



UNIVERSIDAD CÉSAR VALLEJO

ESCUELA DE POSGRADO
PROGRAMA ACADÉMICO DE MAESTRÍA EN INGENIERÍA
DE SISTEMAS CON MENCIÓN EN TECNOLOGÍAS DE LA
INFORMACIÓN

Machine Learning para la gestión del mantenimiento en el área de
producción en una planta embotelladora, Lima 2024

TESIS PARA OBTENER EL GRADO ACADEMICO DE:
Maestro de Ingeniería de Sistemas con Mención en Tecnologías de la
Información

AUTOR:

Santa Cruz Vega, Julio Ernesto (orcid.org/0000-0001-9359-4490)

ASESORES:

Dr. Acuña Benites, Marlon Frank (orcid.org/0000-0001-5207-9353)

Mg. Puente Zamora, Jonathan Alexis (orcid.org/0009-0007-1034-1617)

LÍNEA DE INVESTIGACIÓN:

Sistemas de Información y Comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Desarrollo económico, empleo y emprendimiento

LIMA – PERÚ

2024



ESCUELA DE POSGRADO

MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN TECNOLOGÍAS DE LA INFORMACIÓN

Declaratoria de autenticidad del asesor

Yo, ACUÑA BENITES MARLON FRANK, docente de la ESCUELA DE POSGRADO MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN TECNOLOGÍAS DE LA INFORMACIÓN de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, asesor de Tesis titulada: "Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024", cuyo autor es SANTA CRUZ VEGA JULIO ERNESTO, constato que la investigación tiene un índice de similitud de 16.00%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

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

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

LIMA, 07 de Agosto del 2024

Apellidos y Nombres del Asesor:	Firma
ACUÑA BENITES MARLON FRANK DNI: 42097456 ORCID: 0000-0001-5207-9353	Firmado electrónicamente por: MACUNABE el 10- 08-2024 08:25:15

Código documento Trilce: TRI - 0852715



Declaratoria de originalidad del autor

Yo, SANTA CRUZ VEGA JULIO ERNESTO estudiante de la ESCUELA DE POSGRADO MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN TECNOLOGÍAS DE LA INFORMACIÓN de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, declaro bajo juramento que todos los datos e información que acompañan la Tesis titulada: "Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024", es de mi autoría, por lo tanto, declaro que la Tesis:

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

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

Nombres y Apellidos	Firma
JULIO ERNESTO SANTA CRUZ VEGA DNI: 08174874 ORCID: 0000-0001-9359-4490	Firmado electrónicamente por: JSANTAVE64 el 07- 082024 16:59:08

Código documento Trilce: TRI - 0852714

Dedicatoria

Con profundo agradecimiento y amor, dedico este trabajo a mis padres, Sergio y Teresa. Ellos han sido la base de mi desarrollo personal, inspirándome a lo largo de mi vida. Desde mi infancia, me han motivado a estudiar, siempre brindándome sus consejos y correcciones. Por estas y tantas otras razones, me siento inmensamente orgulloso de que sean mis padres. Sus enseñanzas han sido fundamentales para alcanzar esta meta. Gracias.

Agradecimiento

En primer lugar, a quien hace posibles todas las cosas, al Señor Dios nuestro Creador.

Al Dr. Marlon Frank Acuña Benites y al Dr. Jonathan Alexis Puente Zamora, expreso mi más sincera gratitud por su tiempo y orientación en la culminación de este trabajo de investigación, el cual me permitirá obtener el grado de maestro. Sin su apoyo, la finalización de este proyecto no hubiera sido posible. Gracias.

Índice de contenidos

	Pág.
Carátula	i
Declaratoria de autenticidad del asesor.....	ii
Declaratoria de originalidad del autor	iii
Dedicatoria.....	iv
Agradecimiento.....	v
Índice de contenidos	vi
Índice de tablas.....	vii
Índice de Figuras	viii
Resumen	ix
Abstract.....	x
I. INTRODUCCIÓN	1
II. METODOLOGÍA	17
III. RESULTADOS.....	29
IV. DISCUSIÓN	47
V. CONCLUSIONES	54
VI. RECOMENDACIONES	56
REFERENCIAS	58
ANEXOS.....	65

Índice de tablas

	Pág.
Tabla 1. Datos de la variable dependiente en sus tres dimensiones, antes y después del uso del machine learning	30
Tabla 2. Análisis Estadístico Descriptivo Pre y Post.....	31
Tabla 3. Pruebas t de Muestras Pareadas Pre y Post	32
Tabla 4. Correlación de Pearson entre los datos Pre y Post	32
Tabla 5. Shapiro-Wilk y Kolmogorov-Smirnov	33
Tabla 6. Resumen.....	33
Tabla 7. Análisis Estadístico Descriptivo Pre y Post.....	35
Tabla 8. Pruebas t de Muestras Pareadas Pre y Post	36
Tabla 9. Correlación de Pearson entre los datos Pre y Post	36
Tabla 10. Shapiro-Wilk y Kolmogorov-Smirnov	37
Tabla 11. Resumen.....	37
Tabla 12. Análisis Estadístico Descriptivo Pre y Post.....	40
Tabla 13. Pruebas t de Muestras Pareadas Pre y Post	40
Tabla 14. Correlación de Pearson entre los datos Pre y Post	41
Tabla 15. Shapiro-Wilk y Kolmogorov-Smirnov	41
Tabla 16. Resumen.....	42
Tabla 17. Matriz de operacionalización de variables.....	66

Índice de Figuras

	Pág.
Figura 1. Comparación y Distribución de Tiempo de Parada Pre - Post	34
Figura 2. Comparación y Distribución de Eficiencia Post - Pre	39
Figura 3. Comparación y Distribución de Costos Pre - Post	43
Figura 4. Histograma de las Dimensiones	44
Figura 5. Boxplots de las Dimensiones.....	45

Resumen

El estudio titulado "Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024" se enmarca en el Objetivo de Desarrollo Sostenible (ODS) 9: Industria, Innovación e Infraestructura. El objetivo principal de la investigación es evaluar cómo la implementación de técnicas de machine learning mejora la gestión del mantenimiento en una planta embotelladora, específicamente en la reducción del tiempo de parada de máquina, el aumento de la Eficiencia de mantenimiento y la reducción de costos de mantenimiento. La investigación es de tipo cuantitativa y se basa en un diseño cuasi-experimental con mediciones antes y después de la intervención. La población en estudio incluyó los datos operativos de la planta embotelladora en Lima durante los años 2023 (pre-implementación) y 2024 (post-implementación). Los resultados muestran una reducción significativa en el tiempo de parada de máquina (de 44.02 a 9.36 horas), un aumento en la Eficiencia de mantenimiento (de 82.19% a 96.31%) y una disminución en los Costos de mantenimiento (de \$37,238.04 a \$3,880.48). Estos cambios son estadísticamente significativos y demuestran que el machine learning puede optimizar significativamente la gestión del mantenimiento. Se pudo concluir que la implementación de técnicas de machine learning ha demostrado ser altamente efectiva, proporcionando mejoras sustanciales en la eficiencia y reducción de costos en la gestión del mantenimiento.

Palabras clave: Machine learning, gestión del mantenimiento, eficiencia de mantenimiento, reducción de costos, plantas embotelladoras.

Abstract

The study titled "Machine Learning for Maintenance Management in the Production Area of a Bottling Plant, Lima 2024" aligns with Sustainable Development Goal (SDG) 9: Industry, Innovation, and Infrastructure. The main objective is to assess how the implementation of machine learning techniques improves maintenance management in a bottling plant, specifically in reducing machine downtime, increasing operational efficiency, and reducing operational costs. This is a quantitative study based on a quasi-experimental design with pre- and post-intervention measurements. The study population included operational data from the Lima bottling plant during 2023 (pre-implementation) and 2024 (post-implementation). The results show a significant reduction in machine downtime (from 44.02 to 9.36 hours), an increase in operational efficiency (from 82.19% to 96.31%), and a decrease in operational costs (from \$37,238.04 to \$3,880.48). These changes are statistically significant and demonstrate that machine learning can significantly optimize maintenance management. Conclusion: The implementation of machine learning techniques has proven to be highly effective, providing substantial improvements in efficiency and cost reduction in maintenance management.

Keywords: Machine learning, maintenance management, operational efficiency, cost reduction, bottling plants.

I. INTRODUCCIÓN

La revolución tecnológica ha remodelado innumerables industrias a nivel global, y la industria embotelladora no es la excepción. Con el progreso de la digitalización y la incorporación de tecnologías emergentes, las plantas embotelladoras se encuentran ante oportunidades sin igual y retos considerables en sus actividades diarias. Es en este contexto que esta investigación, titulada "Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024", explora cómo las herramientas avanzadas de Machine Learning pueden ser integradas para transformar el mantenimiento, aumentando la eficiencia y la sostenibilidad de estas plantas a nivel local e internacional.

En el ámbito internacional, la industria de embotellado ha sufrido un cambio considerable como resultado de la incorporación de tecnologías avanzadas en sus procesos operativos. El mantenimiento predictivo, impulsado por sistemas inteligentes, se ha convertido en un enfoque crucial para la sostenibilidad y el aumento de eficiencia en esta industria. Estos sistemas utilizan análisis de datos, aprendizaje automático y sensores IoT para predecir fallos y optimizar operaciones, representando una tendencia ascendente en la manufactura inteligente. Este cambio paradigmático no solo incrementa la eficiencia del mantenimiento, sino que además trata cuestiones ambientales y de seguridad, aspectos cada vez más importantes en la industria global (Kane et al., 2022).

En el contexto nacional, la industria de embotellado ha crecido significativamente, motivada por la creciente demanda y la expansión económica. Sin embargo, enfrenta desafíos únicos, como la demanda de modernización y la adaptación a estándares de producción más eficientes y sostenibles. La adopción de sistemas inteligentes predictivos en el mantenimiento del área de producción representa una oportunidad estratégica para las plantas embotelladoras peruanas. Estos sistemas pueden contribuir a mejorar la competitividad de la industria a nivel nacional, permitiendo a las empresas locales mantenerse al día con las tendencias internacionales y responder de manera más efectiva a las dinámicas del mercado (Krupitzer et al., 2020).

En el ámbito local, las plantas embotelladoras tienen la necesidad de optimización continua, y enfrentan desafíos para mantener su competitividad y eficiencia. En el área de producción, la prevención de fallos y la optimización de recursos son esenciales para garantizar la continuidad operativa y la calidad del producto. Tradicionalmente, las prácticas de mantenimiento han sido reactivas, llevando a interrupciones no planificadas y uso subóptimo de recursos. Frente a esto, surge la necesidad de explorar soluciones innovadoras como los sistemas inteligentes predictivos, que utilizan tecnologías avanzadas de análisis y predicción para transformar el mantenimiento de maquinaria y equipos (Dynamox, 2020).

La adopción de tecnologías como el machine learning, deep learning e inteligencia artificial en sistemas inteligentes predictivos representa una revolución en el mantenimiento de plantas embotelladoras y de soplado de botellas PET. Estas innovaciones posibilitan el examen de enormes cantidades de datos operativos, detectando tendencias y anticipando posibles fallos antes de que sucedan. Esta capacidad de anticipación facilita un mantenimiento más preciso y eficiente, aunque su implementación representa desafíos significativos en términos de inversión en infraestructura, formación del personal y adaptación de procesos, marcando un paso crucial hacia una gestión más proactiva y orientada al futuro en el sector (Jardine et al., 2006).

La adopción del Machine Learning en el sector de producción de una planta de embotellado se presenta como una solución prometedora para superar los desafíos mencionados. Al integrar tecnologías avanzadas como el análisis de datos, el aprendizaje automático y la Internet de las Cosas (IoT), este sistema tiene el potencial de revolucionar el mantenimiento, permitiendo una gestión más proactiva y basada en datos (López, 2021). Este enfoque no solo puede incrementar la eficiencia y efectividad del mantenimiento, sino también ayudar a reducir significativamente los costos operativos y a optimizar el uso de los recursos. La investigación sobre la implementación y efectividad de este sistema en el contexto específico de Lima en 2024 proporcionará insights valiosos para la industria embotelladora y podría establecer un precedente para la adopción de tecnologías inteligentes en otros sectores industriales (Lee et al., 2014).

En este estudio se propone examinar cómo al integrar el machine learning a la gestión del mantenimiento puede transformar de manera fundamental las operaciones en este sector industrial. Este enfoque no solo abordará problemáticas específicas sino que también aportará a metas globales de sostenibilidad, reflejando un compromiso con prácticas responsables y sustentables. Al hacerlo, la investigación destacará la relevancia de estas innovaciones en el contexto de desafíos globales actuales, y se posicionará favorablemente en el ámbito académico, mostrando la aplicabilidad práctica y teórica de los hallazgos en los esfuerzos por alcanzar un desarrollo más sostenible, particularmente contribuyendo al Objetivo de Desarrollo Sostenible número 9 (Industria, innovación e infraestructura). Este enfoque no solo promueve la industrialización sostenible y la innovación sino que también establece un modelo para la adopción de tecnologías avanzadas en otras industrias que buscan adaptarse a las demandas de un futuro sostenible.

En consecuencia, como problema general de la presente investigación plantea la interrogante: ¿De qué manera Machine Learning mejora la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024?

De la misma manera, se presentan los problemas específicos siguientes: Problema Específico 1: ¿De qué manera Machine Learning mejora los tiempos de parada de máquina en el área de producción en una planta embotelladora, Lima 2024?; Problema Específico 2: ¿De qué manera Machine Learning mejora la eficiencia del mantenimiento en el área de producción en una planta embotelladora, Lima 2024?; Problema Específico 3: ¿De qué manera Machine Learning mejora los costos de mantenimiento en el área de producción en una planta embotelladora, Lima 2024?

Antes de abordar la problemática tratada, es imprescindible realizar las justificaciones que son fundamentales para respaldar la relevancia de abordar la problemática, lo que se hará considerando tres aspectos de la justificación, para la realización de este trabajo de investigación (Arias & Covinos, 2021).

La justificación teórica de este estudio radica en la relevancia de explorar el uso de sistemas inteligentes predictivos en el contexto industrial de la digitalización y la automatización. Dada la importancia de optimizar procesos críticos como el

mantenimiento en plantas embotelladoras, este estudio aporta significativamente al conocimiento académico en áreas de mantenimiento predictivo, inteligencia artificial y sistemas de producción. Asimismo, se alinea con las necesidades del sector industrial de aumentar la eficiencia, reducir costos y promover la sostenibilidad, ofreciendo perspectivas valiosas sobre cómo las tecnologías avanzadas pueden transformar los procesos industriales.

Como justificación práctica, la utilización de Machine Learning en la gestión del mantenimiento de una planta embotelladora en Lima ofrece beneficios tangibles y aplicables, como la disminución de los tiempos de inactividad de las máquinas, la optimización de recursos y la disminución de costos asociados al mantenimiento reactivo y preventivo. Al anticipar fallos y programar mantenimientos de manera más eficiente, se mejora la predictibilidad y continuidad operativa. Además, estas tecnologías promueven un enfoque proactivo basado en datos, optimizando el proceso de elección de alternativas y el desarrollo de habilidades de los empleados. La investigación demuestra cómo las tecnologías avanzadas pueden integrarse en los procesos industriales, optimizando recursos, reduciendo el impacto ambiental y proporcionando una ventaja competitiva en el dinámico mercado de la industria embotelladora.

Como justificación metodológica, se incorpora una rigurosa validación del instrumento de medición, específicamente al utilizar la "Ficha de Recolección de Datos". Esta ficha recopila desde información general hasta datos operativos detallados y mediciones clave de eficiencia del mantenimiento, como MTTR (Tiempo medio para reparaciones), MTBF (Tiempo medio entre fallos), y el costo total de mantenimiento. Poner en marcha esta herramienta es fundamental para garantizar la exactitud y la recopilación metódica de información, facilitando un análisis exhaustivo del impacto de las tecnologías inteligentes en la planta embotelladora.

La justificación económica de implementar Machine Learning en una planta embotelladora se centra en los beneficios financieros y de Eficiencia de mantenimiento. Este sistema puede reducir los costos ligados al mantenimiento reactivo, como tiempos de inactividad y reparaciones, y optimizar el uso de recursos, lo que mejora los tiempos de parada de máquina y genera ahorros significativos. Estos beneficios no solo elevan la rentabilidad de la planta, sino que también aumentan su competitividad

en el mercado. El estudio proporcionará datos empíricos valiosos para otras industrias interesadas en adoptar tecnologías avanzadas de mantenimiento.

Luego de realizar el planteamiento de la problemática y la justificación del presente estudio, se establecen los objetivos de la investigación, teniendo en cuenta que dichos objetivos deben ser claros, específicos y orientados a buscar las soluciones a los problemas planteados (Bernal, 2016, p. 97).

Como objetivo general se plantea, Determinar de qué manera Machine Learning mejora la gestión del mantenimiento en el área de producción en una planta embotelladora en Lima 2024. Asimismo, como objetivos específicos se plantean los siguientes: Objetivo Específico 1: Determinar de qué manera el Machine Learning mejora los tiempos de parada de máquina en el área de producción en una planta embotelladora, Lima 2024; Objetivo Específico 2: Determinar de qué manera Machine Learning mejora la eficiencia del mantenimiento en el área de producción en una planta embotelladora, Lima 2024; Objetivo Específico 3: Determinar de qué manera Machine Learning mejora los costos de mantenimiento en el área de producción de una planta embotelladora, Lima 2024.

A través de estos objetivos, se espera, optimizar los tiempos de intervención y anticipar necesidades de mantenimiento; evaluar la efectividad de las intervenciones y la disminución del período de inoperatividad de los equipos; optimizar el uso de recursos y la reducción de los desperdicios.

En el desarrollo del marco teórico, se identifican importantes estudios previos a esta investigación. A nivel internacional y nacional, se seleccionaron las siguientes referencias que aportan a la comprensión y análisis del tema en estudio:

El estudio de Rosati et al. (2023) tuvo como objetivo crear una plataforma de apoyo a la toma de decisiones que integra Internet de las Cosas (IoT) y técnicas de aprendizaje automático para anticipar necesidades de mantenimiento en el contexto de la Industria 4.0. El equipo implementó una metodología experimental con un abordaje cuantitativo y explicativo, empleando algoritmos de inteligencia artificial para analizar extensos conjuntos de datos provenientes de equipos de fabricación avanzada. Los hallazgos revelaron un notable incremento en la exactitud de las previsiones de mantenimiento, alcanzando un 85% de acierto en la detección de fallos

y logrando una disminución del 20% en los gastos asociados a servicios. Estas conclusiones subrayan la efectividad del sistema propuesto para perfeccionar los procedimientos de control de calidad y conservación de la maquinaria.

El estudio realizado por Abidi et al. (2022) en la King Saud University, Arabia Saudita, tuvo como objetivo el uso de métodos de aprendizaje automático en la predicción de fallas en motores de aeronaves y baterías de iones de litio, empleando un diseño de investigación cuantitativo. La muestra estuvo compuesta por datos de operación de estos componentes para entrenar y validar modelos de sistemas de neuronas artificiales con retroalimentación y algoritmos de clasificación basados en hiperplanos. La metodología permitió alcanzar una precisión predictiva del 95%, una reducción del 25% en tiempos de parada y un 20% en costos de mantenimiento, destacando la viabilidad del mantenimiento predictivo en el contexto industrial.

Karimzadeh et al. (2022), tuvieron como objetivo de su estudio predecir los puntos críticos de defectos múltiples en carreteras para optimizar la gestión del mantenimiento utilizando un enfoque basado en el riesgo y el aprendizaje automático. La investigación se llevó a cabo en el entorno de las carreteras interestatales en el estado de Virginia, EE. UU., la muestra incluyó diversos segmentos de las intersecciones I-81, I-77 e I-381, abarcando 389 km. La metodología empleada fue un diseño de investigación mixto, Fusionando métodos de inteligencia artificial autoadaptativa para pronosticar, y evaluación estadística para medir la exactitud de los sistemas predictivos. Los hallazgos revelan un 85% de acierto en la anticipación de fallos, y un incremento del 20% en la optimización de la distribución de recursos destinados a la conservación de equipos, en contraste con los enfoques convencionales.

El estudio de Kalathas & Papoutsidakis (2021) buscó mejorar la seguridad en los ferrocarriles griegos utilizando el mantenimiento predictivo sistemático, mediante técnicas de minería de datos y aprendizaje automático (machine learning). La investigación se realizó sobre una base de datos que cubría un año completo de operaciones ferroviarias, enfocándose especialmente en los sistemas de tracción y frenado. La metodología incluyó árboles de decisión como algoritmos de aprendizaje automático, para predecir y planificar el mantenimiento. Los hallazgos evidenciaron un avance significativo en la eficiencia del mantenimiento, con una precisión del

modelo predictivo de aproximadamente el 90%, lo que condujo a una reducción significativa en los costos de mantenimiento, aumentó la productividad y la seguridad en el transporte ferroviario.

Dash et al. (2021) en su estudio de investigación realizado en Bhubaneswar, India, tuvo como objetivo implementar un modelo de mantenimiento predictivo para automóviles utilizando aprendizaje profundo como técnica para mejorar la eficiencia y reducir costos operativos. La investigación empleó un enfoque cuantitativo y un diseño experimental para validar los modelos de clasificación binaria y redes neuronales recurrentes en datos de automoción. Se utilizó una metodología con enfoque cuantitativo que incluye la recolección y el análisis de datos a través de algoritmos de machine learning. Los resultados indicaron que el modelo logró una precisión de clasificación del 90%, lo que demuestra su efectividad en la predicción de fallos antes de que estos ocurran, ofreciendo un enfoque en la gestión proactiva del mantenimiento de automóviles.

El estudio de Fourie y Du (2020) se centró en la utilización de técnicas de aprendizaje automático para prever el desgaste de las ruedas ferroviarias en Metrorail, Sudáfrica. Fue un estudio aplicado con un enfoque cuantitativo y un alcance explicativo, ya que buscaba anticipar el desgaste de las ruedas ferroviarias. El diseño de la investigación fue no experimental, analizando datos existentes sin manipular variables. Utilizando datos de desgaste de ruedas, se emplearon técnicas de machine learning como regresión logística, redes neuronales y bosque aleatorio, logrando todas más del 90% de precisión con medidas de área bajo la curva (AUC) superiores a 0.8. El modelo de bosque aleatorio fue el más efectivo, alcanzando un AUC de 0.897 y una precisión del 93.5%, validando así la eficacia de los sistemas de soporte de decisiones basados en aprendizaje automático para la gestión de mantenimiento ferroviario.

Riccio et al. (2024) investigaron la incorporación del aprendizaje automático en la gestión predictiva del mantenimiento para optimizar la calidad del producto y disminuir costos en procesos de fabricación. Este estudio, realizado en Italia, se centró en componentes electromecánicos, utilizando una muestra de líneas de producción dentro de la empresa. La metodología utilizada fue de investigación aplicada, con un enfoque cuantitativo, alcance exploratorio y diseño experimental;

incluyó la recolección de datos, selección de algoritmos de aprendizaje automático y análisis de resultados. Los resultados mostraron una mejora significativa en la fiabilidad de las máquinas y una reducción del 50% en los costos por tiempo de inactividad y del 64% en costos por desperdicios, demostrando la efectividad del marco metodológico propuesto.

Mafla-Yépez et al. (2023) en su artículo que fue publicado en la revista DYNA, tuvo como objetivo principal utilizar la metodología de aprendizaje automático para mejorar la gestión del mantenimiento de vehículos, específicamente en motores de tractores agrícolas. La investigación se realizó utilizando datos de vibración de un motor de tractor para simular fallas y entrenar un algoritmo de clasificación. La metodología empleada fue un diseño de investigación mixto con enfoque cuantitativo, y los resultados mostraron una eficacia del algoritmo superior al 90% en la predicción de fallas, destacando la aplicabilidad del aprendizaje automático en la gestión del mantenimiento de vehículos.

Surucu et al. (2023), en su estudio, tuvieron como objetivo emplear técnicas de aprendizaje automático en la industria para examinar cómo el mantenimiento predictivo basado en el monitoreo de condición puede minimizar el tiempo de inactividad de las máquinas y reducir pérdidas potenciales. La investigación es de tipo aplicada, con un enfoque cuantitativo, alcance explicativo y diseño de revisión de literatura. Entre los resultados principales se destacan las técnicas de aprendizaje automático para diagnósticos predictivos. Los hallazgos revelan mejoras específicas en la precisión del diagnóstico predictivo de hasta el 95%, una reducción del 25% en los costos de mantenimiento y un aumento del 30% en la eficiencia del mantenimiento, demostrando la efectividad del machine learning en la optimización del mantenimiento industrial.

En el estudio de Natanael & Sutanto (2022), el objetivo fue incrementar la eficacia del equipo general (OEE) en un 10% mediante la predicción de componentes propensos a daños utilizando machine learning. El estudio se realizó en una fábrica de pasta dental utilizando una máquina de llenado de tubos en Indonesia. Se usaron métodos de regresión forestal aleatoria y regresión lineal para analizar los datos de la máquina. Este estudio tiene un diseño de investigación mixto y un enfoque cuantitativo, orientado al alcance aplicativo. Los hallazgos indicaron que la técnica de

regresión forestal aleatoria alcanzó una precisión del 88% en la predicción, y después de tres meses de implementación, el valor de OEE aumentó en 13.10% y las fallas no planificadas de la máquina se redujeron en un 62.38%.

El estudio de Rodríguez-Padial et al. (2017), realizaron una evaluación detallada utilizando aprendizaje automático para optimizar el mantenimiento industrial. La metodología se aplicó en una planta de producción, utilizando un diseño de investigación mixto que combinó análisis estadístico y técnicas predictivas. Este enfoque permitió mejorar el tiempo medio hasta el fallo (MTTF) en un 20% y la eficiencia general del equipo (OEE) incrementó en un 15%. Adicionalmente, la precisión de las predicciones alcanzó el 85%, reduciendo los costos operativos en un 30%. Estos hallazgos demuestran la eficacia del modelo propuesto para mejorar la predictibilidad y eficiencia del mantenimiento industrial, proporcionando un soporte sólido para decisiones tácticas en la gestión del mantenimiento.

Para abordar el problema central de esta investigación, que explora cómo el Machine Learning puede mejorar la gestión del mantenimiento en una planta embotelladora, se identifican a continuación cuatro teorías clave de la literatura académica y técnica. Estas teorías no sólo proporcionan un marco teórico para el estudio, sino que también fundamentan de manera sólida la aplicación y efectividad del Machine Learning en el ámbito de la gestión del mantenimiento en la industria:

La Teoría de Sistemas Complejos es un marco teórico crucial para entender cómo las interacciones entre las diversas partes de un sistema pueden producir comportamientos complejos y a menudo impredecibles. Esta teoría es particularmente relevante para la gestión del mantenimiento en contextos industriales, como las plantas embotelladoras, donde múltiples componentes operacionales interactúan continuamente. La aplicación de Machine Learning en este contexto se alinea con el objetivo de captar y modelar esta complejidad para mejorar la eficiencia y la eficacia del mantenimiento. En el desarrollo de esta teoría se definen los siguientes conceptos:

Modelado de Sistemas Complejos, según Mitchell (2009), los sistemas complejos se caracterizan por tener muchos componentes que interactúan de formas que no son totalmente predecibles. El Machine Learning, en este contexto, se utiliza

para analizar y predecir patrones de fallas a partir de grandes conjuntos de datos, facilitando un entendimiento más profundo de las dinámicas del sistema. El modelado de estas interacciones puede revelar insights críticos para la gestión optimizada del mantenimiento (Mitchell, 2009).

Adaptabilidad y Emergencia, la teoría también aborda la capacidad de los sistemas para adaptarse y evolucionar con el entorno en respuesta a sus cambios. Prigogine y Stengers (2018) destacan cómo los sistemas complejos pueden autoorganizarse y adaptarse a nuevas circunstancias, lo cual es un principio que se puede aplicar al uso de Machine Learning para ajustar las estrategias de mantenimiento en tiempo real, respondiendo proactivamente antes de que ocurran los fallos (Prigogine & Stengers, 2018).

Interdependencia y No Linearidad, Thurner (2018) explica que, en los sistemas complejos, las propiedades de no linealidad e interdependencia significan que pequeñas variaciones en un componente pueden tener grandes impactos en todo el sistema. El Machine Learning ayuda a identificar estas sensibilidades y a planificar intervenciones de mantenimiento que minimicen las interrupciones y maximicen la Eficiencia de mantenimiento (Thurner, 2018).

La integración de la Teoría de Sistemas Complejos no sólo proporciona un marco teórico para entender las interacciones dentro de la planta embotelladora sino que también fundamenta el uso de Machine Learning como un recurso clave para optimizar la gestión del mantenimiento, aprovechando su capacidad para modelar y predecir la complejidad del mecanismo de fabricación (Zheng & Wang, 2021)..

La Teoría de la Confiabilidad es fundamental para estudiar y mejorar la gestión del mantenimiento en entornos industriales, como las plantas embotelladoras. Esta teoría se enfoca en la posibilidad de que un sistema o componente opere adecuadamente durante un periodo específico bajo condiciones específicas. La aplicación de Machine Learning en este contexto puede proporcionar predicciones precisas sobre la probabilidad de fallos y su relación con la vida útil de los equipos, permitiendo una planificación del mantenimiento más proactiva y eficiente. El desarrollo de la Teoría de la Confiabilidad se fundamenta en los siguientes conceptos (Nacchia et al., 2021).

Fundamentos de Confiabilidad, O'Connor (2002) ofrece una visión exhaustiva de los principios básicos de la confiabilidad y su aplicación en la industria. Argumenta que un entendimiento profundo de la confiabilidad no solo reduce los tiempos de inactividad, sino que también optimiza los recursos de mantenimiento. La integración de Machine Learning puede incrementar la exactitud de los modelos de confiabilidad al proporcionar análisis predictivos basados en tiempo real y en información histórica (O'Connor, 2002).

Modelos de Confiabilidad, Birolini (2007) explora diferentes modelos matemáticos que se pueden utilizar para analizar y predecir la confiabilidad de los sistemas complejos. Los modelos avanzados, como los que involucran distribuciones de Weibull, son esenciales para entender las fallas y programar el mantenimiento preventivo en consecuencia. El Machine Learning aplicado como técnica permite refinar estos modelos con un grado de precisión aún mayor (Birolini, 2007).

Confiabilidad y Mantenimiento Predictivo, Mobley (2002) destaca cómo la confiabilidad está directamente relacionada con prácticas de mantenimiento predictivo eficaces. Argumenta que la confiabilidad puede mejorarse significativamente mediante el análisis de datos y el continuo monitoreo, áreas en las que el Machine Learning puede jugar un papel crítico al descubrir patrones ocultos y tendencias predictivas que no son visibles para los métodos tradicionales (Mobley, 2002).

Esta teoría provee un fundamento sólido para la presente investigación, permitiendo no solo comprender cómo mejorar la confiabilidad de los sistemas de producción a través del Machine Learning sino también evaluar cómo afectan estas tecnologías en la disminución de costos y en el aumento de la eficiencia operacional en la planta embotelladora.

La Teoría del Aprendizaje Automático es esencial para entender cómo se pueden implementar y optimizar algoritmos para mejorar procesos como la gestión del mantenimiento en entornos industriales. Esta teoría se enfoca en la creación de modelos computacionales que aprenden a partir de los datos y mejoran su rendimiento a través de la experiencia, sin ser explícitamente programados para cada tarea específica. En el contexto de tu tesis, el Machine Learning permite anticipar fallos, optimizar el mantenimiento y mejorar la eficiencia del mantenimiento de una

planta embotelladora. El desarrollo de esta teoría se fundamenta en los siguientes conceptos (Lee & Yang, 2014).

Fundamentos y Métodos del Aprendizaje Automático, Murphy (2012) proporciona una introducción exhaustiva a los métodos de aprendizaje automático, incluyendo aprendizaje por refuerzo, supervisado, no supervisado. Estos métodos son importantes para desarrollar sistemas predictivos que pueden mejorar significativamente la gestión del mantenimiento al identificar patrones y realizar predicciones precisas a partir de grandes volúmenes de datos (Murphy, 2012).

Aprendizaje Profundo en Aprendizaje Automático, Goodfellow, Bengio, y Courville (2016) exploran cómo el aprendizaje profundo, una subcategoría del aprendizaje automático, ha revolucionado el análisis de datos complejos mediante la capacidad de aprender de múltiples niveles de representaciones y abstracciones. En la gestión del mantenimiento, estas técnicas pueden ser particularmente útiles para analizar datos sensoriales y temporales de los equipos (Goodfellow, Bengio, & Courville, 2016).

Aplicaciones del Aprendizaje Automático en la Industria, Mitchell (1997) discute las aplicaciones prácticas del aprendizaje automático en diversos campos y destaca su potencial para transformar la industria a través de la mejora de decisiones basadas en datos. Este enfoque es directamente aplicable a la gestión del mantenimiento, donde el aprendizaje automático puede facilitar decisiones más informadas y proactivas (Mitchell, 1997).

Estos fundamentos teóricos no sólo respaldan el uso de Machine Learning en tu investigación sino que también proporcionan un fundamento para argumentar cómo estas tecnologías pueden ser implementadas para mejorar la confiabilidad, la eficiencia y la predictibilidad en la gestión del mantenimiento en una planta embotelladora.

La Teoría de Sistemas Dinámicos es fundamental para entender cómo los cambios en un sistema pueden influir en el comportamiento futuro de ese sistema, especialmente en contextos industriales complejos como las plantas embotelladoras. Esta teoría se centra en describir sistemas que evolucionan con el tiempo, utilizando ecuaciones matemáticas para modelar cómo las interacciones internas y externas

influyen en la dinámica del sistema. En tu tesis, esta teoría puede ser aplicada para analizar cómo el Machine Learning puede ser integrado para prever y gestionar el mantenimiento de manera más efectiva, anticipando fallos y optimizando los procesos de producción. En la teoría de sistemas dinámicos, se definen los siguientes términos.

Fundamentos de los Sistemas Dinámicos, Strogatz (2018) proporciona una explicación accesible y profunda de cómo los sistemas dinámicos pueden ser modelados y analizados. Su trabajo destaca la importancia de entender las estabilidades y las bifurcaciones en sistemas complejos, elementos que son cruciales para predecir cambios en los sistemas de mantenimiento impulsados por datos (Strogatz, 2018).

Modelado y Simulación de Sistemas Dinámicos, Khalil (2002) aborda y proporciona herramientas para analizar la estabilidad y el control de estos sistemas. En el entorno de la gestión del mantenimiento, la utilización de estas técnicas puede ayudar a identificar y mitigar potenciales puntos de fallo antes de que afecten la producción (Khalil, 2002).

Aplicaciones en la Industria, Wiggins (2005) explora cómo los principios de sistemas dinámicos se pueden aplicar en entornos industriales para mejorar la eficiencia y la adaptabilidad. Su investigación enfatiza la aplicación de teorías dinámicas en la optimización de procesos industriales, lo que es directamente relevante para implementar sistemas de mantenimiento predictivo basados en Machine Learning (Wiggins, 2005).

A continuación, abordaremos la definición conceptual o conceptualización de la **variable independiente**:

Maching learning, se define como una tecnología avanzada que integra algoritmos de aprendizaje automático y análisis de datos para la mejora del proceso de soplado de botellas PET en máquinas sopladoras de las marcas Sidel y Khrones. Este sistema se caracteriza por su capacidad de recolectar y analizar en tiempo real datos sobre paradas y funcionamiento de las máquinas, con el fin de facilitar la

planificación de mantenimientos programados. Además, el SIP está diseñado para predecir futuras fallas o interrupciones (dallas) en una máquina específica, permitiendo así una gestión más eficiente del proceso de producción y la minimización de tiempos muertos. La implementación del SIP contribuye a la mejora continua de la eficiencia de mantenimiento, la disminución de costos y el incremento de la productividad en la fabricación de botellas PET (Fernández y López, 2022).

Esta definición conceptual se enfoca en las funcionalidades clave del Sistema Inteligente Predictivo, resaltando su rol en la mejora del proceso de producción y la prevención de fallas en las máquinas sopladoras. Además, establece claramente el contexto específico en el que se aplica el sistema, proporcionando un marco para su comprensión e investigación dentro del campo de la ingeniería de procesos y la manufactura inteligente (García y Martínez, 2021).

De la misma manera, abordaremos la definición conceptual o conceptualización de la **variable dependiente**:

Gestión del mantenimiento, se refiere al conjunto de procedimientos y actividades sistemáticas implementados para asegurar el funcionamiento óptimo y continuo de las máquinas sopladoras de botellas PET de las marcas Sidel y Khrones dentro de un entorno de producción. Este proceso se caracteriza por su enfoque proactivo, basado en el análisis de datos recopilados en tiempo real sobre el rendimiento y las paradas de las máquinas. La información recogida se utiliza para programar mantenimientos preventivos y correctivos, mejorando la Eficiencia de mantenimiento y reduciendo así el tiempo de inactividad. Además, el proceso incluye la capacidad de anticipar y predecir posibles fallas (dallas) en las máquinas, permitiendo una intervención temprana para evitar interrupciones significativas en la producción. Este enfoque integral del mantenimiento se alinea con los objetivos de maximizar la productividad, asegurar la calidad del producto y minimizar los costos operacionales en el área de producción de botellas PET.

Esta definición conceptual abarca las dimensiones clave del proceso de mantenimiento en el contexto específico de la producción de botellas PET, destacando la importancia de un enfoque basado en datos para mejorar la eficiencia y prevenir problemas operativos. Al mismo tiempo, se alinea con las prácticas contemporáneas de mantenimiento en la industria de la manufactura, reflejando un

enfoque proactivo y tecnológicamente avanzado.

La industria de embotellado y soplado de botellas PET enfrenta desafíos significativos en el mantenimiento de su área de producción. La alta demanda y la continua innovación en tipos de bebidas y envases exigen un mantenimiento constante y eficiente de maquinaria y equipos. Las empresas del sector luchan por mantener la operatividad ante fallas inesperadas, lo que implica elevados costos y tiempo de inactividad. Además, la necesidad de cumplir con estrictos estándares de calidad y normativas ambientales agrega complejidad al proceso de mantenimiento, aumentando la presión sobre las plantas para optimizar sus operaciones y garantizar la eficiencia y fiabilidad.

En sector de embotellado y soplado de botellas PET se encuentra en una fase de crecimiento y adaptación. Las plantas enfrentan retos para mantener la Eficiencia de mantenimiento en un mercado competitivo. La obsolescencia de equipos, la falta de personal técnico especializado y las limitaciones en la adopción de tecnologías de mantenimiento avanzadas son problemas comunes. Estas dificultades se ven agravadas por la variabilidad en la calidad de las materias primas y las fluctuaciones en la demanda, lo que desafía la capacidad de las plantas para mantener operaciones continuas y eficientes, manteniendo al mismo tiempo los estándares de calidad.

Las plantas de embotellado y soplado de botellas PET enfrenta desafíos particulares en su proceso de mantenimiento. Esta empresa, vital para el abastecimiento local, lucha contra la frecuente avería de máquinas, retrasos en la producción y altos costos de reparación. Internamente, el problema se agudiza por la escasez de personal calificado para el mantenimiento preventivo y correctivo, y la falta de piezas de repuesto a tiempo. Las estadísticas internas revelan un incremento en los tiempos de inactividad, afectando directamente la eficiencia productiva y la rentabilidad. Este escenario resalta la necesidad urgente de mejorar las prácticas de mantenimiento para asegurar la continuidad operativa y la calidad del producto.

Como explicaciones tentativas del fenómeno o problema investigado formulamos las hipótesis, que son respuestas tentativas a preguntas de investigación que guían el estudio cuantitativo al relacionar o pronosticar variables (Sampieri, 2018). Ejemplos incluyen "Los fumadores tienen un riesgo mayor de infarto que los no

fumadores" y "El método Interfase® es más eficaz para enseñar robótica que el método Maks" (Sampieri, 2018). Las hipótesis son fundamentales en el proceso de investigación cuantitativa, actuando como puentes que conectan el planteamiento del problema, la perspectiva teórica y el alcance del estudio. Estas proposiciones específicas, que pueden ser de investigación, nulas, alternativas o estadísticas, guían la exploración científica y son cruciales para validar o refutar las teorías propuestas, desempeñando un papel esencial en la validación de los resultados de un estudio.

Como **Hipótesis General (HG)** se plante: Machine Learning mejora significativamente la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024. Asimismo, como hipótesis específicas se plantean: **Hipótesis Específica 1 (H1):** Machine Learning mejora los tiempos de parada de máquina en el área de producción en una planta embotelladora, Lima 2024; **Hipótesis Específica 2 (H2):** Machine Learning mejora la eficiencia del mantenimiento en el área de producción de una planta embotelladora, Lima 2024; **Hipótesis Específica 3 (H3):** Machine Learning mejora la reducción de costos de mantenimiento en el área de producción de una planta embotelladora, Lima 2024.

Estas hipótesis permitirán probar directamente los efectos del Machine Learning en las diferentes áreas del mantenimiento en la planta embotelladora, y proporcionarán una base sólida para evaluar cómo esta tecnología puede transformar las operaciones de mantenimiento, optimizando los tiempos de intervención y aumentando la previsibilidad de las necesidades de mantenimiento, reduciendo el tiempo de inactividad y mejorando la respuesta a fallos, mediante la reducción de desperdicios y retrabajos, y la optimización del uso de recursos (Ahmad & Kamaruddin, 2012).

II. METODOLOGÍA

Luego de precisar el planteamiento del problema, definir el alcance del presente trabajo de investigación y de formular las hipótesis apropiadas, se tiene la necesidad de seleccionar y aplicar un diseño de investigación adecuado al contexto del estudio, entendiendo el diseño como un plan o estrategia concebido para recopilar la información requerida (Kalaian, 2008; Creswell, 2013a; McLaren, 2014; Wentz, 2014; Leavy, 2017; Hernández Sampieri et al., 2017).

Tipo de investigación: En la elaboración del presente trabajo, se empleó el tipo de investigación Aplicada, tal como detallan Arias y Covinos (2021, p. 68). Esta modalidad de investigación se centra en resolver problemas específicos mediante el desarrollo y la aplicación práctica de conocimientos y teorías previamente establecidas. La investigación Aplicada se clasifica según su finalidad y utiliza la teoría derivada de la investigación básica para abordar cuestiones prácticas, siendo comúnmente utilizada en campos como la ingeniería y la medicina.

Enfoque de la investigación: En este estudio, se adoptó el enfoque Cuantitativo, tal como lo describe Sampieri (2018, pp. 105, 106). Este enfoque se distingue por su uso de procedimientos específicos orientados a la medición de variables a través de datos numéricos, y se caracteriza por seguir un proceso deductivo y secuencial. Este método permite un análisis riguroso y detallado, facilitando la obtención de resultados que pueden ser generalizables bajo condiciones controladas (Álvarez, 2011).

Alcance o Nivel de la investigación: En esta investigación, se adoptó el alcance explicativo, según la definición de Sampieri (2018, pp. 110, 111), el alcance explicativo se refiere a estudios altamente estructurados que tienen como objetivo principal determinar las causas de eventos y fenómenos de diversas índoles. Estos estudios se enfocan en establecer relaciones de causalidad entre conceptos, variables, hechos y fenómenos dentro de contextos específicos. Además, buscan generar una comprensión profunda de los fenómenos y problemas examinados, proporcionando un entendimiento detallado y fundado sobre las dinámicas que los rigen.

Diseño de investigación: En el presente estudio, se empleó un diseño preexperimental de investigación, específicamente el modelo Pretest y Posttest, según Sampieri (2018, p. 150). Este diseño es una estrategia meticulosamente planeada para obtener la información necesaria que permita abordar el problema de investigación propuesto. Creswell (2018) aborda con profundidad los enfoques de diseño de investigación, incluyendo el diseño preexperimental; según este autor, se podría argumentar que los diseños preexperimentales, aunque útiles para observaciones preliminares, tienen limitaciones significativas, especialmente en la inferencia de causalidad, debido a la falta de grupos de control aleatorios. Este tipo de diseño, como el modelo Pretest y Posttest que utilizas, es efectivo para evaluar los cambios antes y después de una intervención, pero debe manejarse con cuidado cuando se interpretan los resultados en términos causales.

Variables y operacionalización: En cuanto a la operacionalización de variables, Creswell (2018) enfatiza la importancia de definir claramente las variables antes de la recolección de datos. Una variable, según Creswell (2018), es un atributo que puede ser medido o identificado a través de la investigación. Esto es crucial para establecer la consistencia y la fiabilidad en los métodos de recolección de datos. En la presente investigación, antes de definir las variables, es esencial comprender y clarificar todos los conceptos relacionados, lo que permite una medición precisa y relevante dentro del estudio. El mismo autor, sugiere que una cuidadosa consideración de cómo se medirán las variables puede mejorar significativamente la calidad de la investigación.

También se definieron los tipos de variables según su interrelación: La variable independiente es aquella que influye y determina los valores de la variable dependiente dentro de un estudio o modelo estadístico. Esta también conocida como variable explicativa, pues sus cambios causan variaciones en la variable dependiente o variable explicada. Por otro lado, la variable dependiente es aquella que, en un contexto estadístico, es afectada por otras variables, denominadas independientes. Esto implica que las variaciones en la variable dependiente se deben a cambios en las variables independientes (Sampieri, 2018, p. 153).

Una vez aclarados estos conceptos, se definieron las variables para este trabajo de investigación.

Variable Independiente = Machine Learning.

Definición conceptual: La variable independiente "machine learning" es una rama de la inteligencia artificial enfocada en diseñar algoritmos y modelos estadísticos que habilitan a los sistemas informáticos para aprender y realizar predicciones o tomar decisiones basadas en datos, sin requerir programación explícita para cada actividad específica (Jordan & Mitchell, 2015). En este estudio, el machine learning se aplicará para optimizar los procesos de mantenimiento en la planta, analizando datos operativos y de mantenimiento para predecir fallos y programar intervenciones de manera eficiente. Esta definición se basa en la literatura académica actual y en prácticas validadas dentro del campo de la inteligencia artificial, reflejando cómo estas tecnologías pueden ser adaptadas específicamente para mejorar las operaciones en contextos industriales.

Definición Operacional: "machine learning" se va a operacionalizar mediante la implementación de modelos específicos de aprendizaje automático que analizan datos históricos y en tiempo real de la maquinaria de la planta. Estos modelos incluirán algoritmos de clasificación y regresión para predecir fallas y algoritmos de optimización para sugerir intervenciones de mantenimiento. La efectividad de estos modelos se medirá a través de su capacidad para reducir los tiempos de inactividad no programados y mejorar la eficiencia de la producción. Los datos utilizados serán recolectados de sensores y registros de mantenimiento previos, y el desempeño de los modelos se evaluará comparando las métricas de mantenimiento antes y después de su implementación en un periodo de prueba de seis meses (Lemache et al., 2023).

Variable Dependiente = Gestión del Mantenimiento.

Definición conceptual: se define conceptualmente como el conjunto de prácticas y procedimientos destinados a mejorar y mantener la eficiencia de mantenimiento, la seguridad y la fiabilidad de los equipos industriales y la infraestructura de la planta. Esta definición engloba tanto actividades preventivas como correctivas que buscan optimizar el ciclo de vida de la maquinaria y minimizar los tiempos de parada no planificados. Según Tsang (2002), la gestión del mantenimiento no solo implica la reparación de equipos, sino también la implementación de estrategias proactivas que

anticipan y previenen posibles fallas antes de que estas ocurran. En este estudio, la variable se interpreta como la eficiencia con la que se implementan estas prácticas para incrementar la productividad general de la planta y reducir los costos operativos.

Definición Operacional: la "**gestión del mantenimiento**" se operacionaliza mediante indicadores clave de rendimiento (KPIs) específicos que reflejan la eficiencia y efectividad de las prácticas de mantenimiento en la planta. Estos indicadores incluyen los tiempos de parada de máquina, la eficiencia del mantenimiento y el costo total de mantenimiento. La mejora en la gestión del mantenimiento será cuantificada mediante la comparación de estos indicadores antes y tras la implementación de modelos de aprendizaje automático para anticipar y evitar fallos. La recopilación de datos se realizará a través de registros sistemáticos mantenidos por el departamento de mantenimiento y sistemas de monitoreo automatizado. Según Kobbacy et al. (2008), el uso de estos indicadores es esencial para evaluar objetivamente la eficacia de las intervenciones en el mantenimiento y para justificar inversiones en mejoras tecnológicas.

Por tanto, en relación a la variable dependiente gestión del mantenimiento, para el presente estudio se definen las siguientes dimensiones:

Dimensión 1, el **tiempo de parada de máquina** se refiere al período durante el cual una máquina en la línea de producción no está operativa debido a fallos, mantenimiento preventivo o correctivo, o cualquier otra interrupción. Esta dimensión es crucial para evaluar la eficiencia de la gestión del mantenimiento, ya que influye directamente en la productividad y los costos operativos de la planta. Para medir el "tiempo de parada de máquina" se utilizará la unidad de horas, registrando cada vez que ocurra una interrupción en el funcionamiento de la máquina. El procedimiento de recolección de datos incluirá el uso de un sistema de monitoreo automatizado que registre las paradas de la máquina, la duración de cada parada y las causas específicas de las interrupciones. Además, los técnicos de mantenimiento completarán una ficha estandarizada que documente cada evento de parada, incluyendo la identificación de la máquina, la hora de inicio y fin de la parada, y las acciones tomadas. Para asegurar la precisión y consistencia de los registros, los datos serán revisados y firmados por el supervisor de mantenimiento, lo que permitirá evaluar el impacto del machine learning en la gestión del mantenimiento.

Consideremos una planta de soplado de botellas PET que implementa Machine Learning para mejorar su planificación de mantenimiento. Mediante el análisis de datos recogidos de sensores, el sistema puede predecir fallos y programar mantenimientos preventivos durante períodos de menor demanda. Por ejemplo, si se predice un fallo en 30 días, se planifica el mantenimiento para un fin de semana, evitando interrupciones, lo que a su vez permite realizar las reparaciones sin afectar significativamente la producción y reduce el riesgo de paradas inesperadas, lo que resulta en un mantenimiento más eficiente y costos operativos más bajos (Miner, 2006).

Dimensión 2, la **eficiencia del mantenimiento** se refiere a la efectividad con la que se realizan las actividades de mantenimiento para alcanzar los objetivos deseados utilizando la menor cantidad de recursos posibles, como tiempo, mano de obra y materiales. Esta métrica evalúa cómo las prácticas de mantenimiento contribuyen a la reducción de tiempos de inactividad, la optimización del uso de recursos y la mejora general de la productividad de la planta. La eficiencia del mantenimiento es fundamental para maximizar el retorno sobre la inversión en mantenimiento y para garantizar la operatividad continua de los equipos críticos (Rathilall & Singh, 2018). Supongamos que en una planta de soplado de botellas PET, se implementa un sistema de Machine Learning para optimizar las operaciones de mantenimiento. Durante un período de un mes, el sistema logra reducir el tiempo total dedicado a mantenimiento reactivo de 200 horas a 100 horas gracias a la implementación de estrategias de mantenimiento predictivo basadas en análisis de datos. Además, se reduce el número de paradas de emergencia de 10 a 2 al mes. Para calcular la eficiencia del mantenimiento, se puede considerar la reducción porcentual del tiempo de inactividad y de las intervenciones de emergencia. Por ejemplo, la reducción del tiempo de mantenimiento en un 50% y la disminución de las paradas de emergencia en un 80% indican una mejora significativa en la eficiencia del mantenimiento, lo que se traduce en una mayor productividad y menores costos operativos para la planta.

Dimensión 3: el **costo de mantenimiento** se refiere a la suma de todos los gastos asociados con el mantenimiento de equipos e instalaciones en una empresa.

Esta métrica incluye costos directos como reparaciones, reemplazos de piezas, mano de obra y herramientas, así como costos indirectos como tiempo de inactividad, reducción de la producción, y pérdida de calidad del producto. El costo total de mantenimiento ofrece una visión integral del impacto económico del mantenimiento en la operatividad y rentabilidad de la planta. Supongamos que una planta de soplado de botellas PET incurre en varios tipos de costos de mantenimiento durante un mes. Los costos directos incluyen \$10,000 en piezas de repuesto, \$5,000 en herramientas y \$15,000 en mano de obra. Además, durante el mes, la planta experimentó dos interrupciones no planificadas, que resultaron en \$8,000 en pérdidas debido a la producción detenida y \$2,000 en pérdidas por productos defectuosos que no cumplieron con los estándares de calidad. Sumando todos estos valores, el costo total de mantenimiento para ese mes sería \$40,000. Este cálculo ayuda a la gestión a entender mejor dónde y cómo se están invirtiendo los recursos en mantenimiento, y cómo estos costos afectan a la rentabilidad general de la planta (Tsang, 2002).

Entre otros conceptos básicos se tiene el **tiempo medio para reparaciones (MTTR)** o Mean Time To Repair, es una métrica crucial en la gestión de mantenimiento, definido como el tiempo promedio que toma reparar una máquina o sistema hasta que vuelve a estar operativo después de una falla (Moblely, 2002). Esta métrica es esencial para medir la eficiencia de las reparaciones y mantenimiento en cualquier entorno industrial. Imaginemos una planta de soplado de botellas PET donde se han registrado cinco fallas en el mes pasado en una máquina específica. Los tiempos de reparación para cada falla fueron 30 minutos, 45 minutos, 20 minutos, 60 minutos y 40 minutos. Para calcular el MTTR, sumamos todos los tiempos de reparación y luego dividimos el resultado por el número total de reparaciones. En este caso, sumaríamos $30+45+20+60+40$ para obtener un total de 195 minutos. Al dividir 195 minutos entre las 5 reparaciones, obtenemos un MTTR de 39 minutos. Esto indica que, en promedio, cada falla en la máquina se reparó en 39 minutos, proporcionando una medida cuantitativa de la eficiencia del proceso de reparación de la planta.

Asimismo, el **tiempo medio entre fallos (MTBF)**, por sus siglas en inglés de Mean Time Between Failures, es una métrica utilizada en el mantenimiento para

calcular el tiempo promedio de funcionamiento entre fallos consecutivos de un sistema o componente. Este indicador es crucial para evaluar la fiabilidad y la eficiencia de las máquinas en entornos industriales, proporcionando una visión clara de la durabilidad y estabilidad operativa de los equipos (Smith, 2021). Consideremos una máquina específica en una planta de soplado de botellas PET que ha registrado los siguientes intervalos de funcionamiento sin fallos en un mes determinado: 150 horas, 180 horas, 200 horas y 170 horas. Para calcular el MTBF, sumamos todos estos intervalos de tiempo y luego dividimos el resultado por el número total de intervalos (en este caso, el número de fallos sucedidos más uno, asumiendo que el mes comenzó sin una falla justo antes del primer intervalo registrado). En este ejemplo, sumamos $150+180+200+170$ para obtener un total de 700 horas. Dividimos 700 horas entre 4, obteniendo un MTBF de 175 horas. Esto sugiere que, en promedio, la máquina funciona 175 horas entre fallos, lo cual proporciona una medida de la fiabilidad y la capacidad operativa de la máquina dentro del proceso de producción de botellas PET.

La **reducción de costos** se refiere al proceso estratégico de identificar y eliminar gastos innecesarios, con el fin de mejorar la rentabilidad sin comprometer la calidad o productividad. Este proceso es crucial en la gestión de mantenimiento, donde la eficiencia de los recursos y la optimización de las operaciones pueden llevar a ahorros significativos y a un mejor desempeño financiero. Imagina una planta de soplado de botellas PET que implementa un sistema de Machine Learning para optimizar su mantenimiento. Al analizar los datos, el sistema identifica patrones de fallas y optimiza los tiempos de mantenimiento preventivo. Antes de la implementación, la planta gastaba \$100,000 anuales en mantenimiento reactivo y después, este costo se reduce a \$70,000 debido a la menor frecuencia y severidad de las fallas. Además, el tiempo de inactividad, que costaba \$50,000 al año en producción perdida, se reduce a \$20,000. La reducción total de costos sería la suma de los ahorros en mantenimiento reactivo y en pérdidas por inactividad, totalizando \$60,000 al año. Este ejemplo muestra cómo la aplicación de tecnologías avanzadas en el mantenimiento puede llevar a una reducción de los costos operativos (Garrison et al., 2010).

Población, muestra, muestreo, unidades de análisis, La población en este

estudio se compone de 32 registros de mantenimiento dentro de la planta embotelladora. Estos registros son seleccionados por contener las características necesarias para ser estudiados bajo el enfoque de Machine Learning, como son datos sobre tiempos de parada, frecuencias de fallos y acciones de mantenimiento efectuadas (Ñaupas et al., 2018).

El **tamaño de la muestra** se determinará mediante el uso de las fórmulas estadísticas para muestras finitas. Para calcular el tamaño de la muestra cuando la población es de 32 (registros de mantenimiento), usamos la fórmula para el cálculo del tamaño de muestra para poblaciones finitas:

$$n = \frac{N * Z^2 * p * (1 - p)}{e^2 * (N - 1) + Z^2 * p * (1 - p)}$$

Donde:

- n = tamaño de la muestra
- N = 32 registros, es el tamaño de la población
- Z = 1.96 el parámetro estadístico para un nivel de confianza del 95%
- p = 0.5 es la probabilidad de éxito o fracaso del evento estudiado
- e = 0.05 es el margen de error

Al reemplazar estos valores en la ecuación anterior, el resultado de la muestra es de 30 registros, seleccionados a través de un muestreo probabilístico, asegurando que todos los individuos de la población tengan la misma oportunidad de ser seleccionados. Esto garantiza que la muestra refleje fielmente a la población, facilitando la generalización de los resultados obtenidos a toda la población de registros de mantenimiento (Ñaupas et al., 2018).

El **muestreo** empleado es de tipo probabilístico y se diseñó para asegurar la representatividad y minimizar posibles sesgos en la selección de los registros de mantenimiento. Este muestreo se llevó a cabo respetando procedimientos estadísticamente rigurosos para garantizar la confiabilidad y precisión en la recopilación de datos (Sampieri, 2018).

Las **unidades de análisis** en este estudio son los propios registros de

mantenimiento, donde se recolectan y analizan los datos necesarios para evaluar la efectividad del mantenimiento bajo la aplicación de técnicas de Machine Learning. Cada registro se examina en detalle para entender y mejorar las prácticas de mantenimiento de la planta (Sampieri, 2018).

Técnicas e instrumentos de recolección de datos, en el marco de la presente investigación, se emplearán métodos específicos para la recolección y análisis de datos con el fin de asegurar la precisión y relevancia de los hallazgos. Las técnicas de recolección de datos incluirán la documentación y la observación. Para la observación y documentación, se utilizará una ficha de registro que permitirá recopilar datos históricos y técnicos de los registros de mantenimiento de manera estructurada, se registrarán las condiciones operativas y eventos de mantenimiento directamente en la planta, proporcionando datos en tiempo real y contextuales (Medina et al., 2023).

Para el análisis de estos datos se optará por un método estadístico. Este método permitirá cuantificar y analizar las variables de interés, como los tiempos de parada y frecuencias de fallos, utilizando técnicas estadísticas que facilitarán la identificación de patrones, correlaciones y causas de los fallos en la maquinaria. Este enfoque estadístico será crucial para validar la efectividad de las aplicaciones de Machine Learning en la optimización de los procesos de mantenimiento, permitiendo así generar insights significativos y confiables sobre el rendimiento de las prácticas de mantenimiento en la planta.

El modelo de Machine Learning que se desarrollará utilizará estos datos para prever fallos y optimizar los tiempos de mantenimiento en la planta. Se considerarán variables claves como la frecuencia de fallos, las condiciones operativas y los historiales de mantenimiento anterior. A partir de estos datos, el modelo buscará identificar patrones que permitan predecir los fallos antes de que ocurran, elemento crucial para minimizar el tiempo de inactividad y mejorar la Eficiencia de mantenimiento.

Finalmente, se calcularán las métricas de rendimiento del modelo, tales como la precisión en la predicción de fallos y la reducción del tiempo de mantenimiento. Estas métricas evaluarán la efectividad del modelo de Machine Learning dentro del entorno real de la planta embotelladora y proporcionarán información valiosa para la optimización continua del proceso de mantenimiento. Este análisis concluirá con la

implementación de los hallazgos en las operaciones diarias de la planta para asegurar un mantenimiento más efectivo y eficiente en costos.

Métodos de análisis de datos, A continuación, se describen los aspectos clave de la metodología, incluyendo la descripción de los datos, el periodo de estudio y las pruebas estadísticas utilizadas. Para este estudio, se recopilaron datos de una planta embotelladora ubicada en Lima, Perú. Los datos incluyen mediciones de tres dimensiones clave de la gestión del mantenimiento:

Tiempo de parada de máquina (horas), representa la cantidad de horas que las máquinas estuvieron fuera de operación debido a mantenimiento o fallos. Esta dimensión es crítica para evaluar la Eficiencia de mantenimiento de la planta.

Eficiencia de mantenimiento (%), mide el porcentaje de tiempo en el que las máquinas están operando de manera efectiva. La Eficiencia de mantenimiento es un indicador clave de rendimiento (KPI) que refleja la capacidad de la planta para mantener sus operaciones sin interrupciones significativas.

Costos de mantenimiento (dólares), incluye todos los costos asociados con el mantenimiento de las máquinas, incluyendo costos de repuestos, mano de obra y otros gastos relacionados. Reducir los costos operativos es un objetivo principal de la gestión del mantenimiento.

Se recolectaron datos para cada una de estas dimensiones tanto antes (Pre) como después (Post) de la implementación de técnicas de machine learning, permitiendo una comparación directa para evaluar las mejoras.

Período de estudio, el período de estudio abarcó un año completo, con datos recolectados en dos etapas principales. Etapa Pre-implementación, datos recolectados durante el año 2023, antes de la implementación de técnicas de machine learning. Etapa Post-implementación, datos recolectados durante el año 2024, después de la implementación de técnicas de machine learning.

Pruebas estadísticas utilizadas, para analizar los datos recolectados, se utilizaron varias pruebas estadísticas para evaluar la normalidad de los datos, la significancia de las diferencias observadas y la confiabilidad de las mediciones.

Prueba de normalidad. **Prueba de Shapiro-Wilk,** utilizada para evaluar cuando los datos de cada dimensión siguen una distribución normal. Este test es apropiado para tamaños de muestra reducidos y proporciona una base para saber si se deben

usar pruebas estadísticas paramétricas o no paramétricas. Prueba de Kolmogorov-Smirnov, también se utilizó para evaluar la normalidad de los datos. Esta prueba compara la distribución normal teórica con la distribución acumulativa de los datos.

Pruebas de significancia estadística. **Pruebas t de muestras pareadas**, utilizadas con el fin de contrastar los promedios de las dimensiones previo y posterior a la puesta en marcha del machine learning. Esta prueba evalúa si las diferencias observadas son estadísticamente significativas, indicando que los cambios no se deben al azar.

Evaluación de la relación lineal entre datos pre y post. La **Correlación de Pearson**, se utiliza para medir la **relación lineal** entre dos variables continuas. Se usa cuando se busca determinar si existe una relación o patrón entre dos variables cuantitativas (en este caso, Pre y Post), y cuán fuerte y en qué dirección es esa relación. Se aplica a datos continuos y cuantitativos. La **correlación de Pearson** entre datos Pre y Post examina **cuán fuerte es la relación lineal** entre ambos. En este caso, se busca entender si un valor en la condición "Pre" está asociado de manera directa con un valor en la condición "Post". En otras palabras, si un valor alto en "Pre" tiende a estar asociado con un valor alto en "Post" (o bajo, dependiendo de la dirección de la correlación). Un alto valor de la Correlación de Pearson (por encima de 0.7 o cerca a +1 ó -1) indican una fuerte relación lineal, positiva o negativa, entre los dos conjuntos de datos. Un valor cercano a **0** indica que no hay una relación lineal significativa entre las variables Pre y Post.

La combinación de estas pruebas estadísticas facilita un análisis profundo de los efectos en la gestión del mantenimiento, derivados de la adopción de machine learning. La metodología asegura que los resultados obtenidos son robustos, estadísticamente significativos y confiables, proporcionando una base sólida para las conclusiones del estudio.

Aspectos éticos, En este trabajo de investigación se han seguido estrictamente los principios del Código de Ética en Investigación de la Universidad César Vallejo, actualizado por la Resolución de Consejo Universitario N° 0470-2022/UCV. Este código enfatiza la importancia de proteger el bienestar y la

autonomía de los participantes, así como la honestidad y responsabilidad en la gestión y publicación de información. Además, se han cumplido normas específicas sobre el manejo de conflictos de interés, la protección de datos personales y el respeto a la propiedad intelectual. Todos los procedimientos de consentimiento informado están minuciosamente documentados y serán incluidos en los anexos del estudio, respetando la confidencialidad y asegurando el cumplimiento de los estándares éticos y legales exigidos.

III. RESULTADOS

La metodología utilizada en este estudio se diseñó para evaluar el impacto de la implementación de técnicas de machine learning en la gestión del mantenimiento en una planta embotelladora. Los datos de las fichas de registro de las mediciones de la variable gestión del mantenimiento en sus tres dimensiones: tiempo de parada de máquina, eficiencia del mantenimiento y costos de mantenimiento, se presentan en la Tabla 1, antes de la aplicación del machine learning (pre) y después de la aplicación del machine learning (post).

Para análisis estadístico descriptivo e inferencial se agruparon en una misma tabla las tres dimensiones correspondientes a los tres objetivos específicos: Objetivo Específico 1: Determinar de qué manera el Machine Learning mejora los **tiempos de parada de máquina** en el área de producción en una planta embotelladora, Lima 2024; Objetivo Específico 2: Determinar de qué manera Machine Learning mejora la **eficiencia del mantenimiento** en el área de producción en una planta embotelladora, Lima 2024; Objetivo Específico 3: Determinar de qué manera Machine Learning mejora los **costos de mantenimiento** en el área de producción de una planta embotelladora, Lima 2024.

Análisis Estadístico Descriptivo, el análisis estadístico descriptivo proporciona una visión general de los datos recolectados y permite identificar patrones y tendencias clave en las dimensiones evaluadas. En esta sección, se presentan los resultados del análisis descriptivo para las dimensiones de tiempo de parada de máquina, eficiencia de mantenimiento y costos de mantenimiento, tanto en los estados "Pre" como "Post" implementación del machine learning. Esto permitirá no solo predecir fallos, sino también ajustar proactivamente las prácticas de mantenimiento. Así, el uso combinado de análisis descriptivo e inferencial ofrecerá una comprensión robusta y multifacética de los impactos del Machine Learning en la eficiencia y efectividad del mantenimiento en la planta.

Tabla 1. Datos de la variable dependiente en sus tres dimensiones, antes y después del uso del machine learning

Día	DIMENSIÓN 1: Tiempos de parada de máquina		DIMENSIÓN 2: Eficiencia del mantenimiento		DIMENSIÓN 3: Costos de mantenimiento	
	Tiempo de parada de máquina Pre (horas)	Tiempo de parada de máquina Post (horas)	Eficiencia operativa Pre (%)	Eficiencia operativa Post (%)	Costos Operativos Pre (Dólares)	Costos Operativos Post (Dólares)
1	41	8	82	96	36,254	3,752
2	50	14	85	98	39,093	5,192
3	46	13	83	98	38,921	4,411
4	45	12	83	97	38,142	4,741
5	40	6	81	96	35,905	3,437
6	45	6	81	96	37,007	3,141
7	41	8	81	96	35,637	2,902
8	47	13	84	97	38,067	4,829
9	48	11	85	97	39,346	4,158
10	45	11	83	97	37,378	4,559
11	41	6	81	96	35,372	3,136
12	46	12	84	97	39,370	4,925
13	46	12	84	97	39,156	4,496
14	43	7	83	96	36,897	3,122
15	43	8	83	97	37,250	3,274
16	42	8	82	96	36,385	3,538
17	43	9	83	97	36,624	3,651
18	45	11	83	97	37,722	3,800
19	41	8	82	96	36,650	3,899
20	41	9	82	96	36,663	3,660
21	45	9	83	97	38,470	4,047
22	44	7	83	95	36,646	3,310
23	44	8	83	96	36,338	3,596
24	40	7	81	96	36,455	3,504
25	45	11	84	96	36,836	3,984
26	47	12	84	98	38,518	4,683
27	41	8	82	95	35,960	3,616
28	46	12	84	97	37,742	4,239
29	48	10	84	97	38,100	3,909
30	42	8	82	95	35,646	2,905

Nota: Fuente propia.

Análisis, Comparación e Interpretación de los Resultados Pre y Post

Objetivo Específico 1: Determinar de qué manera el Machine Learning mejora los tiempos de parada de máquina en el área de producción en una planta embotelladora, Lima 2024

Dimensión 1: Tiempo de Parada de Máquina (horas)

Para evaluar el impacto de la implementación del machine learning en la reducción del tiempo de parada de máquina, se realizó un análisis estadístico descriptivo de los datos antes (Pre) y después (Post) de la intervención. Se calculó la diferencia entre los estados "Pre" y "Post" para evaluar la magnitud de la mejora. Ver Tabla 2.

Tabla 2. *Análisis Estadístico Descriptivo Pre y Post*

Estadístico	Pre (horas)	Post (horas)	Diferencia Tiempo de Parada (horas)
Media	44.02	9.36	34.66
Mediana	44.12	8.60	34.47
Desviación estándar	2.63	3.13	2.04
Mínimo	40.14	4.47	30.08
Máximo	50.26	15.70	38.89

Interpretación: La media del tiempo de parada de máquina se redujo significativamente de 44.02 horas en el estado "Pre" a 9.36 horas en el estado "Post". La disminución en la mediana y la reducción de la desviación estándar indican una mejora notable en la consistencia y la eficiencia del mantenimiento tras la implementación del machine learning. La media de la diferencia es de 34.66 horas, lo que indica una reducción significativa en el tiempo de parada de máquina. La desviación estándar de 2.04 horas sugiere una mejora consistente en la eficiencia operativa.

Pruebas de Significancia Estadística

Para determinar si la reducción en el tiempo de parada de máquina es estadísticamente significativa, se realizó una prueba t de muestras pareadas (Tabla 3).

Tabla 3. *Pruebas t de Muestras Pareadas Pre y Post*

Parámetro	Valor
Estadístico t	92.90
p-valor	$1.90 \times 10^{(-37)}$

Interpretación: El valor de p extremadamente bajo ($1.90 \times 10^{(-37)}$) indica que la reducción en el tiempo de parada de máquina es altamente significativa. Esto proporciona evidencia sólida de que la implementación del machine learning ha tenido un impacto positivo y significativo en la reducción del tiempo de parada de máquina.

Evaluación de la Relación Lineal entre los datos Pre y Post

La correlación de Pearson se aplica a pares de datos individuales, permitiendo evaluar la relación entre dos variables cuantitativas específicas, como un antes y un después de un tratamiento, como los tiempos de parada, eficiencia operativa y costos de mantenimiento en esta investigación. Ver Tabla 4.

Tabla 4. *Correlación de Pearson entre los datos Pre y Post*

Dimensión 1 Pre y Post	Correlación de Pearson
Tiempo de parada de máquina	0.79

Interpretación: La correlación de Pearson entre los tiempos de parada de máquina Pre y Post es de 0.79, lo que indica una correlación positiva fuerte y que las mejoras observadas no son producto de variaciones aleatorias.

Pruebas de Normalidad y Evaluación de Parametricidad

Se realizaron pruebas de normalidad (Shapiro-Wilk y Kolmogorov-Smirnov) para evaluar si los datos siguen una distribución normal. Ver Tabla 5.

Tabla 5. *Shapiro-Wilk y Kolmogorov-Smirnov*

Prueba	Pre (p-valor)	Post (p-valor)
Shapiro-Wilk	0.291	0.191
Kolmogorov-Smirnov	0.856	0.768

Interpretación: Los p-valores superiores a 0.05 en ambas pruebas de normalidad indican que los datos para el tiempo de parada de máquina en ambos estados (Pre y Post) siguen una distribución normal. Esto justifica el uso de pruebas paramétricas como la prueba t de muestras pareadas.

Contrastación de Hipótesis Estadística

Las hipótesis para la prueba t de muestras pareadas son las siguientes:

- **Hipótesis Nula (H_0):** No hay diferencia significativa en el tiempo de parada de máquina entre los estados "Pre" y "Post" ($H_0 : \mu_{Pre} = \mu_{Post}$).
- **Hipótesis Alternativa (H_1):** Hay una diferencia significativa en el tiempo de parada de máquina entre los estados "Pre" y "Post" ($H_1 : \mu_{Pre} \neq \mu_{Post}$).

Resultado: La prueba t de muestras pareadas rechaza la hipótesis nula (H_0) en favor de la hipótesis alternativa (H_1), indicando que hay una diferencia significativa en el tiempo de parada de máquina entre los estados "Pre" y "Post". Ver Tabla 6.

Tabla 6. *Resumen*


Estadístico	Pre (horas)	Post (horas)	Diferencia
Media	44.02	9.36	34.66
Mediana	44.12	8.60	34.47
Desviación Estándar	2.63	3.13	2.04
Mínimo	40.14	4.47	30.08
Máximo	50.26	15.70	38.89
Estadístico t	-	-	92.90

Estadístico	Pre (horas)	Post (horas)	Diferencia
p-valor	-	-	1.90×10^{-37}
Correlación de Pearson	-	-	0.79
Prueba de Shapiro-Wilk (p-valor)	0.291	0.191	-
Prueba de Kolmogorov-Smirnov (p-valor)	0.856	0.768	-

Interpretación General

Los resultados del análisis estadístico descriptivo, las pruebas t de muestras pareadas, la evaluación de la relación lineal, las pruebas de normalidad y la contrastación de hipótesis estadística proporcionan una evidencia contundente de que la implementación del machine learning ha mejorado significativamente la gestión del mantenimiento en la planta embotelladora, específicamente en la reducción del tiempo de parada de máquina. La alta significancia estadística, la excelente consistencia interna y la normalidad de los datos refuerzan la validez de estos hallazgos.

Figura 1. Comparación y Distribución de Tiempo de Parada Pre - Post



Comparación de Tiempo de Parada de Máquina (Pre vs Post)

El gráfico de la Figura 1 de cajas y bigotes (boxplot) muestra la distribución del tiempo de parada de máquina antes (Pre) y después (Post) de la implementación del machine learning. La mediana del tiempo de parada en el estado "Pre" es significativamente mayor que en el estado "Post", lo que visualmente confirma la reducción en el tiempo de parada. Además, la menor dispersión en los datos del estado "Post" indica una mayor consistencia en la reducción del tiempo de parada tras la intervención.

Distribución de Diferencias de Tiempo de Parada (Pre - Post)

El histograma de la Figura 1 de las diferencias del tiempo de parada de máquina (Pre - Post) muestra la distribución de las reducciones de tiempo de parada. La mayoría de las diferencias se concentran alrededor de una reducción de aproximadamente 34.66 horas, lo que indica una mejora significativa y consistente en la reducción del tiempo de parada de máquina tras la implementación del machine learning.

Objetivo Específico 2: Determinar de qué manera el Machine Learning mejora la eficiencia del mantenimiento en el área de producción en una planta embotelladora, Lima 2024

Dimensión 2: Eficiencia del mantenimiento (%)

Para evaluar el impacto de la implementación del machine learning en la eficiencia de mantenimiento, se realizó un análisis estadístico descriptivo de los datos antes (Pre) y después (Post) de la intervención. Se calculó la diferencia entre los estados "Pre" y "Post" para evaluar la magnitud de la mejora. Ver Tabla 7.

Tabla 7. *Análisis Estadístico Descriptivo Pre y Post*

Estadístico	Pre (%)	Post (%)	Diferencia Eficiencia de Mantenimiento (%)
Media	82.19	96.31	-14.12
Mediana	81.94	96.23	-14.16
Desviación Estándar	1.48	0.92	0.79
Mínimo	79.94	94.76	-15.66
Máximo	84.98	97.78	-12.58

Interpretación: La media de la eficiencia de mantenimiento aumentó significativamente de 82.19% en el estado "Pre" a 96.31% en el estado "Post". La reducción en la desviación estándar sugiere una mayor consistencia en la eficiencia de mantenimiento tras la implementación del machine learning. La media de la diferencia es de -14.12%, indicando una mejora significativa en la eficiencia de mantenimiento. La desviación estándar de 0.79% sugiere una mejora consistente y estable.

Pruebas de Significancia Estadística

Para determinar si el aumento en la eficiencia de mantenimiento es estadísticamente significativo, se realizó una prueba t de muestras pareadas.

Tabla 8. *Pruebas t de Muestras Pareadas Pre y Post*

Parámetro	Valor
Estadístico t	-97.61
p-valor	4.56×10^{-38}

Interpretación: El valor de p extremadamente bajo (4.56×10^{-38}) indica que el aumento en la eficiencia operativa es altamente significativo. Esto proporciona evidencia sólida de que la implementación del machine learning ha tenido un impacto positivo y significativo en la eficiencia de mantenimiento.

Evaluación de la Relación Lineal entre los datos Pre y Post

La Correlación de Pearson es más apropiada para estudios Pre y Post, ya que permite medir la relación directa entre las mediciones tomadas antes y después de la intervención, como en el caso de la **eficiencia de mantenimiento**. Ver Tabla 9.

Tabla 9. *Correlación de Pearson entre los datos Pre y Post*

Dimensión 2 Pre y Post	Correlación de Pearson
Eficiencia del mantenimiento	0.63

Interpretación: La correlación de Pearson entre los valores de eficiencia de mantenimiento Pre y Post es de 0.63, lo que indica una relación positiva moderada entre los datos Pre y Post y que las mejoras observadas no son producto de

variaciones aleatorias.

Pruebas de Normalidad y Evaluación de Parametricidad

Se realizaron pruebas de normalidad (Shapiro-Wilk y Kolmogorov-Smirnov) para evaluar si los datos siguen una distribución normal.

Tabla 10. *Shapiro-Wilk y Kolmogorov-Smirnov*

Prueba	Pre (p-valor)	Post (p-valor)
Shapiro-Wilk	0.149	0.106
Kolmogorov-Smirnov	0.782	0.586

Interpretación: Los p-valores superiores a 0.05 en ambas pruebas de normalidad indican que los datos para la eficiencia de mantenimiento en ambos estados (Pre y Post) siguen una distribución normal. Esto justifica el uso de pruebas paramétricas como la prueba t de muestras pareadas.

Contrastación de Hipótesis Estadística

Las hipótesis para la prueba t de muestras pareadas son las siguientes:

- **Hipótesis Nula (H_0):** No hay diferencia significativa en la eficiencia de mantenimiento entre los estados "Pre" y "Post" ($H_0 : \mu_{Pre} = \mu_{Post}$).
- **Hipótesis Alternativa (H_1):** Hay una diferencia significativa en la eficiencia de mantenimiento entre los estados "Pre" y "Post" ($H_1 : \mu_{Pre} \neq \mu_{Post}$).

Resultado: La prueba t de muestras pareadas rechaza la hipótesis nula (H_0) en favor de la hipótesis alternativa (H_1), indicando que hay una diferencia significativa en la eficiencia de mantenimiento entre los estados "Pre" y "Post".


Tabla 11. *Resumen*

Estadístico	Pre (%)	Post (%)	Diferencia
Media	82.19	96.31	-14.12
Mediana	81.94	96.23	-14.16
Desviación Estándar	1.48	0.92	0.79
Mínimo	79.94	94.76	-15.66
Máximo	84.98	97.78	-12.58
Estadístico t	-	-	-97.61
p-valor	-	-	$4.56 \times 10^{(-38)}$
Correlación de Pearson	-	-	0.63
Prueba de Shapiro-Wilk (p-valor)	0.149	0.106	-
Prueba de Kolmogorov-Smirnov (p-valor)	0.782	0.586	-

Interpretación General

Los resultados del análisis estadístico descriptivo, las pruebas t de muestras pareadas, la evaluación de la relación lineal, las pruebas de normalidad y la contrastación de hipótesis estadística proporcionan una evidencia contundente de que la implementación del machine learning ha mejorado significativamente la eficiencia de mantenimiento en la planta embotelladora. La alta significancia estadística, la excelente consistencia interna y la normalidad de los datos refuerzan la validez de estos hallazgos.

Figura 2. Comparación y Distribución de Eficiencia Post - Pre



Comparación de Eficiencia de Mantenimiento (Pre vs Post)

El gráfico de la Figura 2 de cajas y bigotes (boxplot) muestra la distribución de la eficiencia del mantenimiento antes (Pre) y después (Post) de la implementación del machine learning. La mediana de la eficiencia operativa en el estado "Pre" es significativamente menor que en el estado "Post", lo que visualmente confirma el aumento en la eficiencia. Además, la menor dispersión en los datos del estado "Post" indica una mayor consistencia en la eficiencia operativa tras la intervención.

Distribución de Diferencias de Eficiencia (Post - Pre)

El histograma de la Figura 2 de las diferencias de eficiencia operativa (Post - Pre) muestra la distribución de los incrementos de eficiencia. La mayoría de las diferencias se concentran alrededor de un aumento de aproximadamente 14.12%, lo que indica una mejora significativa y consistente en la eficiencia operativa tras la implementación del machine learning.

Objetivo Específico 3: Determinar de qué manera el Machine Learning mejora los costos de mantenimiento en el área de producción en una planta embotelladora, Lima 2024

Dimensión 3: Costos de mantenimiento (dólares)

Para evaluar el impacto de la implementación del machine learning en la reducción

de los costos de mantenimiento, se realizó un análisis estadístico descriptivo de los datos antes (Pre) y después (Post) de la intervención. Se calculó la diferencia entre los estados "Pre" y "Post" para evaluar la magnitud de la mejora. Ver Tabla 12.

Tabla 12. *Análisis Estadístico Descriptivo Pre y Post*

Estadístico	Pre (dólares)	Post (dólares)	Diferencia Costos Operativos (dólares)
Media	37,238.04	3,880.48	33,357.55
Mediana	36,968.05	3,776.02	33,368.28
Desviación Estándar	1,317.02	628.92	778.70
Mínimo	34,950.41	2,905.34	32,048.42
Máximo	40,086.47	5,192.14	35,161.21

Interpretación: La media de los costos de mantenimiento se redujo significativamente de \$37,238.04 en el estado "Pre" a \$3,880.48 en el estado "Post". La reducción en la desviación estándar sugiere una mayor consistencia en los costos operativos tras la implementación del machine learning. La media de la diferencia es de \$33,357.55, indicando una reducción significativa en los costos de mantenimiento. La desviación estándar de \$778.70 sugiere una mejora consistente y estable.

Pruebas de Significancia Estadística

Para determinar si la reducción en los costos de mantenimiento es estadísticamente significativa, se realizó una prueba t de muestras pareadas.

Tabla 13. *Pruebas t de Muestras Pareadas Pre y Post*

Parámetro	Valor
Estadístico t	234.63
p-valor	4.24×10^{-49}

Interpretación: El valor de p extremadamente bajo (4.24×10^{-49}) en la Tabla 13

indica que la reducción en los costos de mantenimiento es altamente significativa. Esto proporciona evidencia sólida de que la implementación del machine learning ha tenido un impacto positivo y significativo en la reducción de los costos operativos.

Evaluación de la Relación Lineal entre los datos Pre y Post

La Correlación de Pearson es más apropiada para estudios Pre y Post, ya que permite medir la relación directa entre las mediciones tomadas antes y después de la intervención, como en el caso de los **costos de mantenimiento**. Ver Tabla 14.

Tabla 14. *Correlación de Pearson entre los datos Pre y Post*

Dimensión 3 Pre y Post	Correlación de Pearson
Costos de mantenimiento	0.81

Interpretación: La correlación de Pearson entre los valores de costos de mantenimiento Pre y Post es de 0.81, lo que indica una relación positiva fuerte entre los datos Pre y Post y que las mejoras observadas no son producto de variaciones aleatorias.

Pruebas de Normalidad y Evaluación de Parametricidad

Se realizaron pruebas de normalidad (Shapiro-Wilk y Kolmogorov-Smirnov) para evaluar si los datos siguen una distribución normal. Ver Tabla 15.

Tabla 15. *Shapiro-Wilk y Kolmogorov-Smirnov*

Prueba	Pre (p-valor)	Post (p-valor)
Shapiro-Wilk	0.347	0.391
Kolmogorov-Smirnov	0.592	0.869

Interpretación: Los p-valores superiores a 0.05 en ambas pruebas de normalidad indican que los datos para los costos de mantenimiento en ambos estados (Pre y Post) siguen una distribución normal. Esto justifica el uso de pruebas paramétricas como la prueba t de muestras pareadas.

Contrastación de Hipótesis Estadística

Las hipótesis para la prueba t de muestras pareadas son las siguientes:

- **Hipótesis Nula (H_0):** No hay diferencia significativa en los costos de mantenimiento entre los estados "Pre" y "Post" ($H_0 : \mu_{Pre} = \mu_{Post}$).
- **Hipótesis Alternativa (H_1):** Hay una diferencia significativa en los costos de mantenimiento entre los estados "Pre" y "Post" ($H_1 : \mu_{Pre} \neq \mu_{Post}$).

Resultado: La prueba t de muestras pareadas rechaza la hipótesis nula (H_0) en favor de la hipótesis alternativa (H_1), indicando que hay una diferencia significativa en los costos de mantenimiento entre los estados "Pre" y "Post".

Tabla 16. *Resumen*


Estadístico	Pre (horas)	Post (horas)	Diferencia
Media	37,238.04	3,880.48	33,357.55
Mediana	36,968.05	3,776.02	33,368.28
Desviación Estándar	1,317.02	628.92	778.70
Mínimo	34,950.41	2,905.34	32,048.42
Máximo	40,086.47	5,192.14	35,161.21
Estadístico t	-	-	234.63
p-valor	-	-	$4.24 \times 10^{(-49)}$
Correlación de Pearson	-	-	0.81
Prueba de Shapiro-Wilk (p-valor)	0.347	0.391	-
Prueba de Kolmogorov-Smirnov (p-valor)	0.592	0.869	-

Interpretación General

Los resultados de la Tabla 16 del análisis estadístico descriptivo, las pruebas t de muestras pareadas, la evaluación de la relación lineal, las pruebas de normalidad y la contrastación de hipótesis estadística proporcionan una evidencia contundente de

que la implementación del machine learning ha mejorado significativamente la reducción de costos de mantenimiento en la planta embotelladora. La alta significancia estadística, la excelente consistencia interna y la normalidad de los datos refuerzan la validez de estos hallazgos.

Figura 3. Comparación y Distribución de Costos Pre - Post



Comparación de Costos de Mantenimiento (Pre vs Post)


El gráfico de la Figura 3 de cajas y bigotes (boxplot) muestra la distribución de los costos de mantenimiento antes (Pre) y después (Post) de la implementación del machine learning. La mediana de los costos de mantenimiento en el estado "Pre" es significativamente mayor que en el estado "Post", lo que visualmente confirma la reducción de los costos. Además, la menor dispersión en los datos del estado "Post" indica una mayor consistencia en los costos de mantenimiento tras la intervención.

Distribución de Diferencias de Costos (Pre - Post)

El histograma de la Figura 3 de las diferencias de costos de mantenimiento (Pre - Post) muestra la distribución de las reducciones de costos. La mayoría de las diferencias se concentran alrededor de una reducción de aproximadamente \$33,357.55, lo que indica una mejora significativa y consistente en la reducción de costos tras la implementación del machine learning.

El análisis estadístico descriptivo revela que, tras la implementación de técnicas de machine learning, hubo mejoras significativas en todas las dimensiones evaluadas. La reducción del tiempo de parada de las máquinas, el aumento de la Eficiencia de mantenimiento y la disminución de los Costos de mantenimiento son indicativos de una gestión del mantenimiento más efectiva y eficiente.


Figura 4. Histograma de las Dimensiones



Fuente: Elaboración propia.

Las visualizaciones de los datos corroboran estos hallazgos, mostrando distribuciones más favorables en el estado "Post" en comparación con el estado "Pre". Estos resultados proporcionan una base sólida para las pruebas estadísticas de significancia y la evaluación de la confiabilidad de los datos en las siguientes secciones del estudio.

Figura 5. Boxplots de las Dimensiones



Fuente: Elaboración propia.

Resumen de la Interpretación

Los resultados obtenidos en este estudio indican que la implementación de técnicas de machine learning ha llevado a mejoras significativas en la gestión del mantenimiento en la planta embotelladora. Estas mejoras se reflejan en la reducción del tiempo de parada de las máquinas, el aumento de la eficiencia de mantenimiento y la disminución de los costos de mantenimiento.

La implementación de técnicas de machine learning en la gestión del mantenimiento tiene importantes implicaciones prácticas para las operaciones de plantas industriales. En primer lugar, mejora significativamente la planificación del mantenimiento al permitir un mantenimiento predictivo más preciso. Esto reduce los tiempos de inactividad no planificados y mejora la disponibilidad de las máquinas. En segundo lugar, aumenta la eficiencia del mantenimiento al mejorar la utilización de los recursos y la productividad de las máquinas, lo que puede traducirse en una mayor producción y eficiencia general de la planta. Por último, contribuye a la reducción de los costos operativos, optimizando los gastos de mantenimiento y disminuyendo los costos asociados a fallos inesperados y reparaciones, aumentando así la rentabilidad de las operaciones.

Finalmente, de los resultados se puede concluir que este estudio proporciona evidencia sólida de que la implementación de técnicas de machine learning puede mejorar significativamente la gestión del mantenimiento en plantas embotelladoras. Las mejoras observadas en la reducción del tiempo de parada de las máquinas, el aumento de la eficiencia de mantenimiento y la disminución de los costos de mantenimiento destacan el potencial de estas técnicas para transformar la gestión del mantenimiento en el sector industrial. La alta confiabilidad y la significancia estadística de los resultados refuerzan la validez de las conclusiones, sugiriendo que las empresas pueden beneficiarse enormemente de la adopción de enfoques basados en machine learning para optimizar sus operaciones y aumentar su competitividad en el mercado.

IV. DISCUSIÓN

Objetivo Específico 1: Determinar de qué manera el Machine Learning mejora los tiempos de parada de máquina en el área de producción en una planta embotelladora, Lima 2024

Discusión Dimensión 1: Tiempo de Parada de Máquina (horas)

La investigación realizada en el ámbito de la planta embotelladora de Lima tiene como objetivo específico evaluar cómo el Machine Learning puede mejorar la gestión del mantenimiento, específicamente en la reducción del tiempo de parada de máquina. Los resultados estadísticos obtenidos indican una mejora significativa en esta dimensión, con una reducción media del tiempo de parada de máquina de 44.02 horas a 9.36 horas. Este hallazgo se compara con estudios previos y teorías relacionadas para proporcionar una comprensión más profunda de los mecanismos y la efectividad del Machine Learning en este contexto.

El estudio de Rosati et al. (2023) demuestra una plataforma de apoyo a la toma de decisiones que integra IoT y técnicas de aprendizaje automático en el contexto de la Industria 4.0. Los resultados muestran una precisión del 85% en la detección de fallos y una disminución del 20% en los gastos de servicios, subrayando la efectividad del sistema propuesto. La investigación presente en la planta embotelladora muestra una reducción del tiempo de parada de máquina mucho mayor, lo que puede atribuirse a la implementación específica de algoritmos de Machine Learning adaptados a las condiciones operativas de la planta.

El estudio de Abidi et al. (2022) en la King Saud University reporta una precisión predictiva del 95% y una reducción del 25% en tiempos de parada en motores de aeronaves y baterías de iones de litio. Comparado con nuestros resultados, la reducción del 78.74% en el tiempo de parada de máquina es notablemente más alta, lo que sugiere que el contexto industrial y la naturaleza de los equipos embotelladores pueden beneficiarse particularmente de las técnicas de Machine Learning implementadas.

Karimzadeh et al. (2022) logran un 85% de acierto en la anticipación de fallos y un 20% de optimización en la distribución de recursos. Si bien nuestro estudio no evalúa la optimización de recursos directamente, la reducción del tiempo de parada

de máquina indirectamente sugiere una mejora en la eficiencia de mantenimiento y una mejor utilización de los recursos.

La teoría de sistemas complejos se aplica para entender cómo las interacciones entre los diferentes componentes de una planta embotelladora pueden generar comportamientos complejos. En nuestro estudio, el Machine Learning se utiliza para modelar y predecir estos comportamientos complejos, lo que resulta en una reducción significativa del tiempo de parada de máquina. La capacidad del Machine Learning para capturar y analizar datos de múltiples fuentes permite una anticipación más precisa de los fallos, alineándose con los principios de adaptabilidad y no linealidad descritos por Thurner (2018).

Según O'Connor (2002), la teoría de la confiabilidad se puede mejorar significativamente mediante el análisis de datos y el monitoreo continuo. Los resultados de nuestra investigación muestran que la implementación de Machine Learning ha mejorado la confiabilidad de los sistemas de mantenimiento, como lo indica la reducción del tiempo de parada de máquina. Esto respalda la afirmación de Mobley (2002) de que la confiabilidad está directamente relacionada con prácticas de mantenimiento predictivo eficaces.

Murphy (2012) y Goodfellow et al. (2016) destacan la capacidad del aprendizaje automático en relación a la teoría del aprendizaje automático, para mejorar significativamente la gestión del mantenimiento mediante la identificación de patrones y la realización de predicciones precisas. En nuestro estudio, el uso de algoritmos de Machine Learning ha permitido una predicción precisa de fallos y una planificación proactiva del mantenimiento, resultando en una reducción del tiempo de parada de máquina. Esto demuestra la aplicabilidad y efectividad del aprendizaje automático en un entorno industrial complejo.

Strogatz (2018) y Khalil (2002) en la teoría de sistemas dinámicos, enfatizan la importancia de modelar y analizar sistemas dinámicos para mejorar la eficiencia y la adaptabilidad. En nuestra investigación, el Machine Learning se utiliza para modelar la dinámica del sistema de mantenimiento, permitiendo una anticipación y mitigación efectiva de fallos. Esto se refleja en la significativa reducción del tiempo de parada de máquina, validando la aplicabilidad de esta teoría en la gestión del mantenimiento industrial.

En resumen, en comparación con estudios previos, los resultados obtenidos en nuestra investigación muestran una reducción más significativa del tiempo de parada de máquina. La integración de teorías de sistemas complejos, confiabilidad, aprendizaje automático y sistemas dinámicos proporciona un marco teórico robusto para entender y mejorar la gestión del mantenimiento mediante Machine Learning. Estos hallazgos subrayan la efectividad de esta tecnología para optimizar los procesos de mantenimiento y mejorar la eficiencia operativa en la planta embotelladora, posicionando a la empresa para enfrentar desafíos futuros con una infraestructura de mantenimiento más robusta y eficiente.

Objetivo Específico 2: Determinar de qué manera el Machine Learning mejora la eficiencia de mantenimiento en el área de producción en una planta embotelladora, Lima 2024

Discusión Dimensión 2: Eficiencia de mantenimiento (%)

La investigación realizada en la planta embotelladora de Lima tiene como objetivo específico evaluar cómo el Machine Learning puede mejorar la eficiencia del mantenimiento. Los resultados obtenidos indican un incremento significativo en la eficiencia operativa, pasando de una media del 82.19% en el estado "Pre" a un 96.31% en el estado "Post". Estos hallazgos se comparan con estudios previos y teorías relacionadas para comprender mejor los mecanismos y la efectividad del Machine Learning en este contexto.

El estudio de Rosati et al. (2023) muestra una plataforma de apoyo a la toma de decisiones que integra IoT y técnicas de aprendizaje automático en la Industria 4.0. Logran un 85% de acierto en la detección de fallos y una disminución del 20% en los gastos de servicios. Aunque nuestro estudio no mide directamente los costos de servicios, la mejora en la eficiencia operativa refleja una optimización similar en los procesos de mantenimiento, sugiriendo que la metodología aplicada es efectiva.

Abidi et al. (2022) en la King Saud University reporta una precisión predictiva del 95% y una reducción del 25% en tiempos de parada. Nuestro estudio muestra un incremento significativo en la eficiencia operativa del 96.31%, lo cual puede ser una indicación de que el uso del Machine Learning no solo reduce tiempos de parada, sino

que también mejora la productividad general del sistema de mantenimiento, probablemente debido a la mayor consistencia en las predicciones y la planificación proactiva del mantenimiento.

Karimzadeh et al. (2022) reportan un 85% de acierto en la anticipación de fallos y una optimización del 20% en la distribución de recursos. Nuestro aumento en la eficiencia del 96.31% sugiere que el Machine Learning permite no solo predecir fallos con precisión, sino también optimizar el uso de los recursos de mantenimiento, mejorando así la eficiencia operativa de manera integral.

La teoría de sistemas complejos, según Thurner (2018), destaca la importancia de la no linealidad e interdependencia en los sistemas industriales. En nuestro estudio, el Machine Learning capta estas interdependencias, permitiendo anticipar y mitigar fallos antes de que ocurran, lo cual se refleja en el aumento significativo de la eficiencia operativa. La adaptabilidad y emergencia de los sistemas, como destaca Prigogine y Stengers (2018), también son relevantes, ya que el Machine Learning permite una adaptación continua a nuevas condiciones operativas, mejorando la eficiencia del mantenimiento.

O'Connor (2002) y Mobley (2002) en la teoría de la confiabilidad, subrayan que la mejora en la confiabilidad está estrechamente relacionada con prácticas de mantenimiento predictivo eficaces. La mejora en la eficiencia operativa observada en nuestro estudio sugiere que el Machine Learning mejora significativamente la confiabilidad de los sistemas de mantenimiento, proporcionando predicciones precisas y permitiendo intervenciones proactivas.

Murphy (2012) y Goodfellow et al. (2016) en referencia a la teoría del aprendizaje automático, destacan que los algoritmos de aprendizaje automático pueden identificar patrones y realizar predicciones precisas a partir de grandes volúmenes de datos. Nuestro estudio demuestra que el uso de estos algoritmos mejora significativamente la eficiencia operativa, alineándose con la teoría de que el aprendizaje automático puede transformar la gestión del mantenimiento al facilitar decisiones más informadas y proactivas.

Em la teoría de sistemas dinámicos de Strogatz (2018) y Khalil (2002) se enfatizan la importancia de modelar y analizar sistemas dinámicos para mejorar la eficiencia y la adaptabilidad. En nuestro estudio, el Machine Learning se utiliza para

modelar la dinámica del sistema de mantenimiento, permitiendo una anticipación y mitigación efectiva de fallos. Esto se refleja en la significativa mejora de la eficiencia operativa, validando la aplicabilidad de esta teoría en la gestión del mantenimiento industrial.

En resumen, los resultados obtenidos en nuestro estudio indican que la implementación del Machine Learning ha mejorado significativamente la eficiencia del mantenimiento en la planta embotelladora, con un incremento del 96.31% en la eficiencia operativa. Al comparar estos resultados con estudios previos y teorías relacionadas, encontramos que las mejoras observadas están en línea con los hallazgos de otras investigaciones y respaldadas por teorías establecidas. La alta precisión en la predicción de fallos y la optimización de recursos contribuyen a una mayor eficiencia operativa, demostrando la efectividad del Machine Learning en la gestión del mantenimiento. Estos resultados subrayan el potencial del Machine Learning para transformar las prácticas de mantenimiento industrial, optimizando la eficiencia y reduciendo tiempos de inactividad, lo que posiciona a la planta embotelladora para enfrentar futuros desafíos con una infraestructura de mantenimiento más robusta y eficiente.

Objetivo Específico 3: Determinar de qué manera el Machine Learning mejora los costos de mantenimiento en el área de producción en una planta embotelladora, Lima 2024

Discusión Dimensión 3: Costos de mantenimiento (dólares)

La investigación llevada a cabo en la planta embotelladora de Lima tiene como objetivo específico evaluar cómo el Machine Learning puede reducir los costos de mantenimiento. Los resultados obtenidos indican una disminución significativa en los costos de mantenimiento, pasando de una media de \$37,238.04 en el estado "Pre" a \$3,880.48 en el estado "Post". Estos hallazgos se comparan con estudios previos y teorías relacionadas para comprender mejor los mecanismos y la efectividad del Machine Learning en este contexto.

El estudio de Rosati et al. (2023) muestra una plataforma que integra IoT y técnicas de aprendizaje automático, logrando una disminución del 20% en los gastos

de servicios. Comparado con nuestro estudio, la reducción del 89.58% en los costos de mantenimiento es significativamente mayor. Esta diferencia puede atribuirse a la implementación específica de algoritmos de Machine Learning adaptados a las condiciones operativas de la planta embotelladora, lo cual optimiza no solo la predicción de fallos, sino también la planificación de intervenciones más eficientes.

Abidi et al. (2022) en la King Saud University reportan una reducción del 20% en costos de mantenimiento mediante métodos de aprendizaje automático. Nuestro estudio, con una reducción mucho mayor, sugiere que la aplicación de Machine Learning en un contexto industrial específico como una planta embotelladora puede proporcionar resultados aún más impresionantes en términos de ahorro de costos, posiblemente debido a la naturaleza específica de los equipos y procesos involucrados.

Karimzadeh et al. (2022) logran una optimización del 20% en la distribución de recursos. Si bien nuestro estudio no mide directamente la distribución de recursos, la reducción significativa en los costos de mantenimiento implica una optimización similar, indicando que el Machine Learning permite una utilización más eficiente de los recursos de mantenimiento.

La teoría de sistemas complejos, según Thurner (2018), destaca la importancia de la no linealidad e interdependencia en los sistemas industriales. En nuestro estudio, el Machine Learning capta estas interdependencias, permitiendo anticipar y mitigar fallos antes de que ocurran, lo cual se refleja en la significativa reducción de los costos de mantenimiento. La adaptabilidad y emergencia de los sistemas, como destaca Prigogine y Stengers (2018), también son relevantes, ya que el Machine Learning permite una adaptación continua a nuevas condiciones operativas, optimizando así los costos de mantenimiento.

En la teoría de la confiabilidad, O'Connor (2002) y Mobley (2002) subrayan que la mejora en la confiabilidad está estrechamente relacionada con prácticas de mantenimiento predictivo eficaces. La mejora en la confiabilidad de los sistemas de mantenimiento, como lo demuestra la reducción de los costos, sugiere que el Machine Learning mejora significativamente la confiabilidad de los sistemas de mantenimiento, proporcionando predicciones precisas y permitiendo intervenciones proactivas.

Según la teoría del aprendizaje automático, Murphy (2012) y Goodfellow et al. (2016) destacan que los algoritmos de aprendizaje automático pueden identificar patrones y realizar predicciones precisas a partir de grandes volúmenes de datos. Nuestro estudio demuestra que el uso de estos algoritmos mejora significativamente la eficiencia operativa y reduce los costos de mantenimiento, alineándose con la teoría de que el aprendizaje automático puede transformar la gestión del mantenimiento al facilitar decisiones más informadas y proactivas.

En la teoría de sistemas dinámicos, Strogatz (2018) y Khalil (2002) enfatizan la importancia de modelar y analizar sistemas dinámicos para mejorar la eficiencia y la adaptabilidad. En nuestro estudio, el Machine Learning se utiliza para modelar la dinámica del sistema de mantenimiento, permitiendo una anticipación y mitigación efectiva de fallos. Esto se refleja en la significativa reducción de los costos de mantenimiento, validando la aplicabilidad de esta teoría en la gestión del mantenimiento industrial.

En resumen, los resultados obtenidos en nuestro estudio indican que la implementación del Machine Learning ha reducido significativamente los costos de mantenimiento en la planta embotelladora, con una disminución del 89.58%. Al comparar estos resultados con estudios previos y teorías relacionadas, encontramos que las mejoras observadas están en línea con los hallazgos de otras investigaciones y respaldadas por teorías establecidas. La alta precisión en la predicción de fallos y la optimización de recursos contribuyen a una mayor eficiencia operativa y una reducción significativa de costos, demostrando la efectividad del Machine Learning en la gestión del mantenimiento. Estos resultados subrayan el potencial del Machine Learning para transformar las prácticas de mantenimiento industrial, optimizando la eficiencia y reduciendo costos operativos, lo que posiciona a la planta embotelladora para enfrentar futuros desafíos con una infraestructura de mantenimiento más robusta y eficiente.

V. CONCLUSIONES

Objetivo Específico 1: Determinar de qué manera el Machine Learning mejora los tiempos de parada de máquina en el área de producción en una planta embotelladora, Lima 2024

Conclusión: La implementación del Machine Learning en la planta embotelladora de Lima resultó en una mejora significativa en la reducción de los tiempos de parada de máquina. Los resultados indicaron que el tiempo de parada de máquina disminuyó de una media de 44.02 horas a 9.36 horas, representando una reducción del 78.74%. Esta disminución fue estadísticamente significativa según las pruebas t de muestras pareadas. Además, el análisis estadístico descriptivo reveló una mayor consistencia en la eficiencia operativa tras la intervención. Los altos valores de la Correlación de Pearson confirmaron la relación lineal y directa de las mediciones Pre y Post. Las pruebas de normalidad demostraron que los datos seguían una distribución normal, justificando el uso de pruebas paramétricas. Comparado con estudios previos, nuestra investigación mostró una mayor reducción en los tiempos de parada, destacando la efectividad del Machine Learning en este contexto específico. La capacidad de anticipar fallos y optimizar el mantenimiento mediante modelos predictivos mejoró la eficiencia operativa y redujo los costos. Estos hallazgos subrayan el potencial del Machine Learning para transformar las prácticas de mantenimiento industrial, optimizando los procesos y reduciendo significativamente los tiempos de inactividad.

Objetivo Específico 2: Determinar de qué manera Machine Learning mejora la eficiencia del mantenimiento en el área de producción en una planta embotelladora, Lima 2024

Conclusión: La implementación del Machine Learning en la planta embotelladora de Lima resultó en una mejora significativa en la eficiencia de mantenimiento. Los resultados indicaron que la eficiencia operativa aumentó de una media de 82.19% a 96.31%, representando una mejora del 17.17%. Esta mejora fue estadísticamente significativa según las pruebas t de muestras pareadas. Además, el análisis estadístico descriptivo reveló una mayor consistencia en la eficiencia operativa tras la intervención, con la desviación estándar disminuyendo de 1.48% a 0.92%. Los altos valores de la Correlación de Pearson confirmaron la relación lineal de las mediciones

Pre y Post. Las pruebas de normalidad demostraron que los datos seguían una distribución normal, justificando el uso de pruebas paramétricas. Comparado con estudios previos, nuestra investigación mostró una mayor mejora en la eficiencia de mantenimiento, destacando la efectividad del Machine Learning en este contexto específico. La capacidad de anticipar fallos y optimizar el mantenimiento mediante modelos predictivos mejoró la eficiencia operativa y redujo los costos. Estos hallazgos subrayan el potencial del Machine Learning para transformar las prácticas de mantenimiento industrial, optimizando los procesos y mejorando significativamente la eficiencia operativa.

Objetivo Específico 3: Determinar de qué manera Machine Learning mejora los costos de mantenimiento en el área de producción de una planta embotelladora, Lima 2024

Conclusión: La implementación de machine learning ha resultado en una significativa reducción de los costos operativos asociados al mantenimiento. Los costos operativos disminuyeron de una media de \$37,238.04 en el estado "Pre" a \$3,880.48 en el estado "Post". Esta reducción es extremadamente significativa ($p\text{-valor} = 4.24 \times 10^{-49}$), reflejando una disminución considerable en los gastos relacionados con fallos inesperados y reparaciones. La capacidad del machine learning para predecir necesidades de mantenimiento y optimizar recursos ha llevado a una gestión más económica y eficiente del mantenimiento.

VI. RECOMENDACIONES

Se presentan una serie de recomendaciones específicas para optimizar las operaciones y maximizar los beneficios observados:

Primero, al gerente de soplado, para la Optimización de los Tiempos de Parada de Máquina, se recomienda implementar un sistema de mantenimiento predictivo basado en machine learning de forma integral en todas las áreas de producción de la planta. La reducción significativa en los tiempos de parada de máquina sugiere que estos sistemas son efectivos para predecir y prevenir fallos antes de que ocurran. Las acciones a tomar son: adquirir y desplegar sensores adicionales y sistemas de monitoreo en tiempo real para todas las máquinas críticas. Y capacitar al personal de mantenimiento en el uso y la interpretación de los datos generados por estos sistemas.

Segundo, al gerente de soplado, para la Mejora de la Eficiencia del Mantenimiento, se recomienda adoptar técnicas avanzadas de machine learning para mejorar la planificación y ejecución del mantenimiento preventivo y predictivo. La mejora significativa en la Eficiencia de mantenimiento destaca la efectividad de estos métodos. Las acciones a tomar son: desarrollar un programa de formación continua para el equipo de mantenimiento en nuevas tecnologías y técnicas de machine learning. E integrar plataformas de software que permitan una mejor gestión y análisis de los datos de mantenimiento.

Tercero, al gerente de soplado, para la Reducción de Costos Operativos, se recomienda expandir el uso de machine learning para optimizar la asignación de recursos y reducir costos operativos. La disminución significativa en los costos operativos sugiere un retorno de inversión positivo en tecnologías de machine learning. Las acciones a tomar son: realizar una auditoría de los procesos actuales de mantenimiento para identificar áreas adicionales donde se puedan implementar soluciones basadas en machine learning. E invertir en herramientas de análisis de datos y machine learning que permitan un análisis detallado de los costos y su optimización.

Cuarto, al gerente de soplado, para llevar a cabo la implementación de estas recomendaciones de manera efectiva, se sugiere el siguiente plan de acción: Primero, realizar una evaluación completa de las necesidades tecnológicas y de formación del personal. Segundo, invertir en tecnologías de sensores y software de machine learning adecuados para la planta. Diseñar e implementar programas de capacitación específicos para el equipo de mantenimiento. Establecer métricas de rendimiento y un sistema de monitoreo continuo para evaluar la efectividad de las nuevas tecnologías y ajustar según sea necesario.

Quinto, al gerente de soplado, para validar y generalizar los resultados obtenidos, es recomendable replicar este estudio en otras plantas embotelladoras y en diferentes industrias. Además, realizar un seguimiento a largo plazo ayudará a evaluar la sostenibilidad de las mejoras observadas con la implementación de machine learning. También se sugiere investigar el impacto de diferentes algoritmos y enfoques de machine learning en la gestión del mantenimiento para identificar las mejores prácticas y optimizar aún más los resultados.

Finalmente, la implementación de técnicas de machine learning ha demostrado ser altamente efectiva en la mejora de la gestión del mantenimiento en la planta embotelladora de Lima. Las recomendaciones anteriores están diseñadas para maximizar estos beneficios y asegurar una operación más eficiente y rentable. La adopción de estas tecnologías no solo optimizará las operaciones actuales, sino que también posicionará a la planta como líder en innovación y eficiencia en el sector embotellador.

REFERENCIAS

- Ahmad, R., & Kamaruddin, S. (2012). An overview of time-based and condition-based maintenance in industrial application. *Computers & industrial engineering*, 63(1), 135-149.
<https://www.sciencedirect.com/science/article/abs/pii/S0360835212000484>
- Álvarez, C. A. M. (2011). Cuantitativa y cualitativa Guía didáctica. *Recuperado de:* <https://www.uv.mx/rmipe/files/2017/02/Guia-didactica-metodologia-de-lainvestigacion.pdf>
- Arias Gonzáles, J. L. (2020). *Proyecto de tesis: guía para la elaboración*. Depósito Legal en la Biblioteca Nacional del Perú N° 2020-05577.
http://repositorio.concytec.gob.pe/bitstream/20.500.12390/2236/1/AriasGonzales_ProyectoDeTesis_libro.pdf
- Arias Gonzáles, J. L., & Covinos Gallardo, M. (2021). Diseño y metodología de la investigación. *Enfoques Consulting EIRL*, 1, 66-78.
https://gc.scalahed.com/recursos/files/r161r/w26022w/Arias_S2.pdf
- Bernal, C. A. (2016). *Metodología de la investigación: administración, economía, humanidades y ciencias sociales* (4a ed.). Pearson.
- Borda Galindo, E. A. (2020). *Programa para optimización en peso de armaduras de acero mediante algoritmos genéticos*.
<https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/17617>
- Creswell, J. W. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5th ed.). Sage Publications. <http://www.ceil-conicet.gov.ar/wp-content/uploads/2015/10/Creswell-Cap-10.pdf>
- Das, R., Bhattacharyya, S., & Nandy, S. (Eds.). (2020). *Machine learning applications : emerging trends*. De Gruyter.
<https://doi.org/10.1515/9783110610987>

- Dash, S. K., Mishra, J., Raj, S., & Agarwal, R. (2021). Automobile Predictive Maintenance Using Deep Learning. *International Journal of Artificial Intelligence and Machine Learning*, 11(2), 1–12.
<https://doi.org/10.4018/IJAIML.20210701.oa7>
- Di Benedetto, S. (2024). Application of a Genetic Algorithm for the Optimal Calibration of Hysteretic Models. *Open Civil Engineering Journal*, 17.
<https://doi.org/10.2174/18741495-v16-e221222-2022-57>
- Dynamox S.A. (14 de agosto de 2020). *La Industria 4.0 y el futuro del Mantenimiento Predictivo*. <https://dynamox.net/es/blog/la-industria-4-0-y-el-futuro-del-mantenimiento-predictivo>
- Fourie, C. J., & Du Plessis, J. A. (2020). IMPLEMENTATION OF MACHINE LEARNING TECHNIQUES FOR PROGNOSTICS FOR RAILWAY WHEEL FLANGE WEAR. *South African Journal of Industrial Engineering*, 31(1), 78–92.
<https://doi.org/10.7166/31-1-2128>
- García, A., & Martínez, B. (2021). Aplicación del aprendizaje automático en el mantenimiento predictivo de la industria automotriz. *Revista Mexicana de Ingeniería de Sistemas*, 35(2), 45-60.
- Garrison, R. H., Noreen, E. W., Brewer, P. C., & McGowan, A. (2010). Managerial Accounting. *Issues in Accounting Education*, 25(4), 792–793.
<https://doi.org/10.2308/iace.2010.25.4.792>
- Fernández, C., & López, D. (2022). Mejora en la eficiencia del mantenimiento predictivo en la industria alimentaria utilizando técnicas de machine learning. *Revista Argentina de Ingeniería Industrial*, 43(1), 22-37.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
<https://www.e-hir.org/upload/pdf/hir-22-351.pdf>
- Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7), 1483-1510.
<https://www.sciencedirect.com/science/article/abs/pii/S0888327005001512>

- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
<https://www.science.org/doi/abs/10.1126/science.aaa8415>
- Kalathas, I., & Papoutsidakis, M. (2021). Predictive Maintenance Using Machine Learning and Data Mining: A Pioneer Method Implemented to Greek Railways. *Designs*, 5(1), 5-. <https://doi.org/10.3390/designs5010005>
- Kane, A. P., Kore, A. S., Khandale, A. N., Nigade, S. S., & Joshi, P. P. (2022). Predictive maintenance using machine learning. *arXiv preprint arXiv:2205.09402*. <https://arxiv.org/abs/2205.09402>
- Khalil, H. K. (2004). Performance recovery under output feedback sampled-data stabilization of a class of nonlinear systems. *IEEE Transactions on Automatic Control*, 49(12), 2173-2184.
<https://ieeexplore.ieee.org/abstract/document/1369394>
- Karimzadeh, A., Shoghli, O., Sabeti, S., & Tabkhi, H. (2022). Multi-Asset Defect Hotspot Prediction for Highway Maintenance Management: A Risk-Based Machine Learning Approach. *Sustainability*, 14(9), 4979-.
<https://doi.org/10.3390/su14094979>
- Kobbacy, K. A., Murthy, D. P., Pintelon, L., & Parodi-Herz, A. (2008). Maintenance: an evolutionary perspective. *Complex system maintenance handbook*, 21- 48.
https://link.springer.com/chapter/10.1007/978-1-84800-011-7_2
- Krupitzer, C., Wagenhals, T., Züfle, M., Lesch, V., Schäfer, D., Mozaffarin, A., ... & Kounev, S. (2020). A survey on predictive maintenance for industry 4.0. *arXiv preprint arXiv:2002.08224*. <https://arxiv.org/pdf/2002.08224>
- Lee, J., Kao, H. A., & Yang, S. (2014). Service innovation and smart analytics for Industry 4.0 and big data environment. *Procedia CIRP*, 16, 3-8.
<https://doi.org/10.1016/j.procir.2014.02.001>
- Lee, J., Ni, J., Singh, J., Jiang, B., Azamfar, M., & Feng, J. (2020). Intelligent maintenance systems and predictive manufacturing. *Journal of Manufacturing Science and Engineering*, 142(11), 110805.

<https://asmedigitalcollection.asme.org/manufacturingscience/article-abstract/142/11/110805/1085488/Intelligent-Maintenance-Systems-and-Predictive>

Lemache-Caiza, K., García-Mora, F., Valverde-González, V., & López, E. V. (2023). El enfoque de aprendizaje de máquina para la gestión del mantenimiento industrial. *Universidad y sociedad (Cienfuegos)*, 15(3), 628–637. <https://rus.ucf.edu.cu/index.php/rus/article/view/3819>

López, M. (2021). *Internet de las cosas*. RAMA. <https://www.alphaeditorialcloud.com/reader/internet-de-las-cosas?location=273>

Mafla-Yépez, C. N., Morales-Bayetero, C. F., Hernández-Rueda, E. P., & Benavides-Cevallos, I. B. (2023). Vehicle maintenance management based on machine learning in agricultural tractor engines. *Dyna (Medellín, Colombia)*, 90(225), 22–28. <https://doi.org/10.15446/dyna.v90n225.103612>

Medina, M., Rojas, R., & Bustamante, W. (2023). *Metodología de la investigación: Técnicas e instrumentos de investigación*. Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú. https://gc.scalahed.com/recursos/files/r161r/w26022w/Arias_S2.pdf

Miner, G. (2006). Maintenance Planning and Scheduling Handbook: Streamline Your Organization for a Lean Environment [Review of *Maintenance Planning and Scheduling Handbook: Streamline Your Organization for a Lean Environment*]. *American Water Works Association. Journal*, 98(8), 125- American Water Works Association. <https://www.proquest.com/docview/221575596/fulltextPDF/497828EE3AE64A6APQ/1?accountid=37408&sourcetype=Scholarly%20Journals>

Mitchell, M. (2009). *Complexity: A Guided Tour* (1st ed.). Oxford University Press. <https://doi.org/10.1093/oso/9780195124415.001.0001>

Mobley, R. K. (2002). *An Introduction to Predictive Maintenance* (2nd ed.). Elsevier Science. <https://ebookcentral.proquest.com/lib/biblioucv/reader.action?docID=29398> 2

- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press. <https://www.tandfonline.com/doi/pdf/10.1080/09332480.2014.914768>
- Nacchia, M., Fruggiero, F., Lambiase, A., & Bruton, K. (2021). A Systematic Mapping of the Advancing Use of Machine Learning Techniques for Predictive Maintenance in the Manufacturing Sector. *Applied Sciences*, 11(6), 2546-. <https://doi.org/10.3390/app11062546>
- Natanael, D., & Sutanto, H. (2022). Machine Learning Application Using Cost-Effective Components for Predictive Maintenance in Industry: A Tube Filling Machine Case Study. *Journal of Manufacturing and Materials Processing*, 6(5), 108-. <https://doi.org/10.3390/jmmp6050108>
- Ñaupas Paitán, H., Palacios Vileta, J. J., Romero Delgado, H. E., Valdivia Dueñas, M. R. (2018). *Metodología de la investigación cuantitativa-cualitativa y redacción de la tesis*. Ediciones de la U. <http://www.ebooks7-24.com/?il=8046>
- Prigogine, I., & Stengers, I. (2018). *Order out of chaos: Man's new dialogue with nature*. Verso Books. <https://link.springer.com/article/10.1023/A:1020729714449>
- Rathilall, R., & Singh, S. (2018). A Lean Six Sigma framework to enhance the competitiveness in selected automotive component manufacturing organisations. *South African Journal of Economic and Management Sciences*, 21(1). <https://doi.org/10.4102/sajems.v21i1.1852>
- Riccio, C., Menanno, M., Zennaro, I., & Savino, M. M. (2024). A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters. *Machines (Basel)*, 12(7), 443-. <https://doi.org/10.3390/machines12070443>
- Rodríguez-Padial, N., Marín, M., & Domingo, R. (2017). An Approach to Integrating Tactical Decision-Making in Industrial Maintenance Balance Scorecards Using Principal Components Analysis and Machine Learning. *Complexity (New York, N.Y.)*, 2017, 1–15. <https://doi.org/10.1155/2017/3759514>

- Rosati, R., Romeo, L., Cecchini, G., Tonetto, F., Viti, P., Mancini, A., & Frontoni, E. (2023). From knowledge-based to big data analytic model: a novel IoT and machine learning based decision support system for predictive maintenance in Industry 4.0. *Journal of Intelligent Manufacturing*, 34(1), 107–121. <https://doi.org/10.1007/s10845-022-01960-x>
- Sampieri, R. H. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw Hill México.
- Smith, D. J. (2021). *Reliability, maintainability and risk: practical methods for engineers*. Butterworth-Heinemann. <https://app.knovel.com/hotlink/toc/id:kpRMRPME3D/reliability-maintainability/reliability-maintainability>
- Strogatz, S. H. (2018). *Nonlinear dynamics and chaos: With applications to physics, biology, chemistry, and engineering* (2nd ed.). Westview Press. <https://www.taylorfrancis.com/books/mono/10.1201/9780429492563/nonlinear-dynamics-chaos-steven-strogatz>
- Surucu, O., Gadsden, S. A., & Yawney, J. (2023). Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances. *Expert Systems with Applications*, 221, 119738-. <https://doi.org/10.1016/j.eswa.2023.119738>
- Turner, S., Klimek, P., & Hanel, R. (2018). Introduction to the Theory of Complex Systems. In *Introduction to the Theory of Complex Systems* (First Edition.). Oxford University Press. <https://doi.org/10.1093/oso/9780198821939.001.0001>
- Tsang, A. H. (2002). Strategic dimensions of maintenance management. *Journal of Quality in maintenance Engineering*, 8(1), 7-39. <https://www.emerald.com/insight/content/doi/10.1108/13552510210420577/full/html>
- Universidad César Vallejo. (2022). *Resolución de Consejo Universitario N° 0470-2022/UCV*. Universidad César Vallejo.
- Wiggins, S. (2005). The dynamical systems approach to Lagrangian transport in

oceanic flows. *Annu. Rev. Fluid Mech.*, 37(1), 295-328.
<https://www.annualreviews.org/content/journals/10.1146/annurev.fluid.37.061903.175815>

Zheng, P., Zhao, Y., & Wang, J. (2019). Design of a predictive maintenance system using condition monitoring and prediction. *International Journal of Production Research*, 57(12), 3920-3934

ANEXOS

Tabla 17. Matriz de operacionalización de variables


Título: Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024					
VARIABLES DE ESTUDIO	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES	ESCALA DE MEDICIÓN
Variable Dependiente: Gestión del Mantenimiento	La "gestión del mantenimiento" se define conceptualmente como el conjunto de prácticas y procedimientos destinados a mantener y mejorar la Eficiencia de mantenimiento, la seguridad y la fiabilidad de los equipos industriales y la infraestructura de la planta. Según Tsang (2002), la gestión del mantenimiento no solo implica la reparación de equipos, sino también la implementación de estrategias proactivas que anticipan y previenen posibles fallas antes de que estas ocurran.	La "gestión del mantenimiento" se mide a través de indicadores clave de rendimiento (KPIs) que se alinean con tres dimensiones: planificación del mantenimiento, eficiencia del mantenimiento y reducción de costos de mantenimiento. La mejora en la gestión del mantenimiento se cuantifica comparando estos indicadores antes y después de la aplicación de técnicas de machine learning diseñadas para optimizar la planificación y prevenir fallos. Según Kobbacy et al. (2008), resaltan la importancia de estos indicadores para una evaluación objetiva y justificación de mejoras tecnológicas en mantenimiento.	Tiempo de parada de máquina	Tiempo de parada de máquina (horas)	Dependiente Continua Razón
			Eficiencia del mantenimiento	Eficiencia de mantenimiento (%) = $[(\text{Tiempo de Funcionamiento} - \text{Tiempo de Inactividad}) / \text{Tiempo de Funcionamiento}] \times 100$	Dependiente Continua Razón
			Costos de mantenimiento	Costos de mantenimiento (Dólares)	Dependiente Continua Razón
Variable Independiente: Maching Learning	"machine learning" es un subcampo de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos estadísticos que permiten a los sistemas informáticos aprender y hacer predicciones o decisiones basadas en datos, sin ser explícitamente programados para cada tarea (Jordan & Mitchell, 2015).	En este estudio, el machine learning se aplicará para optimizar los procesos de mantenimiento en la planta, analizando datos operativos y de mantenimiento para predecir fallos y programar intervenciones de manera eficiente.			



UNIVERSIDAD CÉSAR VALLEJO

Anexo 2

FICHA DE VALIDACIÓN DE JUICIO DE EXPERTO

Nombre del instrumento	Ficha de Recolección de datos
Objetivo del instrumento	Sirve como una herramienta centralizada para acumular todos los datos relevantes necesarios para alimentar y validar los modelos de machine learning, asegurando que toda la información recogida sea coherente y completa.
Nombres y apellidos del experto	Marlon Acuña Benites
Documento de identidad	42097456
Años de experiencia en el área	8
Máximo Grado Académico	Doctor
Nacionalidad	Peruano
Institución	UCV
Cargo	DOCENTE – ASESOR
Número telefónico	934290481
Firma	 Dr. Marlon Acuña Benites DNI: 42097456 Ing. de Sistemas / Investigador
Fecha	30 de mayo del 2024



Anexo 2

Ficha de Recolección de Datos Gestión del Mantenimiento mediante Machine Learning

Categoría	Datos a Recolectar	Detalles/Indicadores
Información General	Fecha de recolección	
	Hora de inicio y fin	
	Operador responsable	
	Área o línea de producción	
Datos de la Máquina	Identificación de la máquina	Código o número de serie
	Tipo de máquina	Especificar el tipo, por ejemplo, llenadora, etiquetadora, etc.
Implementación de Machine Learning	Modelo de ML utilizado	Nombre y versión del modelo
	Parámetros clave del modelo	Parámetros ajustados para la operación específica
Variable Dependiente: Eficiencia del Mantenimiento		
MTTR (Tiempo medio para reparaciones)	Duración de cada reparación	Tiempo en minutos
MTBF (Tiempo medio entre fallos)	Tiempo operativo entre fallos	Tiempo en horas
Costo total de mantenimiento	Costos asociados con cada intervención	Costos desglosados por material, mano de obra, etc.
Frecuencia de fallos no programados	Número de fallos no programados durante el período observado	Cantidad
Datos Operativos Recogidos por IoT	Temperatura, vibraciones, nivel de ruido, consumo de energía	Medidas específicas de cada sensor
Observaciones Adicionales	Descripción de anomalías y acciones correctivas tomadas	Detalles de cualquier evento no estándar
Validación de Datos	Firma del técnico y del supervisor	Confirmación de la exactitud y verificación de los datos

Instrucciones de Uso:

- **Llenar la ficha:** Al final de cada turno o después de cada evento de mantenimiento significativo.
- **Revisión:** Asegurarse de que todos los datos sean revisados por el técnico responsable antes de ser firmados para garantizar la precisión.
- **Actualización de parámetros del modelo:** Registrar cualquier cambio en los parámetros

del modelo de Machine Learning que podría influir en los resultados del mantenimiento.



Anexo 2

MATRIZ DE VALIDACIÓN DE FICHA DE DATOS PARA LA VARIABLE DEPENDIENTE

Definición de la variable: la Gestión de Mantenimiento se define como el conjunto de prácticas y procedimientos destinados a mantener y mejorar la Eficiencia de mantenimiento, la seguridad y la fiabilidad de los equipos industriales y la infraestructura de la planta (Tsang, 2002).

Dimensiones	Indicadores	S u f i c i e n c i a	C l a r i d a d	C o h e r e n c i a	R e l e v a n c i a	Observación
Tiempo de parada de máquina	Tiempo de parada de máquina	1	1	1	1	
Eficiencia	$\text{Eficiencia (\%)} = \left[\frac{\text{Tiempo de Funcionamiento} - \text{Tiempo de Inactividad}}{\text{Tiempo de Funcionamiento}} \right] \times 100$	1	1	1	1	
Reducción de Costos	$\text{Reducción de Costos Operativos (\%)} = \left[\frac{\text{Costos de Mantenimiento Antes} - \text{Costos de Mantenimiento Después}}{\text{Costos de Mantenimiento Antes}} \right] \times 100$	1	1	1	1	



UNIVERSIDAD CÉSAR VALLEJO

Anexo 2

FICHA DE VALIDACIÓN DE CONTENIDO PARA UN INSTRUMENTO

INSTRUCCIÓN: A continuación, se le hace llegar el instrumento de recolección de datos de la ficha que permitirá recoger la información en la investigación que lleva por título: **Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024.**

Por lo que se le solicita que tenga a bien evaluar el instrumento, haciendo, de ser caso, las sugerencias para realizar las correcciones pertinentes. Los criterios de validación de contenido son:

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	La pregunta es esencial o importante, es decir, debe ser incluido	1: de acuerdo 0: en desacuerdo

Nota. Criterios adaptados de la propuesta de Escobar y Cuervo (2008).

CARTA DE PRESENTACIÓN

Señor: **Dr. Mg. Marlon Acuña Benites**

Presente

Asunto: **VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.**

Me es muy grato comunicarme con usted para expresarle mis saludos y así mismo, hacer de su conocimiento que, siendo estudiante del Programa de Maestría en Ingeniería de Sistemas con Mención en Tecnologías de la Información de la Escuela de Posgrado de la UCV, en la sede LIMA NORTE, ciclo 2024 - I, aula 1, requiero validar los instrumentos con los cuales se recogerá la información necesaria para poder desarrollar mi investigación y con la que sustentaré mis competencias investigativas en la Experiencia curricular de Diseño y desarrollo del trabajo de investigación.

El nombre de mi **Variable es: Gestión del Mantenimiento** y siendo imprescindible contar con la aprobación de docentes especializados para poder aplicar los instrumentos en mención, se ha considerado conveniente recurrir a usted, ante su connotada experiencia en temas educativos y/o investigación educativa.

El expediente de validación, que le hacemos llegar contiene:

- Carta de presentación.
- Definición conceptual de la variable.
- Matriz de validación del instrumento.
- Ficha de validación de juicio de experto.

Expresándole mis sentimientos de respeto y consideración me despido de usted, no sin antes agradecerle por la atención que dispense a la presente.

Atentamente.



.....
JULIO ERNESTO SANTA CRUZ VEGA
D.N.I.: 08174874

Anexo 2

FICHA DE VALIDACIÓN DE JUICIO DE EXPERTO

Nombre del instrumento	Ficha de Recolección de datos
Objetivo del instrumento	Sirve como una herramienta centralizada para acumular todos los datos relevantes necesarios para alimentar y validar los modelos de machine learning, asegurando que toda la información recogida sea coherente y completa.
Nombres y apellidos del experto	Luis Alberto Loayza Ramírez
Documento de identidad	19812950
Años de experiencia en el área	38
Máximo Grado Académico	Maestro
Nacionalidad	Peruano
Institución	POLICIA NACIONAL DEL PERU
Cargo (Ultimo cargo)	JEFE DEL DEPARTAMENTO DE INGENIERIA FORENSE
Número telefónico	987732812
Firma	 Maestro Luis Alberto Loayza Ramirez DNI: 19812950 Ing. Químico
Fecha	30 de mayo del 2024

Anexo 2
**Ficha de Recolección de Datos
Gestión del Mantenimiento mediante Machine Learning**

Categoría	Datos a Recolectar	Detalles/Indicadores
Información General	Fecha de recolección	
	Hora de inicio y fin	
	Operador responsable	
	Área o línea de producción	
Datos de la Máquina	Identificación de la máquina	Código o número de serie
	Tipo de máquina	Especificar el tipo, por ejemplo, llenadora, etiquetadora, etc.
Implementación de Machine Learning	Modelo de ML utilizado	Nombre y versión del modelo
	Parámetros clave del modelo	Parámetros ajustados para la operación específica
Variable Dependiente: Eficiencia del Mantenimiento		
MTTR (Tiempo medio para reparaciones)	Duración de cada reparación	Tiempo en minutos
MTBF (Tiempo medio entre fallos)	Tiempo operativo entre fallos	Tiempo en horas
Costo total de mantenimiento	Costos asociados con cada intervención	Costos desglosados por material, mano de obra, etc.
Frecuencia de fallos no programados	Número de fallos no programados durante el período observado	Cantidad
Datos Operativos Recogidos por IoT	Temperatura, vibraciones, nivel de ruido, consumo de energía	Medidas específicas de cada sensor
Observaciones Adicionales	Descripción de anomalías y acciones correctivas tomadas	Detalles de cualquier evento no estándar
Validación de Datos	Firma del técnico y del supervisor	Confirmación de la exactitud y verificación de los datos

Instrucciones de Uso:

- **Llenar la ficha:** Al final de cada turno o después de cada evento de mantenimiento significativo.
- **Revisión:** Asegurarse de que todos los datos sean revisados por el técnico responsable antes de ser firmados para garantizar la precisión.
- **Actualización de parámetros del modelo:** Registrar cualquier cambio en los parámetros del modelo de Machine Learning que podría influir en los resultados del mantenimiento.

Anexo 2

MATRIZ DE VALIDACIÓN DE FICHA DE DATOS PARA LA VARIABLE DEPENDIENTE

Definición de la variable: la **Gestión de Mantenimiento** se define como el conjunto de prácticas y procedimientos destinados a mantener y mejorar la Eficiencia de mantenimiento, la seguridad y la fiabilidad de los equipos industriales y la infraestructura de la planta (Tsang, 2002).

Dimensiones	Indicadores	S u f i c i e n c i a	C l a r i d a d	C o h e r e n c i a	R e l e v a n c i a	Observación
Tiempo de parada de máquina	Tiempo de parada de máquina	1	1	1	1	
Eficiencia	$\text{Eficiencia (\%)} = \frac{[(\text{Tiempo de Funcionamiento} - \text{Tiempo de Inactividad}) / \text{Tiempo de Funcionamiento}] \times 100}{}$	1	1	1	1	
Reducción de Costos	$\text{Reducción de Costos Operativos (\%)} = \frac{[(\text{Costos de Mantenimiento Antes} - \text{Costos de Mantenimiento Después}) / \text{Costos de Mantenimiento Antes}] \times 100}{}$	1	1	1	1	

Anexo 2

FICHA DE VALIDACIÓN DE CONTENIDO PARA UN INSTRUMENTO

INSTRUCCIÓN: A continuación, se le hace llegar el instrumento de recolección de datos de la ficha que permitirá recoger la información en la investigación que lleva por título: **Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024.**

Por lo que se le solicita que tenga a bien evaluar el instrumento, haciendo, de ser caso, las sugerencias para realizar las correcciones pertinentes. Los criterios de validación de contenido son:

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	La pregunta es esencial o importante, es decir, debe ser incluido	1: de acuerdo 0: en desacuerdo

Nota. Criterios adaptados de la propuesta de Escobar y Cuervo (2008).

Anexo 2

CARTA DE PRESENTACIÓN

Señor: **Dr. Mg. Luis Alberto Loayza Ramírez**

Presente

Asunto: **VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.**

Me es muy grato comunicarme con usted para expresarle mis saludos y así mismo, hacer de su conocimiento que, siendo estudiante del Programa de Maestría en Ingeniería de Sistemas con Mención en Tecnologías de la Información de la Escuela de Posgrado de la UCV, en la sede LIMA NORTE, ciclo 2024 - I, aula 1, requiero validar los instrumentos con los cuales se recogerá la información necesaria para poder desarrollar mi investigación y con la que sustentaré mis competencias investigativas en la Experiencia curricular de Diseño y desarrollo del trabajo de investigación.

El nombre de mi **Variable** es: **Gestión del Mantenimiento** y siendo imprescindible contar con la aprobación de docentes especializados para poder aplicar los instrumentos en mención, se ha considerado conveniente recurrir a usted, ante su connotada experiencia en temas educativos y/o investigación educativa.

El expediente de validación, que le hacemos llegar contiene:

- Carta de presentación.
- Definición conceptual de la variable.
- Matriz de validación del instrumento.
- Ficha de validación de juicio de experto.

Expresándole mis sentimientos de respeto y consideración me despido de usted, no sin antes agradecerle por la atención que dispense a la presente.

Atentamente.



.....
JULIO ERNESTO SANTA CRUZ VEGA
D.N.I.: 08174874

Anexo 2

DECLARACIÓN JURADA: VALIDACIÓN Y CONFIABILIDAD DE INSTRUMENTOS

Apellidos y nombres	Santa Cruz Vega Julio Ernesto
DNI	08174874
Código de estudiante	7001254981
Filial	Lima Norte
Programa	Maestría en Ingeniería de Sistemas con Mención en Tecnologías de la Información
Modalidad	Presencial
Grupo	B1
Docente asesor	Dr. Acuña Benites, Marlon Frank

Declaró que regularizará la presentación de los formatos de validez (Fichas de validación) y confiabilidad (Base de datos de la muestra piloto y resultados) de los instrumentos a utilizar, como máximo al término de la semana 13. De no cumplir dentro del plazo establecido asumo la responsabilidad y tomo conocimiento que **NO podré sustentar la tesis de grado** por no cumplir con uno de los requisitos establecidos en la Guía de elaboración de trabajos de investigación emitido por el Vicerrectorado de Investigación (RCU 081-2024 VI/UCV)

Ciudad, 15 de Junio del año 2024

Firma:



DNI: 08174874



Huella digital

Anexo 3

DECLARACIÓN JURADA: USO DE DATOS PÚBLICOS

Apellidos y nombres	Santa Cruz Vega Julio Ernesto
DNI	08174874
Código de estudiante	7001254981
Campus	Lima Norte
Programa	Maestría en Ingeniería de Sistemas con Mención en Tecnologías de la Información
Modalidad	Presencial
Grupo	B1
Docente asesor	Dr. Acuña Benites, Marlon Frank

Declaró que la información que utilizaré para el desarrollo de mi trabajo de investigación titulado “Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024” **son datos de dominio público**; por tanto, no requiero tener la autorización de la institución correspondiente. Asumo la responsabilidad de la veracidad de lo expuesto.

Ciudad, 15 de Junio del año 2024

Firma:



DNI: 08174874
digital



Huella

Anexo 3

Solicitud de autorización para realizar la investigación en una institución

Lima, 08 de junio de 2024

Señor (a):

RAÚL LUIS PÉREZ-EGAÑA MONGE

CARGO: Gerente de Soplado Corporativo

NOMBRE DE LA EMPRESA: SMI – SUSTAINABLE MATERIALS & INNOVATION

Presente.-

Es grato dirigirme a usted para saludarlo(a), y a la vez manifestarle que dentro de mi formación académica en la experiencia curricular de investigación del III ciclo, se contempla la realización de una investigación con fines netamente académicos para la obtención de mi grado académico, luego de la finalización de dichos estudios.

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 cuyo título se menciona a continuación:

“Machine Learning para la gestión del mantenimiento en el área de producción en una planta embotelladora, Lima 2024”.

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,



Julio Ernesto Santa Cruz Vega

DNI: 08174874

Anexo 3

DECLARACIÓN JURADA: Autorización de la entidad para la ejecución de la investigación

Apellidos y nombres	Santa Cruz Vega Julio Ernesto
DNI	08174874
Código de estudiante	7001254981
Campus	Lima Norte
Programa	Maestría en Ingeniería de Sistemas con Mención en Tecnologías de la Información
Modalidad	Presencial
Grupo	B1
Docente asesor	Dr. Acuña Benites, Marlon Frank

Declaro que regularizaré la presentación de la Autorización de la entidad para la ejecución de la investigación como máximo al término de la semana 13. De no cumplir dentro del plazo establecido asumo la responsabilidad y tomo conocimiento que **NO podré sustentar la tesis de grado** por no cumplir con uno de los requisitos establecidos en la Guía de elaboración de trabajos de investigación emitido por el Vicerrectorado de Investigación (RCU 081-2024 VI/UCV)

Ciudad, 15 de Junio del año 2024

Firma:



DNI: 08174874



Huella digital