



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

“Modelo de mantenimiento predictivo y proactivo para el funcionamiento de las maquinarias de la empresa Acería del Ecuador C.A. ADELCA.”

Cifuentes Simbaña, Darwin Israel

Vicerrectorado de Investigación, Innovación y Transferencia de Tecnológica

Centro de Posgrados

Maestría en Gestión de Sistemas de Información e Inteligencia
de Negocios

Trabajo de titulación, previo a la obtención del título de Magister en Gestión de Sistemas
de Información e Inteligencia de Negocios

Phd. Gualotuña Álvarez, Tatiana Marisol

01 de agosto de 2023



Plagiarism and AI Content Detection Report

TESIS ENTREGABLE DARWIN CIFUENT...

Scan details

Scan ID: February 23, 2024 at 14:54 UTC
 Total Pages: 67
 Total Words: 18621

Plagiarism Detection



Type of plagiarism	Words
Identical	2.4% 305
Minor Changes	2.4% 427
Paraphrased	2.4% 399
Ornated Words	2.1% 469

AI Content Detection



Text coverage	Words
AI text	0.7% 116
Human text	99.3% 18140

[Learn more](#)

Plagiarism Results: (57)

Copleaks Internal Database 0.0%

que cumple con los requisitos legales, técnicos, científicos, técnicos y metodológicos establecidos por la

Copleaks Internal Database 0.0%

que cumple con los requisitos legales, técnicos, científicos, técnicos y metodológicos establecidos por la

¿Es lo mismo, Business Intelligence y Big Data? - Business Process Outsou... 0.0%

https://profidice.com.co/translate.google/lo-mismo-business-inteligencia-y-big-data?_x_tr_sl=es&_x_tr_tl=...

Skip to primary navigation Skip to main content Skip to footer Bus...

Business Intelligence y Big Data. ¿Son lo mismo? 0.0%

https://www.grupobases.com/translate.google/lo-mismo-business-inteligencia-y-big-data-con-lo-mismo?_x_tr_sl=...

Certified by

About this report
<https://copleaks.com>

copleaks.com



El mes a certificación por:
 TATIANA MARISOL
 GUALOTUÑA ALVAREZ

Phd. Gualotuña Álvarez, Tatiana Marisol

Directora



Vicerrectorado de Investigación, Innovación y Transferencia de Tecnología

Centro de Posgrados

Certificación

Certifico que el trabajo de titulación: **"Modelo de mantenimiento predictivo y proactivo para el funcionamiento de las maquinarias de la empresa Acería del Ecuador C.A. ADELCA."** fue realizado por el señor **Cifuentes Simbaña, Darwin Israel**; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Sangolquí, 01 de agosto de 2023



Phd. Gualotuña Álvarez, Tatiana Marisol

Directora

C.C.: 1711498418



Vicerrectorado de Investigación, Innovación y Transferencia de Tecnología

Centro de Posgrados

Responsabilidad de Autoría

Yo, Cifuentes Simbaña, Darwin Israel, con cédula de ciudadanía N° 1721401972, declaro que el contenido, ideas y criterios del trabajo de titulación: “Modelo de mantenimiento predictivo y proactivo para el funcionamiento de las maquinarias de la empresa Acería del Ecuador C.A. ADELCA.” es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 01 de agosto de 2023



Cifuentes Simbaña, Darwin Israel

C.C.: 1721401972



Vicerrectorado de Investigación, Innovación y Transferencia de Tecnología

Centro de Posgrados

Autorización de Publicación

Yo, Cifuentes Simbaña, Darwin Israel, con cédula de ciudadanía N° 1721401972, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: "Modelo de mantenimiento predictivo y proactivo para el funcionamiento de las maquinarias de la empresa Acería del Ecuador C.A. ADELCA." en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 01 de agosto de 2023



.....
Cifuentes Simbaña, Darwin Israel

C.C.: 1721401972

Dedicatoria

Dedico el presente trabajo a Dios, que es mi padre que me ha bendecido siempre y me permitido cumplir cada uno de mis sueños y anhelos.

A mi familia: mis padres y mi hermana que son parte fundamental de mi vida que de una u otra forma siempre han estado junto a mí, son mi mayor admiración.

A mi novia Gabriela, por ser parte de mi vida y mi felicidad a quien amo demasiado.

Darwin Cifuentes

Agradecimiento

Agradecimiento a Dios,

Agradecimientos a todas las personas que contribuyeron en el desarrollo del presente trabajo

Agradecimiento a la empresa que me brindo todas las facilidades para desarrollarme como profesional y ser parte del presente trabajo.

A la Dra. Tatiana Gualotuña, por su valiosa guía

Al Msc. Paul Diaz por su apoyo incondicional en mi titulación.

Índice de contenidos

Dedicatoria.....	6
Agradecimiento.....	7
Índice de tablas.....	12
Índice de figuras.....	13
Resumen	15
Abstract.....	16
Capítulo I	17
Introducción	17
Antecedentes	17
Planteamiento del problema	19
Objetivos	22
<i>Objetivo general</i>	22
<i>Objetivos específicos</i>	22
Preguntas de investigación.....	22
Hipótesis de investigación	23
Metodología	24
<i>Fase N°1 Estudio del estado actual</i>	25
<i>Fase N°2 Estudio del estado del arte</i>	25
<i>Fase N°3 Planteamiento de la solución</i>	26
<i>Fase N°4 Implementación de la solución</i>	26
<i>Fase N°5 Pruebas y evaluación</i>	26

Señalamiento de variables	27
Justificación, importancia y alcance del proyecto	27
Capítulo II	28
Estado de arte y marco teórico	28
Estado del arte	28
Criterios de inclusión	28
Criterios de exclusión	28
Cadena de búsqueda	30
Conclusiones de los trabajos relacionados.....	37
Marco teórico.....	38
Inteligencia de negocios	38
La industria 4.0.....	40
Análisis de datos	45
Big data.....	45
Maquinaria industrial	46
Sistemas de mantenimiento	47
<i>Tipos de mantenimiento.....</i>	<i>47</i>
<i>Costos por mantenimiento</i>	<i>48</i>
Costos directos.....	49

	10
Costos indirectos.....	49
Modelos de predicción.....	49
<i>Modelo Deep Learning</i>	49
<i>Modelo Decision Tree</i>	50
<i>Modelo Naive Bayes</i>	51
<i>Modelo Random Forest</i>	51
<i>Modelo K-NN</i>	52
Capítulo III	52
Modelo de mantenimiento predictivo y proactivo.....	52
Fase 1: Comprensión del negocio	53
Fase 2: Comprensión de datos.....	54
Fase 3: Preparación de los datos	56
Fase 4: Modelado.....	57
Fase 5: Evaluación.....	59
Fase 6: Implementación:	60
Capítulo IV	61
Implementación del modelo de mantenimiento predictivo y proactivo	61
Fase 1: Comprensión del negocio	61
Fase 2: Comprensión de los datos	65
Fase 3: Preparación de los datos	71

Fase 4: Modelado.....	79
Fase 5: Evaluación.....	86
Fase 6: Implementación.....	87
Validación del modelo.....	96
Capítulo V.....	98
Conclusiones.....	98
Recomendaciones.....	99
Bibliografía.....	101

Índice de tablas

Tabla 1 <i>Grupo de control</i>	29
Tabla 2 <i>Cadena de búsqueda</i>	31
Tabla 3 <i>Resultados de la cadena de búsqueda</i>	33
Tabla 4 <i>Planificación del proyecto</i>	64
Tabla 5 <i>Descripción de la fuente de datos</i>	66
Tabla 6 <i>Descripción de los campos del inventario de equipos</i>	66
Tabla 7 <i>Descripción de los campos del registro de demoras</i>	68
Tabla 8 <i>Descripción del plan de actividades de mantenimiento</i>	70
Tabla 9 <i>Evaluación de los modelos de predicción</i>	86
Tabla 10 <i>Resumen de los datos reales del tipo de parada</i>	90
Tabla 11 <i>Resumen de los datos predictivos del tipo de parada</i>	91
Tabla 12 <i>Predicción de fallas por equipo</i>	92
Tabla 13 <i>Predicción de daños o fallas</i>	94

Índice de figuras

Figura 1 <i>Diagrama de espina de pescado</i>	20
Figura 2 <i>Metodología Ad-hoc</i>	24
Figura 3 <i>Variables dependientes e independientes</i>	38
Figura 4 <i>Conocimiento, información y datos</i>	39
Figura 5 <i>Evolución de la industria</i>	41
Figura 6 <i>Desarrollo del sector industrial</i>	42
Figura 7 <i>Características del producto inteligente</i>	43
Figura 8 <i>Características del servicio inteligente</i>	44
Figura 9 <i>Metodología CRISP-DM</i>	53
Figura 10 <i>Sistema de control de mantenimientos</i>	62
Figura 11 <i>Proceso de elaboración del acero</i>	63
Figura 12 <i>Criticidad de equipos</i>	67
Figura 13 <i>Detalle de paradas por departamento</i>	69
Figura 14 <i>Demoras por equipos</i>	69
Figura 15 <i>Demoras por turnos</i>	70
Figura 16 <i>Pre-procesamiento de datos</i>	72
Figura 17 <i>Lectura de la fuente de datos</i>	73
Figura 18 <i>Identificación de los tipos datos</i>	74
Figura 19 <i>Selección de roles</i>	75
Figura 20 <i>Detalle de estadísticas</i>	76
Figura 21 <i>Selección de atributos</i>	77
Figura 22 <i>Reemplazo de valores faltantes</i>	78
Figura 23 <i>Diseño del modelo Deep Learning</i>	79
Figura 24 <i>Resultados del modelo Deep Learning</i>	80
Figura 25 <i>Evaluación del rendimiento estadístico del modelo Deep Learning</i>	80

Figura 26 <i>Diseño del modelo Decision Tree</i>	81
Figura 27 <i>Resultados del modelo Decision Tree</i>	81
Figura 28 <i>Evaluación del rendimiento estadístico del modelo Decision Tree</i>	82
Figura 29 <i>Diseño del modelo Naive Bayes</i>	82
Figura 30 <i>Resultados del modelo Naive Bayes</i>	83
Figura 31 <i>Evaluación del rendimiento estadístico del modelo Naive Bayes</i>	83
Figura 32 <i>Diseño del modelo Random Forest</i>	84
Figura 33 <i>Resultados del modelo Random Forest</i>	84
Figura 34 <i>Evaluación del rendimiento estadístico del modelo Random Forest</i>	85
Figura 35 <i>Diseño del modelo K-NN</i>	85
Figura 36 <i>Implementación del modelo Deep Learning</i>	88
Figura 37 <i>Resultados de la implementación del modelo Deep Learning</i>	88
Figura 38 <i>Exactitud de la implementación del modelo Deep Learning</i>	89
Figura 39 <i>Clasificación del error de la implementación del modelo Deep Learning</i>	89
Figura 40 <i>Evaluación estadística de la implementación del modelo Deep Learning</i>	90
Figura 41 <i>Predicción de daños o fallas por equipo</i>	93
Figura 42 <i>Predicción de daños por equipo en base a los turnos</i>	94
Figura 43 <i>Predicción de los daños o fallas</i>	95

Resumen

ADELCA es una empresa siderúrgica, actualmente cuenta con dos plantas industriales: la Planta Industrial de Alóag y la Planta Industrial de Milagro donde disponen un alto número de maquinarias para la producción del acero lo que se evidencia claramente que se destina elevados recursos para el mantenimiento de la maquinaria, determinando que se debe analizar los procesos de mantenimiento preventivo y correctivo. **Problema:** al presentarse fallas en el proceso de mantenimiento genera demoras en el recambio de repuestos cuando realizan mantenimientos correctivos, ocasionando que los procesos de producción se detengan y refleje pérdidas económicas, alto uso de mano de obra mientras realizan los mantenimientos respectivos de la maquinaria, en algunos casos se planifica mantenimientos anuales que pueden durar un mes o dos meses, de ello también depende si las bodegas disponen de los respectivos repuestos caso contrario se debe esperar la importación del repuesto. **Objetivo:** Establecer un modelo de mantenimiento predictivo y proactivo basado en industria 4.0 que permita el mantenimiento eficiente de la maquinaria de producción de la empresa ADELCA C.A. **Metodología:** Para la realización de esta investigación se está aplicando una metodología ad-hoc que está compuesta de 5 etapas en donde se desarrolla toda la investigación. **Resultados esperados:** Con la aplicación de este proyecto se pretende obtener el diseño de un modelo predictivo y proactivo que ayude a mejorar el sistema de mantenimiento de las maquinarias que intervienen en todo el sistema de producción, permitiendo ser más eficaces en el proceso y a la vez disminuyendo los costos de mantenimiento.

Palabras claves: mantenimiento predictivo, industria 4.0, análisis de datos.

Abstract

ADELCA is a steel company, it currently has two industrial plants: the Alóag Industrial Plant and the Milagro Industrial Plant where they have a high number of machinery for the production of steel, which clearly shows that high resources are allocated for maintenance of the machinery, determining that preventive and corrective maintenance processes should be analyzed. Problem: when failures occur in the maintenance process, it generates delays in the replacement of spare parts when corrective maintenance is carried out, causing production processes to stop and reflecting economic losses, high use of labor while carrying out the respective maintenance of the machinery, In some cases, annual maintenance is planned that can last 1 month or two months, it also depends on whether the warehouses have the respective spare parts; otherwise, you must wait for the spare part to be imported. Objective: Establish a predictive and proactive maintenance model based on industry 4.0 that allows efficient maintenance of the production machinery of the company ADELCA C.A. Methodology: To carry out this research, an ad-hoc methodology is being applied that is composed of 5 stages where all the research is carried out. Expected results: With the application of this project, it is intended to obtain the design of a predictive and proactive model that helps to improve the maintenance system of the machinery that intervenes in the entire production system, allowing to be more efficient in the process and at the same time reducing maintenance costs.

Key words: predictive maintenance, industry 4.0, data analysis.

Capítulo I

Introducción

Antecedentes

Acería del Ecuador C.A. ADELCA fue fundada en 1963 por un grupo de empresarios ecuatorianos con el objetivo de proveer al país de productos de acero para la construcción ya que hasta ese entonces dichos productos se importaban, es la siderúrgica número uno del Ecuador; pionera en el reciclaje y fabricación de acero. Sus operaciones se realizan bajo estrictas normas técnicas de calidad y de seguridad, apegados a la protección ambiental, ADELCA de forma permanente renueva sus procesos y destina recursos a la inversión en desarrollo tecnológico en cada una de sus procesos de producción.

ADELCA satisface las necesidades de los sectores de la construcción, metalmecánico, seguridad perimetral, agropecuario, industrial, entre otros se ha convertido en el motor que impulsa el desarrollo social económico del Ecuador.

ADELCA está comprometida con el país, por esa razón y como parte de su visión corporativa de Responsabilidad Social, ADELCA impulsa continuamente proyectos sostenibles en beneficio de las comunidades, colaboradores y clientes. (ADELCA, s.f.)

La empresa ha sido parte del todo el proceso de la evolución industrial llegando así a la Industria 4.0 donde existe la utilización de herramientas de inteligencia de negocios, sistemas ciber físicos, una industria más inteligente, la utilización del internet de las cosas, big data y la hiperconectividad, la cual es de vital importancia que la empresa Acería del Ecuador C.A. ADELCA sea parte de la transformación a una industria 4.0 donde la toma de decisiones y los procesos de producción como tal sea más inteligente lo que ha llevado a empezar con el tratamiento al sistema de mantenimiento de las maquinarias de la empresa.

ADELCA, cuenta con dos plantas industriales: la Planta Industrial de Alóag y la Planta Industrial de Milagro donde disponemos un alto número de maquinarias para la producción del acero lo que se evidencia claramente que la empresa destina elevados recursos para el mantenimiento de la maquinaria, valores que se encuentran sustentados en los estados financieros de la empresa lo que tiene una gran incidencia en sus resultados anuales, determinando que la empresa debe analizar los procesos de mantenimiento preventivo y correctivo.

La empresa realiza sus mantenimientos en base a un Plan de Mantenimiento Anual que lo elabora el gerente de mantenimiento conjuntamente con cada uno de los inspectores, su enfoque principal es realizar mantenimiento preventivo con la finalidad de no tener paras en la producción y si es necesario realizar un mantenimiento correctivo.

La empresa dispone de una base de datos donde detallan las actividades que cada mecánico realiza cuando incurre en algún mantenimiento, se generan órdenes de mantenimiento donde se tiene el número de horas que se invirtió, los repuestos y en el caso de necesitar servicios externos.

La industria con el pasar de los años ha dado grandes cambios hasta la actualidad, donde la primera revolución industrial se basó en el mecanismo de vapor agua, la segunda revolución industrial se enfocó en producir en base a líneas de producción apoyándose con el uso de la electricidad, la tercera revolución industrial se enfocó en la automatización para poder realizar sus procesos y la cuarta revolución industrial se enfoca en sistemas autónomos donde se manejan casi sin la intervención humana y alimentándose únicamente de datos, como es la inteligencia artificial y el aprendizaje de las máquinas para la realización de actividades, tareas, cálculos y procesamiento de información con la finalidad de mejorar sus resultados en las industrias tanto económicos como de procesos.

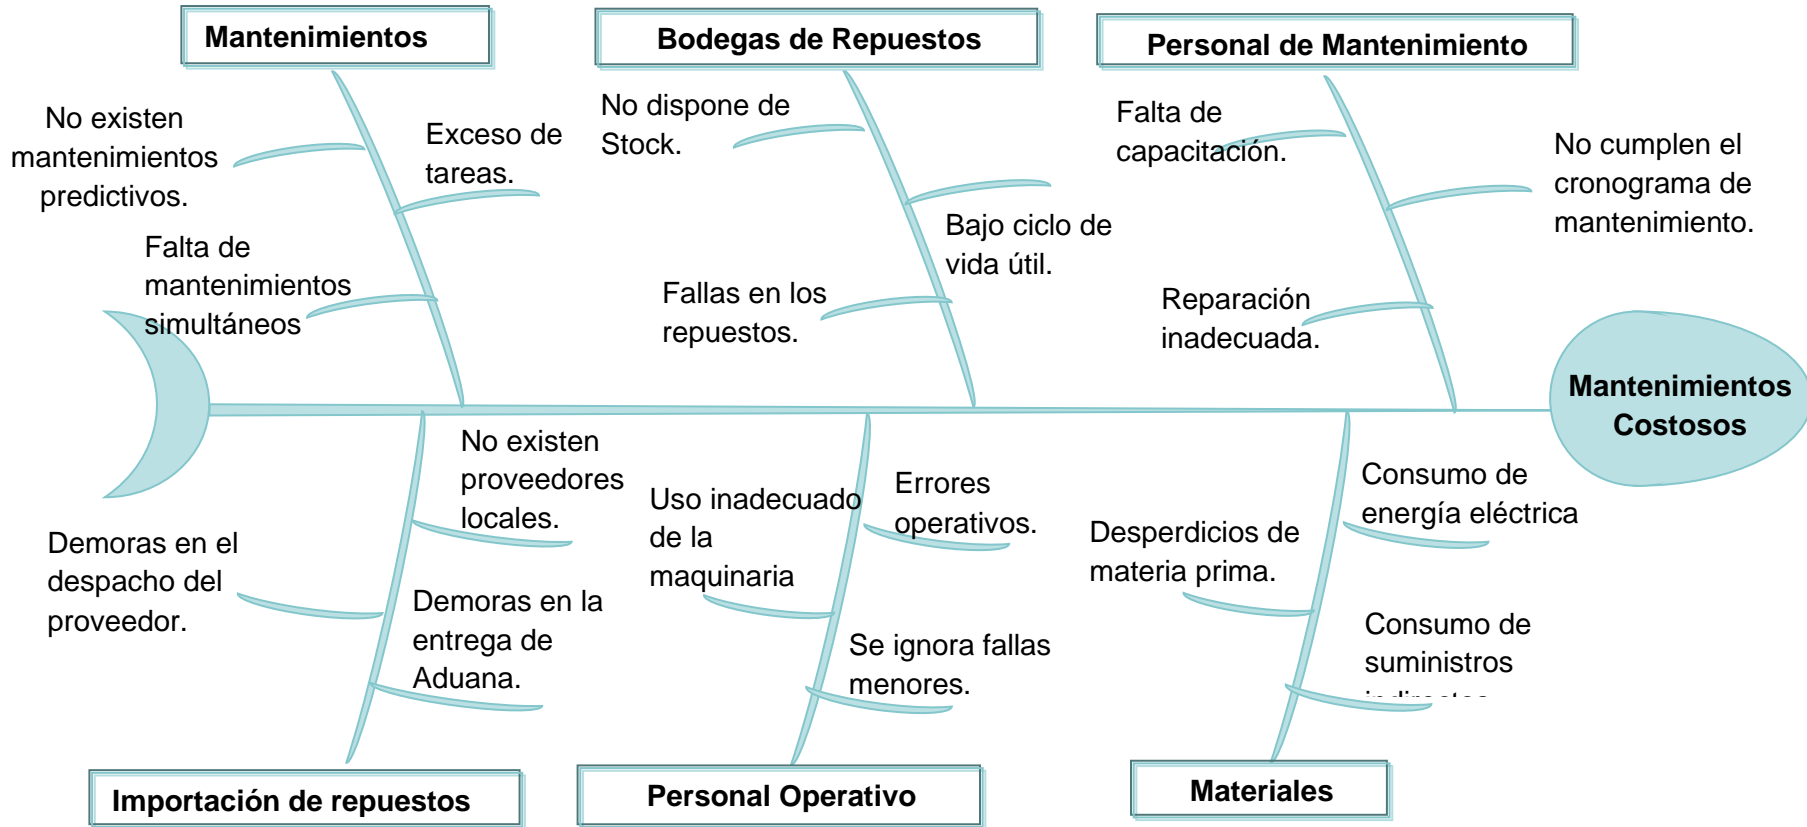
Acería de Ecuador con relación a las grandes industrias a nivel mundial está en desventaja ya que el avance tecnológico ha transformando el mundo de los negocios y dentro de ello están las industrias siderúrgicas, donde mediante el uso de la tecnología se brindan nuevos productos y servicios a menor costo, permitiendo de esta manera revolucionar a la industria con la generación de ventajas competitivas. Al no estar explotando los datos que genera la industria está perdiendo las oportunidades de generar nuevos procesos de mantenimiento en base al conocimiento y valorando que es lo que mejor le resulta a la empresa en la toma de decisiones.

Planteamiento del problema

La empresa Acería del Ecuador C.A. ADELCA al tener un alto costo del mantenimiento de la maquinaria generado por demoras en el recambio de repuestos en los mantenimientos correctivos, ocasiona que los procesos de producción se detengan y reflejen pérdidas económicas, así también se refleja un alto uso de la mano de obra para realizar los mantenimientos respectivos los cuales en algunos casos se planifican anualmente y tienen una duración de uno o dos meses, de ello también depende si las bodegas disponen de los respectivos repuestos caso contrario se debe esperar la importación del mismo, conllevando así a tener paras en la producción al no disponer de los repuestos necesarios.

Figura 1

Diagrama de espina de pescado



Nota. Presenta los efectos y causas del problema planteado.

Como se describe en la figura 1 se ha identificado varias causas por las cuales el mantenimiento de la maquinaria está ocasionando un alto costo, por una parte, existe exceso de tareas en el plan anual de mantenimiento, la omisión de errores por parte del personal operativo, el uso inadecuado de la maquinaria de acuerdo a las especificaciones técnicas que mencionan los fabricantes. Otro factor importante es la calidad de los repuestos que se está utilizando ya que alguno de ellos puede contener fallas o simplemente poseen un bajo ciclo de vida de los repuestos.

Es fundamental mantener un stock óptimo de los repuestos en bodega de acuerdo a las necesidades de la empresa, ya que no se puede esperar meses en la importación de un repuesto sensible y que sea de vital importancia para el funcionamiento de la maquinaria. Es por ello que es necesario y primordial realizar un análisis actual a los costos de mantenimientos de las maquinarias, enfocada en la inteligencia de negocios con la aplicación de la industria 4.0

Objetivos

Objetivo general

Establecer un modelo de mantenimiento predictivo y proactivo basado en industria 4.0 que permita el monitoreo oportuno de la maquinaria de producción de la empresa ADELCA C.A.

Objetivos específicos

OE1. Estudiar el proceso de mantenimiento de la maquinaria de ADELCA C.A. para analizar todas las fases de los procesos de mantenimiento y determinar donde se encuentran las causas que genera la demora en el recambio de los repuestos.

OE2. Realizar una investigación de literatura con el propósito de identificar los modelos predictivos como proactivos para el mantenimiento de la maquinaria industrial.

OE3. Establecer un modelo de mantenimiento basado en la vida útil de la maquinaria facilitándonos la programación de sustitución de partes y piezas.

OE4. Implementar el modelo de mantenimiento predictivo con la utilización de herramientas de inteligencia de negocios que permita mitigar la demora en el recambio de repuestos de la maquinaria de ADELCA C.A.

OE5. Validar el modelo de mantenimiento predictivo y proactivo en las maquinarias de ADELCA C.A. permitiéndonos identificar la disminución de los rubros pagados por la reparación de la maquinaria o alquiler de la misma.

Preguntas de investigación

Para la elaboración de la presente investigación se ha establecido las siguientes preguntas de investigación relacionados a los objetivos antes indicados:

OE1. – RQ1. ¿Cuál es la situación actual de Acería del Ecuador en base al sistema de mantenimiento de las maquinarias?

OE1. – RQ2. ¿Cuál es la situación actual de Acería del Ecuador con relación a las grandes industrias internacionales respecto a sus sistemas de mantenimiento?

OE2. – RQ1. ¿Qué modelos predictivos como proactivos existen para el mantenimiento de la maquinaria industrial?

OE2. – RQ2. ¿Cuáles son los modelos planteados para mejorar el sistema de mantenimiento de las maquinarias?

OE2. – RQ3. ¿Qué tipos de mantenimientos permiten realizar de manera eficiente el recambio de repuestos?

OE3. – RQ1. ¿Cuáles son los modelos de mantenimiento predictivo y proactivo más utilizados a nivel mundial?

OE3. – RQ2. ¿Es viable estructurar un modelo de mantenimiento basado en la reducción de costos?

OE4. – RQ1. ¿Qué dificultades existen en la implementación de la metodología predictiva de mantenimiento de maquinarias?

OE4. – RQ2. ¿Qué herramientas se puede utilizar a la par con la metodología predictiva de sistemas de mantenimientos?

OE5. – RQ1. ¿Bajo qué parámetros se tomó en consideración la validación del modelo de mantenimiento?

OE5. – RQ2. ¿El modelo propuesto generó los resultados esperados por la compañía?

Hipótesis de investigación

La aplicación de un modelo de mantenimiento predictivo y proactivo reducirá los costos de mantenimiento, como la planificación de recursos humanos, materiales y tecnológicos facilitando la programación de la sustitución de las partes y piezas de las maquinarias de producción.

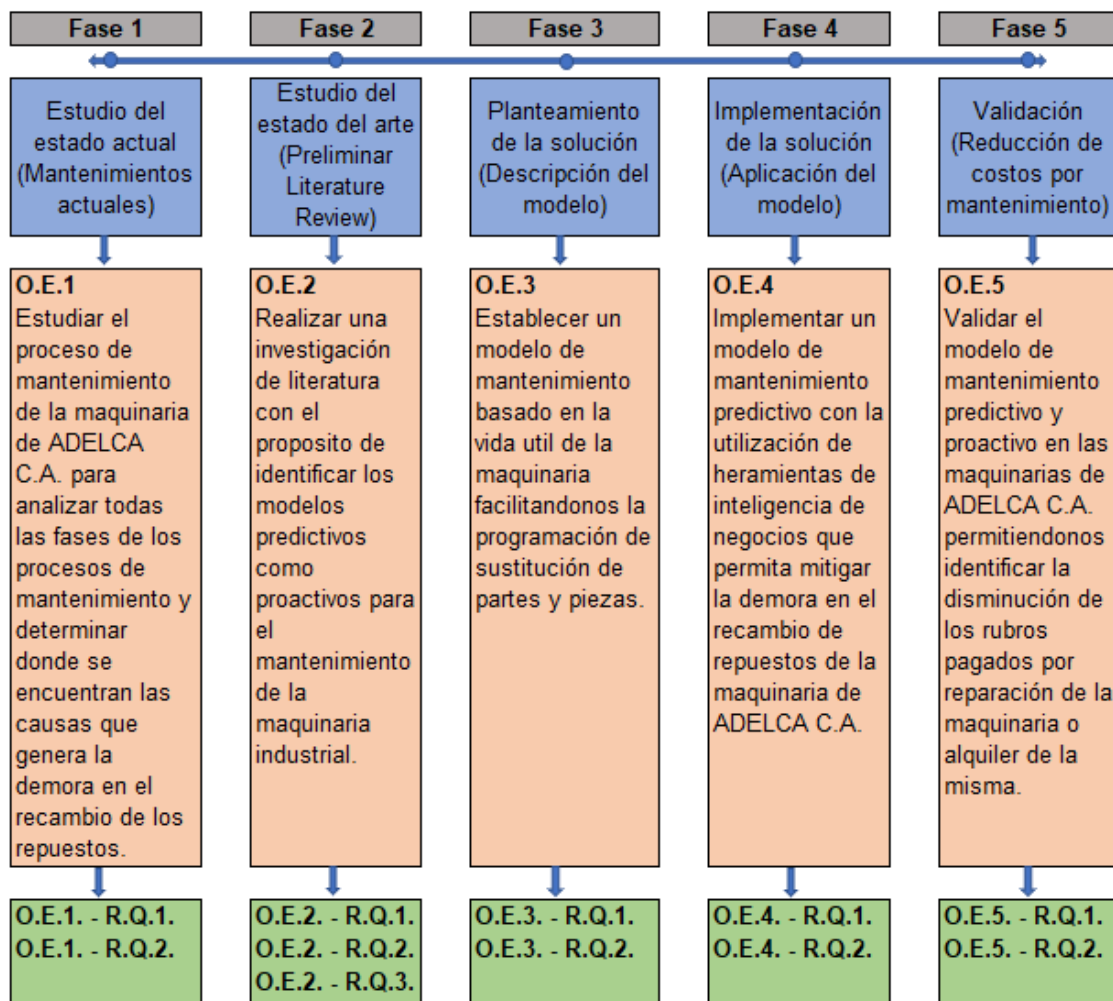
La investigación se realizará a través de una investigación exploratoria basada en la investigación de literatura, enfocándose en el análisis de datos.

Metodología

La metodología que se utilizó en el presente trabajo es una metodología ad-hoc la mismas que está compuesta de cinco fases que se muestran a continuación.

Figura 2

Metodología Ad-hoc



Nota. Descripción de la metodología presentada elaborado por el autor.

Fase N°1 Estudio del estado actual

Esta fase consiste en establecer el estado actual utilizando uno de los métodos de investigación científica. Para el caso de estudio se ha realizado el levantamiento de la información en el área de mantenimiento de la empresa.

Fase N°2 Estudio del estado del arte

En esta fase se realizó una revisión de literatura a través de la utilización de la técnica "Preview Literatura Review".

Esta técnica nos permitió identificar los siguientes:

- ✓ **Motivación para la revisión:** para lo cual se importante tener identificado el problema y plantearlo de una manera tal que se interesante su revisión.
- ✓ **Obtención de un grupo de control:** para obtener un grupo de control se debe identificar los estudios que tengan relación con el tema investigado, luego hacer una selección de documentos que serán parte del grupo de control.
- ✓ **Construcción de una cadena de búsqueda:** en función de los documentos definidos como grupo de control se identificaron cuáles son las palabras claves de cada documento y se toman los términos más representativos. Con los términos más representativos se construye las cadenas utilizando preposiciones AND Y OR.
- ✓ **Identificación de filtros:** se determinaron criterios de inclusión y exclusión como año de publicación, idioma, tema, etc.
- ✓ **Obtención de estudios primarios:** se ingresan las cadenas de búsqueda construidas en los pasos anteriores, hasta tener un resultado reducido el cual ubica los documentos que serán considerados como los resultados primarios.

Fase N°3 Planteamiento de la solución

En el desarrollo de esta fase se realizó un análisis del problema y se deduce la solución al problema planteado a través de la metodología CRIPS-DM, donde se describe cada una de las fases que componen la metodología, donde se planteó realizar un modelo predictivo implementando técnicas y algoritmos de minería de datos.

Fase N°4 Implementación de la solución

Para la implementación de la solución se ha desarrollado cada una de las fases de la metodología CRISP-DM con la información que la empresa dispone, así como el tratamiento de cada uno de los datos de mantenimientos que realiza actualmente la empresa para poder determinar cuál modelo de predicción es más eficiente y logre cumplir con los objetivos del negocio.

Fase N°5 Pruebas y evaluación

La fase pruebas y evaluación contempla los siguientes criterios que deben ser evaluados para determinar el grado al que el modelo responde a los objetivos del negocio.

- ✓ **Evaluación de los resultados:** la evaluación se centra en la precisión y la totalidad de un modelo, en este punto lo importante es analizar el porcentaje en que el modelo cumple los objetivos del negocio y detecta errores que hagan que el modelo sea deficiente y no cumplan con lo requerido.
- ✓ **Revisión del proceso:** Se procedió a realizar un análisis más pormenorizado de los mantenimientos predictivos y proactivos del negocio, con la finalidad de verificar si estos han sido eficientes y eficaces; si hay la posibilidad de realizar mejoras y determinar si existen tareas y actividades que se han pasado por alto y que permitan asegurar la calidad de los procesos de mantenimientos.

- ✓ **Decisión sobre siguientes pasos:** Después de realizar la evaluación de resultados y la verificación del proceso, se debe tomar una decisión sobre cuáles son las siguientes actividades a realizarse y que el negocio debe realizar.

Señalamiento de variables

Se estableció las siguientes variables en relación a la hipótesis planteada:

- **Variable dependiente:** Reducir costos de mantenimiento y perdidas por paras de producción en el recambio de repuestos.
- **Variable independiente:** Establecer un modelo de mantenimiento predictivo y proactivo en maquinarias industriales.

Justificación, importancia y alcance del proyecto

Al poseer un sistema de mantenimiento tradicional, o quizás un mantenimiento en base a la experiencia del técnico a cargo de la maquinaria se está expuesto a que se ocasione un sin número de inconvenientes con la maquinaria, como es, la falta de mantenimientos preventivos, la mala manipulación de la maquinaria y omisión de errores que está generando la maquinaria; el arreglo provisional para que continúe su funcionamiento por ciertas horas induce a que la empresa incurra en altos costos de mantenimiento o alquiler de las mismas, como también genera grandes pérdidas de dinero por la falta de producción.

Por lo cual se ha motivado el establecer un modelo de mantenimiento predictivo y proactivos basado en la Industria 4.0, la cual implica analizar datos históricos para la generación de conocimientos mediante la utilización de herramientas de inteligencia de negocios que permitirá reducir costos, aplicando nuevas técnicas, facilitando la planificación anual de mantenimientos en las maquinarias y logrando minimizar el tiempo en el recambio de repuestos.

Capítulo II

Estado de arte y marco teórico

Estado del arte

Para establecer un correcto estado del arte se realizó una búsqueda que forma parte de SYSTEMATIC LITERATURE REVIEW (Revisión Sistemática de Literatura) utilizando como fuentes de información la investigación de literatura y metodologías enlazados a la problemática investigada; esta búsqueda se la realizó en el repositorio académico IEEE (Institute Electrical and Electronics Engineers).

Criterios de inclusión

Los criterios de inclusión utilizadas que permitirá tener información y datos actualizados son los siguientes:

- Artículos en idioma inglés.
- Artículos que contengan modelos de mantenimientos predictivos para maquinarias.
- Artículos que contengan información en base a la Industria 4.0
- Artículos que contengan información de mantenimientos en industrias siderúrgicas.
- Artículos que contengan análisis de datos para mantenimientos predictivos.

Criterios de exclusión

Los criterios de exclusión utilizados son:

- Artículos que contengan mantenimientos predictivos en base de sensores, análisis térmicos
- Artículos que contengan mantenimientos de equipos tecnológicos y hospitalarios.

En la tabla 1 se presentan los grupos de control

Tabla 1

Grupo de control

Grupo de control	Título	Palabras claves
EC01	A Pilot for Proactive Maintenance in Industry 4.0	Industry, Analytics, Cyber Physical Systems
EC02	An Industrial Analytics Approach to Predictive Maintenance for Machinery Applications	Predictive Maintenance, Industrial Analytics
EC03	Data Analytics for Industrial Process Improvement A Vision Paper	Production, Data Analysis, Data Visualization, Tools, Automation, Data Models, Business
EC04	Concept of Predictive Maintenance of Production Systems in Accordance with Industry 4.0	Predictive Maintenance, Knowledge Discovery, Manufacturing Processes, Data Models
EC05	Predictive Maintenance 4.0 as next evolution step in industrial maintenance development	Industry 4.0, Predictive Maintenance, Industrial Maintenance
EC06	Smart Industry: Technology for the Future	Automation, Industrial Enterprise, Smart Manufacturing, Digital Technologies, Video Surveillance System, Predictive analytics, Virtual Data Center, Hybrid Clouds, Digital Dual Hardware Technologies, Smart Potential, Remote Monitoring System
EC07	Maintenance of Complex Systems – From Preventive to Predictive	Predictive Maintenance, In-Flight Entertainment and Connectivity, Condition Based Monitoring
EC08	Maintenance 4.0: Intelligent and Predictive Maintenance System Architecture	Industry 4.0, Industrial Maintenance, Predictive Maintenance, Data Analysis, Augmented Reality.
EC09	The Prediction of Remaining Useful Life (RUL) in Oil and Gas Industry using Artificial Neural Network (ANN) Algorithm	Prediction, Remaining Useful Life, RUL, Artificial Neural Network, ANN, Machine Learning, Alteryx, Power BI, Visualization
EC10	Prediction algorithms using specialized software tools for steel industry equipment	Turbo Blowers, Maintenance, Predictive Models, Machine Learning, Steel Industry
EC11	Predictive Maintenance in the 4th Industrial Revolution: Benefits, Business Opportunities and Managerial Implications	Industry 4.0, Predictive Maintenance, Smart Manufacturing, Industrial Management, Predictive Analytics.

Grupo de control	Título	Palabras claves
EC12	What Maintenance is Worth the Money? A Data-Driven Answer	Predictive Maintenance, Industrial data Analytics, Maintenance Effectiveness Estimation
EC13	A Cognitive Analytics based Approach for Machine Health Monitoring, Anomaly Detection, and Predictive Maintenance	Machine Learning, Cognitive Analytics, Anomaly Detection, Machine Health Monitoring, Predictive Maintenance.
EC14	Metodología de mantenimiento predictivo 4.0 para asegurar procesos de producción.	Predictive Maintenance, Industry 4.0, Big Data, Automation, Robotic, Lean Systems.
EC15	Sustainable service oriented equipment maintenance management of steel enterprises using a two-stage optimization approach	Equipment Maintenance, Steel Enterprises, Complex constraints, Two-Stage Optimization approach.
EC16	Data Analytics for Predictive Maintenance of Industrial Robots	Data Analytics, Predictive Maintenance, Robot manipulators
EC17	Predictive Industrial Maintenance with a Viable Systems Model and Maintenance 4.0	Maintenance 4.0, Manufacturing Execution Systems (MES), Cyber-Physical Systems, Viable Systems Model, Digital Manufacturing, Data Mining.
EC18	Machine Learning approach for Predictive Maintenance in Industry 4.0	Predictive Maintenance, Machine Learning, Industries, Current Measurement, Time Measurement, Forecasting
EC19	On the Use of Predictive Models for Improving the Quality of Industrial Maintenance: an Analytical Literature Review of Maintenance Strategies	Standards, Data Models, Predictive Models, Preventive Maintenance, Predictive Maintenance, Data Integration
EC20	Predictive Maintenance for Infrastructure Asset Management	Maintenance Engineering, Predictive Models, Industries, Monitoring, Machine Learning, Analytical Models, Data Models
EC21	Predictive Situation Awareness Model for Smart Manufacturing	Data Fusion, Situation Awareness, Predictive Situation Awareness, Predictive Manufacturing Situation Awareness, Industry 4.0, Smart Manufacturing, Multi-Entity Bayesian Networks.

Nota. Esta tabla muestra los artículos que están como grupo de control.

Cadena de búsqueda

Para obtener la cadena de búsqueda se realizó un recuento de las palabras repetidas de las palabras claves en cada uno de los grupos de estudio. Dando como resultado el detalle que se refleja en la tabla N°2.

Palabra clave	EC 01	EC 02	EC 03	EC 04	EC 05	EC 06	EC 07	EC 08	EC 09	EC 10	EC 11	EC 12	EC 13	EC 14	EC 15	EC 16	EC 17	EC 18	EC 19	EC 20	EC 21	TO TAL	
Industrial Analytics		X										X											2
Data Models			X	X																X	X		4
Steel Enterprises															X								1
Steel Industry										X													1

Nota. Esta tabla muestra las palabras claves que más se repetían en el grupo.

Con los términos identificados anteriormente se construyó diferentes cadenas de búsqueda para utilizarse en la base datos de IEEE, donde se consideran el número de artículos y de los cuales cuantos estudios de control están en esas cadenas.

Tabla 3*Resultados de la cadena de búsqueda*

N°	Cadena	Número de artículos	Estudios de control
CD01	("All Metadata":predictive maintenance) AND ("All Metadata":Industry 4.0) AND ("All Metadata":predictive models) OR ("All Metadata":Predictive Models) AND ("All Metadata":Steel Industry)	480	EC03-EC010
CD02	("All Metadata":predictive maintenance) AND ("All Metadata":Industry 4.0) AND ("All Metadata":predictive models) OR ("All Metadata":Predictive Models) AND ("All Metadata":Steel Industry) AND ("All Metadata":Industrial Analytics) AND ("All Metadata":Steel Enterprises)	146	EC03-EC04-EC16-EC021
CD03	("All Metadata":Industry 4.0) AND ("All Metadata":predictive maintenance) OR ("All Metadata":Predictive Models) AND ("All Metadata":Steel Industry) AND ("All Metadata":Industrial Analytics)	276	EC01-EC03-EC04-EC05-EC08-EC10-EC16-EC18-EC21
CD04	("All Metadata":Industry 4.0) AND ("All Metadata":predictive maintenance) AND ("All Metadata":Predictive Models) OR ("All Metadata":Predictive Analytics) AND ("All Metadata":Industrial Analytics) OR ("All Metadata":Prediction) AND ("All Metadata":Data Analytics) AND ("All Metadata":Steel Industry)	508	EC01-EC02-EC03-EC04-EC06-EC08-EC09-EC10-EC12-EC13-EC16-EC21

Nota. Esta tabla muestra los resultados obtenidos de las cadenas de búsqueda.

Con lo cual podemos definir que la cadena CD04 es la más adecuada con números de artículos manejables al tema de estudio y con más estudios partes del grupo de control.

Una vez realizada la búsqueda en IEEE con la cadena de búsqueda se obtuvo 508 resultados de los cuales tenemos 12 artículos del grupo de control.

Prediction algorithms using specialized software tools for steel industry equipment

El artículo presenta un modelo de mantenimiento predictivo aplicable en la industria siderúrgica utilizando algoritmos de análisis de software que describen modelos de pronóstico, enfoque estadístico para equipos industriales utilizando la herramienta de Power BI desarrollados en base de la formulación DAX que ofrece un almacén para la limpieza de datos, genera formulas en expresiones de análisis de datos y paneles interactivos. El modelo tiene la función de caracterizar la degradación de los equipos turbosopladores. (E.Raducan, 2020)

An industrial analytics approach to predictive maintenance for machinery applications

El documento describe como se pueden utilizar el análisis de los datos para realizar soluciones de mantenimiento predictivo, utilizando datos ya existentes de las instalaciones de producción y reduciendo el esfuerzo de realización. Permitiendo garantizar la disponibilidad, aumentar la productividad y al mismo tiempo reducir los costos de producción.

Las estrategias utilizadas comprenden en abordar el análisis fuera de línea para el mantenimiento predictivo de arriba hacia abajo (conocimiento de cómo funciona la maquina) o de abajo hacia arriba (conocimiento en base a datos disponibles de la maquina)

Realizan estudios a dos casos industriales el primero a una máquina de moldeo por inyección donde mediante el uso de algoritmos de aprendizaje automático derivan el comportamiento normal de la máquina, posterior a ello con el uso de funciones de análisis de tendencias lograron determinar la predicción de fallas conocidas lo que llevo a la reducción del tiempo de inactividad. El segundo caso es el sistema de transporte para la producción de periódicos donde se plateo dos objetivos, el primer objetivo reducir la inactividad de la máquina y el segundo objetivo reducir los costos de mantenimiento comparando datos que generaron una cadena de transportador dañado con una cadena de transportador nueva combinando datos para desarrollar un modelo para predecir estados futuros. (Carlos Paiz Gatica, 2016)

Metodología de mantenimiento predictivo 4.0 que asegura procesos de producción.

“Este artículo establece un diseño metodológico de un mantenimiento predictivo de industria 4.0; el cual busca combinar distintas técnicas y herramientas de producción y operaciones utilizando mecanismos tecnológicos con un enfoque inteligente. En la cual indica que el análisis predictivo se enfoca en un análisis matemático avanzado, con soporte de la estadística, minería de datos, análisis de bigdata, etc. La predicción consiste en pronosticar eventos que ocurrirán en el futuro.” (Miguel A. Luna Pérez, 2019)

Identifican cuatro tipos de familias de algoritmos:

Algoritmos de clasificación y predicción: Quest, Chaid, C.5.0, lista de decisión, regresión lineal.

Algoritmos de asociación: a priori, carma, reglas de asociación.

Algoritmos de segmentación: K-medias, Kohonen, TwoStep.

Algoritmos de automodelado: Autoclasificador, Auto numérico, Auto clúster.

On the use of predictive models for improving the quality of industrial maintenance: an analytical literature review of maintenance strategies

Este análisis busca revisar proyectos de mantenimientos inteligentes ya existentes, determinando los estudios más eficientes que puedan implicar un desafío para su aplicación, pero así también identificar los beneficios de su uso en la técnica de análisis de datos. Así también se realizó la búsqueda de literatura de distintos modelos de predicción:

Modelos basados en el conocimiento: Rule-based fuzzy logic + condition-based fusion diagnosis

Modelos basados en los datos: ADMM (altering direction method of multipliers) algorithm + Decision Fusion, RNN-based health indicator for RUL prediction, kNN + discrete Bayesian filter, Statistics, Deep Learning, PCA + kNN

Modelos Hybridos: k-means, association rules (GSP, Apriori), Neural Networks, Random forest, Decision Tree, kNN, Simulation + multi-sensor fusion Multi sensor

“Por último, argumenta que cualquier instalación industrial mejora la calidad del mantenimiento cuando la técnicas y tecnologías aplicadas en datos son bien utilizadas.” (Merkt, 2019)

The prediction of remaining useful life (RUL) in oil and gas industry using artificial neural network (ANN) algorithm

El artículo desarrolla un análisis predictivo modelo de flujo de trabajo de la integración entre las herramientas de Alteryx para hacer predicción de RUL utilizando un conjunto de datos multivariados del mundo real de la industria del gas adicional utilizando Microsoft Power BI para visualizar el resultado de la predicción para una mejor comprensión.

El algoritmo que utilizaron en el artículo es Red Neural Artificial (ANN) debido a su capacidad de aprender de un gran volumen de datos y alta exactitud en la predicción. (Muhammad Farhan, 2019)

Predictive maintenance for infrastructure asset management

El documento describe que una de las preocupaciones claves para la industria que es reducir el tiempo de inactividad y los costos que incurren en el mantenimiento, el avance de la tecnología enfocados en datos introdujo el paradigma con el nombre de mantenimiento predictivo que busca encontrar el momento óptimo para el mantenimiento de un activo. Utilizando datos históricos, activos registrados, registros de mantenimientos y operaciones a detalle y la aplicación de técnicas como es algoritmos de aprendizajes automáticos basados en árboles, regresión lineal, vector de soporte y redes neuronales para poder desarrollar modelos predictivos precisos. (Zaharah Allah Bukhsh, 2020)

What maintenance is worth the money? A data-driven answer

El documento explica de como en las operaciones industriales el mantenimiento representa una gran parte de los costos operativos entre un 15% a 60% de los costos totales de producción, los gerentes de mantenimiento tiene poca visibilidad en determinar si el gasto del mantenimiento es dinero bien gastado o no, tampoco tienen métodos cuantitativos para responder preguntas si hace o no la diferencia de realizar el mantenimiento preventivo cada seis meses de la maquinaria o si una acción en particular mejora o no el rendimiento de la compañía.

El documento presenta un algoritmo para eliminar el efecto de carga y estacionalidad en los indicadores de desempeño de equipo basado en modelos aprendidos de datos históricos y luego métodos de inferencia estadística para estimar la efectividad de los mantenimientos.

(Qiyao Wang, 2018)

Conclusiones de los trabajos relacionados

Una vez concluida con la revisión de literatura determinamos que el mantenimiento en las industrias es un factor muy importante y a la vez sensible que la mayoría de las industrias no han considerado los datos para poder tomar decisiones efectivas que permitan disminuir el costo de mantenimiento con herramientas de inteligencia de negocios.

En la actualidad los costos de mantenimiento representan entre el 15% al 60% del costo total de producción ocasionando la disminución de la rentabilidad que podría tener una empresa, esto se debe a que las industrias siguen realizando sus mantenimientos preventivos y correctivos y no explotan la gran cantidad de datos que genera la industria.

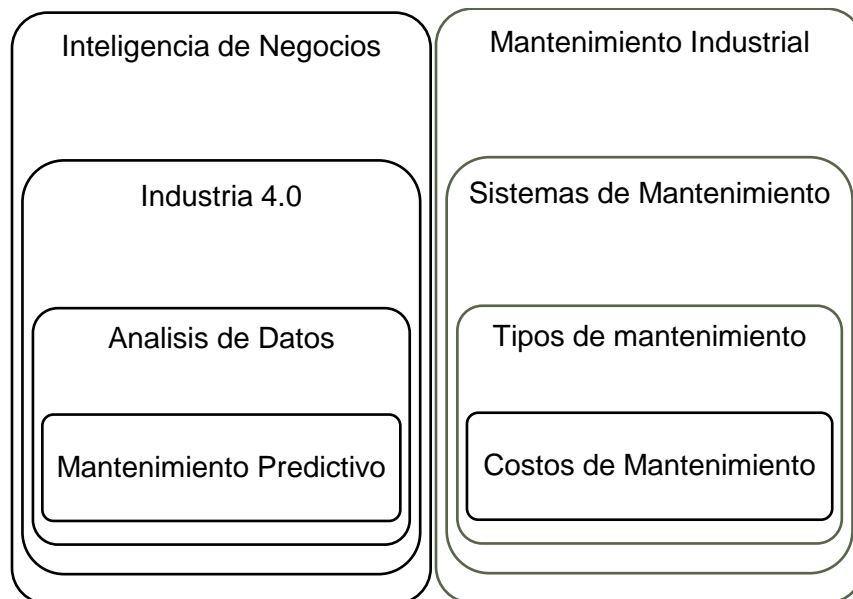
Al contar con información histórica se puede aplicar un sin número de algoritmos que permitan realizar predicciones para un mantenimiento predictivo los más posible exacto y a su vez utilizando la herramienta de Microsoft Power BI mediante código DAX, complementando con la visualización de la información para que sea más entendible los datos analizados.

Marco teórico

El fundamento teórico se basa en la hipótesis considerando las variables dependientes e independientes, donde mostramos los temas de acuerdo a la siguiente jerarquía.

Figura 3

Variables dependientes e independientes



Nota. Este grafico representa las variables consideradas en el presente trabajo.

Inteligencia de negocios

“La inteligencia de Negocios o BI que en ingles significa (Business Intelligence), es un concepto que incluye las aplicaciones, la infraestructura y las herramientas, y las mejores prácticas que permiten el acceso y el análisis de la información para mejorar y optimizar las decisiones y el rendimiento.” (Gartner, 2018).

Estas herramientas de la mano de estrategias sirven para transformar información en conocimiento de negocio mediante el análisis de datos (Grupo IGN, 2016), mediante un proceso de búsqueda, recuperación, análisis y visualización.

Estos datos son información que puede ser generada por su propia actividad es decir interna o externa que la empresa dispone ya sea del mercado, de sus competidores, clientes, proveedores, stakeholders o incluso de sus empleados.

Es así que podría mencionarse que son recursos netamente administrativos utilizado la mayor parte en el ámbito empresarial, con la evolución tecnológica es necesario que sean aplicadas en organizaciones actuales y modernas. Esto busca la mayor parte que estas organizaciones aprovechen al máximo la información que posean a nivel interno y externo; tanto de sus clientes como la de sus proveedores y hasta de sus competidores inclusive, todo con el fin de lograr ventajas competitivas en un mercado hostil y demasiado dinámico. (Helmer Muñoz, 2016)

Existen algunos elementos que están relacionados con la inteligencia de negocios, por lo tanto, sería los elementos importantes en la continuidad de lo que más adelante se desarrollará en el proceso de negocios inteligentes.

Figura 4

Conocimiento, información y datos



Nota. Este grafico representa los factores claves de la inteligencia de negocios. Tomado de (Helmer Muñoz, 2016)

Como se describe en la figura N°4 los elementos son: el conocimiento, la información y los datos; estos últimos después de un análisis eficiente se convierte en información y esto al final en conocimiento. Con la finalidad de que si se desarrollan de mejor manera conlleve a la analítica.

Los datos son información primaria que carece de análisis y por tanto no contribuyen por si solos en la toma de decisiones, también se puede ver como un conjunto simples valores, que no aportan a ningún proceso.

Sin embargo, la información conlleva distintos grupos de datos que en su conjunto se pueden procesar con la finalidad de obtener un significado que sean de utilidad para la toma de decisiones.

El conocimiento es simplemente el conjunto de información ya procesada que mezcla valores, información, experiencias, etc. que sirven para tomar una acción posterior al conocimiento ya establecido.

La industria 4.0.

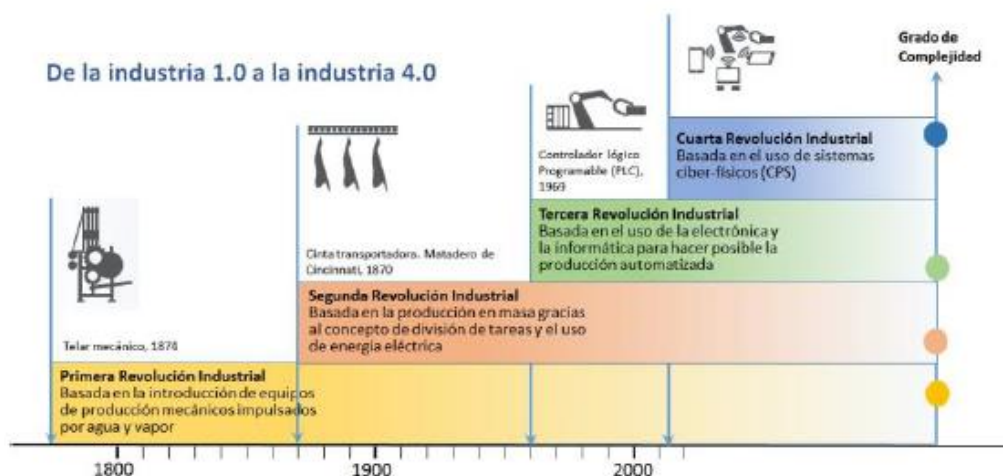
Al hablar de la industria 4.0 se enfoca en un modelo de organización con la finalidad de controlar la cadena de valor, verificando el ciclo de vida del producto durante toda la etapa del proceso de fabricación apoyándose las tecnologías.(Román, 2021)

La industria 4.0 es utilizada en Europa específicamente en Alemania y la cual en los últimos años está globalizándose su utilización con respecto a los resultados obtenidos. A nivel mundial también es conocida como Industria Inteligente. Al hablar de industria 4.0. es un método que ha revolucionado la industria debido a que con el uso de la tecnología permite manejar las industria de una forma inteligente y digital donde se aprovecha cada dato que generan en sus procesos de producción.

A inicios de la revolución industrial en los siglos XVIII y XIX mecanizaron los procesos de producción existiendo un cambio al sistema artesanal.

Figura 5

Evolución de la industria



Nota. El siguiente gráfico muestra la evolución de la industria. Tomado de (Román, 2021)

La segunda revolución industrial apareció con la producción en serie facilitando la producción en masa y el uso de la energía eléctrica eliminando la producción por agua y vapor., donde se automatizo los procesos industriales de fabricación eliminando tareas que tomen mucho tiempo en la producción. Esto ayudo a que las empresas industriales disminuyan costos en la producción y su economía sea más saludable. (Román, 2021)

La tercera revolución industrial se da con el uso de la electrónica y la informática permitiendo que las industrias realicen su producción de forma automatizada.

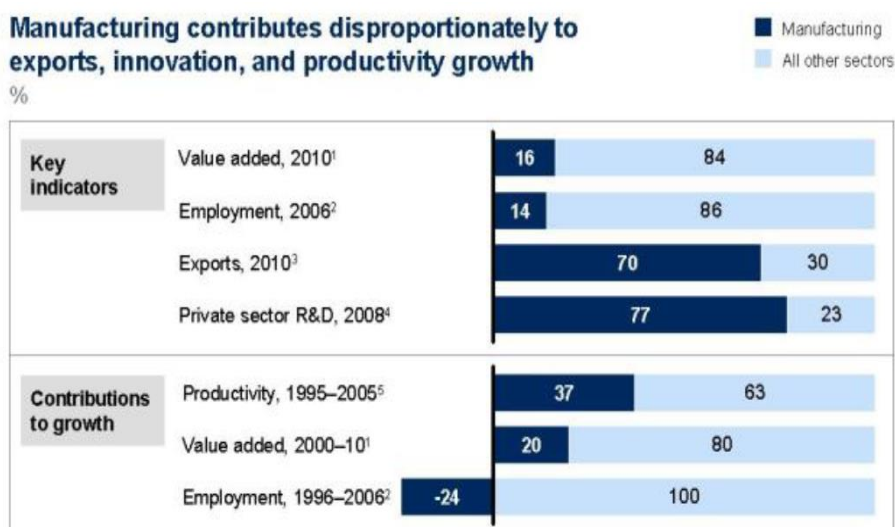
La cuarta revolución industrial se basa en la digitalización como es el internet de las cosas, la nube, los sistemas ciber-físicos, robótica pero la parte mas fundamental es el tratamiento de información que las industrias poseen para poder generar ventaja competitiva y analizar sus cuellos de botella permitiéndoles ser más eficientes, eficaces en el proceso de producción.

La globalización de la economía ha ejercido una gran presión sobre la industria europea y su competitividad y el resultado ha sido el traslado en las últimas décadas la producción a países asiáticos.

El avance de la economía a presionado a que la industria europea sea más competitiva permitiéndose recuperar la contribución del PIB, lo que ha permitido que crezca exponencialmente el impulso de la innovación tecnológica, tenemos así también un impacto en el continente asiático.

Figura 6

Desarrollo del sector industrial



Nota. Describe la contribución de la industria en el PIB. Tomado de (Román, 2021)

“Soluciones inteligentes Los productos inteligentes se caracterizan por disponer de electrónica, software embebido y conectividad lo que, en conjunto, le dotan de nuevas características, capacidades y funciones.

Los sistemas ciber-físicos, el internet de las cosas (IOT) permite mejorar el rendimiento de las máquinas debido al uso de diferentes tecnologías, que ayuda a la recolección de

información como son los sensores, análisis de aceites, datos de calor entre otros. El humano analiza esa información generando patrones para poder tener una mejor intervención de la maquinaria tanto en su producción como su mantenimiento. (Román, 2021)

Figura 7

Características del producto inteligente



Nota. El gráfico muestra las características de un producto inteligente. Tomado de (Román, 2021)

Las características del producto inteligente son las siguientes:

- Conectado: uso de dispositivos que permita la interacción de datos.
- Adaptable: productos equipados con tecnología que permite la adaptación automática del producto.

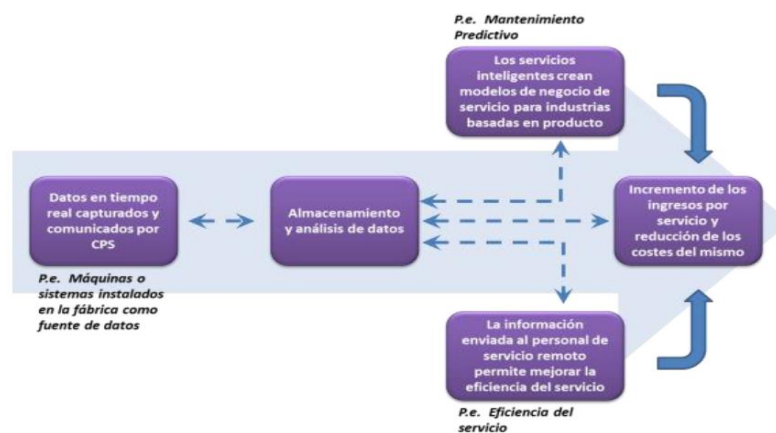
- Inteligente: poseen un proceso autónomo que le permite tomar decisiones y aprender de forma automática.

Consiente: proporcionan información sobre las condiciones del producto y del entorno.
(Román, 2021)

“Los servicios inteligentes permiten ofrecer servicios innovadores y establecer nuevos modelos de negocio, por ejemplo, modelos de pago por uso o servicio. La comunicación con el fabricante, la recogida de grandes cantidades de datos y su análisis es la base para generar nuevas ofertas de servicios y optimizar los modelos existentes. Los modelos analíticos aplicados a esos datos (Big Data) pueden automatizar la toma de decisiones”. (Román, 2021)

Figura 8

Características del servicio inteligente



Nota. El siguiente gráfico describe lo que comprende el servicio inteligente. Tomado de
(Román, 2021)

Un ejemplo, predecir el momento en que un sistema requerirá mantenimiento.

Los productores de maquinarias podrán establecer patrones en base a la data histórica del mantenimiento de las maquinarias permitiendo realizar la mejora en sus producciones.

Análisis de datos

“Con un número creciente de productos (CPS) y sistemas inteligentes (CPPS) en las fábricas y el mercado, la cantidad de datos de que dispondrán los fabricantes se multiplicará. Su análisis permitirá identificar patrones e interdependencias, analizar los procesos y descubrir ineficiencias e incluso predecir eventos futuros. Con ello se abrirán nuevas oportunidades, no solo de mejorar de la eficiencia, sino del descubrimiento de servicios para el cliente al que se conocerá mucho mejor”. (Román, 2021)

Big data

“La gran diferencia entre los casos de uso de Big Data y los de aplicaciones de Data Warehouse o Business Intelligence (BI) son la naturaleza y la velocidad de los datos que se gestionan. Normalmente, las aplicaciones Big Data son miles de veces más grandes y requieren una respuesta más rápida que las aplicaciones de BI”. (PÉREZ)

“IDC Government Insight define Big Data como una nueva generación de tecnologías y arquitecturas diseñadas para extraer valor económico de grandes volúmenes de una amplia variedad de datos, mediante la capacidad de captura, descubrimiento y/o análisis a gran velocidad. Esta definición abarca hardware, software y servicios de integración, organización, gestión, análisis y presentación de datos que se caracteriza con las cuatro Vs: Volumen, Variedad, Velocidad y Valor”. (PÉREZ)

Según IBM las soluciones Big Data se distinguen de las soluciones TIC tradicionales considerando cuatro dimensiones:

- **Volumen:** procesar grandes cantidades de datos.
- **Velocidad:** procesar información a grandes velocidades
- **Variedad:** se debe procesar diferentes tipos de datos estructurados como no estructurados.

- **Veracidad:** debe haber a velocidad la validación de datos.

Se debe procesar datos que permitan tener una analítica avanzada de un gran flujo de datos.

- **Variabilidad:** disponer una buena elasticidad en base a la variabilidad de los flujos de datos que pueden ser predecibles o completamente aleatorios.

- **Volumen:** permite el tratamiento de grandes cantidades de datos para obtener información para toma de decisiones.

Maquinaria industrial

“Esta división comprende la fabricación de maquinaria y equipo que actúan de manera independiente sobre los materiales ya sea mecánica o térmicamente, o que realizan operaciones sobre los materiales (como el manejo, el rociado, el pesado o el embalado), incluidos sus componentes mecánicos que producen y aplican fuerza, y cualquier parte primaria fabricada especialmente. Se incluye la fabricación de aparatos fijos y móviles o manuales, destinados a ser utilizados en actividades industriales, de construcción y de ingeniería civil, en la agricultura o en el hogar. Se incluye también la fabricación de equipo especial para el transporte de pasajeros o de carga en zonas delimitadas. Se establece una distinción entre la fabricación de maquinaria de uso especial, es decir, maquinaria de uso exclusivo en una industria o en un pequeño grupo de industrias de la CIIU, y la de maquinaria de uso general, es decir, de maquinaria que se utiliza para una amplia gama de industrias de la CIIU. Se incluye también la fabricación de otros tipos de maquinaria de uso especial no clasificados en otra parte, se utilicen o no en un proceso de manufactura, como equipo para atracciones de feria, equipo automático para boleras, etcétera. No se incluye la fabricación de productos de metal de uso general, aparatos de control conexos, equipo informático, equipo de

medición y de prueba, aparatos de distribución y control de la energía eléctrica ni de vehículos automotores de uso general”. (Universidad de Buenos Aires)

Sistemas de mantenimiento

“Define al mantenimiento como: toda una serie de acciones que deben realizar las personas encargadas de este departamento o área, con la finalidad de que los equipos, maquinas, componentes e instalaciones involucrados dentro de un proceso industrial estén en las condiciones requeridas de funcionamiento para lo cual fue diseñado, construido, instalado y puesto en operación. Esta serie de actividades incluye toda una combinación de conocimiento, experiencia, habilidad y trabajo en equipo, junto con las otras dependencias de la organización para que exista una buena labor administrativa y operativa, cumpliendo, así como los indicadores de desempeño o de gestión que cada organización aplica y para que sus metas de alcancen”. (Pérez Rondón, 2021)

Tipos de mantenimiento

Mantenimiento predictivo: “El mantenimiento predictivo se puede considerar como una técnica para presagiar el punto futuro de falla, anomalía, rotura o avería de un componente de una máquina, de tal forma que dicho componente pueda reemplazarse, con base en un plan justo antes de que falle. Así, el tiempo muerto del equipo se disminuye y el tiempo de vida del componente se prolonga”. (Pérez Rondón, 2021)

También hay otras técnicas predictivas no tan sofisticadas como realizar inspecciones visuales y lecturas de indicadores. El mantenimiento predictivo se basa en analizar la data histórica y establecer patrones que puedan ser comparados con las variables de su vida útil.

Mantenimiento preventivo: “se fundamenta en una serie de labores y actividades planificadas que se llevan a cabo dentro de periodos definidos, se diseña con el objetivo de garantizar que los activos de las compañías cumplan con las funciones requeridas dentro del

entorno de operaciones para optimizar la eficiencia de los procesos; para prevenir y adelantarse a las fallas de los elementos, componentes, máquinas o equipos; como también hace referencia a diferentes acciones, como cambios o reemplazos, adaptaciones, restauraciones, inspecciones, evaluaciones, etc., realizadas en periodos de tiempo por calendario o uso de estos (tiempos dirigidos)". (Pérez Rondón, 2021)

Mantenimiento correctivo: "se le denomina también mantenimiento reactivo, que, a nivel industrial en nuestro país, Latinoamérica y muchos países subdesarrollados es utilizado en un alto porcentaje. Este mantenimiento correctivo se aplica cuando la máquina deja de operar, porque se presenta la falla o avería y su objetivo es poner en marcha su funcionamiento, afectando lo menos posible la productividad; generalmente se repara o se reemplaza el componente del equipo o de la máquina, haciéndolo en el menor tiempo posible". (Pérez Rondón, 2021)

Tipos de mantenimientos correctivos:

El mantenimiento correctivo no programado: se da cuando aparece la falla en la maquinaria, generando la respectiva parada para realizar el mantenimiento o cambio del repuesto.

El mantenimiento correctivo programado o planificado: se realiza cuando se detecta que algún componente de una máquina esta por fallar por lo que se planifica el mantenimiento para solucionar la falla de la maquinaria.

Costos por mantenimiento

"En la manufactura de las empresas de alto nivel existen una firme convicción, afirmando que sus mayores activos son sus máquinas, equipos y procesos, en conjunto con el personal que lo opera y mantiene. Los costos de mantenimiento pueden componerse de la

suma de todos los gastos que se requiere para su aplicación y su desempeño, durante un periodo de tiempo”. (Serrano, s.f.)

Costos directos.

Son costos que se generan con los trabajos directos de mantenimiento de maquinarias como son:

La mano de obra en el mantenimiento de la maquinaria.

El consumo de repuestos, suministros y otros insumos.

Gastos adicionales: el consumo eléctrico, administración entre otros.

Costos indirectos.

Son costos que se generan en las fallas de las maquinarias que pueden ser las siguientes:

Costos por incumplimiento de contratos en despacho de productos.

Horas extras para cumplir con la planificación de producción

Paras de la producción por fallas de las maquinarias.

Modelos de predicción

Los modelos de predicción en los cuales nos enfocamos para el desarrollo del presente trabajo es bajo el aprendizaje supervisado, donde se tomó datos etiquetados que permita entrenar a los algoritmos permitiendo obtener datos con precisión.

Modelo Deep Learning

“Deep Learning se basa en una red neuronal artificial de alimentación hacia adelante de múltiples capas que se entrena con un descenso de gradiente estocástico utilizando propagación hacia atrás. La red puede contener una gran cantidad de capas ocultas que

consisten en Neuronas con funciones de activación tanh, rectifier, y maxout. Las funciones avanzadas, como la tasa de aprendizaje adaptable, el recocido de tasas, el entrenamiento de impulso, el abandono y la regularización permite una alta precisión predictiva. Cada nodo de cómputo entrena una copia de los parámetros del modelo global en sus datos locales con subprocesos múltiples y contribuye periódicamente al modelo global a través del promedio del modelo en la red". (Rapidminer, Rapidminer Documentation, s.f.)

Deep Learning enseña a las computadoras a hacer algo que les resulta natural a los humanos: aprender con el ejemplo. El aprendizaje profundo es un subconjunto del aprendizaje automático, que se diferencia por la forma e que estructura los algoritmos en capas de nodos de toma de decisiones interconectados para modelar datos más complejos. Estas capas crean una red neuronal artificial que pueden tomar decisiones inteligentes por sí misma, como analizar imágenes, y textos en lenguaje natural, permite que los vehículos autónomos detecten señales de alto e identificar patrones que indiquen ciberataques antes de que ocurran. (Rapidminer, Rapidminer Glossary, s.f.)

Con el Deep Learning la computadora recibe una combinación de datos correctamente etiquetados y sin etiquetar para buscar patrones por su cuenta. Los datos etiquetados brindan orientación, pero los programadores no necesitan supervisar el modelo. Con el tiempo los algoritmos de aprendizaje profundo encontraran patrones o asociaciones que no pueden ser evidentes para los científicos de datos humanos y ayudarán a que los resultados sean aún más precisos. (Rapidminer, Rapidminer Glossary, s.f.)

Modelo Decision Tree

"Decision Tree es una colección similar a un árbol de nodos destinados a crear una decisión sobre la afiliación de valores a una clase o una estimación de un valor objetivo numérico. Cada nodo representa una regla de división para un atributo específico. Para la clasificación esta regla separa valores pertenecientes a diferentes clases, para la regresión los

separa con el fin de reducir el error de manera óptima para el criterio del parámetro seleccionado. La construcción de nuevos nodos se repite hasta que se cumplan los criterios de parada. Se determinan una predicción para el atributo de la etiqueta de clase en función de la mayoría de ejemplos que llegaron a esta hoja durante la generación, mientras que se obtiene una estimación de un valor numérico promediando los valores de una hoja”. (Rapidminer Documentation, s.f.)

Modelo Naive Bayes

Naive Bayes es un clasificador de alto sesgo y baja varianza que puede construir un buen modelo incluso con un pequeño conjunto de datos. Es simple de usar y computacionalmente económico. Los casos de usos típicos involucran la categorización de texto, incluida la detención de spam, el análisis de sentimientos y los sistemas de recomendación. (Rapidminer Documentation, s.f.)

La suposición fundamental de Naive Bayes es que, dado el valor de la etiqueta (clase), el valor de cualquier atributo es independiente del valor de cualquier otro atributo. Estrictamente hablando, esta suposición rara vez es cierta, pero la experiencia muestra que el clasificador Naive Bayes a menudo funciona bien. La suposición de independencia simplifica enormemente los cálculos necesarios para construir el modelo de probabilidad Naive Bayes.

Para complementar el modelo de probabilidad, es necesario hacer algunas suposiciones sobre las distribuciones de probabilidad condicional para los atributos individuales dada la clase. Utiliza densidades de probabilidad gaussianas para modelar los datos de atributo. (Rapidminer Documentation, s.f.)

Modelo Random Forest

“Random Forest es un conjunto de árboles aleatorios, especificado por el parámetro número de árboles. Cada nodo de un árbol representa una regla de división para un atributo

especifico. Solo un subconjunto de atributos, especificando con el criterio de relación del subconjunto, se considera para la selección de la regla de división. Esta regla separa los valores de forma óptima para el criterio del parámetro seleccionado. Para clasificación la regla es separar valores pertinentes a diferentes clases, mientras que para regresión los separa para reducir el error que comete la estimación. La construcción de nuevos nodos se repite hasta que se cumple los criterios de parada. Después de la generación, el modelo de bosque aleatorio se puede aplicar a nuevos ejemplos. Cada árbol aleatorio genera una predicción siguiendo las ramas del árbol de acuerdo con las reglas de división. Las predicciones de clase se basan en la mayoría de ejemplos, mientras que las estimaciones se obtienen a través del promedio de los valores". (Rapidminer Documentation, s.f.)

Modelo K-NN

K-NN es un modelo de k-vecino más cercano, que se utiliza para la clasificación o regresión. El algoritmo k-vecino más cercano se basa en comparar un ejemplo desconocido con los k-ejemplos de entrenamiento que son los vecinos más cercanos del ejemplo desconocido. El primer paso de la aplicación del algoritmo k-vecino más cercano es un nuevo ejemplo es encontrar los k ejemplos de entrenamiento más cercanos. La "cercanía" se define en términos de una distancia en el espacio n-dimensional, definido por los n atributos en el conjunto de ejemplos de entrenamiento.

Capítulo III

Modelo de mantenimiento predictivo y proactivo


"La metodología que servirá de guía para los procesos y actividades que se desarrollará en el presente trabajo es la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) (Proceso Estándar Inter-Industrias para Minería de Datos), el modelo es flexible y se puede personalizar fácilmente". (IBM CORPORACIÓN, 2021). La metodología que se utiliza

para la explotación de minería de datos dando soluciones analíticas para minería de datos y análisis predictivo.

La metodología propuesta consta de 6 fases como se muestra en la figura 7:

Figura 9

Metodología CRISP-DM



Nota. El siguiente gráfico describe la metodología CRIPS-DM. Tomado de (IBM CORPORACIÓN, 2021).

Este modelo consta de seis fases: Fase 1 Comprensión del Negocio, Fase 2 Comprensión de datos, Fase 3 Preparación de los datos, Fase 4 Modelado, Fase 5 Evaluación y Fase 6 Implementación.

Fase 1: Comprensión del negocio

En esta fase se basa en entender los objetivos del proyecto, sus requerimientos desde el punto de vista del negocio para convertir este conocimiento en un proceso de minería de datos para cumplir con los objetivos.

Se determina los objetivos del negocio y se evalúa su situación como es: conocer los riesgos, contingencias, requerimientos, así como determinar los objetivos de la minería de datos.

Las actividades que se realizan en la comprensión del negocio son las siguientes:

1. Determinar los objetivos del negocio: se trata de obtener la mayor información posible sobre los objetivos del negocio para la minería de datos. Recopilando información de antecedentes sobre la situación actual del negocio, los recursos disponibles, problemas y objetivos.
2. Evaluación de la situación: en esta actividad se evalúa los tipos de datos disponibles, los riesgos y las contingencias que se debe dar a cada riesgo. Así como también analizar los recursos de hardware, las fuentes de datos y el personal.
Un análisis de costo/beneficio que se obtendrá con la mejor comprensión de los datos.
3. Determinar objetivos de la minería de datos: se define la solución técnica al problema del negocio.
4. Producir un plan del proyecto: se establecerá en forma general el tiempo que tomara desarrollar cada fase, los recursos que son necesarios y considerar los riesgos para el desarrollo de la metodología.

Fase 2: Comprensión de datos

La fase de comprensión de datos implica explorar lo datos con el fin de determinar la calidad de la información.

Las actividades que se desarrollan en esta etapa son las siguientes:

1. Recolección de datos iniciales: consiste en conseguir y acceder a los datos ya que los datos provienen de una variedad de fuentes como:

- a. Datos existentes: esto incluye una amplia variedad de datos, como datos transaccionales, datos de encuestas, registros web.
 - b. Datos comprados: su organización utiliza datos complementarios como datos demográficos.
 - c. Datos adicionales: si las fuentes de datos anteriores no satisfacen las necesidades, es posible se deba realizar encuestas o comenzar un seguimiento adicional.
2. Descripción de los datos: existen diferentes formas para describir los datos, pero la mayoría se centran en la calidad y cantidad de los datos.
- a. La cantidad de los datos: para la mayoría de las técnicas de modelado, existen compensaciones asociadas con el tamaño de los datos. Grandes volúmenes de datos pueden producir modelos más precisos, pero también alargan el tiempo de procesamiento.
 - b. Tipos de valores: los datos pueden tomar una variedad de formatos:
 - Fuente
 - Tipos de datos como: numérico, categórico (cadena) o booleano (verdadero/falso). Prestar atención al tipo de valor puede evitar problemas durante el modelado.
 - Dominios: sexo, rango, tipo de producto
 - Volumen: cantidad de datos
 - Velocidad de cambio de los datos
 - Variedad: estructurado, no estructurado, semi estructurado
 - Veracidad: datos confiables
 - Valor: valor agregado en el análisis de los datos.
 - c. Esquemas de codificación: los datos tienen diferentes características que deben ser interpretados.

3. Exploración de los datos: se explora los datos con tablas, gráficos, y otras herramientas de visualización. Esto ayuda a abordar el objetivo de minería de datos durante la fase de comprensión del negocio.
4. Verificación de la calidad de los datos: los datos rara vez son perfectos, la mayoría contienen errores de codificación, valores faltantes, errores de medición u otros tipos de inconsistencia lo que dificulta el análisis.

Fase 3: Preparación de los datos

La fase de preparación de datos es uno de los aspectos más relevantes y a menudo más laboriosos, se estima que la preparación de los datos suele ocupar el 50% y el 70% del esfuerzo y tiempo del proyecto.

1. Seleccionar los datos: se selecciona los datos relevantes para los objetivos de minería de datos.
 - a. Seleccionar elementos (filas): implica tomar decisiones como que cuentas, productos o clientes incluir.
 - b. Selección de atributos o características: implica tomar decisiones sobre el uso de las mismas como el monto de la transacción o ingresos del hogar.
2. Limpiar los datos: implica observar más de cerca los problemas de los datos que se van a utilizar para el análisis. Ejemplo: datos perdidos, errores de datos, codificaciones inconsistentes entre otros.
3. Construir los datos: es frecuente que se necesite construir nuevos datos.
 - a. Nuevas columnas de datos o características
 - b. Generación de filas de datos
4. Integración de datos: se realiza cuando se dispone de múltiples fuentes de datos para el mismo conjunto de preguntas comerciales.

- a. La fusión: es la unión de dos bases de datos con diferentes atributos. Los datos se fusionan utilizando el mismo identificador de clave.
 - b. Agregar: implica añadir dos o más conjuntos de datos con atributos similares, pero con registros diferentes. Los datos se integran en función de campos parecidos.
5. Formatear los datos: como paso final antes de la construcción del modelo, es útil verificar si ciertas técnicas requieren un formato u orden particular para los datos.

Fase 4: Modelado

El modelado generalmente se lleva a cabo de múltiples interacciones. Por lo general los mineros de datos ejecutan varios modelos o vuelven a la fase de preparación de datos para las manipulaciones requeridas para su modelo de elección. Permitiendo que pueda dar respuesta al problema planteado en la fase de entendimiento del negocio.

1. Selección de técnicas de modelado: la determinación del modelo más apropiado generalmente se basará en las siguientes consideraciones:
 - a. Los tipos de datos disponibles para la minería: los tipos de interés son categóricos o simbólicos.
 - b. Sus objetivos de minería de datos: requiere generar patrones o estimaciones.
 - c. Requisitos específicos de modelado: el modelo requiere un tamaño o tipo de datos en particular, necesitas un modelo con resultados fácilmente presentables.

Al decidir qué modelo usar hay que considerar los siguientes problemas:

¿El modelo requiere que los datos se dividan en conjuntos de pruebas y entrenamiento?

¿Tienes suficientes datos para producir resultados confiables para un modelo dado?

¿El modelo requiere un cierto nivel de calidad de datos? ¿Puede alcanzar este nivel con los datos actuales?

2. Generación de un diseño de prueba: como paso final antes de construir el modelo debe tomarse un momento para considerar nuevamente como se probará los resultados del modelo. Hay dos partes para generar un diseño de prueba integral:

a. Describir los criterios de “bondad” de un modelo.

La **bondad** de un modelo se puede medir de varias maneras. Para modelos supervisados como C5.0 y C&R Tree, las medidas de bondad generalmente estiman la tasa de error del modelo en particular. Para los modelos no supervisados, como las redes de conglomerados de Kohonen, las mediciones pueden incluir criterios como la facilidad de la interpretación, el despliegue o el tiempo de procesamiento requerido.

b. Definición de los datos sobre los que se pondrán a prueba estos criterios.

3. Construyendo los modelos: en la construcción del modelo hay que experimentar con varios modelos diferentes antes de sacar conclusiones. La mayoría de mineros de datos construyen varios modelos y comparan resultados antes de implementarlos o integrarlos.

Existen 3 parámetros para usar en las decisiones de minería de datos:

a. Configuración de parámetros: la mayoría de las técnicas de modelado posee una variedad de parámetros o configuraciones que se pueden ajustar para controlar el proceso de modelado.

b. Los modelos: una vez insertado los nodos de los modelos en la secuencia y editando los parámetros, simplemente ejecute el modelo para producir resultados visibles.

c. Descripción de los resultados del modelo: una vez obtenido los resultados de los modelos hay que analizar la siguiente información.

i. ¿puedes sacar conclusiones significativas de este modelo?

- ii. ¿Hay nuevos conocimientos o patrones inusuales revelados por el modelo?
 - iii. ¿Hubo problemas de ejecución para el modelo? ¿Qué tan razonable fue el tiempo de procesamiento?
 - iv. ¿Tuvo el modelo dificultades con problemas de calidad de datos, con una gran cantidad de datos faltantes?
 - v. ¿Hubo alguna inconsistencia de cálculo que deba tenerse en cuenta?
4. Evaluación del modelo: una vez que se tiene un conjunto de modelos iniciales se determina cuáles son lo suficientemente precisos o efectivos para ser definitivos. Listos para implementar o que ilustra patrones interesantes.
- a. Se evalúa los resultados del modelo de varias opciones como son gráficos de evaluación, nodos de análisis, o gráficos de validación cruzada.
 - b. Realice una revisión de los resultados en función de su comprensión del problema empresarial.
 - c. Considerar si los resultados de un modelo son fácilmente implementables.
 - d. Analice el impacto de los resultados.

Fase 5: Evaluación

En esta fase se debe evaluar los resultados de los esfuerzos utilizando los criterios de éxito comercial establecidos al inicio del proyecto. Esta es la clave para garantizar que su organización pueda hacer uso de los resultados que ha obtenido.

La minería de datos genera dos tipos de resultados:

1. Los modelos finales seleccionados en la fase previa de CRISP-DM
2. Cualquier conclusión o inferencia extraída de los propios modelos, así como del proceso de extracción de datos.

Hay que considerar las siguientes preguntas para la evaluación de los resultados:

¿Sus resultados se expresan claramente y en una forma que se pueda presentar fácilmente?

¿Hay hallazgos particularmente novedosos o únicos que deban destacarse?

¿Puede clasificar los modelos y hallazgos en orden de aplicabilidad o los objetivos comerciales?

¿Qué tan bien responden estos resultados a los objetivos comerciales de su organización?

¿Qué preguntas adicionales ha planteado sus resultados? ¿Cómo podría formular estas preguntas en términos comerciales?

Las metodologías efectivas generalmente incluyen tiempo para reflexionar sobre los éxitos y las debilidades del proceso. El CRISP-DM se basa en aprender de su experiencia para los futuros proyectos de minería de datos sean más efectivos.

Esta fase lo que le ayuda a responder las preguntas de sus objetivos comerciales para la minería de datos, hay dos opciones en este punto:

1. Continúe con la fase de implementación: la siguiente fase le ayudará a incorporar los resultados del modelo en su proceso comercial. Incluso si sus esfuerzos de minería de datos no tuvieron éxito, debe usar la fase de implementación de CRISP-DM para crear un informe final para distribuirlo a los patrocinados del proyecto.
2. Vuelve atrás y refina o reemplaza tus modelos: si encuentra que sus resultados son casi óptimos, pero no del todo considere otra ronda de modelado. Puede tomar lo que ha aprendido en esta fase y usarlo para refinar los modelos y producir mejores resultados.

Fase 6: Implementación:

En esta fase se usa nuevos conocimientos para realizar mejoras dentro de la organización. Esto puede significar la integración formal de la implementación de un modelo.

La fase implementación de CRISP-DM incluye dos tipos de actividades.

1. Planificación y seguimiento del despliegue de resultados.

Si bien puede estar ansioso de compartir los resultados, pero es necesario planificar una implementación de resultados completa y sin problemas.

- a. El primer paso es resumir los resultados obtenidos.
- b. Hay que considerar como se supervisara la implementación.
- c. Identificar problemas de implementación y planificar contingencias.

Con relación al seguimiento y mantenimiento es probable que este modelo deba evaluarse periódicamente para garantizar la efectividad y realizar mejoras continuas o modificarse.

2. Completar tareas de recapitalización, como producir un informe final y realizar una revisión del proyecto.

Un informe final se utiliza para comunicar los resultados a las personas interesadas o dueñas del proceso que pueden ser administradores, técnicos entre otros facilitándoles la toma de decisiones oportunas.

Capítulo IV

Implementación del modelo de mantenimiento predictivo y proactivo

Una vez establecida en el capítulo anterior la metodología propuesta para el desarrollo del siguiente proyecto se procede a desarrollar cada una de las fases en la empresa Acería del Ecuador C.A. ADELCA en el área de fundición.

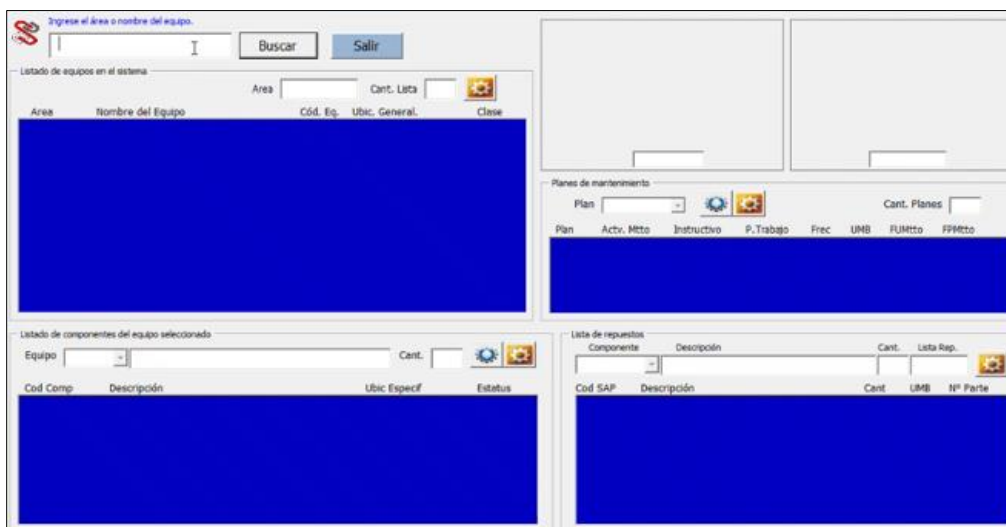
Fase 1: Comprensión del negocio

Análisis de la situación actual

La empresa actualmente lleva el control de mantenimientos con un sistema independiente al ERP que maneja la empresa ya que existen varias restricciones que no se ajustan a los requerimientos de las áreas de mantenimiento.

Figura 10

Sistema de control de mantenimientos



Nota. El siguiente gráfico muestra el sistema que maneja la empresa para mantenimientos. Tomado de Adelca C.A.

La compañía realiza sus mantenimientos de forma preventiva y correctiva considerando los siguientes criterios: las recomendaciones del fabricante de la maquinaria, conocimientos del técnico y eventos que se hayan presentado durante la producción.

Hay que considerar otro factor ya que al tratarse de maquinaria crítica por la actividad que realiza la empresa se debe dar un tratamiento especial la planificación de mantenimientos.

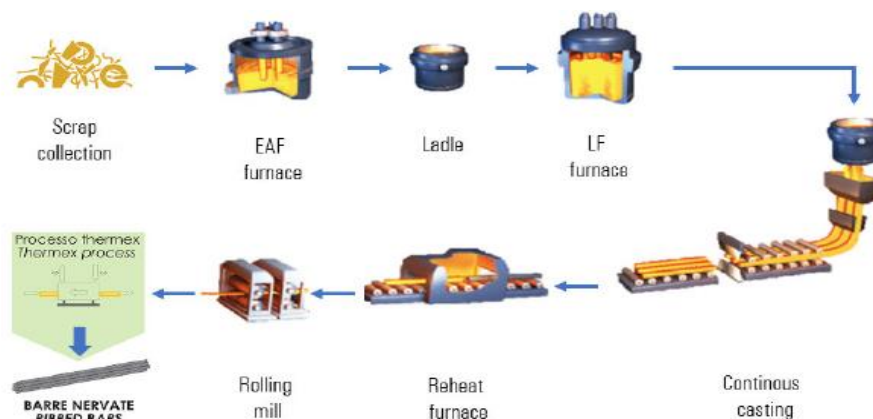
La empresa posee una clasificación de criticidad de equipos y en base a eso se planifica los mantenimientos.

1. **Equipos de criticidad A:** equipos que interrumpen todo el proceso productivo y aumenta más del 20% de los costos mensuales de mantenimiento.
2. **Equipos de criticidad B:** equipos que interrumpen parcialmente el proceso productivo aumentan del 10% al 20% de los costos mensuales de mantenimiento.

3. **Equipos de criticidad C:** no afectan el proceso de producción y no afectan significativamente los costos mensuales de mantenimiento.

Figura 11

Proceso de elaboración del acero



Nota. El siguiente gráfico describe el proceso de elaboración del acero. Tomado de (KISAN SARDA, 2021)

Al ser una industria muy sofisticada el costo de mantenimiento es considerable en la producción de bienes, si se sigue manejando los mantenimientos de la forma tradicional, el recambio de repuestos no es oportuna ya que al presentarse una falla de una maquinaria no contemplada dentro de la planificación de mantenimiento durante la producción genera retrasos y pérdidas en producción.

Por lo que es necesario definir los objetivos del negocio y de minería de datos.

Establecer un modelo de mantenimiento predictivo que permita la reducción de costos, como la sustitución de partes y piezas de forma oportuna.

- Brindar información oportuna al gerente de mantenimiento para que su planificación sea lo más acertada posible y se elimine los tiempos de paradas de producción ocasionadas por fallas de mantenimiento.

- Definir las causas de las incidencias que se presentaron en los mantenimientos para poder controlar y evitar que vuelvan a suceder.

Los objetivos están relacionados con los que se plantearon al inicio del desarrollo del trabajo.

Tabla 4

Planificación del proyecto

Fase	Tiempo	Recursos	Riesgos
Comprensión del negocio	1 semana	Personal Analítico	Cambios de sistemas de mantenimientos
Comprensión de los datos	3 semanas	Personal Analítico	Problemas con los sistemas y datos
Preparación de los datos	5 semanas	Personal Analítico y Software	Problemas con el hardware y software
Modelado	2 semanas	Personal Analítico y Software	Problemas en afinar el modelo
Evaluación	1 semana	Personal Analítico	Problemas en interpretar los resultados
Implementación	1 semana	Personal Mantenimiento	Problemas en la eficacia del modelo

Nota. Esta tabla muestra la planificación de cada una de las etapas de la metodología CRISP-DM

Dentro la parte de comprensión del negocio es necesario indicar que con tipo de herramienta de analítica de datos se trabajará para el desarrollo del presente trabajo.

En este caso se consideró la herramienta Rapidminer tomando en cuenta varios factores para la elección de la herramienta de analítica de datos:

1. Al tener un perfil financiero se requiere de una herramienta de fácil aprendizaje, es decir que no sea demasiada técnica para el uso.
2. Licenciamiento: la mayoría de licencias son pagadas, en este caso se necesita de una licencia académica que me permita desarrollar el análisis de datos de una forma completa. Existen licencias en el mercado gratuitas, pero no se puede ocupar todas las funciones.
3. La herramienta tiene una buena ubicación dentro de la evaluación que realiza Gartner.

Fase 2: Comprensión de los datos

Los datos que se disponen para la elaboración del presente proyecto son la base de datos de planificación de mantenimientos del sistema independiente que se mencionó en la fase de comprensión del negocio donde alimentan diariamente de acuerdo a los mantenimientos que gestiona y realiza la empresa, así como el registro de demoras finales que se presenta en el proceso de producción, los datos considerados para el desarrollo del proyecto son de 11.160 observaciones.

Los datos son estructurados que se disponen en Excel, los cuales se describen a continuación.

Tabla 5*Descripción de la fuente de datos*

Denominación archivos excel	Descripción
Inventario de Equipos	El archivo contiene los datos de cada uno de los equipos del área de acería.
Registro de demoras	El archivo contiene el detalle de las fallas o daños que se presentaron durante la producción.

Nota. Esta tabla describe las fallas que se presentaron durante la producción.

Cada uno de los archivos presentados está compuesto de la siguiente información.

Tabla 6*Descripción de los campos del inventario de equipos*

Campo	Descripción	Tipo de dato
Código del Equipo	Identificación numérica de la maquinaria	Numérico
Área	A qué área específica pertenece el equipo	Texto
Descripción	Identificación textual de la maquinaria	Texto
Ubicación en planta	Descripción geográfica de la ubicación de la maquinaria	Texto
Clase	La descripción de la criticidad del equipo de acuerdo a la producción	Texto

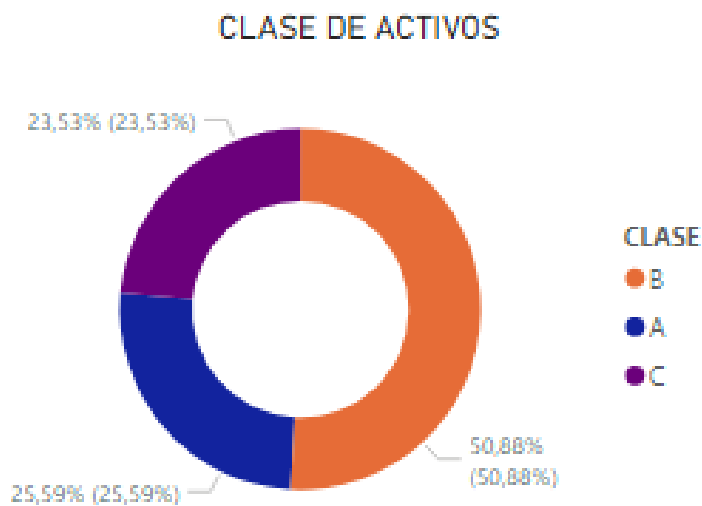
Campo	Descripción	Tipo de dato
Status	Estado de funcionamiento de la maquinaria.	Texto

Nota. Esta tabla describe el inventario de equipos

Esta fuente de datos describe el inventario de equipos que posee la compañía de los cuales podemos destacar la siguiente información.

Figura 12

Criticidad de equipos



Nota. El siguiente grafico muestra la criticidad de equipos.

Tabla 7*Descripción de los campos del registro de demoras*

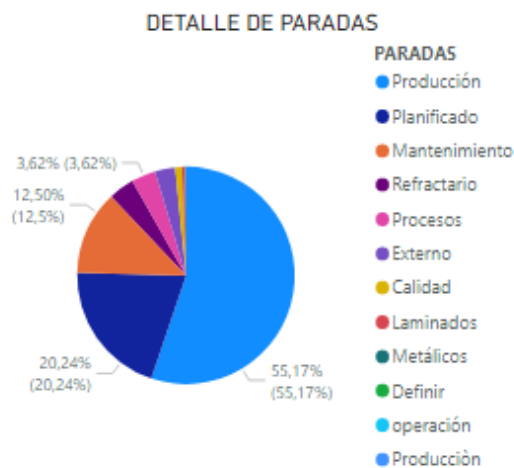
Campo	Descripción	Tipo de dato
Colada	Identificación del número de coladas que se realiza en la producción	Numérico
Fecha	Registro de cuando sucedió la demora	Fecha
Operador	Identificación del personal que se encontraba operando la maquinaria	Texto
Daño o Falla	Descripción de la falla.	Texto
Tiempo	Los minutos que se paró la producción	Numérico
Equipo	Descripción del equipo	Texto
Parada	Descripción del área por la cual se ocasiono la parada de producción	Texto
Observaciones	Descripción detalla del daño	Texto
Año	Año del registro de la falla	Texto
Mes	Mes del registro de la falla	Texto
Turno	Turno en el que se ocasiono la falla	Texto

Nota. Esta tabla muestra el registro de demoras.

De esta fuente de datos podemos resaltar la siguiente información:

Figura 13

Detalle de paradas por departamento



Nota. El siguiente gráfico detalla las paradas que se generan por áreas.

Figura 14

Demoras por equipos



Nota. El siguiente gráfico describe los equipos que más demoras se presentan.

Figura 15*Demoras por turnos*

Nota. El siguiente gráfico demuestra las demoras por turnos.

Tabla 8*Descripción del plan de actividades de mantenimiento*

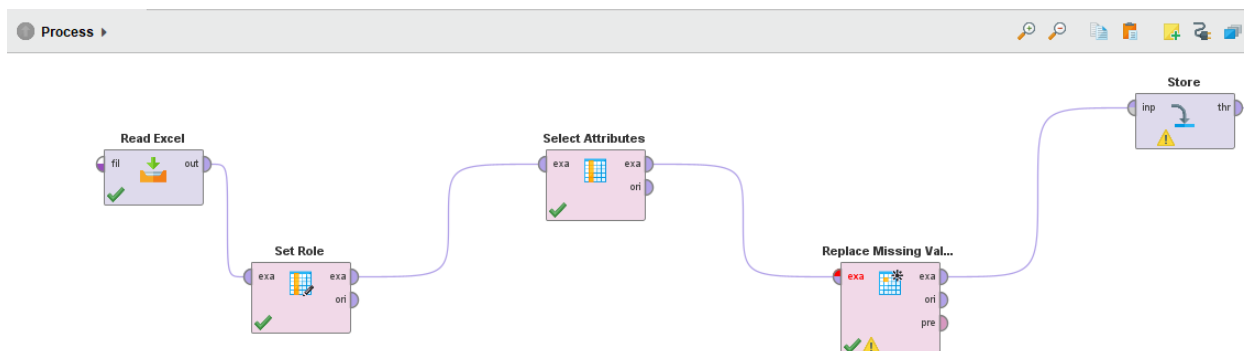
Campo	Descripción	Tipo de dato
Código del Equipo	Identificación del equipo	Numérico
Tipo de parada	Registro de la parada por el cual se realizó el mantenimiento	Texto
Fecha inicio Programa	Fecha de cuando se realizó el mantenimiento.	Texto
Área	Descripción de a qué área pertenece el equipo.	Texto
Clase	Identificación de criticidad del equipo.	Texto

Campo	Descripción	Tipo de dato
Tipo de actividad	Mantenimiento que se realizó al Equipo.	Texto
Prioridad	Escala del tratamiento que se debe darle al equipo.	Numérico
Hora de inicio	Fecha de cuando se inició el mantenimiento	Tiempo
Hora de termino	Fecha de cuando se terminó el mantenimiento.	Tiempo
Tiempo	Número de horas que duró el mantenimiento.	Numérico
Personas	Número de personas que se ocupó para realizar el mantenimiento.	Numérico
Probabilidad	Descripción de la probabilidad de daño.	Texto
Construcción	Clasificación del daño	Texto

Nota. La siguiente tabla describe la información que se dispone del plan de actividades.

Fase 3: Preparación de los datos

En esta fase se procede a validar la fuente de datos y a su vez analizar de cómo está compuesta la información y realizar las respectivas depuraciones con la finalidad de seleccionar las variables que se utilizaran en el modelo predictivo de mantenimiento.

Figura 16*Pre-procesamiento de datos*

Nota. El siguiente gráfico muestra el pre-procesamiento de los datos.

En la figura 16 tenemos el flujo de actividades que se desarrolló para realizar la depuración y validación de la calidad de los datos, donde se pretende obtener la información lista para su respectivo tratamiento.

Los pasos que se realizaron son los siguientes:

1. Se dio lectura a la fuente de datos denominado Plan de Actividades
2. Se identificó los roles, como es el ID y el rol LABEL.
3. Se realiza la exclusión de atributos duplicados y otros datos no importantes.
4. Se reemplaza los valores erróneos que posee la fuente de datos.

Figura 17

Lectura de la fuente de datos

The screenshot shows a software interface with a 'Read Excel' component. A dialog box titled 'Import Data - Select the cells to import.' is open, displaying a table of data. The table has columns labeled A through M and rows numbered 1 through 20. The data includes fields like ACT, PLAN, FECHA I..., FECHA T..., TIPO DE..., AREA, COD. CO..., COD. EQ..., CLASE, DESCRIP..., DESCRIP..., and DESCRIP... The dialog box also shows 'Sheet: Hoja1', 'Cell range: A:AN', and 'Define header row: 1'.

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	ACT	PLAN	FECHA I...	FECHA T...	TIPO DE ...	AREA	COD. CO...	COD. EQ...	CLASE	DESCRIP...	DESCRIP...	DESCRIP...	
2	101037...	PML1086	May 9, 2...	May 9, 2...	Semanal	LINGOT...	EQ1006...	EQ10069	B	MITTO SL...	SISTEMA...	SISTEMA...	
3	101038...	PML1087	May 9, 2...	May 9, 2...	Semanal	LINGOT...	EQ1007...	EQ10070	B	MITTO SL...	SISTEMA...	SISTEMA...	
4	101039...	PML1088	May 9, 2...	May 9, 2...	Semanal	LINGOT...	EQ1007...	EQ10071	B	MITTO SL...	SISTEMA...	SISTEMA...	
5	101040...	PML1003	May 9, 2...	May 9, 2...	Semanal	LINGOT...	EQ1000...	EQ10001	A	MITTO C...	CENTRA...	CENTRA...	
6	101041...	PML3508	May 9, 2...	May 9, 2...	Semanal	LINGOT...	EQ1008...	EQ10089	A	MITTO B...	CENTRA...	CENTRA...	
7	101042...	PML1095	May 9, 2...	May 9, 2...	Semanal	LINGOT...	EQ1007...	EQ10072	C	MITTO C...	CENTRA...	CENTRA...	
8	101043...	PML1002	May 17, ...	May 17, ...	Semanal	LINGOT...	EQ1000...	EQ10001	A	INSPEC...	CENTRA...	CENTRA...	
9	101044...	PML1086	May 17, ...	May 17, ...	Semanal	LINGOT...	EQ1006...	EQ10069	B	MITTO SL...	SISTEMA...	SISTEMA...	
10	101045...	PML1087	May 17, ...	May 17, ...	Semanal	LINGOT...	EQ1007...	EQ10070	B	MITTO SL...	SISTEMA...	SISTEMA...	
11	101046...	PML1088	May 17, ...	May 17, ...	Semanal	LINGOT...	EQ1007...	EQ10071	B	MITTO SL...	SISTEMA...	SISTEMA...	
12	101047...	PML1864	May 17, ...	May 17, ...	Semanal	LINGOT...	EQ1007...	EQ10079	A	MITTO S...	CURVILI...	CURVILI...	
13	101048...	PML1875	May 17, ...	May 17, ...	Semanal	LINGOT...	EQ1008...	EQ10081	A	LUBRIC...	CURVILI...	RODILL...	
14	101049...	PML1002	May 26, ...	May 26, ...	Semanal	LINGOT...	EQ1000...	EQ10001	A	INSPEC...	CENTRA...	CENTRA...	
15	101050...	PML1864	May 26, ...	May 26, ...	Semanal	LINGOT...	EQ1007...	EQ10079	A	MITTO S...	CURVILI...	CURVILI...	
16	101051...	PML1868	May 26, ...	May 26, ...	Semanal	LINGOT...	EQ1008...	EQ10080	A	MITTO S...	CURVILI...	CURVILI...	
17	101052...	PML1872	May 26, ...	May 26, ...	Semanal	LINGOT...	EQ1008...	EQ10081	A	MITTO S...	CURVILI...	CURVILI...	
18	101053...	PML1002	Jun 3, 20...	Jun 3, 20...	Semanal	LINGOT...	EQ1000...	EQ10001	A	INSPEC...	CENTRA...	CENTRA...	
19	101054...	PML1864	Jun 3, 20...	Jun 3, 20...	Semanal	LINGOT...	EQ1007...	EQ10079	A	MITTO S...	CURVILI...	CURVILI...	
20	101055...	PML1872	Jun 3, 20...	Jun 3, 20...	Semanal	LINGOT...	EQ1008...	EQ10081	A	MITTO S...	CURVILI...	CURVILI...	

Nota. El siguiente gráfico muestra los datos que se están cargando al software.

En la figura 17 podemos visualizar los datos tal cual nos remite el área de mantenimiento donde llevan el registro de su plan de mantenimientos, identificando el tipo de parada que se realizó para el mantenimiento de los equipos entre otros datos.

Figura 18

Identificación de los tipos datos

Import Data - Format your columns.

Format your columns.

Replace errors with missing values ⓘ

	TIPO DE PARADA * <i>polynomial</i>	AREA * <i>polynomial</i>	COD. COMP. * <i>polynomial</i>	COD. EQUIPO * <i>polynomial</i>	CLASE * <i>polynomial</i>	DESCRIP P... * <i>polynomial</i>	DESCRIP E... * <i>polynomial</i>	DES <i>polyr</i>
1	Semanal	LINGOTERAS	EQ10069-000	EQ10069	B	MTTO SISTEMA ...	SISTEMA DE SP...	SIST
2	Semanal	LINGOTERAS	EQ10070-000	EQ10070	B	MTTO SISTEMA ...	SISTEMA DE SP...	SIST
3	Semanal	LINGOTERAS	EQ10071-000	EQ10071	B	MTTO SISTEMA ...	SISTEMA DE SP...	SIST
4	Semanal	LINGOTERAS	EQ10001-000	EQ10001	A	MTTO CENTRAL ...	CENTRAL HID. V...	CEN
5	Semanal	LINGOTERAS	EQ10089-000	EQ10089	A	MTTO BOMBAS ...	CENTRAL DE LU...	CEN
6	Semanal	LINGOTERAS	EQ10072-000	EQ10072	C	MTTO CENTRAL ...	CENTRAL HID. B...	CEN
7	Semanal	LINGOTERAS	EQ10001-000	EQ10001	A	INSPECCION VI...	CENTRAL HID. V...	CEN
8	Semanal	LINGOTERAS	EQ10069-000	EQ10069	B	MTTO SISTEMA ...	SISTEMA DE SP...	SIST
9	Semanal	LINGOTERAS	EQ10070-000	EQ10070	B	MTTO SISTEMA ...	SISTEMA DE SP...	SIST
10	Semanal	LINGOTERAS	EQ10071-000	EQ10071	B	MTTO SISTEMA ...	SISTEMA DE SP...	SIST
11	Semanal	LINGOTERAS	EQ10079-000	EQ10079	A	MTTO SEMANAL ...	CURVILINEA 1	CUF
12	Semanal	LINGOTERAS	EQ10081-001	EQ10081	A	LUBRICACION S...	CURVILINEA 3	ROC
13	Semanal	LINGOTERAS	EQ10001-000	EQ10001	A	INSPECCION VI...	CENTRAL HID. V...	CEN
14	Semanal	LINGOTERAS	EQ10079-000	EQ10079	A	MTTO SEMANAL ...	CURVILINEA 1	CUF
15	Semanal	LINGOTERAS	EQ10080-000	EQ10080	A	MTTO SEMANAL ...	CURVILINEA 2	CUF
16	Semanal	LINGOTERAS	EQ10081-000	EQ10081	A	MTTO SEMANAL ...	CURVILINEA 3	CUF
17	Semanal	LINGOTERAS	EQ10001-000	EQ10001	A	INSPECCION VI...	CENTRAL HID. V...	CEN
18	Semanal	LINGOTERAS	EQ10079-000	EQ10079	A	MTTO SEMANAL ...	CURVILINEA 1	CUF

no problems.

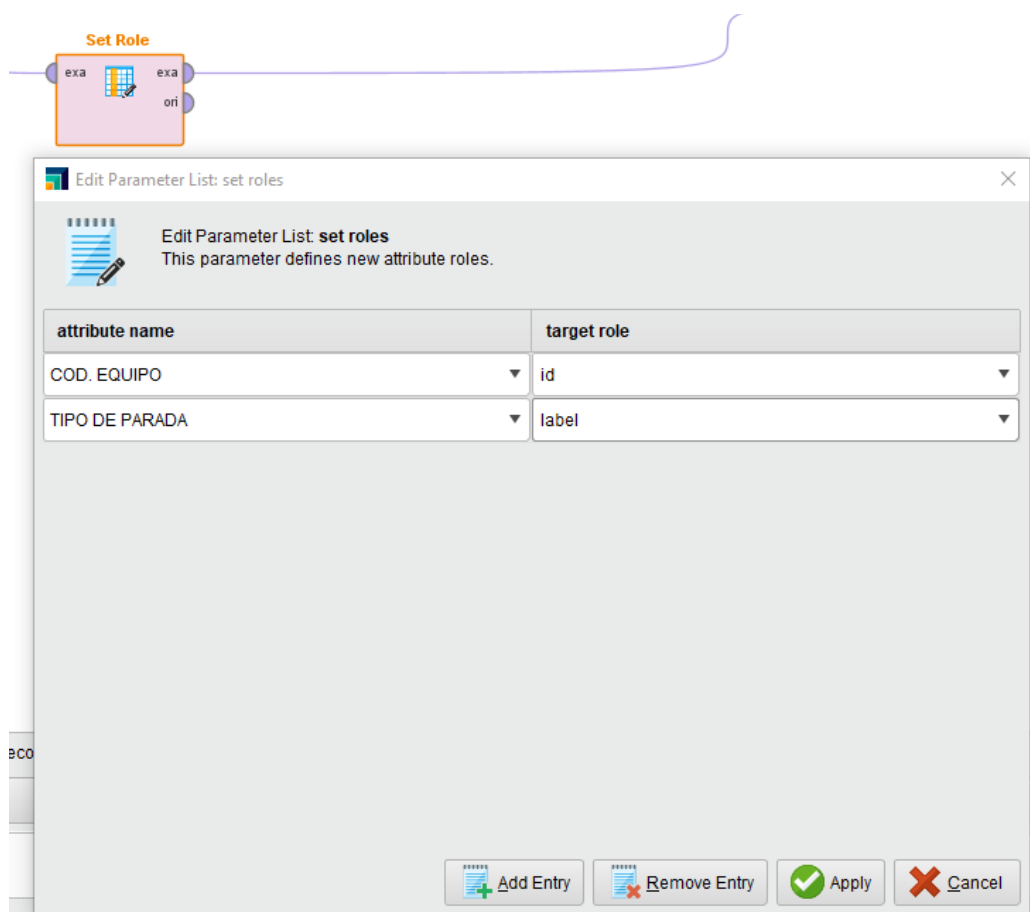
← Previous Finish Cancel

Nota. El siguiente gráfico muestra los tipos de datos que contienen los archivos.

Una vez cargado los datos el sistema identifica el tipo de dato que se está cargando, pero no identifica los respectivos roles, lo que es necesario identificar los datos que representan ID que es un rol especial y debe ser único en la base de datos, así como la etiqueta (label) que actúa como un atributo para poder aprender de los operadores.

Figura 19

Selección de roles



Nota. El siguiente gráfico muestra la selección de roles.

Mediante el operador Set Role procedemos a identificar al COD. EQUIPO con el rol de ID ya que es un dato especial y que no se repite en la base de datos, mientras que el TIPO DE PARADA lo identificamos con el rol de LABEL ya que será un operador para aprender de los demás operadores.

Como se muestra en la figura una vez cargada la fuente de datos podemos observar que existe varias observaciones de datos erróneos donde para el respectivo tratamiento y por tema de calidad de datos es necesario corregir los errores.

Figura 20

Detalle de estadísticas

Name	Type	Missing	Statistics	Filter (40 / 40 attributes):
▼ COD. EQUIPO	Nominal	0	Least EQ19030 (1)	Most EQ12000 (766)
▼ TIPO DE PARADA	Nominal	0	Least Intermedia (7)	Most Semanal (7629)
▼ ACT	Integer	0	Min 101037	Max 181190
▼ PLAN	Nominal	4286	Least PMT1005 (1)	Most PME2287 (64)
▼ FECHA INICIO PROG	Date-time	0	Earliest date Dec 10, 2018	Latest date Dec 28, 2022
▼ FECHA TERMINO PROG	Date-time	4	Earliest date Dec 10, 2018	Latest date Mar 10, 2023
▼ AREA	Nominal	0	Least LINGOTERAS (223)	Most PUENTES (2842)
▼ COD. COMP.	Nominal	1798	Least EQ19030-000 (1)	Most EQ12000-000 (414)
▼ CLASE	Nominal	0	Least C (668)	Most A (5595)
▼ DESCRIP PLAN	Nominal	0	Least Torreta EAF (1)	Most PUENTE G [...] #7 (509)
▼ DESCRIP EQUIPO	Nominal	111	Least VIRADOR TUNDISH 2 (1)	Most HORNO EAF (748)
▼ DESCRIP COMPONENTE	Nominal	1926	Least VIRADOR TUNDISH 2 (1)	Most CUARTO DE BOMBAS (...)

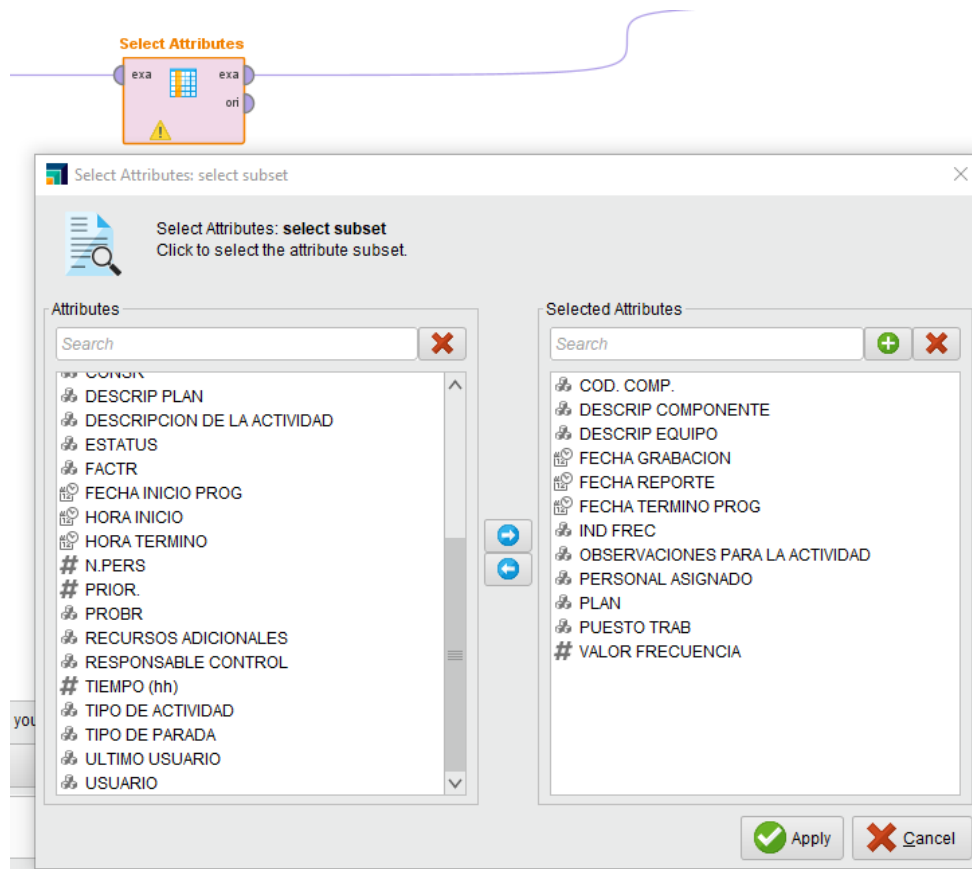
Nota. El siguiente gráfico describe los errores que contienen los datos.

Lo que podemos identificar en la figura 20 son los valores erróneos que posee la data por lo que es necesario corregir los errores y depurar los datos con diferentes operadores que se mencionan a continuación.

Procedemos a depurar los datos erróneos con la función SELECT ATRIBUTES donde vamos a excluir columnas que son redundantes y datos que no son necesarios para el modelo de aprendizaje que necesitamos elaborar.

Figura 21

Selección de atributos

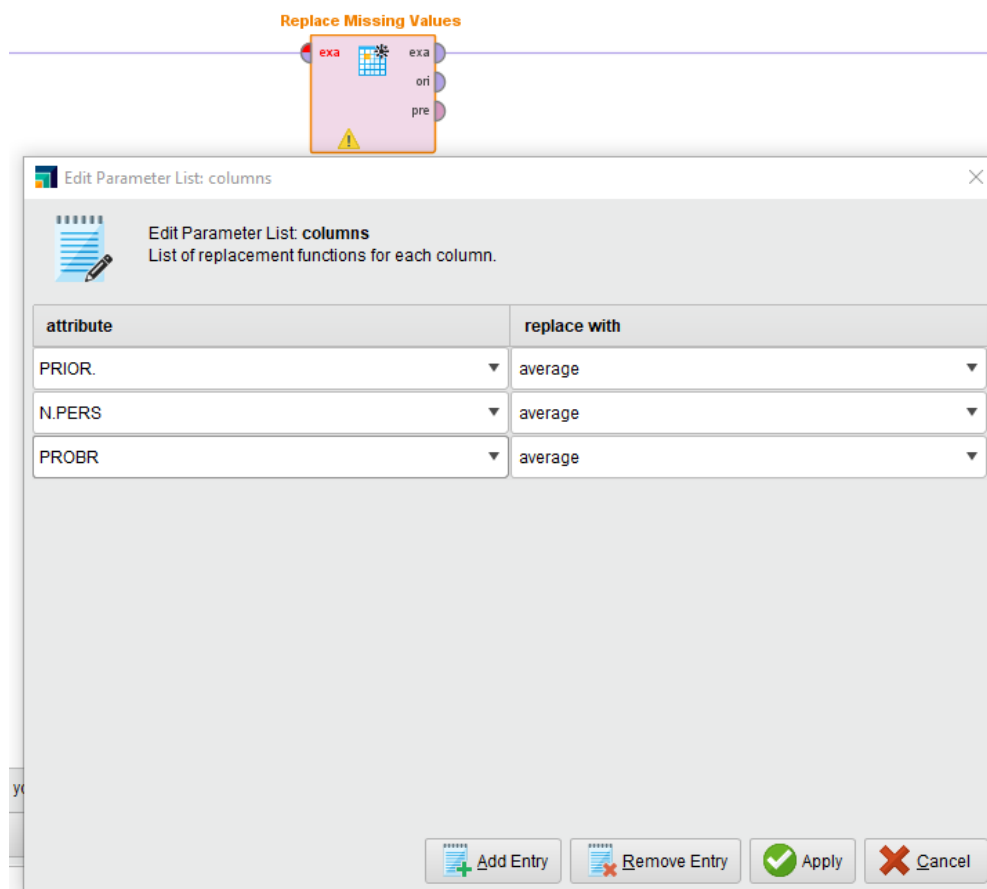


Nota. El siguiente gráfico se realiza la selección de atributos.

La exclusión que se realizó en la figura 21 se lo realizo con mucho criterio considerando que existía duplicidad de información que no ayuda a la preparación del modelo más bien distorsiona la información.

Figura 22

Reemplazo de valores faltantes



Nota. El siguiente gráfico muestra el reemplazo de valores erróneos.

En la figura 22 con la función REPLACE MISSING VALUES lo que procedemos a realizar es reemplazar los valores faltantes por el promedio de la información esto nos ayuda a tener una data más equilibrada.

Una vez realizado todo este proceso de depuración la base de datos contamos con 9.649 observaciones que están lista para poder pasar al siguiente paso que es el modelado de los datos.

Fase 4: Modelado

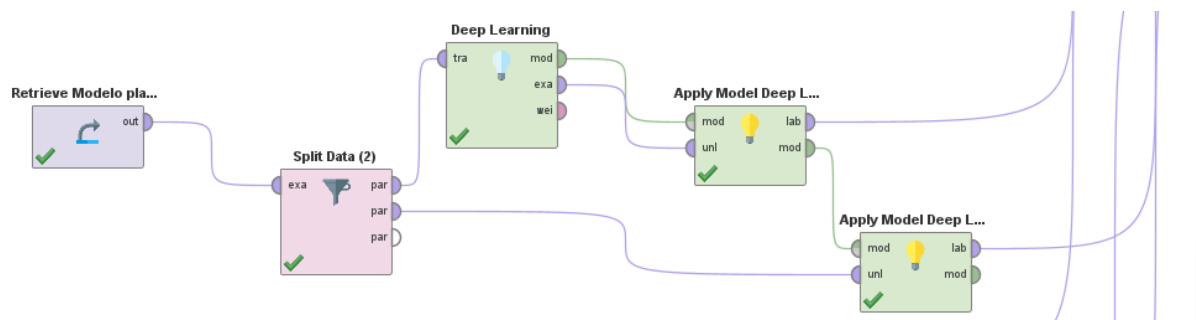
En esta fase lo que procedemos es analizar los diferentes tipos de modelos de predicción que se ajustan al tipo de información que disponemos para el desarrollo del siguiente proyecto.

Para el entrenamiento de los modelos se dividió los datos en donde el 80% se utiliza como entrenamiento de los algoritmos mientras que el 20% para la prueba.

Diseño del modelo Deep Learning

Figura 23

Diseño del modelo Deep Learning



Nota. El siguiente gráfico muestra el modelo Deep Learning.

En la figura 23 como punto de partida son los datos ya procesada donde se aplicó el modelo de predicción Deep Learning donde obtenemos los siguientes resultados.

Donde se determina el tipo de parada que se debería realizar a cada una de las maquinarias en base al aprendizaje de las demás variables con su respectivo grado de confianza.

Figura 24

Resultados del modelo Deep Learning

Row No.	COD. EQUIPO	TIPO DE PA...	prediction(TL...	confidence(Semanal)	confidence(Imprevista)	confidence(Mensual)	confidence(Anual)	confidence(Intermedia)	ACT
1	EQ10069	Semanal	Semanal	0.863	0.006	0.131	0.000	0.000	101037
2	EQ10070	Semanal	Semanal	0.735	0.010	0.256	0.000	0.000	101038
3	EQ10001	Semanal	Semanal	0.905	0.013	0.081	0.000	0.000	101040
4	EQ10089	Semanal	Semanal	0.855	0.008	0.138	0.000	0.000	101041
5	EQ10072	Semanal	Semanal	0.843	0.003	0.154	0.000	0.000	101042
6	EQ10001	Semanal	Semanal	0.756	0.036	0.207	0.000	0.000	101043
7	EQ10069	Semanal	Semanal	0.861	0.006	0.133	0.000	0.000	101044
8	EQ10070	Semanal	Semanal	0.733	0.018	0.248	0.001	0.000	101045
9	EQ10079	Semanal	Semanal	0.697	0.009	0.293	0.001	0.000	101047
10	EQ10081	Semanal	Semanal	0.989	0.001	0.011	0.000	0.000	101048
11	EQ10001	Semanal	Semanal	0.969	0.001	0.028	0.002	0.000	101049
12	EQ10079	Semanal	Semanal	0.985	0.000	0.015	0.000	0.000	101050
13	EQ10080	Semanal	Semanal	0.997	0.000	0.003	0.000	0.000	101051
14	EQ10081	Semanal	Semanal	0.996	0.000	0.004	0.000	0.000	101052
15	EQ10079	Semanal	Semanal	0.821	0.004	0.175	0.000	0.000	101054
16	EQ10081	Semanal	Semanal	0.941	0.002	0.057	0.000	0.000	101055

Nota. El siguiente gráfico muestra los resultados el modelo Deep Learning.

Figura 25

Evaluación del rendimiento estadístico del modelo Deep Learning.

absolute_error

`absolute_error: 0.021 +/- 0.091`

relative_error

`relative_error: 2.11% +/- 9.06%`

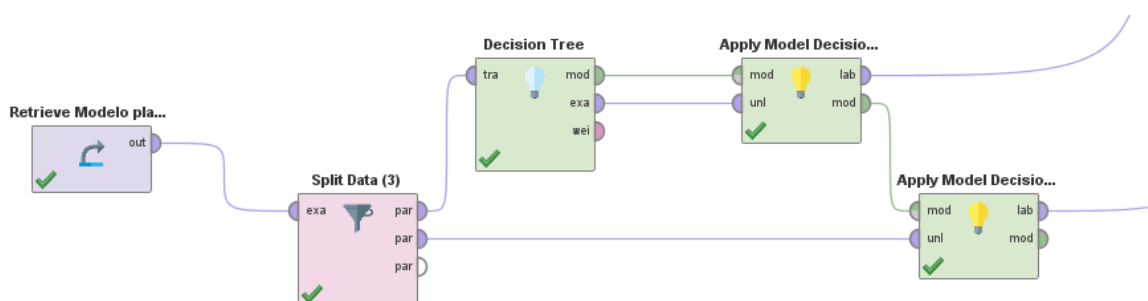
Nota. El siguiente gráfico indican el porcentaje de erro absoluto y error relativo.

Diseño del modelo Decision Tree

Otro de los diseños considerados para el análisis del modelo predictivo es el modelo de DECISION TREE, donde nos muestra la predicción del tipo de parada que se debe realizar a la maquinaria.

Figura 26

Diseño del modelo Decision Tree



Nota. El siguiente gráfico muestra el modelo Decision Tree.

Figura 27

Resultados del modelo Decision Tree

Row No.	COD. EQUIPO	TIPO DE PA...	prediction(TIPO DE PARADA)	confidence(Semanal)	confidence(Imprevista)	confidence(Mensual)	confidence(Anual)	confidence(Intermedia)	ACT
1	EQ10069	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101037
2	EQ10071	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101039
3	EQ10001	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101040
4	EQ10072	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101042
5	EQ10069	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101044
6	EQ10071	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101046
7	EQ10079	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101047
8	EQ10081	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101048
9	EQ10001	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101049
10	EQ10079	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101050
11	EQ10081	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101052
12	EQ10001	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101053
13	EQ10081	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101055
14	EQ10092	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101056
15	EQ10091	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101057
16	EQ10079	Semanal	Semanal	0.869	0.046	0.010	0.075	0.001	101058

Nota. El siguiente gráfico muestra los resultados el modelo Decision Tree.

Figura 28

Evaluación del rendimiento estadístico del modelo Decision Tree

absolute_error

absolute_error: 0.215 +/- 0.269

relative_error

relative_error: 21.51% +/- 26.92%


Nota. El siguiente gráfico indican el porcentaje de erro absoluto y error relativo.

Diseño del modelo naive bayes

El modelo Naive Bayes también es utilizado para predecir, es un clasificador de alto sesgo y de baja varianza, los casos de uso típico involucran la categorización de texto, spam, análisis de sentimientos y sistemas de recomendaciones.

Figura 29

Diseño del modelo Naive Bayes



Nota. El siguiente gráfico muestra el modelo Naive Bayes.

Figura 30

Resultados del modelo Naive Bayes

Row No.	COD. EQUIPO	TIPO DE PA...	prediction(TIPO DE PARADA)	confidence(Semanal)	confidence(Imprevista)	confidence(Mensual)	confidence(Anual)	confidence(Intermedia)	ACT
1	EQ10069	Semanal	Mensual	0.000	0	1.000	0	0	101037
2	EQ10070	Semanal	Mensual	0.000	0	1.000	0	0	101038
3	EQ10071	Semanal	Mensual	0.000	0	1.000	0	0	101039
4	EQ10001	Semanal	Mensual	0.000	0	1.000	0.000	0	101040
5	EQ10089	Semanal	Mensual	0.000	0	1.000	0	0	101041
6	EQ10072	Semanal	Mensual	0.000	0	1.000	0	0	101042
7	EQ10001	Semanal	Mensual	0.000	0	1.000	0	0	101043
8	EQ10069	Semanal	Mensual	0.000	0	1.000	0	0	101044
9	EQ10070	Semanal	Mensual	0.000	0	1.000	0	0	101045
10	EQ10071	Semanal	Mensual	0.000	0	1.000	0	0	101046
11	EQ10079	Semanal	Mensual	0.000	0	1.000	0	0	101047
12	EQ10081	Semanal	Mensual	0.000	0	1.000	0	0	101048
13	EQ10001	Semanal	Mensual	0.000	0	1.000	0	0	101049
14	EQ10079	Semanal	Mensual	0.000	0	1.000	0	0	101050
15	EQ10080	Semanal	Mensual	0.000	0	1.000	0	0	101051
16	EQ10081	Semanal	Mensual	0.000	0	1.000	0	0	101052

Nota. El siguiente gráfico muestra los resultados el modelo Naive Bayes.

Figura 31

Evaluación del rendimiento estadístico del modelo Naive Bayes

absolute_error

`absolute_error: 0.181 +/- 0.369`

relative_error

`relative_error: 18.10% +/- 36.88%`

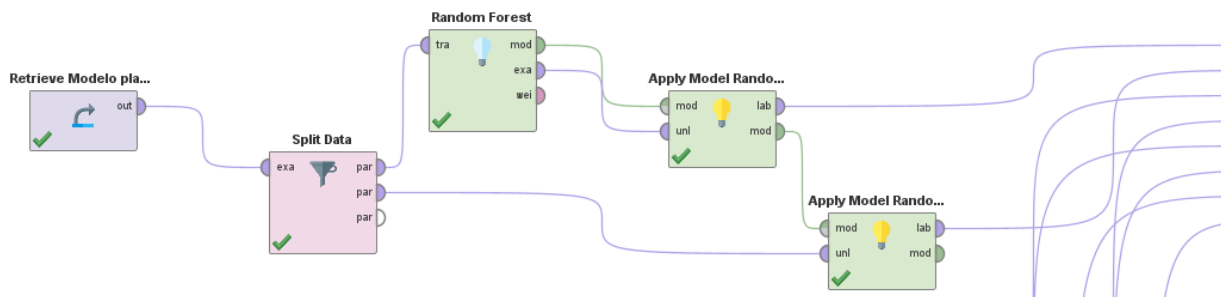
Nota. El siguiente gráfico indican el porcentaje de erro absoluto y error relativo.

Diseño del modelo random forest

El modelo Random Forest es un modelo de predicción que genera un modelo de bosque aleatorio que su uso es para la clasificación y regresión.

Figura 32

Diseño del modelo Random Forest



Nota. El siguiente gráfico muestra el modelo Random Forest.

Figura 33

Resultados del modelo Random Forest

Row No.	COD. EQUIPO	TIPO DE PARADA	prediction(TIPO DE PARADA)	confidence(Semanal)	confidence(Imprevista)	confidence(Mensual)	confidence(Anual)	confidence(Intermedia)	ACT
1	EQ10069	Semanal	Semanal	0.942	0.004	0.048	0.006	0.000	10103
2	EQ10070	Semanal	Semanal	0.942	0.002	0.053	0.003	0.000	10103
3	EQ10071	Semanal	Semanal	0.934	0.002	0.061	0.003	0.000	10103
4	EQ10001	Semanal	Semanal	0.941	0.003	0.047	0.008	0.000	10104
5	EQ10089	Semanal	Semanal	0.933	0.003	0.058	0.006	0.000	10104
6	EQ10072	Semanal	Semanal	0.942	0.002	0.053	0.003	0.000	10104
7	EQ10001	Semanal	Semanal	0.941	0.003	0.047	0.008	0.000	10104
8	EQ10069	Semanal	Semanal	0.942	0.004	0.048	0.006	0.000	10104
9	EQ10070	Semanal	Semanal	0.948	0.002	0.046	0.003	0.000	10104
10	EQ10071	Semanal	Semanal	0.934	0.002	0.061	0.003	0.000	10104
11	EQ10079	Semanal	Semanal	0.805	0.002	0.189	0.004	0.000	10104
12	EQ10081	Semanal	Semanal	0.944	0.002	0.050	0.004	0.000	10104
13	EQ10001	Semanal	Semanal	0.967	0.002	0.022	0.009	0.000	10104
14	EQ10079	Semanal	Semanal	0.965	0.002	0.027	0.006	0.000	10105
15	EQ10080	Semanal	Semanal	0.941	0.022	0.035	0.003	0.000	10105
16	EQ10081	Semanal	Semanal	0.941	0.015	0.041	0.003	0.000	10105

Nota. El siguiente gráfico muestra los resultados el modelo Random Forest.

Figura 34

Evaluación del rendimiento estadístico del modelo Random Forest

absolute_error

absolute_error: 0.068 +/- 0.117

relative_error

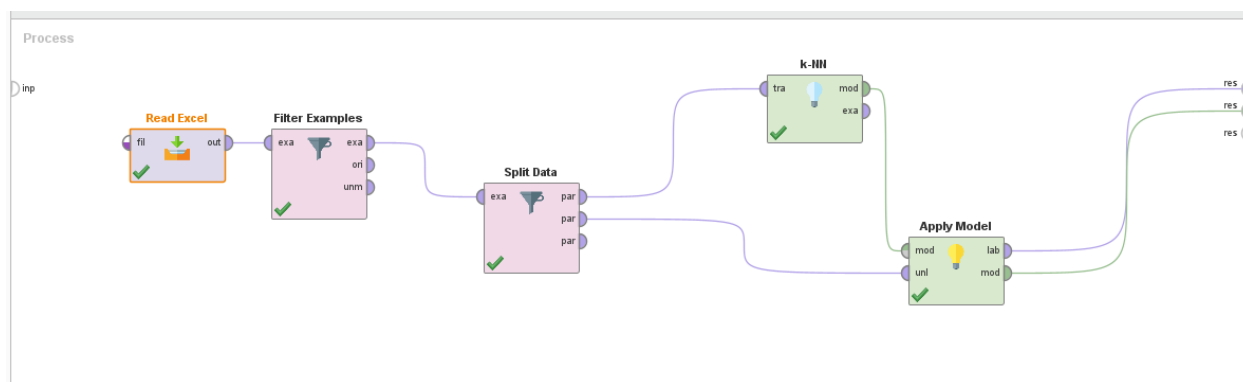
relative_error: 6.82% +/- 11.74%

Nota. El siguiente gráfico indican el porcentaje de erro absoluto y error relativo.

Diseño del modelo K-NN

Figura 35

Diseño del modelo K-NN



Nota. El siguiente gráfico muestra el modelo K-NN.

El diseño del modelo K-NN se utiliza para realizar la clasificación o regresión en este caso en el desarrollo del presente trabajo se utilizó el modelo para realizar una clasificación que permita la predicción tanto de los equipos que más se dañan, así como la agrupación de los daños más representativos que ocurren durante la producción.

Fase 5: Evaluación

Utilizando los datos del plan de mantenimientos se procedió a usar los diferentes modelos de predicción en la herramienta de analítica rapidminer. Los modelos utilizados fueron Deep Learning, Decision Tree, Naive Bayes, Random Forest con el objetivo de utilizar información histórica para establecer un modelo de mantenimiento predictivo y nos permita la reducción de costos.

Para la evaluación de los modelos de predicción se analizó cuál es el modelo más eficiente en base al análisis estadístico, analizando de cada modelo el acierto, la clasificación de error, así como error absoluto y relativo donde se obtuvo los siguientes resultados.

Tabla 9

Evaluación de los modelos de predicción

A predecir	Deep Learning			
	Accuracy	clasification error	Absolute error	Relative error
Tipo de parada	99.07%	0.93%	0.021 +/- 0.091	2.11% +/- 9.06%
A predecir	Decisión Tree			
	Accuracy	Clasification error	Absolute error	Relative error
Tipo de parada	88.11%	11.89%	0.0215% +/- 0.269%	21.51% +/- 26.92%
A predecir	Naive Bayes			
	Accuracy	Clasification error	Absolute error	Relative error
Tipo de parada	82.48%	17.52%	0.181% +/- 0.369%	18.10% +/- 36.88%
A predecir	Random Forest			
	Accuracy	Clasification error	Absolute error	Relative error
Tipo de parada	98.34%	1.66%	0.068 +/- 0.117	6.82% +/- 11.74%

Nota. La siguiente tabla muestra la evaluación de los modelos de predicción.

Donde podemos determinar que el modelo Deep Learning es el modelo más óptimo para la predicción de las futuras paradas de la maquinaria, el mismo que se utilizará para la implementación del modelo de mantenimiento predictivo.

El modelo Deep Learning nos determina una accuracy del 99.07%, una classification error del 0.93%, un absolute error del 0.021 +/- 0.091 y un relative error del 2.11% +/- 9.06%.

Fase 6: Implementación

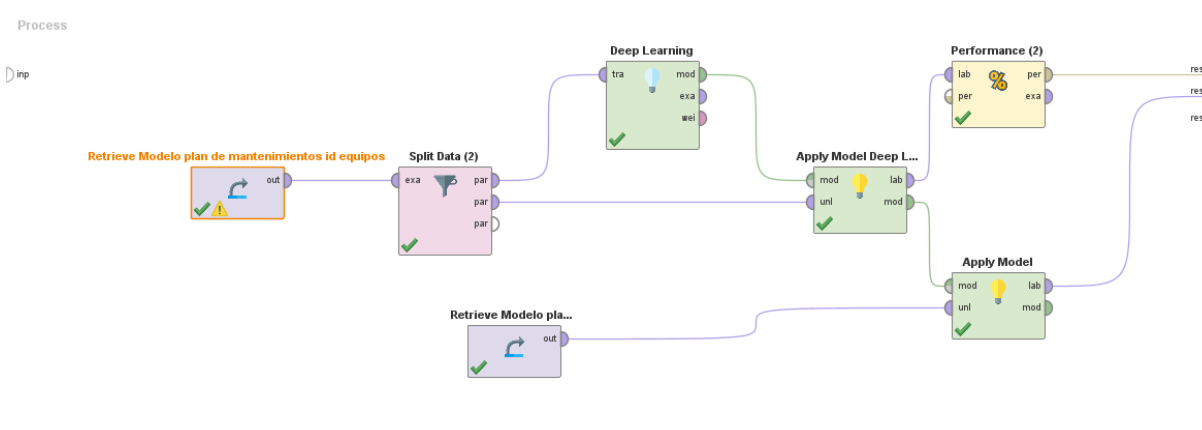
Una vez realizado todas las fases anteriores del tratamiento de datos se procede a la implementación del modelo más óptimo para la predicción de un mantenimiento efectivo.

Para la implementación del modelo desarrollado se utilizó nuevos datos, los mismos que no fueron parte del entrenamiento del modelo. Los nuevos datos se validaron y depuraron de la misma forma como se mencionó en la FASE N°3 para que puedan ser considerados en el modelo entrenado.

Los datos que se consideró para la implementación del modelo son de 1932 observaciones, datos suficientes que nos permitan predecir el tipo de mantenimiento que se debe realizar a las maquinas.

Figura 36

Implementación del modelo Deep Learning



Nota. El siguiente grafico muestra el diseño de la implementación del modelo Deep Learning.

Figura 37

Resultados de la implementación del modelo Deep Learning

Row No.	COD. EQUIPO	TIPO DE PARADA	prediction(TIPO DE PARADA)	confidence(Semanal)	confidence(Imprevista)	confidence(Mensual)	confidence(Anual)	confidence(Intermedia)	ACT
1	EQ10089	Semanal	Semanal	0.991	0.000	0.008	0.001	0.000	101264
2	EQ10093	Semanal	Semanal	0.989	0.000	0.009	0.001	0.000	101265
3	EQ10093	Semanal	Semanal	0.898	0.002	0.087	0.014	0.000	101265
4	EQ10101	Semanal	Semanal	0.998	0.000	0.002	0.000	0.000	101264
5	EQ10074	Semanal	Anual	0.025	0.060	0.031	0.884	0.000	101265
6	EQ10079	Semanal	Semanal	0.903	0.000	0.096	0.001	0.000	101266
7	EQ10080	Semanal	Semanal	0.674	0.001	0.319	0.005	0.000	101267
8	EQ10081	Semanal	Semanal	0.946	0.000	0.053	0.001	0.000	101266
9	EQ10091	Semanal	Semanal	0.999	0.000	0.001	0.000	0.000	101265
10	EQ10093	Semanal	Semanal	0.994	0.000	0.004	0.001	0.000	101270
11	EQ10093	Semanal	Semanal	0.999	0.000	0.001	0.000	0.000	101271
12	EQ10100	Imprevista	Mensual	0.430	0.016	0.488	0.066	0.000	101272
13	EQ10092	Semanal	Semanal	0.998	0.000	0.002	0.001	0.000	101273
14	EQ10094	Semanal	Semanal	0.859	0.011	0.106	0.024	0.000	101274
15	EQ10001	Semanal	Semanal	0.896	0.011	0.075	0.018	0.000	101275
16	EQ10079	Semanal	Semanal	0.902	0.000	0.096	0.001	0.000	101276

Nota. El siguiente grafico muestra los resultados del diseño de la implementación del modelo Deep Learning.

Los resultados que podemos identificar en la Figura N°36 es la predicción del tipo de parada que se debe realizar para cada una de las maquinarias, información que se utilizaría para poder ajustar la planificación de mantenimiento que realizan las áreas de esa forma poder organizar tanto el recurso humano como el uso de cada uno de los suministros que se necesitaran para los respectivos mantenimientos.

Figura 38

Exactitud de la implementación del modelo Deep Learning

accuracy: 86.18%

	true Semanal	true Imprevista	true Anual	true Intermedia	true Mensual	class precision
pred. Semanal	1500	87	21	4	84	88.44%
pred. Imprevista	5	125	0	0	0	96.15%
pred. Anual	34	11	4	0	6	7.27%
pred. Intermedia	0	0	0	0	0	0.00%
pred. Mensual	14	1	0	0	36	70.59%
class recall	96.59%	55.80%	16.00%	0.00%	28.57%	

Nota. El siguiente grafico muestra los resultados de exactitud del modelo implementado.

Los niveles de exactitud del modelo implementado poseen indicadores aceptables donde tenemos una exactitud del 86.18% del modelo implementado.

Figura 39

Clasificación del error de la implementación del modelo Deep Learning

classification_error: 13.82%

	true Semanal	true Imprevista	true Anual	true Intermedia	true Mensual	class precision
pred. Semanal	1500	87	21	4	84	88.44%
pred. Imprevista	5	125	0	0	0	96.15%
pred. Anual	34	11	4	0	6	7.27%
pred. Intermedia	0	0	0	0	0	0.00%
pred. Mensual	14	1	0	0	36	70.59%
class recall	96.59%	55.80%	16.00%	0.00%	28.57%	

Nota. El siguiente grafico muestra los resultados de error del modelo implementado.

Figura 40

Evaluación estadística de la implementación del modelo Deep Learning

absolute_error

`absolute_error: 0.166 +/- 0.324`

relative_error

`relative_error: 16.63% +/- 32.37%`

Nota. El siguiente gráfico indican el porcentaje de erro absoluto y error relativo.

Poseemos un error mínimo del 13.82% del cual es aceptable para poder considerar las predicciones establecidas en el modelo.

Una vez analizado la exactitud del modelo, así como la clasificación del error es de vital importancia analizar los resultados de los tipos de paradas que nos brinda el modelo de mantenimiento predictivo en base a la información analizada.

Tabla 10

Resumen de los datos reales del tipo de parada

N°	Tipo de parada	Número de paradas	Fracción
1	Semanal	1553	0.804
2	Imprevista	224	0.116
3	Mensual	126	0.065
4	Anual	25	0.013
5	Intermedia	4	0.002

Nota. La siguiente tabla muestra paradas reales que tuvo la industria.

Tabla 11

Resumen de los datos predictivos del tipo de parada

N°	Tipo de parada	Número de paradas	Fracción
1	Semanal	1696	0.877
2	Imprevista	130	0.067
3	Anual	55	0.028
4	Mensual	51	0.026
5	Intermedia	0	0

Nota. La siguiente tabla muestra la predicción del tipo de parada a presentarse en la producción.

Como podemos observar en las tablas N°10 disponemos de la información de los tipos de paradas reales que se realizó a los equipos, mientras que la tabla N°11 disponemos de la predicción del tipo de paradas aplicando el método Deep Learning que se debería realizar a los equipos.

La información más importante que podemos determinar en el modelo predictivo es la disminución de las paradas imprevistas de mantenimiento en un 40% con relación a los datos reales lo que permite en primer lugar realizar una planificación de mantenimientos de manera oportuna en base a los equipos que más daños disponen y a su vez un ahorro del costo de mantenimiento.

El modelo de predicción nos indica que la empresa debería aumentar en su planificación el número de paradas semanales, así como el número de paradas mensuales y anuales para la realización de los mantenimientos lo que ayudaría a ser una gestión de mantenimiento más oportuna permitiendo planificar el recurso humano, así como la planificación de repuestos que se necesitaría para el recambio de cada una de las maquinarias.

Al aplicar la analítica para el mantenimiento de las maquinarias de la empresa permite mejorar la productividad, aumentar el rendimiento de las maquinarias y reduciendo los tiempos de inactividad lo que genera pérdidas económicas y consumos de suministros y materiales incensarios.

Por lo cual para complementar al modelo de mantenimiento predictivo anteriormente indicado se ha desarrollado el análisis de los datos del registro de demoras aplicando un modelo de clasificación o regresión K-NN en base a los datos históricos del año 2022 que nos permita predecir mediante agrupaciones cuáles serán los equipos, así como los daños que se pueden presentar en las paradas de la producción que ayudaran a realizar la respectiva parada de mantenimiento.

Los datos fueron tratados anteriormente con la finalidad de poseer datos validados y la información que tengamos como resultado sea de gran utilidad y permita coadyuvar a la toma de decisiones.

Donde se obtuvo los siguientes resultados:

Tabla 12


Predicción de fallas por equipo

N°	Equipo	Número de fallas	Fracción
1	EAF	189	0.592
2	CCM	121	0.379
3	GRUAS	5	0.016
4	CARGA CESTAS	3	0.009
5	LF	1	0.003

Nota. La siguiente tabla muestra la predicción de fallas por equipo.

Figura 41

Predicción de daños o fallas por equipo




Nota. El siguiente grafico nos muestra la predicción de fallas por equipo.

En la Tabla 12 nos indica los equipos más críticos que posee la empresa dando con el 59% de que vuelva a fallar el equipo EAF seguido por el equipo CCM con un 37% que se debería revisar la bitácora de qué tipo de mantenimiento se les está brindando a los equipos, así como cada uno de sus componentes que comprende cada equipo.

Figura 42

Predicción de daños por equipo en base a los turnos



Nota. El siguiente grafico nos muestra la predicción de fallas por turnos.

Al realizar el análisis de los equipos con relación al turno de producción el en turno C es donde más concurrentes son las fallas del equipo EAF lo que es meritorio analizar las condiciones con las que se están desarrollando las actividades tanto del personal de mantenimiento como del personal que se encuentra en la producción para minimizar los daños de los equipos.

Tabla 13

Predicción de daños o fallas


N°	Equipo	Número de fallas real	Número de fallas (Predicción)	Fracción
1	HORNO EAF	28	60	0.190

N°	Equipo	Número de fallas real	Número de fallas (Predicción)	Fracción
2	BOVEDA	17	22	0.070
3	SUBESTACIÓN	16	19	0.060
4	OXICORTE CCM	13	18	0.057
5	LINGOTERAS	14	15	0.047
6	SILO DE CARBÓN	9	14	0.044
7	SENSOR DE NIVEL	6	13	0.041
8	ELEVADOR DE PALANQUILLA	8	11	0.035
9	COLUMNA BRAZO ELECTRICO	5	9	0.028
10	ENDEREZADORAS	7	8	0.025

Nota. La siguiente tabla muestra la predicción de daños por equipos con la aplicación del modelo K-NN.

Figura 43

Predicción de los daños o fallas



Nota. El siguiente grafico muestra la predicción de los equipos más representativos.

Lo que nos muestra la Figura 42 es que mediante la aplicación del modelo de K-NN tenemos los daños más representativos con alto impacto como es el Horno EAF seguido por los daños de la bóveda, daños en la subestación, perforación de paneles, oxicorte de CCM lo que es necesario establecer planes de mantenimientos semanales, anuales y de gran importancia, realizar la valoración cuando se realice la parada anual lo que ayudaría a minimizar el tipo de respuesta ante cualquier acontecimiento imprevisto.

Una vez analizado toda la información podemos demostrar que las industrias y más aún la industria del acero debe implementar la analítica para la realización de mantenimientos predictivos que permitan disminuir la inactividad de las maquinarias en horas de producción, el recambio de repuestos de una manera oportuna evitando tener paras imprevistas e incluso realizar una planificación de importación de repuestos.

Validación del modelo

Una vez implementado el modelo de mantenimiento predictivo procedemos a la validación donde identificaremos los parámetros que se consideró para la validación.

Los parámetros considerados para la validación del modelo están en función:

1. El tipo de industria a la que se está planteando el modelo mantenimiento ya que al ser una empresa siderúrgica cuenta con maquinaria, configuraciones que requieren métodos y procedimientos de mantenimiento completamente distintos a otras industrias.
2. El tipo de información que la empresa dispone para poder analizar y generar los mejores resultados.
3. El modelo se validó en base a los problemas y necesidades que posee la empresa para ser una industria altamente competitiva.

4. Se analizó los datos que mantiene la empresa dando respuesta a la hipótesis planteada en un inicio.

Ahora hablemos sobre los resultados que la compañía obtendría con la aplicación del modelo de mantenimiento predictivo.

Por temas de confidencialidad de la información que maneja la empresa al referirnos exclusivamente de costos no se indicara en el desarrollo del presente trabajo, pero si es factible analizar de forma macro los resultados que alcanzaría la empresa.

Por un lado, se tendía la disminución del 40% de las paradas imprevistas en el proceso de producción eso quiere decir la empresa disminuiría costos por perdida de energía eléctrica ya que al existir una para obligatoriamente al retornar operaciones necesita nuevamente el consumo de energía eléctrica para que las maquinarias estén calibradas y se empiece nuevamente el proceso de producción.

Al disminuir las paradas imprevistas permitiría a los supervisores de mantenimientos planificar de mejor forma su recurso humano y disminuir el número de horas hombre que necesitaría para nuevamente poner en funcionamiento las maquinarias.

Al tener identificado los futuros daños que puede presentarse en los equipos permite que los supervisores establezcan mantenimientos a los equipos más críticos, eliminando los mismos a equipos que no se consideran vulnerables o que pueda fallar durante el proceso de producción.

El modelo de mantenimiento predictivo permite que la empresa pueda realizar una planificación casi real de los repuestos que necesitarían para los futuros mantenimientos permitiendo tener disponibilidad y a su vez coordinar con oportunidad con los demás departamentos para que realicen la gestión de los mismos de forma anticipada.

Capítulo V

Conclusiones

El presente proyecto de investigación busca dar soluciones a una problemática en el manejo de los mantenimientos de la maquinaria en la empresa Acería del Ecuador C.A. ADELCA es así que se ha llegado a determinar que no se puede subestimar los tipos de mantenimientos que actualmente maneja la empresa como son el preventivo y correctivo, debido a que ha permitido el funcionamiento de las maquinarias de la empresa, sin embargo es importante que Acería del Ecuador C.A. ADELCA busque nuevas estrategias y mecanismos tecnológicos como es la industria 4.0 la cual pueda ser implementada en todas sus líneas de producción, lo que permitiría tener un ahorro de recursos humanos, económicos y un mejor mantenimiento de la maquinaria, con el objetivo de prolongar la vida útil de las mismas y la reducción de costos de mantenimiento.

En la investigación de literatura se define que a nivel mundial varias industrias del sector metalúrgico realizan mantenimientos predictivos utilizando diferentes tipos de algoritmos dándole tratamiento a los datos que la empresa disponen apoyándose con software de inteligencia de negocios que permita tener información valiosa, con la finalidad de mejorar la productividad y reducir los costos de producción como del mantenimiento.

El modelo de mantenimiento predictivo que se estableció en el presente proyecto de investigación es bajo la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) el cual permitió tener un manejo de datos referentes a los mantenimientos de la maquinaria, siendo este modelo flexible y personalizado donde se desarrolló distintos tipos de pruebas que nos ayude a desarrollar el modelo de mantenimiento predictivo idóneo para minimizar los costos de mantenimiento. Este modelo consta de seis fases: Fase 1 Comprensión del Negocio, Fase 2 Comprensión de los datos, Fase 3 Preparación de los datos, Fase 4 Modelado, Fase 5 Evaluación y Fase 6 Implementación.

En la implementación del modelo de mantenimiento predictivo se desarrolló cada una de las fases de la metodología CRISP-DM apoyado del software de inteligencia de negocios Rapidminer en la industria Acería del Ecuador C.A. ADELCA donde se analizó los datos que el área de fundición proporcionó y se utilizó diferentes algoritmos que permitió generar modelos de mantenimientos predictivos que facilite programar mantenimientos eficientes que ayuden a la planificación de las demás áreas como lo son el recambio de repuestos.

Con la aplicación de diferentes modelos de predicción en la herramienta Rapidminer se pudo determinar que el modelo DEEP LEARNING es el más óptimo llegando a demostrar que la empresa pueda analizar y ver la viabilidad de establecer mejores prácticas operativas con relación al mantenimiento de las maquinarias permitiendo aumentar el rendimiento de las mismas. El modelo de predicción nos permitió reducir los tiempos de inactividad, mejorar los planes de mantenimientos ayudándonos a ser más efectivos eficientes y eficaces, destinando recursos a maquinarias que son más críticas.

Recomendaciones

El presente proyecto de investigación busca ser una guía metodológica que sirva de base para seguir analizando otras áreas sensibles de la empresa Acería del Ecuador C.A. ADELCA donde se puede mejorar los distintos procesos mediante el tratamiento y análisis de datos los cuales permitirían a la empresa tomar las mejores decisiones en el tema de producción y costos.

Se recomienda utilizar algoritmos no considerados en el presente trabajo donde se evalué el rendimiento con los algoritmos y medir la eficiencia y eficacia de la problemática presentada en la industria del sector metalúrgico.

Al ser una industria del alto riesgo se recomienda implementar la instalación de sensores que permita recopilar la información de diferentes áreas con la finalidad de analizarlas que permita la toma de decisiones de manera oportuna.

Se recomienda a la empresa gestionar un sistema que permita recolectar la información de varios componentes instalados en la empresa que se podría utilizar para explotar esa información, debido a que actualmente se está desperdiciando oportunidades de mejora.

Se recomienda realizar un análisis de la rotación de repuestos de las áreas más críticas que posee la empresa para poder predecir su próximo requerimiento donde los técnicos puedan considerar esa información para la planificación de cada uno de sus mantenimientos.

Bibliografía

ADELCA. (s.f.). Obtenido de https://www.adelca.com/quienes_somos.html

Carlos Paiz Gatica, M. K. (2016). An Industrial Analytics Approach to Predictive Maintenance for Machinery Applications. *IEEE*, 1-4.

Documentation, R. (s.f.). Obtenido de

https://docs.rapidminer.com/10.1/studio/operators/modeling/predictive/bayesian/naive_bayes.html

E.Raducan, V. M. (2020). Prediction algorithms using specialized software tools for steel industry equipment. *IEEE*, 21-24.

Franziska Schäfer, C. Z. (2018). Synthesizing CRISP-DM and Quality Management: A Data Mining Approach for Production Processes. *IEEE*, 190-195.

Gartner, I. (2018). *IT Glossary*. Obtenido de <https://www.gartner.com/it-glossary/business-intelligence-bi>

Grupo IGN. (08 de Junio de 2016). *Grupo IGN*. Obtenido de Software de gestión:

<https://ignsl.es/que-no-es-business-intelligence/>

Helmer Muñoz, R. O. (2016). Inteligencia de los negocios. *Revista Clio America*, 194-211.

IBM CORPORACIÓN. (17 de 08 de 2021). Obtenido de <https://www.ibm.com/docs/it/spss-modeler/saas?topic=dm-crisp-help-overview>

Ing. Octavio Arias, J. Y. (s.f.). Sistema de Gestión de Mantenimiento.

KISAN SARDA, A. A. (2021). A Multi-Step Anomaly Detection Strategy Based on Robust Distances for the Steel Industry. *IEEE*, 53827-53837.

- Merkt, O. (2019). On the Use of Predictive Models for Improving the Quality of Industrial Maintenance: an Analytical Literature Review of Maintenance Strategies. *IEEE*, 693-704.
- Miguel A. Luna Pérez, G. V. (2019). Metodología de mantenimiento predictivo 4.0 para asegurar procesos de producción. *IEEE*, 1-6.
- Muhammad Farhan, I. A. (2019). The Prediction of Remaining Useful Life (RUL) in Oil and Gas Industry using Artificial Neural Network (ANN) Algorithm. *IEEE Conference on Big Data and Analytics (ICBDA)*, 7-11.
- Pérez Rondón, F. A. (2021). *Conceptos generales en la gestión del mantenimiento industrial*. Bucaramanga.
- PÉREZ, F. S. (s.f.). *BIG DATA*. Redexis Gas.
- Qiyao Wang, A. F.-K. (2018). What Maintenance is Worth the Money? A Data-Driven Answer. *IEEE*, 284-291.
- Rapidminer Documentation*. (s.f.). Obtenido de https://docs.rapidminer.com/10.1/studio/operators/modeling/predictive/trees/parallel_decision_tree.html
- Rapidminer Documentation*. (s.f.). Obtenido de https://docs.rapidminer.com/10.1/studio/operators/modeling/predictive/bayesian/naive_bayes.html
- Rapidminer Documentation*. (s.f.). Obtenido de https://docs.rapidminer.com/10.1/studio/operators/modeling/predictive/trees/parallel_random_forest.html

- Rapidminer. (s.f.). *Rapidminer Documentation*. Obtenido de https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/neural_nets/deep_learning.html
- Rapidminer. (s.f.). *Rapidminer Glossary*. Obtenido de <https://rapidminer.com/glossary/deep-learning/>
- Román, J. L. (2021). *Industria 4.0: la transformacion digital de la industria*. Conferencia de Directores y Decanos de Ingenieria Informatica.
- Serrano, G. (s.f.). Obtenido de <https://predictiva21.com/gestion-del-mantenimiento/>
- Universidad de Buenos Aires. (s.f.). *Industria de Maquinaria y Equipo. Programa Interdisciplinario para el Desarrollo*.
- Zaharah Allah Bukhsh, I. S. (2020). Predictive Maintenance for Infrastructure Asset Management. *IEEE*, 40-45.