican horas de mantenimiento preventivo, seguido del área de impresión y conversión. El área de prensa, solo cuenta con mantenimiento correctivo, evidenciado que son las áreas principales del proceso productivo que presentan más fallas, por lo que se deben tomar las acciones correctivas correspondientes.

Tabla 8. Evaluación del mantenimiento de lubricación por áreas Octubre 2020 – Setiembre 2021

Área	Total de horas de mantenimiento de lubricación	Total de horas de mantenimiento Global	Indicador
Extrusión	97.12	286.79	34%

Impresión	39.2	450.75	9%
Laminación	4.33	96.13	5%
Conversión	52.5	560.3	9%
Multifilamento	19	88.75	21%
Recicladora	0.33	61.83	1%
Telares	0	2513.82	0%
Prensa	0	30.51	0%
Trensadora	1.5	1.5	100%
Promedio	23.78	454.49	20%

Fuente. Elaboración propia

En la Tabla 8, se encuentra la evaluación del mantenimiento de lubricación por áreas, mostrándose que el área de trenzadora donde solo cuenta con lubricación el área de talares no cuenta con lubricación, pue son los operarios de cada telar quienes se encargan de lubricar sus máquinas, sin embargo, no existe la debida responsabilidad ni compromiso por parte de ellos lo que genera paros en las maquinarias. El área que cuenta con mayor lubricación, es el área de extrusión con un 33,4%.

Tabla 9. Resumen de evaluación del mantenimiento en la empresa Octubre 2020 – Setiembre 2021

Área	Mantenimiento Preventivo	Mantenimiento Correctivo	Mantenimiento Lubricación
Extrusión	14%	52%	34%
Impresión	1%	91%	9%
Laminación	0%	95%	5%
Conversión	1%	90%	9%
Multifilamento	33%	46%	21%
Recicladora	1%	98%	1%
Telares	22%	78%	0%
Prensa	0%	100%	0%
Trensadora	0%	0%	100%
Promedio	8%	72%	20%

Fuente. Elaboración propia

En el resumen de evaluación del mantenimiento en la fábrica de saco de los meses de octubre 2020 a setiembre 2021, se consideró la (tabla 6), (tabla 7), (tabla 8), donde da como promedio del mantenimiento preventivo es de 8%, el mantenimiento correctivo es de 72%, mientras que el mantenimiento de lubricación es del 20%.

Tabla 10. Evaluación de la disponibilidad de las maquinarias

Equipos	Cantidad de averías	Horas de mantenimiento programados	Hora de Mant. No programado	Mantenibilidad	Confiabilidad	Disponibilidad inmediata
Ext.	146	286,79	125,45	0,51	1,96	56%
Impr.	97	450,75	173,22	0,22	4,65	62%
Lamin.	179	96,13	64,07	1,86	0,54	33%
Convers.	107	560,3	673,35	0,19	5,24	-20%
Multifil.	88	88,75	93,09	0,99	1,01	-5%
Reciclad.	56	61,83	37,54	0,91	1,10	39%

Telares	65	251,82	161,94	0,26	3,87	36%
Promedio	105,4	256,62	189,81	0,70	2,62	29%

Fuente. Elaboración propia

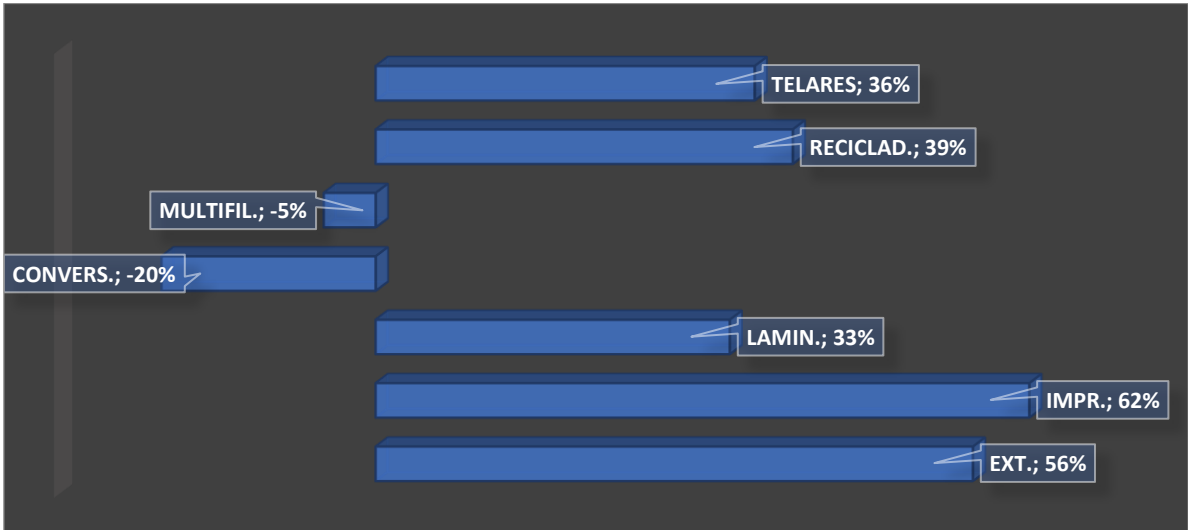


Figura 4. Evaluación de la disponibilidad de las maquinarias

Fuente. Elaboración propia

En el análisis se tiene que la maquina principal extrusora se encuentra con un 56% de disponible, por lo tanto, se hace mención que es la principal, es donde se va enfocado la propuesta de machine learning, para mejorar la disponibilidad de ella.

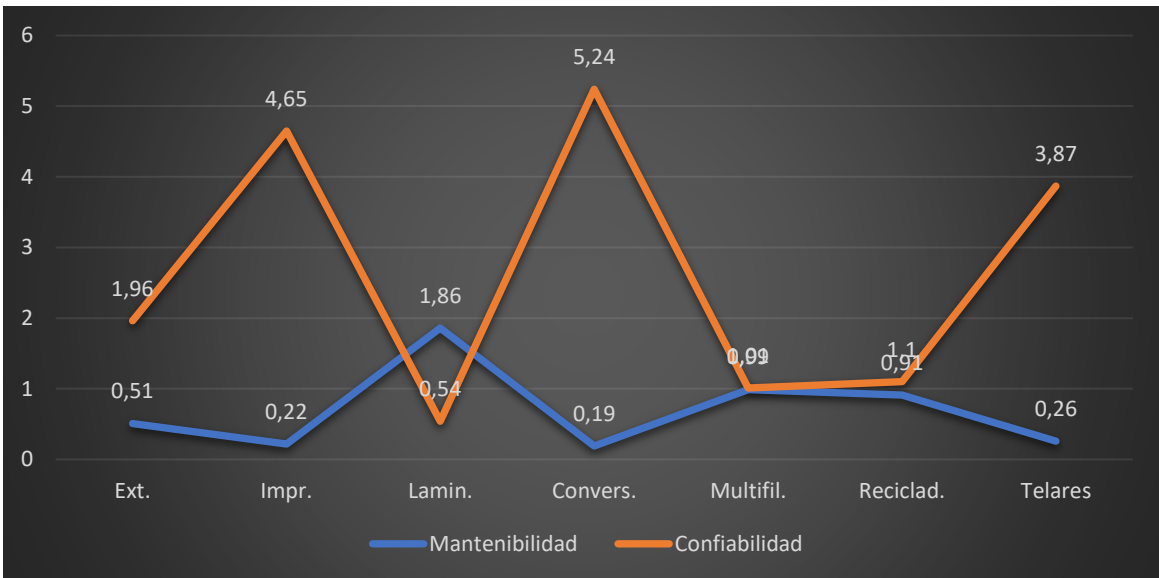


Figura 5. Evaluación de la mantenibilidad y confiabilidad de las maquinarias

Fuente. Elaboración propia

En la figura 4, se representa la evaluación de la mantenibilidad y confiabilidad de las maquinarias, demostrándose que la extrusora está en 0,51 en mantenibilidad, a su vez se encuentra en un término medio confiable 1,96.

4.2. Elaboración de la propuesta de implementación de machine learning en la gestión del mantenimiento de máquinas industriales

La propuesta de implementación de machine learning, para mejorar la gestión de mantenimiento de máquinas industriales:

1. Software

Aplicación Web, programa que codifica en un lenguaje interpretable por un navegador web.

Lenguaje de programación Python, permitirá hacer hincapié en la legibilidad de su código.

Base de datos NoSQL y DynamoDB AWS, servicio de base de datos que es gestionada NoSQL

Api Rest de reconocimiento de facial para las anomalías, en las maquinas industriales.

Api Rest de identificación con base de date del mantenimiento de la empresa.

2. Hardware

Servidor Amazon permitirá alojamiento de la base de datos.

Switch Poe Managed, permite darle control sobre su tráfico LAN, para así ofrecer funciones controlando dicho tráfico.

Sensores de obstáculo, dispositivo electrónico que pone en funcionamiento un sistema, asimismo recogerá información de los obstáculos que interfieren en los maquinarias.

Alarmas, permitirá lanzar las alertas cuando las maquinarias se encuentren fuera de lo establecido.

3. Gestión

Gestión de control de cambio, permitirá gestionar cualquier requerimiento de cambio que afecte el direccionamiento del proyecto de machine learning.

Gestión de pruebas, comprende la planificación, estimación, monitorización, así como el control de las labores de pruebas típicamente establecido por un gestor de pruebas.

Despliegue, la base de datos constará de una serie de módulos para el funcionamiento del sistema.

Implementación, comprenderá que una vez establecido todo las bases de datos, este se conectará con los sensores de las maquinarias, con la finalidad de recoger la información de cada una de ellas.

Tabla 11. Requerimiento funcionales por módulos a desarrollar

N°	Módulo	RF's Solicitud de soluciones	HR's Modelos operativos
1	Seguridad y acceso	6	58
2	Trabajadores	8	74
3	Controles de seguridad	20	170
4	Predicción y prevención	30	250
5	Notificaciones y alarmas	24	202
6	Reportes	40	330
7	Monitoreo	40	330
Total		168	1414

Fuente. Elaboración propia

Entre los requerimientos funcionales, por módulos que se pretenden a desarrollar, se encuentran los módulos de seguridad y acceso, trabajadores, controles de seguridad, predicción y prevención, notificaciones y alarmas, reportes, monitoreo.

Tabla 12. Control de pruebas por módulos a desarrollar

N°	Módulo	CP's Sistemas ciber físicos	HR's Modelos operativos
1	Seguridad y acceso	12	106
2	Trabajadores	16	138
3	Controles de seguridad	40	330
4	Predicción y prevención	40	330
5	Notificaciones y alarmas	34	282
6	Reportes	50	410
7	Monitoreo	50	410
Total		242	2006

Fuente. Elaboración propia

A la vez, los módulos, que se desarrollarán en el control de pruebas, se encuentra seguridad y acceso, trabajadores, controles de seguridad, predicción y prevención, notificaciones y alarmas, reportes y monitoreo.

Tabla 13. Cronograma de ejecución de la implementación

Actividad	Primer Trimestre	Segundo Trimestre	Tercer Trimestre	Cuarto Trimestre
Inicio	X			
Diseño		x		
Desarrollo		x		
Integración			x	X
Implementación				x

Gestión de calidad		x		x
Control y monitoreo				x

Fuente. Elaboración propia

La propuesta de machine learning, en la gestión de mantenimiento se desarrollará en un lapsus de 4 trimestres, considerando las actividades, de inicio, diseño, desarrollo, integración, implementación, gestión de calidad y control de

Tabla 14. Presupuesto de recursos

N°	Perfil	Cant.	Sueldo	Tiempo de contratación	Costo final S/,	Horas laborales
1	Arquitecto de software	1	S/ 5.000,00	3	S/ 15.000,00	528
2	Jefe de proyecto	1	S/ 4.500,00	8	S/ 36.000,00	1232
3	Ingeniero de redes	1	S/ 4.000,00	4	S/ 16.000,00	528
4	Técnico electrónico	1	S/ 3.000,00	3	S/ 9.000,00	352
5	Analista de Big Data	1	S/ 3.500,00	4	S/ 14.000,00	528
6	Analistas funcionales	1	S/ 3.500,00	3	S/ 10.500,00	704
7	Programadores	2	S/ 3.000,00	6	S/ 18.000,00	1056
8	Analista de calidad de software	1	S/ 3.000,00	6	S/ 18.000,00	1056
Total de presupuesto de recursos					S/ 136.500,00	5984

Fuente. Elaboración propia

El total del presupuesto de recursos, que se pretenderá emplear en la propuesta de Machine, es de S/. 136 500,00 soles.

Tabla 15. Presupuesto por software

N°	Software	Cant.	Precio S/.	Precio \$	Total S/.	Total \$
1	Amazon Dynamodb	2	S/ 3.800,00	\$ 1.131,59	S/ 7.600,00	\$ 2.263,18
2	Servidor	4	S/ 2.600,00	\$ 774,25	S/ 10.400,00	\$ 3.097,00
3	Software Machine	1	S/ 12.000,00	\$ 3.573,45	S/ 12.000,00	\$ 3.573,45
Total de presupuesto de Software					S/ 30.000,00	\$ 8.933,63

Fuente. Elaboración propia

Asimismo, se tiene que el presupuesto de software es de un total de S/. 30 000,00 soles, los cuales serán financiados por parte de la empresa.

Tabla 16. Presupuesto de Hardware

N°	Hardware	Canti.	Precio S/.	Precio \$	Total S/.	Total \$
1	Cámara Deeps Lens	10	S/ 1.020,00	\$ 303,74	S/ 10.200,00	\$ 3.037,40
2	Alarmas	10	S/ 1.000,00	\$ 297,79	S/ 10.000,00	\$ 2.977,90
3	Sensores de obstáculo	8	S/ 1.700,00	\$ 506,24	S/ 13.600,00	\$ 4.049,92

4	Switch Poe Managed	2	S/ 3.999,00	\$ 1.190,85	S/ 7.998,00	\$ 2.381,70
Presupuesto de Hardware					S/ 41.798,00	\$ 12.446,92

Fuente. Elaboración propia

El presupuesto de software, se tendrá que es S/.41 798,00 soles, los cuales se pretende ser financiado por parte de la empresa.

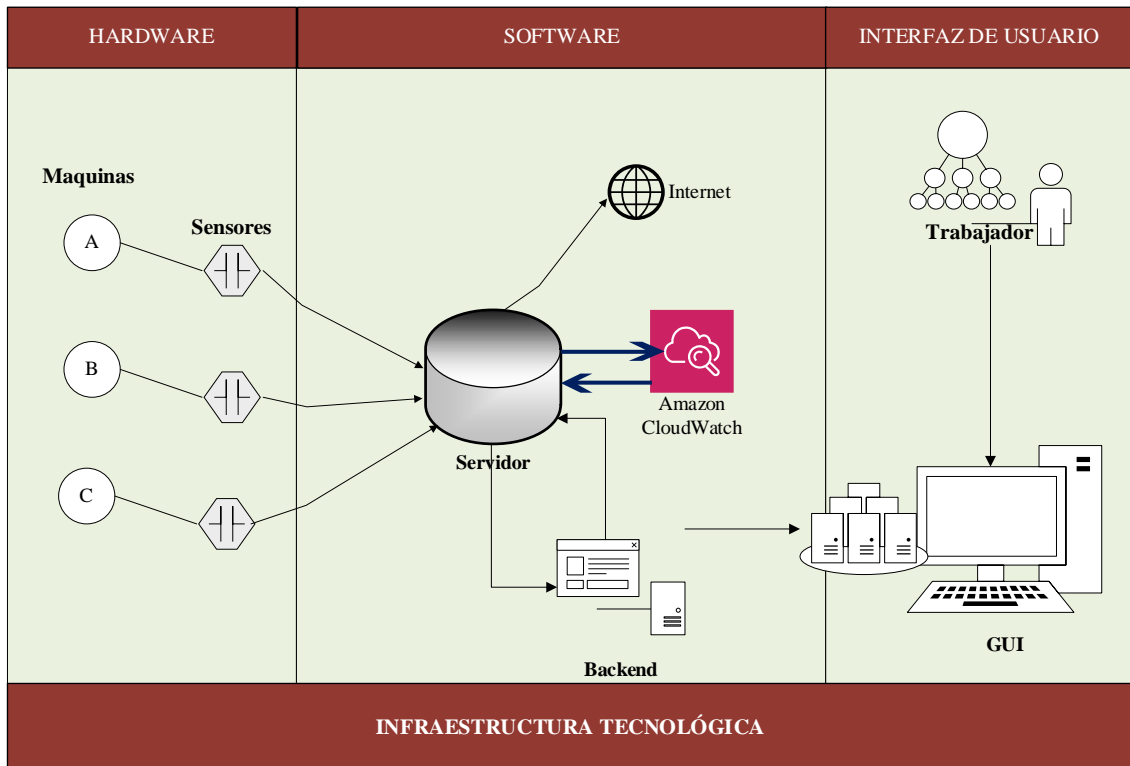


Figura 6. Infraestructura tecnológica

Fuente. Elaboración propia

La infraestructura tecnológica, que contará la propuesta de Machine Learning, consistirá que las máquinas, envíen información a los sensores de obstáculos, asimismo ellos se encontrarán conectado con el servidor que a la vez esto estará conectado con internet. El servidor, se encontrara alojado en Cloud Amazon, asimismo se tendrá un Backend, que contendrá los códigos, así como los algoritmos, que generan la orden al servidor, finalmente se conectará con un interfaz de usuario.

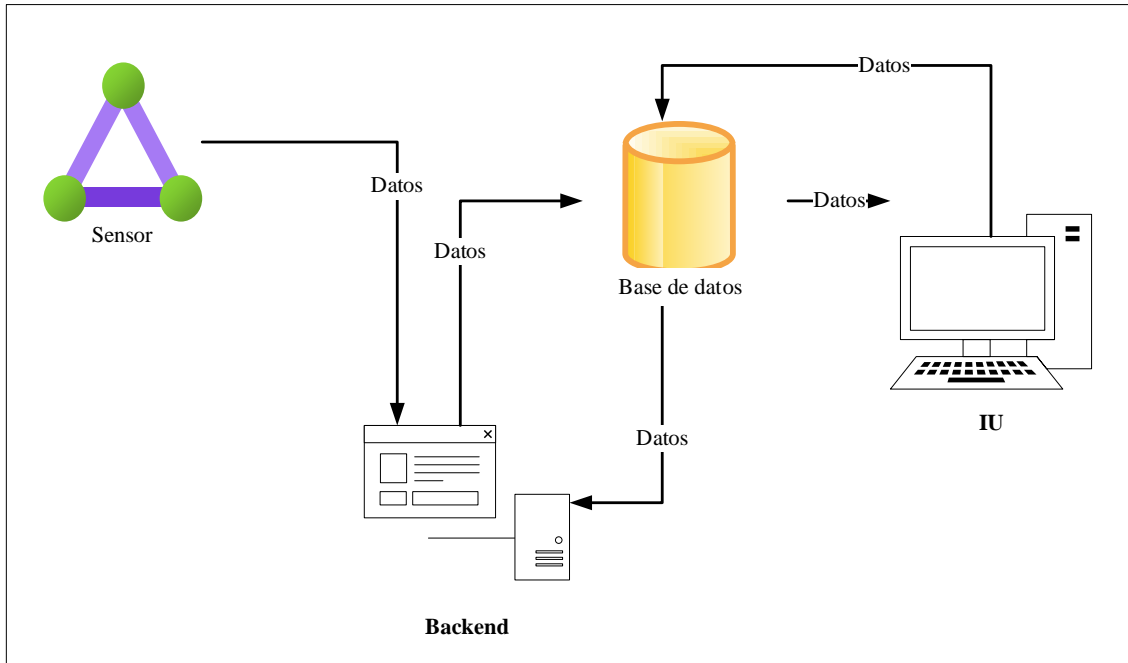


Figura 7. Diagrama de flujo de adquisición de datos

El flujo de adquisición de datos, se realiza cuando el sensor envía datos al backend, donde se encuentran alojados los algoritmos para procesar la información recibida para obtenerla en una base de datos, posteriormente lanzará información mutua al interfaz de usuario, que el mismo puede solicitar o recibir información.

La comprobación de los algoritmos se realizó, mediante php lenguaje y Mysql BD

```
<?php
$data=executesql("select count(id_arduino) as total_fallas, SUM(tiempo_entre_falla) as suma_de_fallas from data_arduinios where estado_idestado=1 order by orden
desc",0);
if(!empty($data)){
    $n_fallas=$data['total_fallas']-1;

    $promedio_entre_fallas=$data['suma_de_fallas']/$n_fallas;
    $confiabilidad_minutos= 1/$promedio_entre_fallas ;
    /* el -1; se le resta proque el primer registro que empezo a operar la maquina, esa tiene valor por default cero, por eso no se considera. en proceso y debe
    restarse ese -1: que einterpreta ala linea origen */
}
?>
```

Figura 8. Algoritmo puro de confiabilidad

```
<div class="col-sm-4 ">
<?php
$data=executesql("select count(id_arduino) as total_fallas, SUM(tiempo_entre_falla) as suma_de_fallas from data_arduinios where estado_idestado=1 order by orden
desc",0);
if(!empty($data)){
    $n_fallas=$data['total_fallas']-1;

    $promedio_entre_fallas=$data['suma_de_fallas']/$n_fallas;
    $confiabilidad_minutos= 1/$promedio_entre_fallas ;
    /* el -1; se le resta proque el primer registro que empezo a operar la maquina, esa tiene valor por default cero, por eso no se considera. en proceso y debe
    restarse ese -1: que einterpreta ala linea origen */
}
?>
<h3>Confiabilidad </h3>
<p>Tiempo promedio entre fallas: <?php echo $promedio_entre_fallas; ?> </p>
<p><b>Resultado:</b> <?php echo $confiabilidad_minutos; ?> </p>
</div>
```

Figura 9. Ejecutando algoritmo de confiabilidad, conectando con sistema

Fuente. Elaboración propia


```

<?php /* Mantenibilidad */
$data_mante=executesql("select sum(reparaciones) as n_reparaciones, SUM(tiempo_mantenimiento) as tiempo_total_mantenimiento from data_arduinios where
estado_idestado=1 order by orden desc",0);
if(!empty($data_mante)){
    $mantenibilidad_minutos=$data_mante['tiempo_total_mantenimiento']/$data_mante["n_reparaciones"];
}
?>

```

Figura 10. Algoritmo puro de mantenibilidad

```

<?php
$data=executesql("select count(id_arduino) as total_fallas, SUM(tiempo_entre_falla) as suma_de_fallas from data_arduinios where estado_idestado=1 order by orden
desc",0);
if(!empty($data)){
    $n_fallas=$data['total_fallas']-1;

    $promedio_entre_fallas=$data['suma_de_fallas']/$n_fallas;
    $confiabilidad_minutos= 1/$promedio_entre_fallas ;
}
?>

```

Figura 11. Ejecutando algoritmo de mantenibilidad, conectando con sistema

```

<?php /* Disponibilidad */
$data_dispo=executesql("select sum(reparaciones) as n_reparaciones, SUM(tiempo_reparacion) as total_tiempo_reparacion from data_arduinios where estado_idestado=1
order by orden desc",0);
if(!empty($data_dispo)){
    $t_promedio_reparacion=$data_dispo['total_tiempo_reparacion']/$data_dispo['n_reparaciones'];

    $disponibilidad= $promedio_entre_fallas/ ($promedio_entre_fallas + $t_promedio_reparacion);
}
?>

```

Figura 12. Algoritmo puro de disponibilidad

```

<div class="col-sm-4 ">
<?php /* Disponibilidad */
$data_dispo=executesql("select sum(reparaciones) as n_reparaciones, SUM(tiempo_reparacion) as total_tiempo_reparacion from data_arduinios where estado_idestado=1
order by orden desc",0);
if(!empty($data_dispo)){
    $t_promedio_reparacion=$data_dispo['total_tiempo_reparacion']/$data_dispo['n_reparaciones'];

    $disponibilidad= $promedio_entre_fallas/ ($promedio_entre_fallas + $t_promedio_reparacion);
}
?>
<h3>Disponibilidad % </h3>
<p>Tiempo promedio entre fallas: <?php echo $promedio_entre_fallas; ?> </p>
<p><b>Resultado:</b> <?php echo ($promedio_entre_fallas>0)?$disponibilidad:'Aún no existen fallas'; ?> </p>
</div>
</div>

```

Figura 13. Ejecutando algoritmo de disponibilidad, conectando con sistema

```
C:\wamp64\www\mori\tuweb7\w2021\ardu_ewin\temperaturas.php - Notepad++
Archivo Editar Buscar Vista Codificación Lenguaje Configuración Herramientas Macro Ejecutar Plugins Ventana ?
string.py A1_azure git acceder new 4 new 3 auten.php index.php class bd.php new 2 banco_preguntas_examenes.php new 1 webinas.php temperaturas.php
232 <div class="col-sm-4 ">
233 <?php /* Mantenibilidad */
234 $data_mante=executesql("select sum(reparaciones) as n_reparaciones, SUM(tiempo_mantenimiento) as tiempo_total_mantenimiento from data_arduin
235 estado_idestado=1 order by orden desc",0);
236 if(!empty($data_mante)){
237     $mantenibilidad_minutos=$data_mante['tiempo_total_mantenimiento']/$data_mante["n_reparaciones"];
238     /* sum(reparaciones) as n_reparaciones: suma todos los 1. que indican que se realizo reparacion, los que no figuran en cero. */
239 }
240 ?>
241 <h3>Mantenibilidad </h3>
242 <p>Tiempo total de mantenimiento: <?php echo $data_mante["tiempo_total_mantenimiento"]; ?> </p>
243 <p>N° reparaciones: <?php echo $data_mante["n_reparaciones"]; ?> </p>
244 <p><b>Resultado:</b> <?php echo ($data_mante["n_reparaciones"]>0)?$mantenibilidad_minutos:'Aún no existen reparaciones'; ?> </p>
245 </div>
246
247
248 <div class="col-sm-4 ">
249 <?php /* Disponibilidad */
250 $data_dispo=executesql("select sum(reparaciones) as n_reparaciones, SUM(tiempo_reparacion) as total_tiempo_reparacion from data_arduin
251 order by orden desc",0);
252 if(!empty($data_dispo)){
253     $t_promedio_reparacion=$data_dispo['total_tiempo_reparacion']/$data_dispo['n_reparaciones'];
254     $disponibilidad= $promedio_entre_fallas/ ($promedio_entre_fallas + $t_promedio_reparacion);
255 }
256 ?>
257 <h3>Disponibilidad & </h3>
258 <p>Tiempo promedio entre fallas: <?php echo $promedio_entre_fallas; ?> </p>
259 <p><b>Resultado:</b> <?php echo ($promedio_entre_fallas>0)?$disponibilidad:'Aún no existen fallas'; ?> </p>
260 </div>
261 </div>
262
263 <div class="col-sm-3 hide criterio_mostrar">
264 <?php select_sql("nregistros"); ?>
265 </div>
266 </div>
267 </form>
PHP Hypertext Preprocessor file length: 13,562 lines: 291 Ln: 1 Col: 1 Pos: 1 Unix (LF) UTF-8 INS
13:56
29/11/2021
```

Figura 14. Algoritmo general para la propuesta

The screenshot shows a web browser window displaying a control system interface. The browser's address bar shows the URL: localhost/mori/tuweb7/w2021/ardu_ewin/index.php?page=temperaturas&module=Temperatura&parenttab=Secciones. The interface has a dark blue sidebar on the left with the title 'SISTEMA CONTROL' and a menu under 'SECCIONES' including 'Inicio', 'Secciones', 'Temperatura', 'Obstaculos', 'Data', and 'Configuraciones'. The main content area is titled 'Bienvenido Soporte' and 'Sección » Temperatura'. It features three summary cards: 'Confiabilidad' (0.0019710906701708 Minutos), 'Mantenibilidad' (Minutos:), and 'Disponibilidad' (Minutos:). Below these is a table with columns: Temp, Fecha, Hora, TPEF (min), ESTADO, and Opciones. The table contains four rows of data, all with 'Habilitado' status. A small blue box with the number '1' is visible in the bottom right corner of the table area.

Temp	Fecha	Hora	TPEF (min)	ESTADO	Opciones
100	2021-10-21	01:24:38	1	Habilitado	[Icon]
100	2021-10-21	01:23:29	21	Habilitado	[Icon]
100	2021-10-21	01:01:50	1500	Habilitado	[Icon]
0	2021-10-20	00:01:00	0	Habilitado	[Icon]

Figura 15. Prueba 1 de los algoritmos

Mantenibilidad

Tiempo total de mantenimiento: 170

Nº reparaciones: 1

Resultado: 170

Disponibilidad

Minutos:

ip	↕↕	T entre falla (min)	↕↕	Mantenimiento(min)	↕↕	Reparación(min)	↕↕
		4					
		1					
		21		50			
		1500		120		360	
		0					

Figura 16. Prueba 2 de los algoritmo

Bienvenido Soporte

Sección » Procesamiento

Confiabilidad

Tiempo promedio entre fallas: 381.5
Resultado: 0.0026212319790301

Mantenibilidad

Tiempo total de mantenimiento: 170
Nº reparaciones: 1
Resultado: 170

Disponibilidad %

Tiempo promedio entre fallas: 381.5
Resultado: 0.51449763991908

<input type="checkbox"/>	Fecha	Hora	Temp	Obst	T entre falla (min)	Mantenimiento(min)	Reparación(min)	ESTADO	Opciones
<input type="checkbox"/>	2021-10-21	01:28:51	100	NO	4			Habilitado	acción
<input type="checkbox"/>	2021-10-21	01:24:38	100	NO	1			Habilitado	acción
<input type="checkbox"/>	2021-10-21	01:23:29	100	NO	21	50		Habilitado	acción
<input type="checkbox"/>	2021-10-21	01:01:50	100	NO	1500	120	360	Habilitado	acción
<input type="checkbox"/>	2021-10-20	00:01:00	0	NO	0			Habilitado	acción

Figura 17. Prueba final comprobada de los algoritmos

Una vez, realizado la simulación de la propuesta de machine learning, se consideró que se reducirá los accidentes, donde el sensor de obstáculos, identificará los obstáculos que se presentan cuando la maquinaria está en movimiento, para lo cual los indicadores de la gestión de mantenimiento quedarían de la siguiente manera:

Tabla 17. Estimación de la mejora de la disponibilidad de las maquinarias

Equipos	Cantidad de averías	Horas de mantenimiento programados	Hora de Mant. No programado	Mantenibilidad	Confiabilidad	Disponibilidad inmediata
Ext.	29	286,79	25,09	0,10	9,89	90%
Impr.	19	450,75	34,644	0,04	23,72	85%
Lamin.	35	96,13	12,814	0,36	2,75	53%
Convers.	21	560,3	134,67	0,04	26,68	32%
Multifil.	17	88,75	18,618	0,19	5,22	8%
Reciclad.	11	61,83	7,508	0,18	5,62	62%
Telares	13	251,82	32,388	0,05	19,37	58%
Promedio	20,71	256,62	37,96	0,14	13,32	0,55

Fuente. Elaboración propia

En la estimación de la mejora de la disponibilidad de las maquinarias, posterior de la implementación de la propuesta, se obtuvo una mejora en la disponibilidad en mantenibilidad, confiabilidad y disponibilidad, reduciendo de esta forma los riesgos críticos de la producción que es seguridad del trabajador, obstáculos presentados en la maquinaria. Por lo tanto, se demuestra que ambas maquinaria obtendrá una disponibilidad del 90% y 85% respectivamente.

4.3. Estimación del costo/beneficio de la implementación de la propuesta.

Con la finalidad de estimar el indicador de beneficio/costo, se realizó el análisis de la producción de los meses de Octubre 2020 a setiembre 2021, de esta forma se calculará el beneficio reflejado en la producción.

Tabla 18. Producción de Enero – Diciembre 2020

Meses	Producción (Kg)
Octubre	341319,59 Kg
Noviembre	319786,83 Kg
Diciembre	307749,31 Kg
Enero	333651,52 Kg
Febrero	479601,88 Kg
Marzo	418206,48 Kg
Abril	333000,52 Kg
Mayo	315777,71 Kg
Junio	349257,20 Kg

Julio	339507,55 Kg
Agosto	351527,64 Kg
Septiembre	298911,51 Kg
Promedio mes	349024,81 Kg
Promedio día	11634,16 Kg
Promedio por hora	1454,27 Kg

Fuente. Elaboración propia

Una vez obtenido el análisis de la producción, se analizó cuando son los beneficios en horas de mantenimiento no programado, destacando que ello se refleja las paradas imprevistas de las maquinarias, basándose en la (Tabla 10) (Tabla 17).

Tabla 19. Análisis del beneficio obtenido en horas

	Horas en promedio
Situación Actual	189,81
Situación esperada	37,60
Beneficio obtenido en horas	152,21

Fuente. Elaboración propia

Posterior de obtener el beneficio obtenido en horas a partir de la implementación de la propuesta de machine learning en la gestión de mantenimiento, se valoriza el beneficio obtenido, para así determinar el beneficio/costo.

Tabla 20. Análisis del beneficio obtenido de la propuesta en S/.

Beneficio obtenido en horas	152,21	Hrs
Promedio por hora	1454,27	Kg
Beneficio obtenido en Kg	221354,437	Kg
Utilidad	2,2	
Beneficio obtenido en S/,	486979,761	S/,

Fuente. Elaboración propia

Tabla 21. Evaluación económica

	0	1	2	3	4	5	6
Incremento de la producción		S/ 486.979,76	S/ 486.979,76	S/ 486.979,76	S/ 486.979,76	S/ 486.979,76	S/ 486.979,76
Total de beneficios		S/ 486.979,76	S/ 486.979,76	S/ 486.979,76	S/ 486.979,76	S/ 486.979,76	S/ 486.979,76
Arquitecto de software	S/ 15.000,00						
Jefe de proyecto	S/ 36.000,00						
Ingeniero de redes	S/ 16.000,00						
Técnico electrónico	S/ 9.000,00						
Analista de Big Data	S/ 14.000,00						
Analistas funcionales	S/ 10.500,00						
Programadores	S/ 18.000,00						
Analista de calidad de software	S/ 18.000,00						
Amazon Dynamodb	S/ 7.600,00	S/ 7.600,00	S/ 7.600,00	S/ 7.600,00	S/ 7.600,00	S/ 7.600,00	S/ 7.600,00
Servidor	S/ 10.400,00	S/ 10.400,00	S/ 10.400,00	S/ 10.400,00	S/ 10.400,00	S/ 10.400,00	S/ 10.400,00
Software Machine	S/ 12.000,00	S/ 12.000,00	S/ 12.000,00	S/ 12.000,00	S/ 12.000,00	S/ 12.000,00	S/ 12.000,00
Cámara Deeps Lens	S/ 10.200,00	S/ 10.200,00	S/ 10.200,00	S/ 10.200,00	S/ 10.200,00	S/ 10.200,00	S/ 10.200,00
Alarmas	S/ 10.000,00	S/ 10.000,00	S/ 10.000,00	S/ 10.000,00	S/ 10.000,00	S/ 10.000,00	S/ 10.000,00
Sensores de movimiento	S/ 13.600,00	S/ 13.600,00	S/ 13.600,00	S/ 13.600,00	S/ 13.600,00	S/ 13.600,00	S/ 13.600,00
Switch Poe Managed	S/ 7.998,00	S/ 7.998,00	S/ 7.998,00	S/ 7.998,00	S/ 7.998,00	S/ 7.998,00	S/ 7.998,00
Total de costo	S/ 208.298,00	S/ 71.798,00	S/ 71.798,00	S/ 71.798,00	S/ 71.798,00	S/ 71.798,00	S/ 71.798,00
Utilidad bruta	-S/ 208.298,00	S/ 415.181,76	S/ 415.181,76	S/ 415.181,76	S/ 415.181,76	S/ 415.181,76	S/ 415.181,76
Depreciación	-S/ 83.319,20	S/ 166.072,70	S/ 166.072,70	S/ 166.072,70	S/ 166.072,70	S/ 166.072,70	S/ 166.072,70
Utilidad ante de impuestos		S/ 249.109,06	S/ 249.109,06	S/ 249.109,06	S/ 249.109,06	S/ 249.109,06	S/ 249.109,06
Impuestos		S/ 74.732,72	S/ 74.732,72	S/ 74.732,72	S/ 74.732,72	S/ 74.732,72	S/ 74.732,72
Utilidad neta	-S/ 291.617,20	S/ 174.376,34	S/ 174.376,34	S/ 174.376,34	S/ 174.376,34	S/ 174.376,34	S/ 174.376,34
VNA	S/ 320.266,99						
TIR	56%						
b/c	2,34						

Fuente. Elaboración propia

a. Valor actual neto

El valor actual, para la tasa de descuento de la propuesta de Machine Learning es VAN= S/ 320.266,99. En la fábrica de sacos, el proyecto es rentable por que el VAN es de VAN= S/ 320.266,99, demostrándose que se genera beneficios después de haber logrado cubrir todos los costos, esto significa que es viable en la mejora de la gestión del mantenimiento

b. Tasa Interna de Retorno

La tasa interna de retorno, es de 56%, siendo mayor al costo del capital de 15%, por ende la mejora de la gestión del mantenimiento genera beneficios, significando un incremento de la rentabilidad

c. Beneficio/costo

En el análisis de beneficio/costo es de S/. 2,34 indicando que por cada nuevo sol invertido, se obtiene un beneficio de 2,34 nuevos soles, es decir que se recupera de su inversión

V. DISCUSIÓN

La presente investigación se realizó en la fábrica de sacos, determinando la disponibilidad de la maquinaria principal extrusora se encuentra en 56%; mantenibilidad es 0,51 confiabilidad de 1,96; mientras que en el aporte de (Yyi et al., 2021) evaluó el tiempo de ejecución es un 0,48% más rápido, un 5,43% de bajo costos, así como el uso de energía es 28,10%, siendo bajo en comparación con los segundo mejores resultados en la precisión de entrenamiento y prueba del modelo de predicción que es de 95,1%, asimismo que el 94,5% respectivamente, indicando que dicho modelo de modelo de mantenimiento se basa en la regresión logística, de dos clases mediante un conjunto de datos en tiempos reales, tales como la gestión de recursos basada en algoritmo genético, que se integra con el aprendizaje automático para el mantenimiento predictivo en computación de niebla. Además se sustenta con el aporte teórico, (Sánchez, 2017) indica que la mantenibilidad se considera como la capacidad del equipo para lograr ser reparado dentro del tiempo, especificado, después de la falla y volver al funcionamiento normal, donde la preocupación es cuanto menos tiempos dedique a trabajos de mantenimiento y reparación mayor será el nivel de mantenimiento.

Con la propuesta de machine learning se logra mejora la gestión de mantenimiento de la maquina principal extrusora en 90%, mantenibilidad en 0,10 y la confiabilidad a 9,89; además se tiene el aporte de (Ullah et al.,2017) se demostró que el rendimiento de MLP, obtuvo un precisión inicial de 79,78% incrementa el MLP, con el corte del gráfico para incrementar la precisión al 84% demostrando que la implementación fue exitosa para un nuevo sistema, indicando que las imágenes térmicas se toman a través de cámaras infrarrojas, sin perturbar las operaciones de funciones de las subestaciones eléctricas. (Dueñas et al., 2020) demostraron que dos empresas colombianas de gran relevancia en el país en la implementación de tecnologías de la industria 4.0 en los procesos de mantenimiento predictivo, determinando de forma correcta cada variable crítica del proceso, mediante la realización de un análisis dato, donde su estructuración.

Asimismo, con respecto a la maquina de embobinadora en el diagnostico actual se encontró un indicador de disponibilidad de 62%, mantenibilidad de 0,22, con una confiabilidad de 4,65 mejorando con la implementación de machine learning la disponibilidad a 85%, la mantenibilidad a 0,04 y una confiabilidad de 23,72 mientras

que (Gonzales, 2021) sostiene que la maquinaria industrial liviana son artefactos destinados a laborar con componentes pequeños, como es el claro sustento al momento de soldar, agujerear, además permitió fabricar recambios específicos de las maquinarias, asimismo que la maquinaria pesada, está compuesta por los artefactos que tienen como finalidad laborar en actividad donde no necesita una aplicación compleja de la fuerza.

La infraestructura tecnológica que contará la propuesta de Machine Learning, consiste que las maquinas envíen información a los sensores de obstáculos, los cuales se encontrarán conectado con el servidor, que a la vez esto se encontrará conectado con internet, indicando que el servidor se encontrará alojado en Cloud Amazon, mediante un Backend, que contendrá los códigos, así como los mismos algoritmo que generan la orden al servidor, finalmente se conectará con un interfaz de usuario; mientras que en el aporte de (Mohan et al., 2021) desglosa en minutos por mes, así como el número de averías en un mes, debido a que los fenómenos que se analizaron posterior de aplicar el enfoque propuesto, asimismo que el sistema incrementó el tiempo medio entre fallos en un 800%, donde se alcanzó un logro de un tiempo de inactividad cero en las industrias, indicando que las averías imprevistas de cualquier planta industrial allanan, el camino para enormes pérdidas para la industria en términos de producción y beneficios.

Con la propuesta de implementación del Machine Learning en la gestión de mantenimiento, se mantuvo un b/costo de 2,34 afirman que por cada sol invertido, se obtiene un beneficio de 2,34 mientras que en el aporte de (Susto, 2021) demostró que la capacitación de múltiples módulos de clasificación con diferentes horizontes de predicción para proporcionar diferentes compensaciones de rendimientos, donde la eficacia de la metodología se demuestro empleando un simulado a un problema de mantenimiento de fabricación en semiconductores de referencia. A la vez, con su fundamento teórico, de (Friedrich et al.,2016) el Machine Learning, forma parte de la inteligencia artificial, donde la manera de pensar da a entender, en vez de realizar alguna actividad por instinto, que se emplea en el cerebro, al momento de considerar un cuestionamiento. Entre los fundamentos de la metodología, se considera el aprendizaje el error y los procesos para el ajuste, seguido de las etapas de un proyecto de Machine Learning. Por otro lado, el análisis del valor actual, en base a la tasa de descuento de la propuesta de Machine

Learning es VAN= S/ 320.266,99 garantizando que se genera beneficio después de haber logra cubrir todos los costos, esto significa que es viable en la mejora de la gestión de mantenimiento, mientras con el aporte de (Ruiz et al., 2019) sostuvo que con el modelo propuesto se fusiona de forma iterativa, donde el conocimiento experto con la información en tiempo real procedente de los procesos de laminación en caliente realizados en la fábrica, además, que el modelo predictivo ha sido ajustado, con la finalidad de evaluar datos reales de procesos 118 k, indicando que sus virtudes para impulsar la era de la industria 4.0, señalando que la integración de las técnicas de vanguardia, implica una revolución profunda y compleja, que suele ser cambiante de los procesos programados a procesos inteligentes, indicando que los cambios programados a procesos inteligentes reactivos, se debe aplicarse en diferentes niveles; mientras que en el aporte de (Ameeth y Cuervo, 2017) señala que el uso del machine learning, se demuestra como un componente vital en el IIoT, demuestra mejoras en el proceso de fabricación en general, induciendo que con el uso de tecnologías de internet las cosas (IoT) en la fabricación permite aprovecharlos casos mejorando el proceso de fabricación aprovecha los datos de la máquina generado por distintos sensores, para aplicar varios análisis sobre ellos para obtener información útil. También, en el aporte de Paolanti (2018) se probó el sistema como claro ejemplo de la industria, a través del desarrollo del análisis del sistema de datos, empleando el enfoque de aprendizaje automático, señalando que el monitoreo de la condición junto con el mantenimiento predictivo de los motores eléctricos, con otros equipos empleados por la industria, evitando grandes pérdidas económicas graves resultantes de fallas inesperadas del motor. Por otra parte, en su fundamento teórico (Sánchez, 2017) señalo que la confiabilidad se refiere a la posibilidad de que el equipo realice sus funciones requeridas sin fallas durante un cierto período de operación en condiciones ambientales. Al calcular la confiabilidad se utiliza el tiempo medio entre fallas de cada dispositivo a analizar. Por otra parte, García (2013) señala que la gestión del mantenimiento es primordial, para garantizar la continuidad del trabajo productivo evitando interrupciones del programa debido a fallas de la máquina, indicando que el mantenimiento, así como todas las actividades son necesarias para mantener las máquinas e instalaciones en condiciones adecuadas que logren las funciones establecidas que mejoran la producción. El mantenimiento, optimiza la

disponibilidad de las maquinarias, con el objetivo de reducir los costos incurridos en las paradas de producción, que son ocasionadas por la deficiencia del mantenimiento de las maquinarias, a través de la ejecución de una determinada cantidad de mantenimiento en el momento establecido (García, 2013).

VI. CONCLUSIONES

1. En la evaluación de la eficiencia actual de la gestión de mantenimiento de máquinas industriales, se logró determinar que las maquinarias que generan mayor riesgo en la producción son la extrusora y la embobinado, además, se demostró que en la extrusora mantiene los indicadores de mantenibilidad de 0,51 confiabilidad, 1,96 disponibilidad 56%; mientras que la embobinadora mantiene mantenibilidad 0,22, confiabilidad 4,65, con disponibilidad del 62%.
2. La propuesta de implementación de machine learning, fue establecido con la finalidad de que permita identificar los obstáculos presentando en las maquinarias en movimiento, con la finalidad de reducir el riesgo al trabajador, así como también se cumpla el mantenimiento establecido por cada maquinaria.
3. En la evaluación del costo beneficio de la implementación de machine learning, se demostró una vez comprobado, los algoritmos de los indicadores de la gestión mantenimiento, dando como resultado que la extrusora tiene un indicador de mantenibilidad 0,10, confiabilidad 9,89, con disponibilidad 90%, mientras que la embobinadora, su nuevo indicador de mantenibilidad es 0,04, confiabilidad 23,72 y disponibilidad 85%, a la vez se demostró un indicador beneficio/costo de 2,34, con un VAN de S/. 320.266,991 soles, demostrándose que genera beneficios después de haber logrado cubrir todos los costos, asimismo con un TIR de 56% siendo mayor que el costo del capital del 15%.

VII. RECOMENDACIONES

Se recomienda a futuros estudiosos de industria 4.0 profundizar en machine learning, debido que es una rama de la inteligencia artificial que se puede implementar en diferentes áreas, en este caso plasmo en el área mediante, que a través de una base de datos, logrará predecir las fallas así como los tiempos de fallas, tiempo por mantenimiento entre otros de cada máquina..

Se recomienda, a la gerencia de la fábrica de sacos, tomar como referencia los resultados de la investigación, con la finalidad que tengan conocimiento cuanto es el beneficio que obtendrán si se digitaliza los procesos productivos de la empresa.

Se recomienda, a la jefatura de mantenimiento, digitalizar su plan de mantenimiento que cuenta la empresa, con el propósito que se cumpla y así de esta forma reducir los costos de mantenimiento correctivo, asimismo que mediante el proceso de machine learning, le permita predecir cuándo fallará la maquinaria.

REFERENCIAS

- ALAVERA. Gestión de mantenimiento preventivo y su relación con la disponibilidad de flota de camiones 730 e Komatsu - 2013. Lima: Ingeniería Industrial. Vol. 34, p. 12. ISSN: 1025-9929. [En línea] 2016.
- ÁLOGOS. Introducción A Machine Learning. [En línea] 2018. <http://alogos.es/introduccion-machine-learning/>. 2018
- AMENDOLA. Organización y gestión del mantenimiento. Valencia: PMM Institute For Learning. [En línea] 2012.
- ARIAS Fidas. El proyecto de investigación 6a Edición. [En línea] 2012. https://www.researchgate.net/publication/301894369_EL_PROYECTO_DE_INVESTIGACION_6a_EDICION.2012
- ARTEAGA y Gorozabel. Implementación del mantenimiento centrado en confiabilidad a maquinarias críticas de la plaza Calderón. [En línea] 2021. <http://revistas.unica.cu/index.php/uciencia/article/view/1784.2021>
- BUSTAMENTE. Gestión de mantenimiento preventivo en la línea de pilado de arroz, para mejorar la productividad de la empresa Induamérica Trade S.A. Universidad César Vallejo. [En línea] 2020. <https://repositorio.ucv.edu.pe/handle/20.500.12692/49913.2020>
- CAMISIÓN, C. y Gonzáles, T. GESTIÓN de la calidad: conceptos, enfoques, modelos. Madrid: Pearson Educación S.A. [En línea] 2016.
- CARRANZA. Gestión del mantenimiento preventivo para mejorar la productividad en el proceso productivo de sacos de una empresa de Lambayeque. (Tesis de pregrado). [En línea] 2020. https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/56713/Carranza_RE-SD.pdf?sequence=1&isAllowed=y.2020
- CONTRERAS, J. Diseño de un modelo para mantenimiento predictivo en motores de inducción utilizando técnicas de la industria 4.0. Universidad Tecnológica del Perú. [En línea] 2020. https://repositorio.utp.edu.pe/bitstream/handle/20.500.12867/4275/Jose_Contreras_Tesis_Titulo%20Profesional_2020.pdf?sequence=1&isAllowed=y.2020

- CRUZ. Mantenimiento preventivo basado en la confiabilidad para mejorar la disponibilidad y confiabilidad en maquinas circulares en la empresa WF S.A.C.- Lima . [En línea] 2019. <http://revistas.ucv.edu.pe/index.php/INNOVACION/article/download/998/783/>. 2019
- DUEÑAS, L., y otros. Casos de éxito en la implementación del mantenimiento predictivo mediante el uso de tecnologías de la industria 4.0 en empresas colombianas. [En línea] 2020. https://repositorio.ulima.edu.pe/bitstream/handle/20.500.12724/13918/Due%c3%b1as_Villegas_Castiblanco_Casta%c3%b1o_Casos-de-%c3%a9xito-en-la-implementaci%c3%b3n-del-mantenimiento-predictivo-mediante-el-uso-de-tecnolog%c3%adas.pdf?sequence=1&isAllowed=y.2020
- FAUSING y Reza. Predictive Maintenance for Pump Systems and Thermal Power Plants: State-of-the-Art Review, Trends and Challenges. MPDI. [En línea] 2020. <https://www.mdpi.com/1424-8220/20/8/2425/htm>.2020
- FRACTTAL. 2021. Fracttal cierra una inversión de US\$ 5.3 millones para transformar el mantenimiento del futuro. [En línea] 2021. <https://www.iagua.es/noticias/global-omnium/fracttal-cierra-inversion-us-53-millones-transformar-mantenimiento-futuro>.2021
- FRIEDRICH, Ebert y Sitftung. La estrategia alemana Industria 4.0: el capitalismo renano en la era de la digitalización. [En línea] 2016. <https://core.ac.uk/download/pdf/228074134.pdf>. 2016
- GARCÍA. Organización y gestión integral del mantenimiento. [En línea] 2016.
- GESING, B, Peterson, S y Michelsen, D. Artificial Intelligence in Logistics. Troisdorf, Germany:DHL Customer Solutions & Innovation. [En línea] 2018.
- GONZALES. Industriales. Maquimedia. [En línea] 2021. <https://maquimedia.com/maquinas/industriales/>.2021
- GUERRERO, C., y otros. Mantenimiento predictivo mediante técnicas de Machine Learning. [En línea] 2019. http://dspace.aepro.com/xmlui/bitstream/handle/123456789/2293/AT03-020_2019.pdf?sequence=1&isAllowed=y.2019

- HADI, y otros. Planning for Maintenance and Repair of Continuous Ship Unloader Using the IRRO Method. *Jurnal Rancang Bangun dan Teknologi*. [En línea] 2021. <http://ojs.pnb.ac.id/index.php/LOGIC/article/view/2383>.2021
- HERNÁNDEZ, Fernández y Baptista. Metodología de la investigación. [En línea] 2016. <https://www.uca.ac.cr/wp-content/uploads/2017/10/Investigacion.pdf>. 2016
- KAI Teoh, Yyi Kai, Singh Gill, Sukhpal y Kumar Parlikad, Ajith. IoT and Fog Computing based Predictive Maintenance Model for Effective Asset Management in Industry 4.0 using Machine Learning. in *IEEE Internet of Things Journal*. [En línea] 2021. <https://ieeexplore.ieee.org/abstract/document/9319212>.2021
- KAI, Ulrich y Fazel. 2020. Analyzing the impact of maintenance on profitability using dynamic bayesian networks. *Procedia CIRP*. [En línea] 2020. <https://www.sciencedirect.com/science/article/pii/S2212827120303231>.2020
- KANAWADAY, Ameeth y Sane, Aditya. Machine learning for predictive maintenance of industrial machines using IoT sensor data. *Frontiers in Education Conference*. [En línea] 2018. <https://ieeexplore.ieee.org/abstract/document/8342870>.2018
- KARUPPIAH, Sankaranarayanan y Mithun. On sustainable predictive maintenance: Exploration of key barriers using an integrated approach. *Sustainable Production and Consumption*. [En línea] 2021. <https://www.sciencedirect.com/science/article/abs/pii/S2352550921000968#!>.2021
- KENDA, Kobcar, _ y Bracun. Condition based maintenance of the two-beam laser welding in high volume manufacturing of piezoelectric pressure sensor. *Journal of Manufacturing Systems*. Volume 59, April 2021, Pages 117-126. [En línea] 2021. <https://www.sciencedirect.com/science/article/pii/S0278612521000352>.2021
- LAWSON, C., y otros. Machine Learning for metabolic engineering. *Metabolic Engineering*. [En línea] 2019. <https://doi.org/10.1016/j.ymben.2020.10.005>.

- LOZANO. 2020. Implementación de TPM para mejorar la productividad en la línea de inyección en la industria plástica, Santa Anita, 2020. (Tesis de pregrado). [En línea] 2020. https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/54087/Lozano_RSE-SD.pdf?sequence=1&isAllowed=y.2019
- LUNA Pérez, Miguel y Vázquez Alvarez , Graciela. Metodología de mantenimiento predictivo 4.0 para asegurar procesos de producción. [En línea] 2019. [http://www.iiisci.org/journal/CV\\$/risici/pdfs/CA639LI19.pdf](http://www.iiisci.org/journal/CV$/risici/pdfs/CA639LI19.pdf).2019
- MAHRAJ, Sakaline y Mushin. Enhancing OEE as a Key Metric of TPM Approach-A Practical Analysis in Garments Industries. European Journal of Engineering and Technology Research . [En línea] 2021. <https://ejers.org/index.php/ejers/article/view/2376>.2021
- MAREN, Zakwan y Jan. An integrated machine learning model for aircraft components rare failure prognostics with log-based dataset. ISA Transactions. [En línea] 2020. <https://www.sciencedirect.com/science/article/abs/pii/S0019057820301750>. 2020
- MASOUD, Taghi y Karimi. Application of the preventive maintenance scheduling to increase the equipment reliability: Case study- bag filters in cement factory. American Institute of Mathematical Sciences. [En línea] 2020. <https://www.aims sciences.org/article/doi/10.3934/jimo.2018146>.2020
- MELNIK. Machine Learning: Mantenimiento predictivo para la industria. TEcno Buildings. [En línea] 2021. <https://www.tecnobuildings.com/blog/machine-learning-mantenimiento-predictivo-para-la-industria>.2021
- MESA, Ortiz y Pinzón. La confiabilidad, la disponibilidad y la mantenibilidad, disciplinas modernas aplicadas al mantenimiento. [En línea] 2016.
- MESA, Ortiz y Pinzón. La confiabilidad, la disponibilidad, mantenibilidad, disciplinas modernas aplicadas al mantenimiento. [En línea] 2019.
- MISARI, Piasson y Sanches. Reliability-Centered Maintenance Task Planning for Overhead Electric Power Distribution Networks. [En línea] 2020. <https://link.springer.com/article/10.1007%2Fs40313-020-00606-8>.2020
- MOHAMMAD y Mohd. Assessment of Piling Machine Operation Performance Using Overall Equipment Effectiveness (OEE) During Piling Construction at

- Universiti Teknikal Malaysia Melaka. *Advances in Mechatronics, Manufacturing, and Mechanical*. [En línea] 2020. https://link.springer.com/chapter/10.1007/978-981-15-7309-5_18.2020
- MOHAN, Roosefert, y otros. Intelligent machine learning based total productive maintenance approach for achieving zero downtime in industrial machinery. *Computers & Industrial Engineering*. [En línea] 2021. <https://www.sciencedirect.com/science/article/abs/pii/S0360835221001716>. 2021
- PACAIIOVA, y otros. Methodology for Complex Efficiency Evaluation of Machinery Safety Measures in a Production Organization. *Mechanical Engineering*. [En línea] 2021. <https://www.mdpi.com/2076-3417/11/1/453/html>.2021
- PANAGIOTIS. Reliability, availability and maintainability analysis of a bag production industry based on the six sigma DMAIC approach. *International Journal of Lean Six Sigma*, Vol. 12 No. 2, pp. 237-263. <https://doi.org/10.1108/IJLSS-09-2019-0101>. [En línea] 2020. <https://www.emerald.com/insight/content/doi/10.1108/IJLSS-09-2019-0101/full/html>.2020
- PANWAR, Kumar y Attri. AHP-VIKOR-based methodology for determining maintenance criticality. *International Journal of Productivity and Quality Management*. [En línea] 2020. <https://www.inderscienceonline.com/doi/abs/10.1504/IJPQM.2020.105964.2020>
- PAOLANTI, Marina, y otros. Machine Learning approach for Predictive Maintenance in Industry 4.0. [En línea] 2018. <https://ieeexplore.ieee.org/abstract/document/8449150>. 2018
- PARRA y Crespo. Técnicas de ingeniería de mantenimiento y fiabilidad aplicadas en el proceso de gestión de activos. . [En línea] 2016.
- PIECHNICKI, Ferreira y Portela. Data fusion framework for decision-making support in reliability-centered maintenance. *Journal of Industrial and Production Engineering*. [En línea] 2020. <https://www.tandfonline.com/doi/abs/10.1080/21681015.2020.1817164>. 2020

- Quatrini, y otros. Machine learning for anomaly detection and process phase classification to improve safety and maintenance activities. *Journal of Manufacturing Systems*. Volume 56, July 2020, Pages 117-132. [En línea] 2020.
<https://www.sciencedirect.com/science/article/abs/pii/S0278612520300765>.
2020
- ROMERO, J. y Rincón, B. Aplicación de machine learning en el mantenimiento predictivo industrial con herramientas de código abierto. [En línea] 2020.
<http://expeditiorepositorio.utadeo.edu.co/bitstream/handle/20.500.12010/10108/Trabajo%20de%20grado.pdf?sequence=1&isAllowed=y>. 2020
- RUIZ Sarmiento, Jose Raul, y otros. A predictive model for the maintenance of industrial machinery in the context of industry 4.0. *Engineering Applications of Artificial Intelligence*. [En línea] 2019.
<https://www.sciencedirect.com/science/article/abs/pii/S0952197619302489>.
2019
- SANCHÉZ.. Técnicas de mantenimiento predictivo, metodología de aplicación en las organizaciones. Bogotá. [En línea] 2017.
- SCHEREIBER, y otros. A performance measurement system for integrated production and maintenance planning. *Procedia CIRP*. Volume 93, 2020, Pages 1037-1042. [En línea] 2020.
<https://www.sciencedirect.com/science/article/pii/S2212827120306375>.
2020
- SEGOVIA. Gestión de mantenimiento preventivo para aumentar la productividad de la empresa Bandas Plast E.I.R.L. Chiclayo - 2019. (Tesis de pregrado). [En línea] 2020.
https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/49542/Segovia_ICDP-SD.pdf?sequence=1&isAllowed=y. 2020
- SUSTO, Gian Antonio, y otros. Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. in *IEEE Transactions on Industrial Informatics*. [En línea] 2017. <https://ieeexplore.ieee.org/abstract/document/6879441>.
2017
- TORRES. Evaluación al área de mantenimiento en una empresa industrial. [En línea] 2018. <https://www.researchgate.net/profile/Carlos-Parra>

19/publication/343135576_Evaluacion_al_area_de_mantenimiento_una_empresa_industrial_dedicada_a_la_construccion_de_estructuras_metalicas_y_mantenimiento_a_equipos_maritimos_y_portuarios/links/5f18458ba6fdc
c. 2018

TORTORA, y otros. The Role of Maintenance Operator in Industrial Manufacturing Systems: Research Topics and Trends. [En línea] 2021. <https://www.mdpi.com/2076-3417/11/7/3193/htm>. 2021

ULLAH, Irfan, y otros. Predictive Maintenance of Power Substation Equipment by Infrared Thermography Using a Machine-Learning Approach. [En línea] 2017. <https://www.mdpi.com/1996-1073/10/12/1987/htm>. 2017

WAKIRU, Muchiri y Chemweno. Integrated maintenance policies for performance improvement of a multi-unit repairable, one product manufacturing system. The Management of Operations. Volume 32, 2021 - Issue 5. [En línea] 2020. <https://www.tandfonline.com/doi/abs/10.1080/09537287.2020.1736684>. 2020

YALI. Optimizing Predictive Maintenance with Machine Learning for Reliability Improvement. [En línea] 2021. <https://asmedigitalcollection.asme.org/risk/article-abstract/doi/10.1115/1.4049525/1094081/Optimizing-Predictive-Maintenance-with-Machine?redirectedFrom=fulltext>. 2021

ZAMBRANO. Propuesta de un plan de mantenimiento del proceso productivo en empresas productoras de hielo. Universidad de Guayaquil. [En línea] 2020. <http://repositorio.ug.edu.ec/bitstream/redug/51426/1/ZAMBRANO%20ZAMBRANO%20BYRON%20LENIN.pdf>. 2020

ANEXOS

Anexo 1. Matriz de operacionalización

Variables	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Escala de medición
Variable independiente. Machine Learning	Conjunto de operaciones con el objetivo de garantizar la continuidad de la actividad operativa, evitando atrasos en el proceso por averías de máquinas y equipos (Gonzales, 2019).	Machine Learning, tendrá que demostrarse que tan fiable, compatibles, asimismo su tiempo de ejecución	Machine Learning	Fiabilidad	Ordinal
				Compatibilidad	Ordinal
				Tiempo de ejecución	Ordinal
Variable dependiente. Gestión del mantenimiento	Es la capacidad de lograr los objetivos y metas programadas con los recursos disponibles en un tiempo predeterminado (Hoyos, 2020).	La gestión del mantenimiento de las maquinarias industriales, se evaluará la confiabilidad, disponibilidad y mantenimiento.	Confiabilidad	$= \frac{1}{\text{Tiempo promedio entre fallas}}$	Ordinal
			Mantenibilidad	$= \frac{\text{Tiempo total de mantenimiento}}{\text{Número de reparaciones}}$	Ordinal
			Disponibilidad	$= \frac{\text{Tiempo promedio entre fallas PEF}}{\text{Tiempo prom. entre fallas} + \text{tiempo prom. para reparación}} \times 100\%$	Ordinal

Fuente. Elaboración propia

Anexo 3. Solicitud de autorización para realizar la investigación

Ciudad, 01 de Octubre de 2021

Señor (a): Emiliano Estela Delgado
CARGO
ATLATINCA S.R.L.
Presente.-

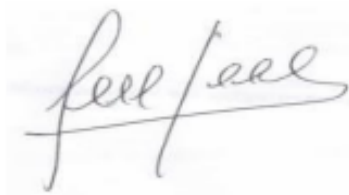
Es grato dirigirme a usted para saludarlo, y a la vez manifestarle que dentro de mi formación académica en la experiencia curricular de investigación del X ciclo, se contempla la realización de una investigación con fines de obtención de mi título profesional al finalizar mi carrera.

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 para mejorar la gestión de mantenimiento de las maquinas industriales". 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,



Dagner Paúl Rojas Bances
DNI 46909269

Anexo 4. Autorización de uso de información de empresa

AUTORIZACIÓN DE USO DE INFORMACIÓN DE EMPRESA

Yo Emiliano Estela Delgado, identificado con DNI 45697896, en mi calidad de jefe del área de mantenimiento de la empresa Atlántica S.R.L. con R.U.C N° 20488011538, ubicada en la ciudad de Chiclayo

OTORGO LA AUTORIZACIÓN,

Al señor Dagner Paúl Rojas Bances Identificado(s) con DNI N° 46909269, de la (x) Carrera profesional Ingeniería Mecánica Eléctrica, para que utilice la siguiente información de la empresa:

Información del mantenimiento de la maquinarias de la empresa
Detalle de las maquinaria

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

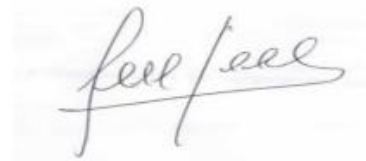
- () Mantener en Reserva el nombre o cualquier distintivo de la empresa; o
() Mencionar el nombre de la empresa.



Emiliano Estela Delgado

DNI: 45697896

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: 46909269

Anexo 6. Validación de instrumento de recolección de datos

CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO

Nombre del instrumento	Formato de inventario de maquinas
Objetivo del instrumento	Realizar un inventario de maquinas
Nombres y apellidos del experto	Pedro Demetrio Reyes TASSARA
Documento de identidad	42354107
Años de experiencia en el área	15 años
Máximo Grado Académico	Maestro en Ciencias de la Ingeniería
Nacionalidad	Paraguaya
Institución	Universidad César Vallejo
Cargo	Docente
Número telefónico	996971230
Firma	 Pedro Demetrio Reyes Tassara INGENIERO MECÁNICO ELECTRICISTA CIP. 88299
Fecha	14/11/2021

Criterios	Detalle	Calificación
Suficiencia	El ítem pertenece a la dimensión y basta para obtener la medición de esta	1: de acuerdo 0: en desacuerdo
Claridad	El ítem se comprende fácilmente, es decir, su sintáctica y semántica son adecuadas	1: de acuerdo 0: en desacuerdo
Coherencia	El ítem tiene relación lógica con el indicador que está midiendo	1: de acuerdo 0: en desacuerdo
Relevancia	El ítem es esencial o importante, es decir, debe ser incluido	1: de acuerdo 0: en desacuerdo

CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO

Nombre del instrumento	Formato de inventario de máquinas
Objetivo del instrumento	Realizar un inventario de máquinas
Nombres y apellidos del experto	Mg Julio César Vílchez Peche
Documento de identidad	17562382
Años de experiencia en el área	5 años
Máximo Grado Académico	Magíster
Nacionalidad	Peruana
Institución	IES "República federal de Alemania"
Cargo	Ingeniero Mecánico Electricista
Número telefónico	+51 978 817 234
Firma	 JULIO CESAR VILCHEZ PECHÉ ING. MECÁNICO ELECTRICISTA REG. CIP. 190666
Fecha	15 /11 / 2021

Crterios	Detalle	Calificación
Suficiencia	El ítem pertenece a la dimensión y basta para obtener la medición	1: de acuerdo 0: en desacuerdo
Claridad	El ítem se comprende fácilmente, es decir, su sintáctica y semántica son adecuadas	1: de acuerdo 0: en desacuerdo
Coherencia	El ítem tiene relación lógica con el indicador que está midiendo	1: de acuerdo 0: en desacuerdo
Relevancia	El ítem es esencial o importante, es decir, debe ser incluido	1: de acuerdo 0: en desacuerdo

CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO

Nombre del instrumento	Formato de inventario de las maquinas
Objetivo del instrumento	Realizar inventario de las máquinas
Nombres y apellidos del experto	Juan Carlos Vives Garnique
Documento de identidad	41524559
Años de experiencia en el área	5
Máximo Grado Académico	Magister
Nacionalidad	Peruana
Institución	Universidad Señor de Sipán
Cargo	Director de EP de Ingeniería Mecánica Eléctrica Docente tiempo completo
Número telefónico	972801971
Firma	 JUAN CARLOS VIVES GARNIQUE INGENIERO MECÁNICO Reg. CIP. N° 147403
Fecha	16 /11/ 2021

Crterios	Detalle	Calificación
Suficiencia	El ítem pertenece a la dimensión y basta para obtener la medición de esta	1: de acuerdo 0: en desacuerdo
Claridad	El ítem se comprende fácilmente, es decir, su sintáctica y semántica son adecuadas	1: de acuerdo 0: en desacuerdo
Coherencia	El ítem tiene relación lógica con el indicador que está midiendo	1: de acuerdo 0: en desacuerdo
Relevancia	El ítem es esencial o importante, es decir, debe ser incluido	1: de acuerdo 0: en desacuerdo