



**Desarrollo de un modelo de estimación de inventario tecnológico mediante
analítica de datos para mejorar tiempos de respuesta ante incidentes**

Jara Bustillos, Johanna Cristina

Vicerrectorado de Investigación, Innovación y Transferencia de Tecnología

Centro de Posgrados

Maestría en Gestión de Sistemas de Información e Inteligencia de Negocios

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

Msc. Gualotuña Alvarez, Tatiana Marisol

15 de diciembre del 2021



TRABAJO_TITULACION_JARA V2.docx

Scanned on: 20:16 January 5, 2022 UTC



Overall Similarity Score



Results Found



Total Words in Text

Identical Words	626
Words with Minor Changes	96
Paraphrased Words	213
Ommited Words	1810



Website | Education | Businesses



VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y
TRANSFERENCIA DE TECNOLOGÍA
CENTRO DE POSGRADOS

CERTIFICACIÓN

Certifico que el trabajo de titulación, "**Desarrollo de un modelo de estimación de inventario tecnológico mediante analítica de datos para mejorar tiempos de respuesta ante incidentes**" fue realizado por la señorita **Jara Bustillos, Johanna Cristina** el mismo que ha sido revisado y analizado en su totalidad, por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 15 de diciembre 2021

Firma:



Gualotuña Álvarez, Tatiana Marisol

Director

C.C.: 1711498418



VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y
TRANSFERENCIA DE TECNOLOGÍA

CENTRO DE POSGRADOS

RESPONSABILIDAD DE AUTORÍA

Yo **Jara Bustillos, Johanna Cristina**, con cédula de ciudadanía n° 1719609396, declaro que el contenido, ideas y criterios del trabajo de titulación: **Desarrollo de un modelo de estimación de inventario tecnológico mediante analítica de datos para mejorar tiempos de respuesta ante incidentes** 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, 15 de diciembre 2021

Firma (s)

.....*Jara Johanna*.....

Jara Bustillos, Johanna Cristina

C.C.: 171960396



VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y
TRANSFERENCIA DE TECNOLOGÍA

CENTRO DE POSGRADOS

AUTORIZACIÓN DE PUBLICACIÓN

Yo **Jara Bustillos, Johanna Cristina** con cédula de ciudadanía n° 1719609396, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Desarrollo de un modelo de estimación de inventario tecnológico mediante analítica de datos para mejorar tiempos de respuesta ante incidentes** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolqui, 15 de diciembre 2021

Firma

.....*Jara Johanna*.....

Jara Bustillos, Johanna Cristina

C.C.: 171960396

Agradecimiento

Agradezco a Dios por poner en mi camino a todas las personas que hicieron posible este logro en mi vida.

Dedicatoria

Le dedico este trabajo a las personas que estuvieron a mi lado en este proceso, acompañándome.

Índice de Contenido

Hoja de resultados de la herramienta Urkund	2
Certificado del director	3
Responsabilidad de autoría	4
Autorización de publicación	5
Agradecimiento.....	6
Dedicatoria.....	7
Índice de Contenido	8
Resumen	15
Abstract	16
Capítulo I	17
Introducción	17
Antecedentes.....	17
Planteamiento del Problema.....	18
Objetivos	20
Objetivo General.....	20
Objetivos Específicos.....	20
Preguntas de Investigación.....	20
Hipótesis de investigación	21
Señalamiento de Variables	21
Justificación, importancia y alcance del proyecto.....	21
Capítulo II	23
Estado de arte y marco teórico	23
Estado del arte	23
Criterios de exclusión.....	23
Criterios de inclusión.....	23
Conclusiones de trabajos relacionados.....	29

Marco Teórico.....	30
Inteligencia de Negocios.....	30
Analítica de datos	31
Analítica predictiva.....	31
Modelos predictivos	31
Regresión.....	32
Árboles de decisión	32
Redes neuronales	32
Técnicas alternativas.....	32
ARIMA.	32
Holt Winters.	32
Análisis Bayesiano.....	33
Modelos de conjuntos	33
Respuesta incremental	33
K nearest neighbor (knn)	33
Cuadrados mínimos parciales.....	33
Máquina vectorial de soporte (SVM)	33
Minería de datos por series de tiempo	33
Sistema de inventario	33
Sistema de Inventario Perpetuo	34
Sistema de Inventario Periódico.....	34
Inventario.....	34
Tipos de inventario	34
Criterio de Elaboración de inventarios	36
Temporal	36
Cíclico o rotativo	36
Por familias.....	36

	10
Capítulo III	37
Desarrollo del proyecto	37
Fase 1: Revisión de requerimientos del negocio.....	37
Fase 2: Acceso y exploración de los datos	41
Selección del Algoritmo	48
Selección de la herramienta.....	49
Fase 3: Pre procesamiento de los datos.....	51
Fase 4: Diseño del modelo	61
Diseño de Regresión Lineal	61
Diseño de Holt Winters	65
Diseño de ARIMA	69
Fase 5: Implementación del modelo	75
Predicción de movimientos de AC/DCDV2 con Holt Winters.....	75
Predicción de movimientos de AC/DCDV1 con Regresión Lineal	77
Predicción de movimientos de FCU850V1 con Holt Winters	78
Predicción de movimientos de AC/DCDV3 con Holt Winters.....	78
Capítulo IV	80
Análisis de Resultados.....	80
Fase 6: Evaluación del modelo	80
Evaluación repuesto AC/DCDV2.....	80
Evaluación repuesto AC/DCDV1.....	81
Evaluación repuesto FCU850V1	82
Evaluación repuesto AC/DCDV3.....	83
Resumen de Resultados.....	84
Capítulo V	87
Conclusiones y Recomendaciones	87
Conclusiones	87
Recomendaciones.....	88
Bibliografía.....	89

Índice de Tablas

Tabla 1 <i>Grupos de Control</i>	24
Tabla 2 <i>Cadena de Búsqueda</i>	25
Tabla 3 <i>Tipos de inventarios por características físicas</i>	35
Tabla 4 <i>Tipos de inventarios por su naturaleza</i>	35
Tabla 5 <i>Objetivos de minería de datos y objetivos de negocio</i>	38
Tabla 6 <i>Riesgos del proyecto</i>	39
Tabla 7 <i>Fuentes de datos</i>	41
Tabla 8 <i>Campos de fuente de despacho de repuestos</i>	41
Tabla 9 <i>Campos de fuente de estaciones de telefonía</i>	42
Tabla 10 <i>Envíos de repuestos</i>	44
Tabla 11 <i>Uso y funcionamiento de repuestos</i>	45
Tabla 12 <i>Resumen de algoritmos</i>	48
Tabla 13 <i>Ponderación de las herramientas</i>	50
Tabla 14 <i>Rendimiento de los algoritmos</i>	75
Tabla 15 <i>Valor real vs predicción AC/DCDV2</i>	81
Tabla 16 <i>Valor real vs predicción AC/DCDV1</i>	82
Tabla 17 <i>Valor real vs predicción FCU850V1</i>	83
Tabla 18 <i>Valor real vs predicción AC/DCDV3</i>	84
Tabla 19 <i>Resumen de resultados</i>	85
Tabla 20 <i>Desviación (horas) de entrega de repuestos al técnico Año 2020</i>	85
Tabla 21 <i>Desviación (horas) de entrega de repuestos al técnico Año 2021</i>	86

Índice de Figuras

Figura 1 <i>Diagrama de espina de pescado</i>	19
Figura 2 <i>Metodología de investigación</i>	37
Figura 3 <i>Flujo para solvencia de incidencias</i>	40
Figura 4 <i>Cantidad de envío de repuestos</i>	43
Figura 5 <i>Despacho de AC/DCV2 2018-2020</i>	46
Figura 6 <i>Despacho de AC/DCV1 2018-2020</i>	46
Figura 7 <i>Despacho de FCU850V1 2018-2020</i>	47
Figura 8 <i>Despacho de AC/DCV3 2018-2020</i>	47
Figura 9 <i>Despacho de ACTPV3 2018-2020</i>	47
Figura 10 <i>Cuadrante mágico para Ciencia de Datos y ML 2021</i>	50
Figura 11 <i>Pre procesamiento de los datos</i>	52
Figura 12 <i>Read Excel</i>	53
Figura 13 <i>Select Attributes-Estaciones</i>	53
Figura 14 <i>Generate Attributes</i>	54
Figura 15 <i>Select Attributes-Repuestos</i>	55
Figura 16 <i>Date to Numerical</i>	56
Figura 17 <i>Resultado de Date to Numerical</i>	56
Figura 18 <i>Operador Join</i>	57
Figura 19 <i>Replace Infinite Values</i>	58
Figura 20 <i>Filtro 1</i>	58
Figura 21 <i>Operador Rename</i>	59
Figura 22 <i>Operador Aggregate y Set Role</i>	59
Figura 23 <i>Filtro Repuesto</i>	60
Figura 24 <i>Resultado Select Attributes</i>	60

Figura 25 <i>Diseño Modelo Regresión Lineal</i>	61
Figura 26 <i>Resultado modelo Regresión Lineal con datos prueba AC/DCDV2</i>	62
Figura 27 <i>Vector de rendimiento Regresión Lineal AC/DCDV2</i>	62
Figura 28 <i>Resultado modelo Regresión Lineal con datos prueba AC/DCDV1</i>	62
Figura 29 <i>Vector de rendimiento Regresión Lineal AC/DCDV1</i>	63
Figura 30 <i>Resultado modelo Regresión Lineal con datos prueba FCU850V1</i>	63
Figura 31 <i>Vector de rendimiento Regresión Lineal FCU850V1</i>	63
Figura 32 <i>Resultado modelo Regresión Lineal con datos prueba AC/DCDV3</i>	64
Figura 33 <i>Vector de rendimiento Regresión Lineal AC/DCDV3</i>	64
Figura 34 <i>Resultado modelo Regresión Lineal con datos prueba ACTPV3</i>	64
Figura 35 <i>Vector de rendimiento Regresión Lineal ACTPV3</i>	65
Figura 36 <i>Diseño Modelo Holt Winters</i>	65
Figura 37 <i>Parámetros Holt Winters</i>	66
Figura 38 <i>Resultado modelo Holt Winters con datos de prueba AC/DCDV2</i>	66
Figura 39 <i>Vector de rendimiento Holt Winters AC/DCDV2</i>	67
Figura 40 <i>Resultado modelo Holt Winters con datos de prueba AC/DCDV1</i>	67
Figura 41 <i>Vector de rendimiento Holt Winters AC/DCDV1</i>	67
Figura 42 <i>Resultado modelo Holt Winters con datos de prueba FCU850V1</i>	68
Figura 43 <i>Vector de rendimiento Holt Winters FCU850V1</i>	68
Figura 44 <i>Resultado modelo Holt Winters con datos de prueba AC/DCDV3</i>	68
Figura 45 <i>Vector de rendimiento Holt Winters AC/DCDV3</i>	69
Figura 46 <i>Resultado modelo Holt Winters con datos de prueba ACTPV3</i>	69
Figura 47 <i>Vector de rendimiento Holt Winters ACTPV3</i>	69
Figura 48 <i>Diseño Modelo ARIMA</i>	70
Figura 49 <i>Parámetros ARIMA</i>	71
Figura 50 <i>Resultado modelo ARIMA con datos de prueba AC/DCDV2</i>	71

Figura 51	<i>Vector de rendimiento ARIMA AC/DCDV2</i>	72
Figura 52	<i>Resultado modelo ARIMA con datos de prueba AC/DCDV1</i>	72
Figura 53	<i>Vector de rendimiento ARIMA AC/DCDV1</i>	72
Figura 54	<i>Resultado modelo ARIMA con datos de prueba FCU850V1</i>	73
Figura 55	<i>Vector de rendimiento ARIMA FCU850V1</i>	73
Figura 56	<i>Resultado modelo ARIMA con datos de prueba AC/DCDV3</i>	73
Figura 57	<i>Vector de rendimiento ARIMA AC/DCDV3</i>	74
Figura 58	<i>Resultado modelo ARIMA con datos de prueba ACTPV3</i>	74
Figura 59	<i>Vector de rendimiento ARIMA ACTPV3</i>	74
Figura 60	<i>Implementación de Holt Winters-AC/DCDV2</i>	76
Figura 61	<i>Resultado Holt Winters-AC/DCDV2</i>	76
Figura 62	<i>Implementación de Regresión Lineal-AC/DCDV1</i>	77
Figura 63	<i>Resultado Regresión Lineal-AC/DCDV1</i>	77
Figura 64	<i>Resultado Holt Winters-FCU850V1</i>	78
Figura 65	<i>Resultado Holt Winters-AC/DCDV3</i>	79
Figura 66	<i>AC/DCDV2 Enero-Junio 2021</i>	80
Figura 67	<i>AC/DCDV1 Enero-Junio 2021</i>	81
Figura 68	<i>FCU850V1 Enero-Junio 2021</i>	82
Figura 69	<i>AC/DCDV3 Enero-Junio 2021</i>	83
Figura 70	<i>Evolución de desviación (horas) de entrega de repuestos</i>	86

Resumen

La empresa Rhelec Ingeniería Cia. Ltda es proveedora de servicios de Telecomunicaciones, maneja la atención de mantenimientos correctivos, en los cuales, se requiere el reemplazo de dispositivos como rectificadores, caba, tarjetas controladoras, módulos, entre otros. La empresa tiene un deficiente control del inventario de repuestos, debido a que su control es manual, no es continuo y el abastecimiento de la bodega se realiza cuando se tiene un stock cero.

El presente proyecto tiene como objetivo desarrollar un modelo de estimación para la gestión de repuestos mediante herramientas de análisis de datos para mejorar los tiempos de repuesta ante incidencias. La metodología para utilizar se basa en el flujo propuesto por MathWorks para el análisis predictivo sumada la fase de comprensión del negocio de CRISP-DM, conformándose de 6 fases: revisión de requerimientos del negocio, acceso y exploración de los datos, pre procesamiento de los datos, diseño del modelo, implementación del modelo y evaluación del modelo.

Se definió el modelo con menor porcentaje de error para los repuestos con más nivel de rotación dentro de la bodega, determinando que Holt Winters es más preciso para AC/DCDV2, FCU850V1, AC/DCDV3 y la Regresión lineal para AC/DCDV1.

Como resultado de la implementación durante 3 meses de los modelos indicados, se obtuvo que el promedio de desviación en tiempos de entrega de repuestos al ingeniero de campo disminuyó a 1.88 horas, lo que indica que mediante los modelos de estimación se puede mejorar los tiempos de repuestos ante incidencias.

Palabras Clave:

- **MODELOS DE ESTIMACIÓN**
- **INVENTARIO TECNOLÓGICO**
- **REPUESTOS**
- **ALGORITMO**

Abstract

Rhelec Ingeniería Cia. Ltda is a provider of Telecommunications services, handles corrective maintenance and requires the replacement of devices such as rectifiers, cobs, controller cards, modules, among others. The company has a deficient control of the spare parts inventory, due to the fact that its control is manual, it is not continuous and the supply of the warehouse is carried out when there is a zero stock.

The objective of this project is to develop an estimation model for the management of spare parts using data analysis tools to improve response times to incidents. The methodology to be used is based on the flow proposed by MathWorks for predictive analysis added to the CRISP-DM business understanding phase, consisting of 6 phases: review of business requirements, access and exploration of data, pre-processing of the data, model design, model implementation and model evaluation.

The model with the lowest percentage of error was defined for the spare parts with the highest turnover level within the warehouse, determining that Holt Winters is more accurate for AC / DCDV2, FCU850V1, AC / DCDV3 and Linear Regression for AC / DCDV1.

As a result of the 3-month implementation of the indicated models, it was obtained that the average deviation in delivery times of spare parts to the field engineer decreased to 1.88 hours, which indicates that using the estimation models, delivery times can be improved. spare parts in incidents.

Key words:

- **ESTIMATION MODELS**
- **TECHNOLOGICAL INVENTORY**
- **SPARE PARTS**
- **ALGORITHM**

Capítulo I

Introducción

Antecedentes

Antiguamente, mantener un alto inventario correspondía a tener un alto capital. Posterior a ello se introdujo el término rotación del inventario como un indicador de eficiencia, sin embargo, su cálculo se realizaba de manera aislada sin contemplar el nivel de servicio a los clientes y los indicadores financieros de los inventarios. Actualmente, el inventario es considerado un riesgo para las empresas por la obsolescencia tecnológica, donde se tiene productos con un ciclo de vida corto, por lo que, las compañías tratan de implementar un ajuste estratégico que consiste en establecer una relación entre la economía, la administración de inventarios, la planeación de la producción, la satisfacción del cliente y la estrategia corporativa. (Vidal Holguín, 2010)

Las organizaciones se enfrentan al reto de pronosticar la demanda del inventario para reducir la incertidumbre al realizar la reposición de stock. La errónea predicción del inventario puede conducir a problemas de sobre almacenamiento o en su defecto, ocasionar un rápido agotamiento de las existencias produciendo la insatisfacción del cliente final. (Kreplak, 2018)

La gestión del inventario en las empresas de telecomunicaciones es un factor decisivo, ya que en ese proceso se administra los bienes que son utilizados en la actividad principal de la organización. (Morán Delgado & Coronel Gómez, 2016)

Mejorar la logística del inventario de repuestos mediante técnicas de análisis predictivo en empresas que ofertan el servicio de telecomunicaciones permite optimizar recursos materiales, capital humano, financiero y tiempo, mantener equilibrado los factores mencionados permiten el crecimiento de la organización, el cumplimiento de las metas y la satisfacción de los requerimientos del cliente, sin embargo, las empresas pueden presentar una reducción del 3% en sus ingresos anuales debido a la mala administración del stock. La optimización de la gestión de repuestos puede disminuir un 30% de los costos anuales del inventario debido a que mejora la rotación y el flujo de la operación. (Recalde Suárez, 2014)

Para la inadecuada planificación del abastecimiento del inventario se plantean soluciones que ayuden a gestionar la cadena de suministro, las mismas que implican un

análisis estadístico de los datos históricos correspondientes a movimientos de los insumos con el fin de elaborar predicciones con un mínimo error, para lo cual, se debe reconocer el patrón de los datos, establecer un modelo de pronóstico, evaluarlo y actualizarlo constantemente con valores reales de la empresa. (Barrenechea García & Félix, 2014)

Planteamiento del Problema

La empresa Rhelec Ingeniería Cia. Ltda es proveedora de servicios de Telecomunicaciones, maneja la atención de mantenimientos correctivos, en los cuales, se requiere el reemplazo de dispositivos como rectificadores, caba, tarjetas controladoras, módulos, entre otros.

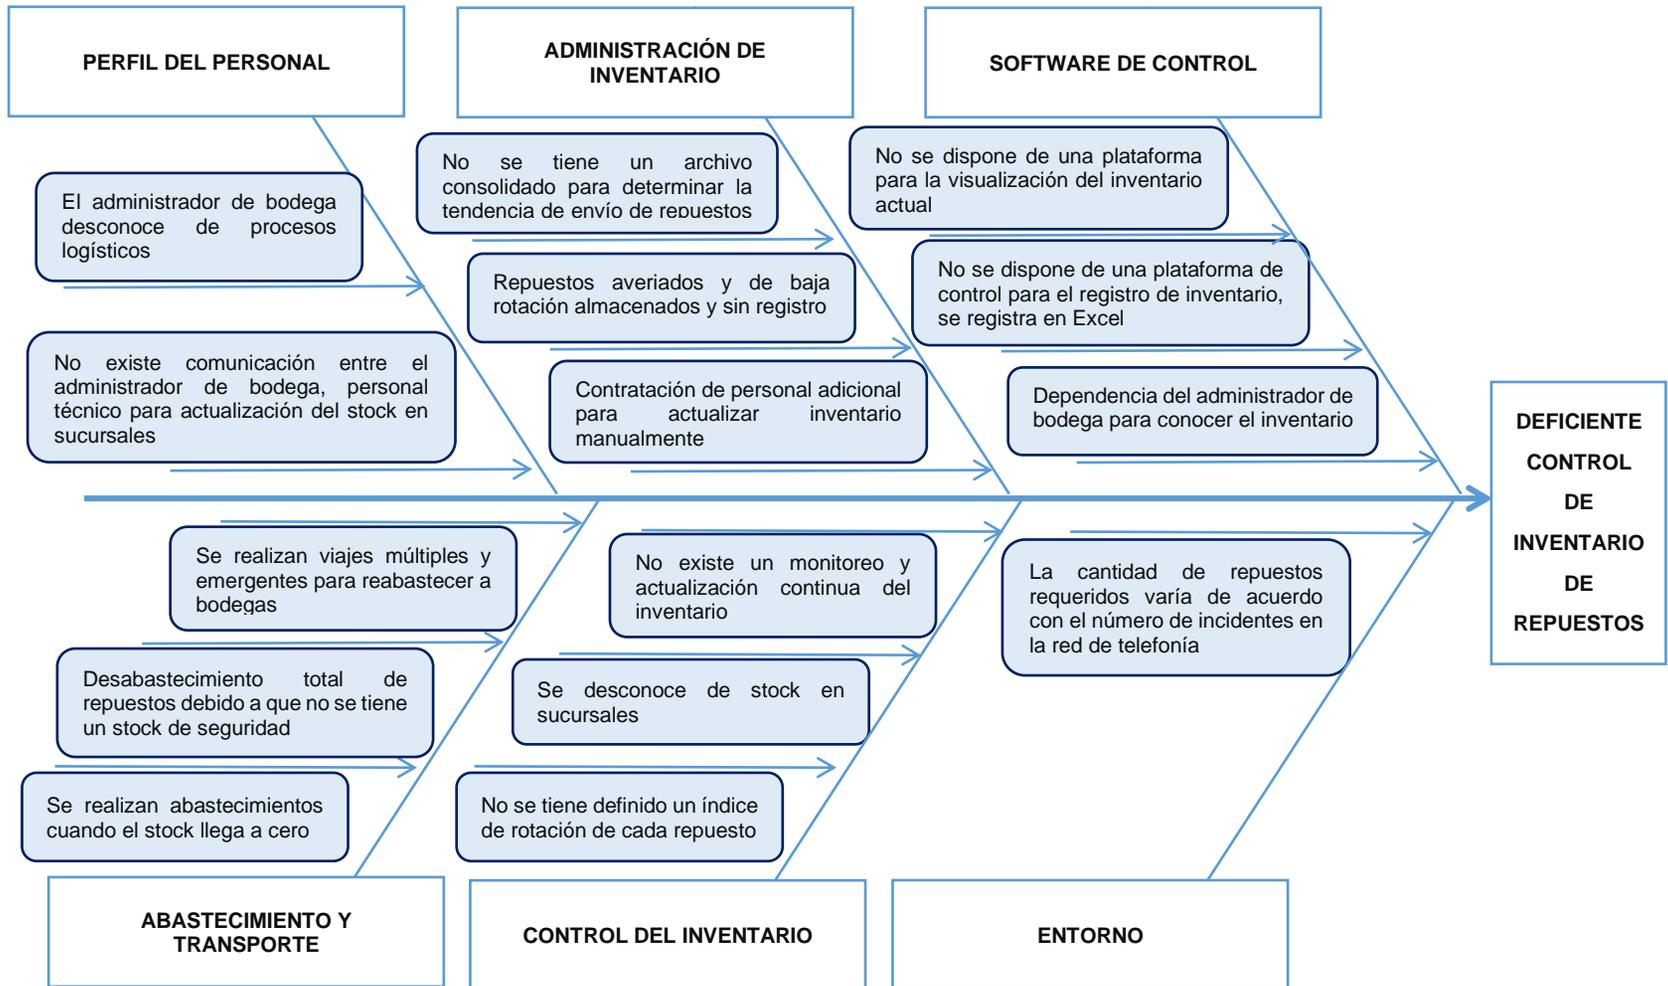
La empresa actualmente tiene un deficiente control del inventario de repuestos que se almacenan en la bodega debido a que no se dispone de un software de control y visualización del inventario, el registro se lo realiza en archivos Excel, al que tiene acceso únicamente el administrador de la bodega, esto implica demora en la obtención de información solicitada por la gerencia o el cliente.

La actualización del inventario no se realiza de manera continua y el proceso es manual, lo que conlleva a solicitar soporte del personal técnico para realizarlo, esto implica pagos adicionales y tiempos altos para realizar esta actividad.

Debido a que no se dispone de un archivo que consolide el historial de los movimientos de los repuestos desde la matriz hacia las sucursales, no se determina una tendencia o predicciones en base a modelos estadísticos sobre la cantidad con la que se debe abastecer la bodega, es por ello que se realizan abastecimientos cuando el stock de un determinado repuesto es nulo. El índice de rotación y el stock de seguridad de cada repuesto no se encuentran definidos, por lo cual, se producen desabastecimientos totales y al presentarse un incidente en la red de telefonía celular que requiera de un repuesto, se incurre en gastos de movilización, viáticos, y aumento del tiempo de solución para solventar el inconveniente. Los tiempos prolongados para la solución afectan al KPI “Desviación en tiempos de entrega de repuestos al ingeniero de campo”, que mantiene un promedio de 5 horas desde septiembre 2019 a abril 2020, incumpliendo el SLA de 2 horas, el tiempo elevado en la resolución de un evento es una causa para que el cliente sancione a la empresa proveedora con multas económicas y esto a su vez reduce la satisfacción del cliente final.

Figura 1

Diagrama de espina de pescado



Objetivos

Objetivo General

Desarrollar un modelo de estimación de gestión de repuestos para estaciones de telefonía móvil mediante herramientas de análisis de datos para mejorar los tiempos de respuesta ante incidencias.

Objetivos Específicos

- **OE1:** Realizar un análisis de literatura para identificar algoritmos de predicción de manejo de inventarios tecnológicos.
- **OE2:** Diseñar el modelo predictivo mediante el análisis de los datos del inventario de repuestos a través de estadística descriptiva.
- **OE3:** Implementar el modelo predictivo mediante herramientas de análisis de datos para determinar la tendencia del inventario tecnológico.
- **OE4:** Evaluar el modelo implementado para validar la mejora de los tiempos de respuesta ante incidencias.

Preguntas de Investigación

Se detallan las preguntas de investigación relacionadas a cada objetivo específico.

- **OE1-RQ1.1:** ¿Cuáles son los estudios existentes referentes al desarrollo de algoritmos de estimación de inventario?
- **OE1-RQ1.2:** ¿Cuáles son los algoritmos de estimación de inventario que se ajustan al contexto del problema planteado?
- **OE2-RQ2.1:** ¿Con qué recursos de la estadística descriptiva se visualiza mejor las características de los datos del inventario?
- **OE2-RQ2.2:** ¿Cuáles son las características de los datos del inventario que determinan el diseño del modelo predictivo?
- **OE3-RQ3.1:** ¿Cuál es la herramienta de análisis de datos que se utilizará para la implementación?

- **OE3-RQ3.2:** ¿La herramienta de análisis de datos seleccionada permite obtener una tendencia del inventario acorde a los requerimientos de la gestión de repuestos?
- **OE4-RQ4.1:** ¿Cuál es el nivel de confianza con el que va a trabajar el modelo de predicción?
- **OE4-RQ4.2:** ¿Cuál es la variación del tiempo de respuesta ante incidencias aplicando el modelo predictivo?

Hipótesis de investigación

El modelo de estimación de gestión de repuestos basado en analítica de datos minimiza los tiempos de respuesta ante incidentes.

Señalamiento de Variables

- Variable Independiente: modelo de estimación
- Variable Dependiente: tiempo de gestión de repuestos en incidentes

La demostración de la hipótesis se realizará mediante la evaluación del modelo de estimación implementado calculando los tiempos de respuesta ante incidentes y validando su mejora.

Justificación, importancia y alcance del proyecto

La empresa Rhelec Ingeniería Cia Ltda se enfoca en prestar servicios de operación y mantenimiento a compañías de telefonía celular, en las cuales se presentan incidentes que producen indisponibilidad de la red debido a la avería de elementos electrónicos, por tal motivo, la empresa mantiene dos bodegas principales, cuyo objetivo es almacenar los repuestos de tales elementos, sin embargo, se presenta un deficiente control del inventario, por lo cual, no se ha determinado índices de rotación ni tendencias de abastecimiento y al presentarse un evento en la red que requiera un repuesto, el mismo debe ser canalizado por un proveedor externo, lo que incrementa el tiempo de solución.

El presente trabajo de investigación, pretende implementar un modelo de gestión de repuestos mediante análisis de datos que permita mejorar el tiempo de respuesta ante eventos emergentes, dado que permitirá analizar el historial de los movimientos de los repuestos desde la matriz hacia las sucursales mediante estadística descriptiva, se podrá

determinar el stock de seguridad que debe mantener cada bodega para evitar el desabastecimiento total y así reducir los viajes emergentes que implica gastos de movilización y viáticos para la empresa proveedora.

Al determinar la tendencia del inventario y evitar tiempos prolongados de degradación total o parcial del servicio de telefonía celular, se mejora la satisfacción del cliente, ya que los mismos son de uso cotidiano tanto en la vida personal como empresarial.

Para medir el rendimiento del proceso que controla la gestión del inventario de repuestos la empresa utiliza el KPI "Desviación en tiempos de entrega de repuestos al ingeniero de campo". Debido a la deficiente gestión, desde septiembre 2019 hasta julio del presente año, se incumple el SLA de este indicador, debido a ello, se establece la evolución del indicador como métrica para evaluar la eficiencia de la implementación del modelo predictivo en el inventario en la empresa, para evitar multas por parte del cliente.

Capítulo II

Estado de arte y marco teórico

Estado del arte

Para realizar el estado del arte, se utilizaron criterios de inclusión y exclusión para proceder con la búsqueda en el repositorio Springer Link, el objetivo del estudio es responder a las preguntas de investigación de los objetivos específicos planteados.

Criterios de exclusión

- Artículos que no contengan modelos predictivos utilizados en inventario.
- Artículos que no utilicen estadística descriptiva para determinar las características de los datos.

Criterios de inclusión

- Se seleccionaron artículos en el idioma inglés.
- Artículos que contengan modelos predictivos para inventario.
- Artículos que mediante estadística descriptiva determinen las características del inventario.
- Artículos que contengan información referente a metodologías utilizadas para el desarrollo de modelos predictivos.
- Artículos que contengan herramientas de análisis de datos para desarrollar modelos predictivos.

En la Tabla 1 se presentan los grupos de control que cumplen con los criterios de inclusión:

Tabla 1*Grupos de Control*

Grupo de control	Título	Palabras Clave
EC1	Implementation of business intelligence, in the inventory of the GranSol Cooperative, with the Power BI tool	Inventory, Business Intelligence, Predictive Analytic, Trend, Stock
EC2	Proactive Supply Chain Performance Management with Predictive Analytics	Supply Chain, Predictive Analytics, Trend, Data Mining, Business Intelligence
EC3	Demand Forecasting of Short Life Cycle Products Using Data Mining Techniques	Trend, Predictive Analytic, Historical data, Demand, Algorithm, Data Mining, Clustering
EC4	Brief Application Description. Neural Networks Based Forecasting Techniques for Inventory Control Applications	Data Mining, Neural Networks, Inventory, Statistical techniques, Demand
EC5	Adaptive Inventory Control in Production Systems	Inventory, Stock, Artificial Intelligence, Neural Networks, Algorithm
EC6	A Web-Based Fuzzy Decision Support System for Spare Parts Inventory Control	Inventory, Algorithm, Stock, Decision Support
EC7	Supply Chain Business Intelligence: Technologies, Issues and Trends	Business Intelligence, Supply Chain, Data Mining
EC8	Application of Data Mining for Supply Chain Inventory Forecasting	Data Mining, Inventory, Business Intelligence, Supply Chain, Trend, Stock, Clustering, Algorithm, Neural Networks, Predictive Analytic

Para obtener la cadena de búsqueda se procedió a realizar el recuento de la repetición de las palabras clave en cada uno de los grupos de estudio, obteniéndose el siguiente resultado: (Inventory OR Stock) AND ((Data Mining) OR (Predictive Analytic)) AND (Algorithm)

Tabla 2

Cadena de Búsqueda

Contexto	Palabra Clave	Ec 1	Ec 2	Ec 3	Ec 4	Ec 5	Ec 6	Ec 7	Ec 8	Número de Repeticiones
Logística de inventario	Inventory	X			X	X	X		X	5
	Stock	X				X	X		X	4
	Supply Chain		X					X	X	3
	Demand			X	X					2
Inteligencia de negocios	Predictive Analytic	X	X	X					X	4
	Trend	X	X	X					X	4
	Data Mining		X	X	X			X	X	5
Algoritmos	Artificial Intelligence					X				1
	Clustering			X					X	2
	Neural networks				X	X			X	3
	Algorithm			X		X	X		X	4

Una vez realizada la búsqueda en Springer Link con la cadena de búsqueda indicada, se obtuvieron 46 resultados, considerando artículos y papers de conferencias, de los cuales se menciona los siguientes:

- **Implementation of business intelligence, in the inventory of the GranSol Cooperative, with the Power BI tool**

El proyecto presenta la implementación del análisis descriptivo y predictivo de la demanda de productos utilizando Power BI, detalla los requerimientos del negocio, el modelado de datos, proceso de ETL, explotación de los datos y presentación de resultados en donde llegaron a determinar los productos más vendidos, detalle por sucursales, tendencia y stock mediante la implementación de técnicas de series temporales utilizando el algoritmo de suavizado exponencial. (Bermeo & Campoverde, 2020)

- **Proactive Supply Chain Performance Management with Predictive Analytics**

El estudio presenta un modelo predictor de gestión del rendimiento de la cadena de suministro que combina el modelado de procesos, la medición del rendimiento, los modelos de minería de datos y las tecnologías del portal web en un modelo único. Además, demuestra el modelo de inteligencia empresarial semántica, el modelo de almacenamiento de datos con dimensiones, medidas y KPI específicos. Como resultado de la implementación del modelo, obtienen proyecciones precisas, información sobre tendencias, oportunidades y posibles problemas.

Los principales beneficios del estudio son: extrae valores adicionales de los repositorios de datos existentes, enfoque global para el rendimiento de la cadena de suministro, planificación basada en el conocimiento y desarrollo de estrategias, cadena de suministro predictiva y receptiva. (Listanti, 2014)

- **Demand Forecasting of Short Life Cycle Products Using Data Mining Techniques**

En el estudio los autores proponen el uso de algoritmos de agrupamiento como k-means y el clasificador de inducción RULES-6 para determinar la tendencia de la demanda de productos sin conocer datos históricos. El objetivo del proyecto es impulsar las operaciones y lograr una ventaja competitiva en empresas que tienen productos de ciclo de vida corto, considerando que la demanda es incierta, volátil y los métodos tradicionales no son efectivos, por lo que desarrollan diferentes métodos para realizar la estimación. El algoritmo implementado es evaluado con datos reales y se determina que tiene la capacidad de pronosticar con precisión las tendencias de nuevos productos. (Afifi, 2020)

- **Brief Application Description. Neural Networks Based Forecasting Techniques for Inventory Control Applications**

En el documento los autores buscan resolver los problemas de inventario en la empresa Retailcorp, rigiéndose en los 2 principios de la competencia: minimizar los inventarios de medicamentos y mejorar la satisfacción del cliente a través de la alta disponibilidad de artículos en stock. Para cumplir con su objetivo utilizan la regresión de datos históricos para calcular una estimación ajustada estacionalmente, describen el uso de técnicas estadísticas tradicionales para evaluar el mejor tipo de red neuronal, y, mediante técnicas de minerías de datos basadas en redes neuronales y descubrimiento de conocimiento desarrollan un nuevo sistema para la optimización del inventario. Como resultado, el inventario de Retailcorp que consta de más de mil millones de dólares en medicamentos se puede reducir en un 50% a cerca de medio billón de dólares, manteniendo el nivel de satisfacción del cliente original (95% nivel de disponibilidad). (Bansal & Gupta, 1998)

- **Application of Data Mining for Supply Chain Inventory Forecasting**

En el estudio los autores aplican herramientas de inteligencia de negocios para obtener información precisa del inventario de la cadena de suministro. De acuerdo a los patrones de ventas, en la fase de modelado, agrupan las tiendas de la cadena de suministro (clústeres), utilizan árboles de decisión y algoritmos de redes neuronales para pronosticar la falta de existencias del inventario a nivel de tienda o producto. (Stefanovic, Stefanovic, & Radenkovic, 2007)

- **Collaborative Predictive Business Intelligence Model for Spare Parts Inventory Replenishment**

El documento se basa en las aplicaciones de minería de datos para la gestión de inventario de la cadena de suministro. El objetivo del estudio es implementar un modelo semántico de BI colaborativo, para cumplir con el mismo, utilizan la tecnología de almacenamiento de datos y minerías de datos para proporcionar información oportuna para la toma de decisiones de gestión de inventario. Las herramientas utilizadas son SQL Server Integration Services para el proceso de ETL y QSL Server Analysis Service para la creación de cubos, dimensiones. La metodología presentada está diseñada para proporcionar predicciones fuera de

stock a nivel de ubicación/producto. El autor experimenta con un conjunto de datos reales de la industria automotriz obteniendo como resultado muy buena precisión y rendimiento del modelo. (Stefanovic, 2015)

- **Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín**

En el proyecto, se desarrolla un modelo predictivo como soporte al área de compras para la adquisición de medicamentos e insumos y evitar un agotamiento total del stock de medicinas y materiales, para ello, se realiza un análisis que considera la caducidad de productos, meses estacionarios de afluencia de pacientes, sobreabastecimientos, entre otros. Para realizar la selección del algoritmo, se explora los datos considerando los requerimientos del negocio y seleccionando las variables de las fuentes de información. Para la selección de la herramienta se evalúa las ventajas, costo, facilidad de instalación y uso, por lo que se define a Rapidminer como la óptima. Debido a la gran cantidad de insumos y medicamentos que maneja el hospital, para realizar el análisis, el autor selecciona uno de ellos para evidenciar su comportamiento de manera gráfica, en donde determina que la información es variable y se encuentra dispersa dentro de una línea de tiempo de un año, por lo cual opta por un algoritmo de series temporales acorde al comportamiento de los datos, posterior a ello, evalúa ARIMA, Random Forest y Holt Winters con distintas características de evaluación, obteniendo como resultado que Holt Winters es un método perdurable en el tiempo, dando como resultado valores de error entre 1.667 y 0.10. (Pillasagua Giler, 2019)

- **Análisis del comportamiento de la predicción de ventas con diferentes técnicas de minería de datos**

En el estudio se aplican modelos de predicción a los productos de una empresa abarrotera con el fin de mejorar el control del inventario y sus ventas. Para ello, analizan la muestra de la información, donde seleccionan los artículos con mayor movimiento, seleccionando como variables el número de ventas y el tiempo. El autor aplica diversas técnicas de minería de datos como series de tiempo (promedio móvil simple, suavización exponencial, suavización exponencial ajustada a la tendencia), regresión lineal y árboles aleatorios utilizando Excel. El objetivo de este estudio es realizar una comparativa de las técnicas y mediante el

cálculo del porcentaje de error, determinar el modelo que genere predicciones de ventas con mayor precisión. (Ramírez Moreno & Michel Nava, 2019)

Conclusiones de trabajos relacionados

Al realizar la revisión de literatura se identifica que una de las dificultades que enfrentan las empresas es el desconocimiento de su inventario, la falta de información obstaculiza la toma de decisiones en el negocio, por lo que buscan optimizar la gestión de su inventario, asegurando la disponibilidad del stock y de esa manera mejorar la satisfacción del cliente final y ser más competitivos. Por este motivo utilizan técnicas de series temporales implementando algoritmos de suavizado exponencial, regresión de datos históricos, ARIMA, Holt Winters, Random Forest, algoritmos de agrupamiento como K-means para determinar la tendencia del inventario, también se implementan árboles de decisión y redes neuronales para pronosticar la falta de las existencias.

Para la selección de la herramienta de minería de datos se evalúan características como el costo de la licencia, si es multiplataforma, complejidad de la interfaz, configuración e instalación, visualización de datos, conversión de datos, módulos de predicción y documentación en la web, en donde basados en dichas características recomiendan el uso de KNIME y RapidMiner

En organizaciones donde no se dispone datos históricos determinan que la combinación de los algoritmos k-means y Rules-6 es un enfoque válido y certero para la estimación de productos de ciclo de vida corto. Mediante la implementación de redes neuronales para optimizar el inventario, reducen el 50% del costo de adquisición manteniendo la satisfacción del cliente con 95% de disponibilidad de los productos. Se determina que al implementar dashboards interactivos que contenga información precisa, veraz y actualizada, se reduce el tiempo de generación de informes.

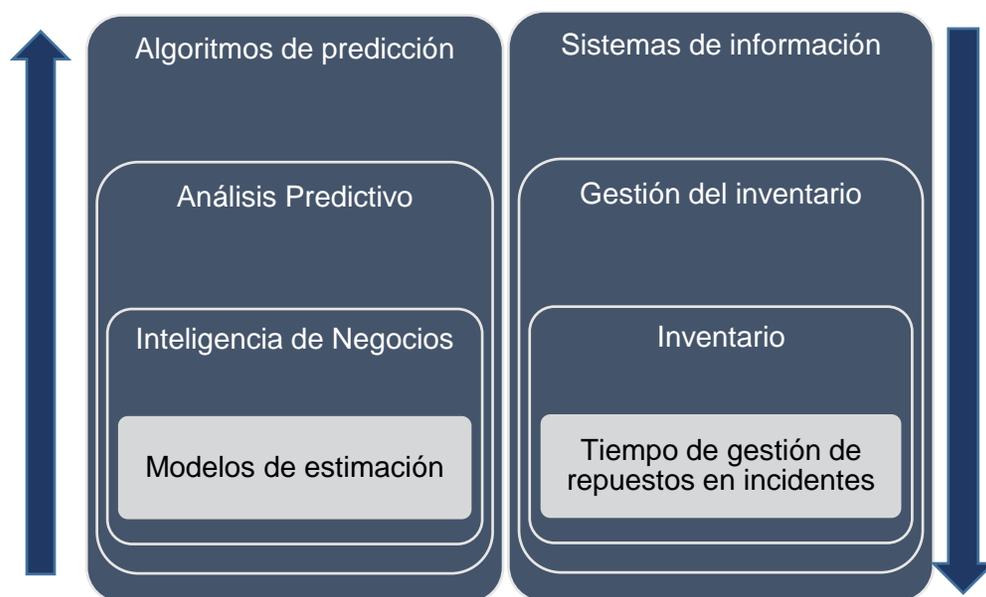
Para la etapa de la selección de la técnica de minería de datos, se realiza la exploración y perfilamiento de los datos, escogiendo un algoritmo que se ajuste al comportamiento de estos y que proporcione los mejores resultados. Sin embargo, de la revisión de literatura se extrae que, cuando se cuenta con muchos productos (superior a 200), insumos o materiales, el análisis se vuelve complejo y extenso, por lo cual, se opta por seleccionar productos al azar, usualmente aquellos que se encuentren en el top 10 de ventas o que presenten más movimiento en el inventario, por ende, en proyectos con

estas características, se aplica diferentes técnicas de minería de datos seleccionando aquella con menor porcentaje de error.

En la fase de evaluación de los algoritmos, utilizan técnicas estadísticas tradicionales para comprobar la eficiencia de las implementaciones como el cálculo del Error Porcentual Absoluto Medio (MAPE).

Marco Teórico

El fundamento teórico se basa en la hipótesis en conjunto con su variable dependiente e independiente, se presentan los temas de estudio, de acuerdo con la siguiente jerarquía:



Inteligencia de Negocios

La inteligencia de negocios engloba a los métodos y procesos de recopilación, almacenamiento, análisis de datos de actividades de las organizaciones para optimizar el rendimiento de sus operaciones mediante una visión integral que permita orientar de forma correcta las decisiones de los directivos. Mediante su implementación se puede visualizar datos históricos y actuales para analizar la evolución del negocio, permite identificar áreas de la empresa en donde se puede obtener mayores ganancias, analizar

el comportamiento del cliente, proveedores y competidores, tendencias del mercado y determinar problemas en la empresa. (Tableau Software, 2020)

Analítica de datos

La analítica de datos es el proceso en el que se examinan conjuntos de datos para extraer conclusiones sobre la información que contienen, con el objetivo de mejorar y agilizar las decisiones de las organizaciones. (IBM, 2019)

La analítica de datos se puede dividir en enfoque de datos cualitativos y cuantitativos, en donde se centran en la comprensión del contenido como texto imágenes, audio o video y en datos numéricos que se pueden medir estadísticamente, correspondientemente.

Analítica predictiva

La analítica predictiva es utilizada para identificar la probabilidad de resultados futuros basado en el análisis de datos históricos mediante el uso de algoritmos y técnicas de aprendizaje automático para reducir riesgos, optimizar operaciones y aumentar ingresos. (SAS Institute Inc, 2019)

Los usos más frecuentes de la analítica predictiva es la detección de fraude, optimización de campañas de marketing, mejoramiento de operaciones y reducción de riesgos. En los bancos y servicios financieros implementan analítica predictiva en sus procesos para calcular el riesgo crediticio y retención de clientes, en empresas de retail para determinar la efectividad de promociones y análisis del comportamiento de clientes, en el área de petróleos, gas y servicios públicos para anticipar fallas en equipos, en el gobierno y sector público es utilizada para entender tendencias poblacionales y en el área de manufactura para identificar factores que influyan en la calidad y fallos de la producción.

Modelos predictivos

Los modelos predictivos utilizan métodos matemáticos y de cálculo para predecir un evento o resultado en base a los cambios de las entradas del modelo, se desarrolla mediante conjuntos de datos de entrenamiento y prueba para validar la precisión, proceso que es iterativo debido a que, en base a los resultados se ajustan los parámetros de configuración del modelo hasta conseguir la efectividad del modelo. (The MathWorks, 2020)

La efectividad del modelo depende del algoritmo, el lenguaje de programación y las fuentes de datos. Las técnicas más utilizadas para el modelo predictivo son la regresión, árboles de decisión y redes neuronales.

Regresión. La regresión es utilizada para determinar la relación entre variables. Mediante la regresión lineal se utiliza una variable independiente para predecir el comportamiento de la variable dependiente. La regresión múltiple utiliza dos o más variables independiente. A través de la regresión logística se predicen variables desconocidas a partir de una variable discreta con base en el valor conocido de otras variables. En la regresión logística binaria la variable de respuesta puede ser 0 o 1, mientras que en la regresión logística múltiple puede tener varios valores como bajo, medio alto, o a su vez, 1, 2 y 3.

Árboles de decisión. Los árboles de decisión generan particiones de los datos en subconjuntos en base a las categorías de las variables de entrada, es un modelo de clasificación, las ramas del árbol representan una elección entre las alternativas. Para este modelo se establecen condiciones que pueden llegar a producirse para obtener una respuesta o decisión. El modelo determina las variables que dividen los datos en grupos con las mayores diferencias. El modelo es eficiente cuando el problema presenta datos faltantes.

Redes neuronales. Las redes neuronales es una técnica avanzada para modelar relaciones extremadamente complejas, puede gestionar relaciones no lineales en los datos, es utilizada para confirmar hallazgos de técnicas como la regresión o árboles de decisión y cuando no se dispone de una fórmula matemática que relacione las variables de entradas. Modelan parámetros de forma gráfica basándose en el reconocimiento de patrones.

Técnicas alternativas.

ARIMA. Autoregressive Integrated Moving Average, es un modelo utilizado para pronosticar series de tiempo. Está definido por los parámetros de orden p , d , q , en donde p especifica el número de términos autorregresivos, d indica el número de diferencias aplicadas a los valores de la serie temporal y q especifica el número de términos de media móvil.

Holt Winters. Es un método de pronóstico que utiliza el suavizado exponencial triple para los componentes de nivel, tendencia y estacional. Está definido por los

parámetros alfa, beta y gamma. En donde alfa es el coeficiente para el suavizado de nivel, beta indica el coeficiente para el suavizado de tendencia y gamma especifica el coeficiente para el suavizado estacional. Tiene dos variantes, estacionalidad aditiva y multiplicativa. En la aditiva, cada temporada cambia en un número constante y en la multiplicativa cada temporada cambia por un factor.

Análisis Bayesiano. en este modelo se inicia con una creencia previa relacionada a la distribución de probabilidad de un parámetro desconocido, éstos se definen como variables aleatorias y a la probabilidad como grado de creencia.

Modelos de conjuntos. en este modelo se entrenan diversos modelos similares, se combinan sus resultados con el objetivo de mejorar la precisión, reducir la parcialidad, la varianza e identificar el modelo más eficiente.

Respuesta incremental. se denominan modelos de elevación neta o elevación ascendente, son utilizados para reducir las mezclas y descubrir los efectos de diferentes programas de marketing.

K nearest neighbor (knn). es un método no paramétrico de clasificación y regresión que predice valores o membresías de clase de un objeto.

Cuadrados mínimos parciales. se utiliza para modelar datos que presentan relaciones entre las entradas y sus resultados incluso si las entradas están correlacionadas y son ruidosas. Busca factores que expliquen variaciones de repuesta y predictores.

Máquina vectorial de soporte (SVM). utiliza algoritmos de aprendizaje asociados para analizar datos y reconocer patrones, es una técnica de aprendizaje supervisado.

Minería de datos por series de tiempo. utilizan la recopilación de datos que tienen el tiempo como variable para analizarlo en intervalos, combina técnicas tradicionales para generar pronósticos.

Sistema de inventario

Un sistema de inventarios es un conjunto de normas, métodos y procedimientos aplicados de manera sistemática, su objetivo es controlar el nivel de existencias de los materiales y productos que se emplean en una empresa. (Recalde Suárez, 2014)

Existen dos tipos de sistemas de inventario: perpetuo y periódico.

Sistema de Inventario Perpetuo

El sistema de inventario perpetuo conocido como sistema de punto de reorden (Reorder Point System) o sistema de cantidad de pedido fijo mantiene un registro y revisión continuo del inventario, permite llevar el control del inventario de un artículo para determinar si es necesario un nuevo pedido. La revisión del inventario se realiza con una frecuencia constante, permite a la organización tomar una decisión acerca de la posición de inventario del artículo para medir la capacidad de satisfacer la demanda futura.

Un sistema de inventario perpetuo automatizado prepara un nuevo pedido de abastecimiento cuando el inventario es demasiado bajo. Para el cálculo de la posición de inventario se emplea la siguiente formula:

Posición de inventario = Inventario disponible + Recepciones Programadas – Pedidos aplazados.

$$IP = OH + SR - BO$$

Sistema de Inventario Periódico

El sistema de inventario periódico no mantiene un registro continuo del inventario disponible, es decir, cada cierto tiempo constante la empresa solicita una cantidad variable de producto. El sistema de inventario periódico permite el coteo físico real del inventario disponible, de esta manera, la organización puede determinar el costo del inventario final.

Inventario

La Real Academia Española define al inventario como el asiento de los bienes y demás cosas pertenecientes a una persona o comunidad, hecho con orden y precisión. (Real Academia Española, 2020)

El proceso de control y gestión de inventarios debe establecer tres parámetros: frecuencia de revisión del estado del inventario, cuándo y con qué cantidad realizar una solicitud para el abastecimiento de existencias.

Tipos de inventario. La administración de los inventarios depende del tipo o naturaleza del negocio y del proceso productivo que se utilice (Crespín Castillo, 2018), los tipos de inventarios se detalla a continuación:

Tabla 3*Tipos de inventarios por características físicas*

Tipo	Detalle
Inventarios de materia prima o insumos	Es el inventario de los materiales que no han sido modificados por el proceso productivo de las empresas, Ejemplo: En una tapicería su inventario de materia prima o insumos está conformado por: Madera, barniz, clavos, tela etc.
Inventarios de materia semielaborada o productos en proceso	Son aquellos materiales que han sido modificados por el proceso productivo de la empresa, pero que todavía no son aptos para la venta. Ejemplo: Ensambladora de vehículos tienen como inventario asientos de cuero
Inventarios de productos terminados	Son aquellos donde se contabilizan todos los productos que van a ser ofrecidos a los clientes y se encuentran aptos para la venta.
Inventario en Transito	Se utilizan con el fin de sostener las operaciones para abastecer los canales que conectan a la empresa con sus proveedores y sus clientes, respectivamente.
Inventarios de materiales para soporte de las operaciones, o piezas y repuestos	Son los productos que, aunque no forman parte directa del proceso productivo de la empresa, es decir no serán colocados a la venta, hacen posible las operaciones productivas de la misma, estos productos pueden ser: maquinarias, repuestos, artículos de oficinas, etc.

Tabla 4*Tipos de inventarios por su naturaleza*

Tipo	Detalle
Inventario manufactura	de Materias primas - Partes, Materiales en proceso- Ensamblados y Subensamblados. Productos terminados completos y refacciones o repuestos
Inventarios conservación y mantenimiento	de Refacciones: Herramientas: Partes de máquinas: Equipos: Lubricantes: Artículos de limpieza: Artículos de ferretería: Materiales de consumo general

Tipo	Detalle
Inventarios de artículos de oficina	Papelería: Formas impresas, Artículos de consumo general.
Inventarios de activos fijos	Maquinaria y Equipo; Muebles, Terrenos, Edificios, Transportes, otros. Estos inventarios no son consumibles por lo que se controlan de manera diferente a los inventarios de consumo general.

Criterio de Elaboración de inventarios. Para determinar el método de gestión y control del inventario que permita optimizar el stock se consideran criterios como temporalidad, rotación, clasificación por familias o ubicación del almacén. (López Montes, 2014)

Temporal: el stock depende de la entrada y salida de las existencias, la frecuencia de medición determina las variaciones de flujo y la capacidad del almacenamiento, pudiendo ser anual, mensual, semanal, diario.

Cíclico o rotativo: está basado en la dimensión que mide el grado de renovación de las mercancías, pudiendo ser de alta, media o baja rotación.

Por familias: se utiliza cuando se realiza un inventario global de la empresa y al presentarse un error, con este método de agrupación se puede encontrar de manera más fácil un error o la ausencia de un artículo.

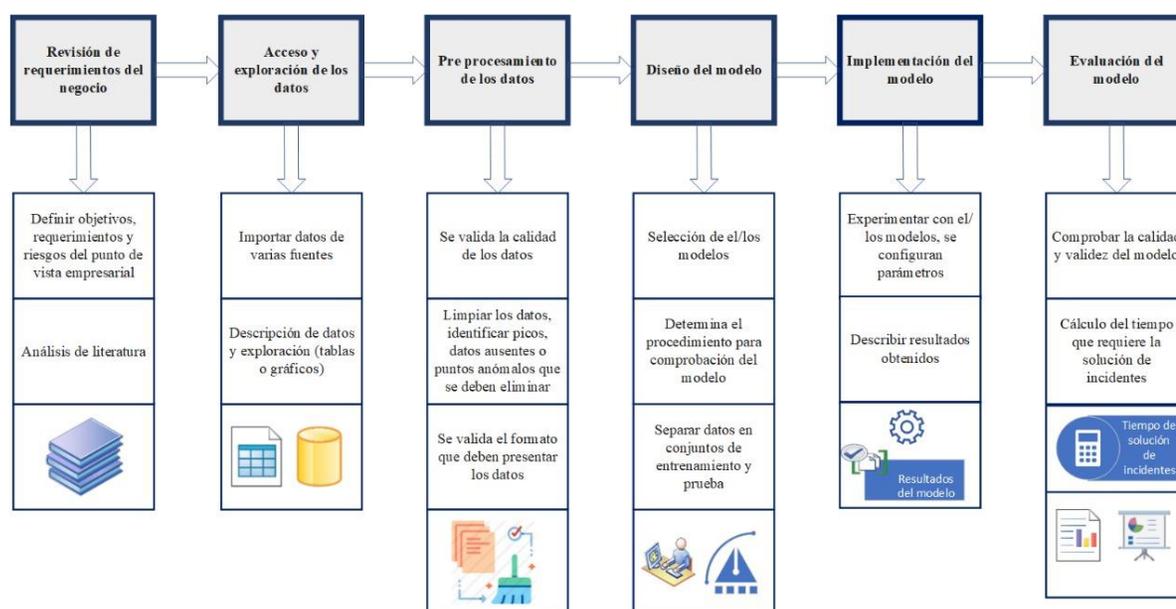
Capítulo III

Desarrollo del proyecto

La metodología planteada para el presente proyecto está basada en el flujo de trabajo para el análisis predictivo propuesto por MathWorks (The MathWorks, 2020), se agrega la fase de Comprensión del negocio de la metodología de CRISP-DM (Nisbet, Miner, & Yale, 2018), dando como resultado 6 fases que engloban a los objetivos específicos de la investigación, las cuales se detallan a continuación:

Figura 2

Metodología de investigación



Fase 1: Revisión de requerimientos del negocio

Se exploran las expectativas de la organización para comprender los objetivos y requisitos del proyecto desde la perspectiva empresarial para enlazarlos a las tareas del proceso de minería de datos, así como los riesgos asociados.

Tabla 5*Objetivos de minería de datos y objetivos de negocio*

Objetivo de minería de datos	Atributos	Indicador de éxito	Conjunto de Datos (Dataset)	Objetivo de negocio
Diseñar e implementar un modelo predictivo para determinar la tendencia del inventario tecnológico.	Mediciones de cantidad y tipo de repuestos utilizados en los centros de mantenimiento.	Reducción en el número de envíos de repuestos desde la matriz hacia los centros de mantenimiento.	Conjunto de datos con la cantidad de envíos realizados por encomienda y con personal técnico.	Reducir el costo de la operación (solvencia del incidente) debido al envío de repuestos en viajes emergentes.
Evaluar el modelo implementado para validar la mejora de los tiempos de respuesta ante incidencias.	Mediciones del tiempo que conlleva desde el inicio del incidente hasta el cambio del repuesto con el cierre del incidente.	Reducción del tiempo de respuesta ante incidentes.	Conjunto de datos con fechas de inicio y fin de incidentes.	Mejorar la satisfacción del cliente con la reducción del tiempo para la solución de incidentes.

Debido a que el cumplimiento de los objetivos del negocio puede verse afectados por factores externos, se procede con la evaluación de los riesgos para la ejecución del proyecto, su probabilidad de ocurrencia en base a la experiencia y se detalla un plan para mitigar sus efectos en la Tabla 6.

Tabla 6*Riesgos del proyecto*

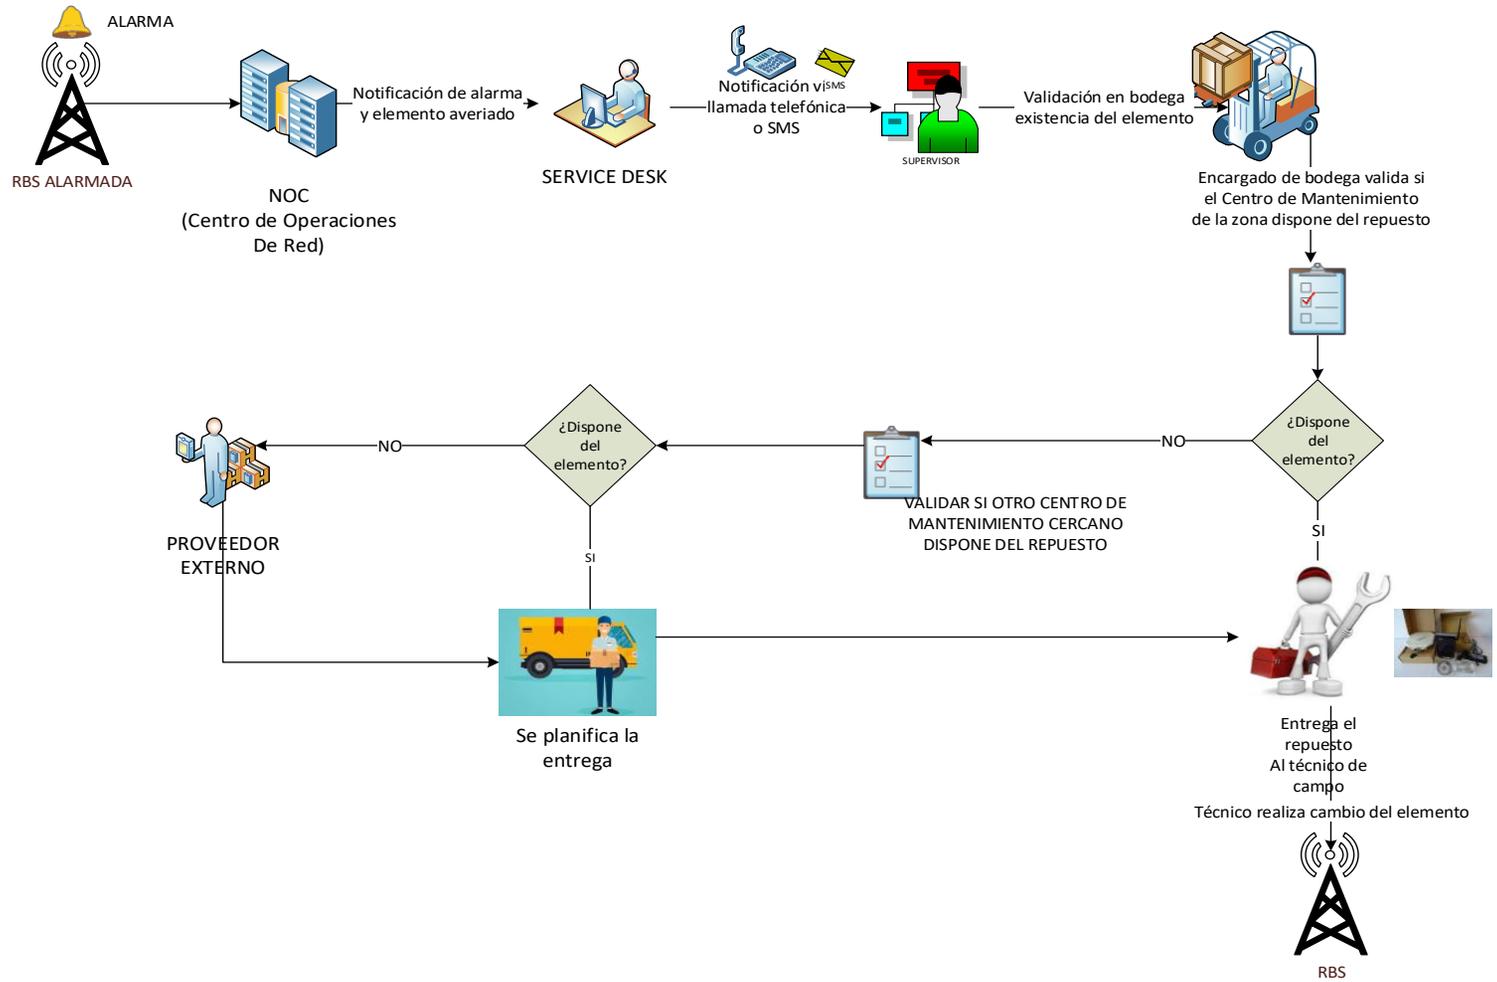
Riesgo	Probabilidad	Plan
No obtener el stock necesario para abastecer las bodegas, ya que el cliente es quien provee los repuestos y existe dependencia.	Alta	Contactar al cliente y facilitar los valores obtenidos para el abastecimiento de stock
Provean repuestos averiados o mal reparados, ya que existen modelos que no cuentan con línea de fabricación.	Media	Solicitar que en las bodegas principales se disponga de un laboratorio para probar el funcionamiento de los repuestos previo al envío a los centros de mantenimiento.

De acuerdo con lo mencionado en el Planteamiento del Problema, la empresa tiene su giro de negocio en las Telecomunicaciones, atendiendo eventos correctivos en las estaciones de telefonía móvil, mismos que pueden requerir o no de un repuesto. Por ello, se detalla un diagrama de flujo en la Figura 3, donde se puede visualizar la secuencia para la resolución de un incidente desde su inicio que consta de las siguientes actividades:

- Notificación de la alarma en la radio base al supervisor a través del NOC y Service Desk.
- Validación de la existencia del repuesto en la bodega del centro de mantenimiento.
- En el caso de disponerlo, el técnico de campo realiza el cambio en la radio base.
- En el caso de no disponerlo, se valida si el mismo existe en otro centro de mantenimiento cercano o con un proveedor externo, se planifica la entrega al técnico de campo y posterior a ello realiza el reemplazo correspondiente en la radio base.

Figura 3

Flujo para solvencia de incidencias



Fase 2: Acceso y exploración de los datos

Se importan los datos de las fuentes, tales como archivos web, bases de datos y hojas de cálculo. Se realiza una descripción de los datos considerando la cantidad, calidad, estado de los datos disponibles y tipos de valores. Se exploran los datos mediante tablas y gráficos.

Las fuentes de datos provienen de archivos Excel proporcionados por el área que maneja la bodega de repuestos de la empresa, se detallan a continuación:

Tabla 7

Fuentes de datos

Nombre del archivo Excel	Descripción
ASIGNACION_DE_ESTACIONES_POR_CENTRO_DE_MANTENIMIENTO	El archivo contiene la distribución de las estaciones de telefonía móvil celular asignadas a cada centro de mantenimiento
DESPACHO_DE_REPUESTOS	El archivo contiene el detalle del movimiento de los repuestos a cada centro de mantenimiento

A continuación, se describe los campos que contiene cada archivo fuente.

Tabla 8

Campos de fuente de despacho de repuestos

Campo	Descripción	Tipo de dato
AÑO	Año en que se realiza el cambio del repuesto	Texto
TYPE	Tipo de repuesto y tecnología a la que afecta en la estación	Texto
PART NUMBER	Número de parte del repuesto	Texto
SERIAL NUMBER (S/N) IN	Número de serial del repuesto	Texto
DESCRIPTION	Nombre genérico o comercial del repuesto	Texto

Campo	Descripción	Tipo de dato
QTY	Cantidad de repuestos utilizados	Texto
INBOUND DATE	Fecha de ingreso del repuesto a la bodega principal	Fecha
OUTBOUND DATE	Fecha de salida del repuesto de la bodega principal	Fecha
REQ. BY	Nombre de la persona que solicita el repuesto	Texto
SITE NAME	Nombre de la estación en la que se realizará el cambio del repuesto	Texto
DELIVERY TO	Nombre de la persona a la que se entrega el repuesto	Texto
DAMAGED S/N	Serial del repuesto averiado retirado de la estación	Texto
DAMAGED HW INBOUND DATE	Fecha en la que se realiza el reemplazo del repuesto en la estación	Fecha

Tabla 9

Campos de fuente de estaciones de telefonía

Campo	Descripción	Tipo de dato
CODIGO	Código único que identifica a la estación de telefonía celular	Texto
REGION	Disposición geográfica: norte o sur del Ecuador	Texto
NOMBRE ESTRUCTURA	Nombre de identificación de la estación	Texto
TIPO DE SITIO PLIEGO TECNICO	Clasificación de la estación por su criticidad	Texto
LATITUD	Coordenada geográfica latitud	Decimal
LONGITUD	Coordenada geográfica longitud	Decimal

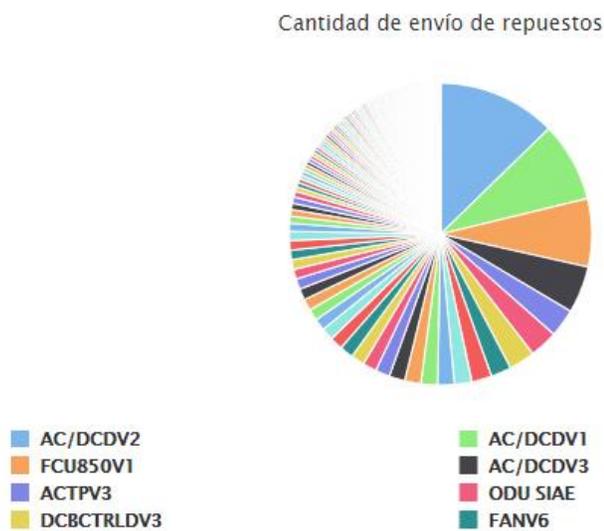
Campo	Descripción	Tipo de dato
TIPO ESTRUCTURA	Clasificación de la estación por su estructura física	Texto
TIPO CONSTRUCCION	Clasificación de la estación de acuerdo con el área de construcción	Texto
PROVINCIA	Provincia donde está ubicada la estación	Texto
CIUDAD	Ciudad donde está ubicada la estación	Texto
CENTRO DE MANTENIMIENTO	Descripción del centro de mantenimiento encargado de la estación	Texto
ESTADO	Descripción del estado de operatividad de la estación	Texto

La fuente denominada DESPACHO_DE_REPUESTOS contiene la información del movimiento de repuestos desde Enero del 2018 hasta Diciembre del 2020. En sus registros se hallaron 223 variantes de repuestos tecnológicos que se almacenan en las bodegas.

Debido a la excesiva cantidad de variedades, se realizará un análisis de aquellos repuestos cuyos envíos o movimientos sean frecuentes y significativos.

Figura 4

Cantidad de envío de repuestos



En la Figura 4 que detalla la cantidad de repuestos enviados desde Enero 2018 hasta Diciembre 2020 a los distintos centros de mantenimiento, los repuestos con más demanda debido a las notificaciones de alarmas que presentan las estaciones de telefonía móvil celular son: rectificadores, tarjetas de alarmas, tarjetas de control, ventiladores y módulos de tecnologías 2G, 3G, 4G.

En la Tabla 10 se detalla el tipo de repuesto, la cantidad de envíos realizados durante los 3 años y el porcentaje del total general.

Tabla 10

Envíos de repuestos

Descripción	Cantidad de envío	% Cantidad de envíos
AC/DCDV2	916	12,87%
AC/DCDV1	605	8,50%
FCU850V1	500	7,03%
AC/DCDV3	360	5,06%
ODU SIAE	218	3,06%
ACTPV3	216	3,04%
DCBCTRLDV3	201	2,82%
FANV6	158	2,22%
COBA 4P12V1	151	2,12%
BPK1	132	1,85%
IDU SIAE	130	1,83%
FSME	127	1,78%
FXCB	123	1,73%
COSA 4P12V1	122	1,71%
FDUAMCO 850V1	110	1,55%
COBA 4P12V3	106	1,49%
ECU 850V3	104	1,46%
FRCA	104	1,46%
FDUAMCO 850V2	100	1,41%
ZXSDR R8860E GU858	96	1,35%
ZXSDR R8882 S1900	90	1,26%

Descripción	Cantidad de envío	% Cantidad de envíos
DCBCTRLDV1	89	1,25%
COBA 4P12V2	89	1,25%
RECTIFICADOR ZXD 2400	88	1,24%
RECTIFICADOR 1500	82	1,15%
MODULO OPTICO	75	1,05%
FRCB	75	1,05%

Se omite el resto de los datos de la tabla, debido a que su movimiento es menor al 1% del total general.

De aquellos repuestos cuyos movimientos superan el 3%, se realizará una descripción de su uso y funcionamiento dentro de la estación de telefonía móvil celular.

Tabla 11

Uso y funcionamiento de repuestos

Descripción	Uso y funcionamiento
AC/DCDV2	Rectificador Siemens V2. Características de ingreso: 110/220 V AC. Características de salida: 30 A, 48 V DC. Al averiarse un rectificador, la carga es repartida entre los rectificadores funcionales y al sobrepasarla, estos tienden a averiarse, provocando intermitencias en la red de telefonía celular.
AC/DCDV1	Rectificador Siemens V1. Características de ingreso: 110/220 V AC. Características de salida: 30 A, 48 V DC. Esta versión se caracteriza por tener un switch de encendido y apagado.
FCU850V1	Módulo de transmisión de 2G. Frecuencia de funcionamiento: 850 MHz. Realiza la transmisión y recepción de la señal de los datos correspondiente a un sector. Cuando el módulo está averiado y no dispone de back up, la calidad del servicio degrada en su totalidad dentro del sector.
AC/DCDV3	Rectificador Siemens V3. Características de ingreso: 110/220 V AC. Características de salida: 40 A, 48 V DC.
ACTPV3	Tarjeta Siemens. La tarjeta controla la interconexión de racks y el funcionamiento de alarmas de la estación. Al averiarse, las alarmas quedan deshabilitadas, por lo cual no se puede monitorear la estación.

Se realiza la exploración de los datos del inventario a través de estadística descriptiva mediante un análisis gráfico de los 5 repuestos que presentan más movimiento en su inventario, se agrupa los repuestos por el mes correspondiente a la fecha de salida del repuesto de la bodega principal debido a que la solicitud para el abastecimiento se debe realizar mensualmente para optimizar los gastos de movilización.

Figura 5

Despacho de AC/DCV2 2018-2020

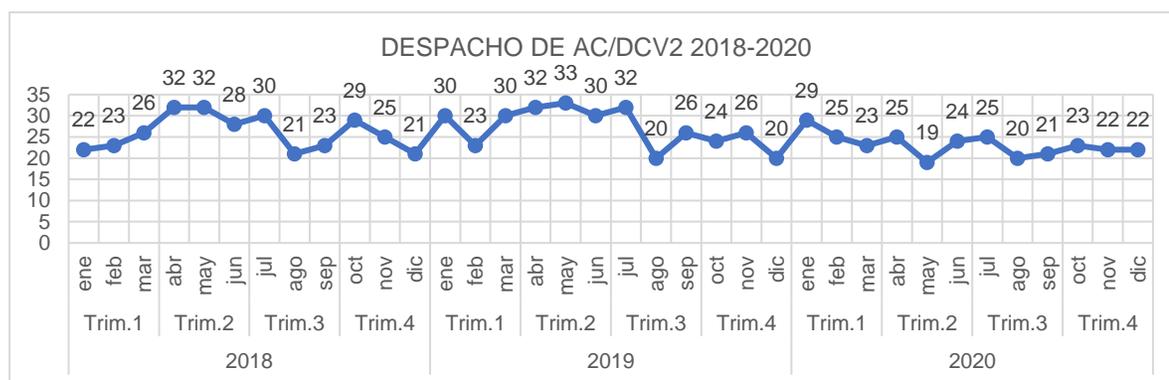


Figura 6

Despacho de AC/DCV1 2018-2020

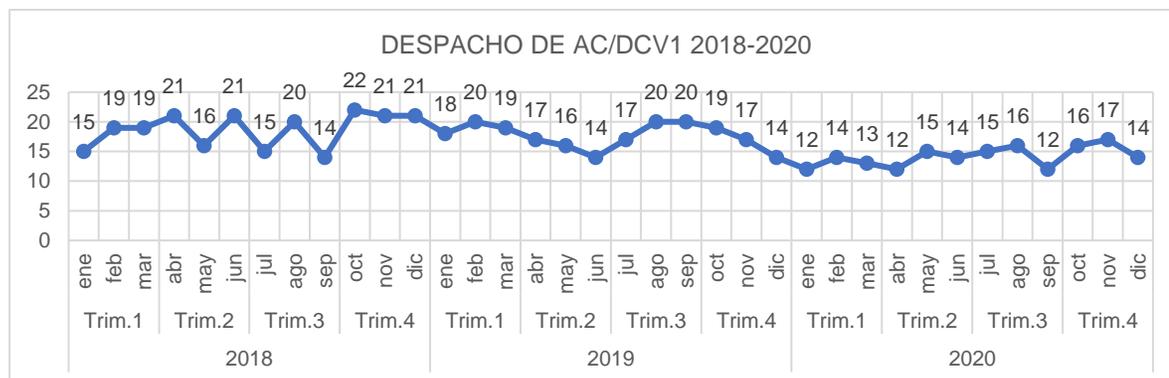
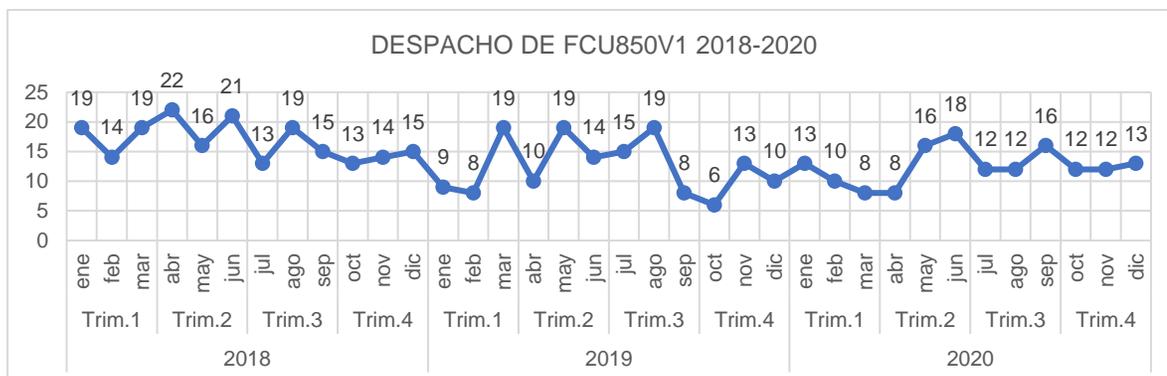


Figura 7*Despacho de FCU850V1 2018-2020***Figura 8***Despacho de AC/DCV3 2018-2020***Figura 9***Despacho de ACTPV3 2018-2020*

Selección del Algoritmo

Como se puede observar en la Tabla 12 se presenta un resumen de los algoritmos analizados en el Estado del Arte, en el que se indica que los más utilizados para realizar predicciones de productos son las variaciones de las series temporales, regresión lineal y árboles de decisión. Sin embargo, como resultado de la exploración gráfica de los datos, se obtiene que la información varía a lo largo del tiempo y se encuentra agrupada por meses a lo largo de 3 años de recopilación de movimientos de repuestos, en donde las variables imperativas son la cantidad de envíos por mes y mes de despacho del repuesto, por lo que se utilizará técnicas como: regresión lineal, ARIMA y Holt Winters de acuerdo con el comportamiento de los datos y al análisis de la literatura descrito en el capítulo anterior, en donde recomiendan realizar una comparativa de las técnicas para evaluar cuál de ellas se adapta a los diferentes repuestos a ser evaluados, debido a que se presenta una variedad de 223.

Tabla 12

Resumen de algoritmos

Algoritmo	Cantidad de trabajos	Trabajos relacionados
Series temporales	4	<ul style="list-style-type: none"> • Implementation of business intelligence, in the inventory of the GranSol Cooperative, with the Power BI tool • Brief Application Description. Neural Networks Based Forecasting Techniques for Inventory Control Applications • Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín • Análisis del comportamiento de la predicción de ventas con diferentes técnicas de minería de datos
Regresión lineal	3	<ul style="list-style-type: none"> • Brief Application Description. Neural Networks Based Forecasting Techniques for Inventory Control Applications • Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín • Análisis del comportamiento de la predicción de ventas con diferentes técnicas de minería de datos

Algoritmo	Cantidad de trabajos	Trabajos relacionados
Arboles de decisión	3	<ul style="list-style-type: none"> • Application of Data Mining for Supply Chain Inventory Forecasting • Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín • Análisis del comportamiento de la predicción de ventas con diferentes técnicas de minería de datos
ARIMA	1	<ul style="list-style-type: none"> • Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín
Holt Winters	1	<ul style="list-style-type: none"> • Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín

Selección de la herramienta

Para realizar la selección de la herramienta, una de las bases es el Cuadrante Mágico de Gartner mostrado en la Figura 10.

Se evaluará: RapidMiner, KNIME, Mathworks seleccionadas debido al conocimiento sobre las mismas y dado que en la revisión de los trabajos relacionados las recomiendan previo análisis del costo de la licencia, complejidad de la interfaz, configuración e instalación, visualización de datos, conversión de datos, módulos de predicción y documentación en la web. Para ello, se realizará una ponderación sobre las características mencionadas.

Figura 10

Cuadrante mágico para Ciencia de Datos y ML 2021



Source: Gartner (March 2021)

Tabla 13

Ponderación de las herramientas

	RapidMiner	KNIME	Mathworks
Costo accesible	4	4	2
Interfaz Sencilla	5	5	3
Facilidad configuración e instalación	4	4	1

	RapidMiner	KNIME	Mathworks
Módulos de Predicción	5	4	5
Documentación en la WEB	5	4	3
Conocimientos previos	5	5	5
Total	28	26	19

Los algoritmos seleccionados serán implementados mediante la herramienta RapidMiner debido a su puntuación obtenida y ventajas como la licencia libre, su interfaz amigable, la facilidad para su configuración e instalación, factibilidad para realizar el proceso ETL, amplia documentación y conocimientos previos sobre el manejo.

Fase 3: Pre procesamiento de los datos

Se verifica la calidad de los datos, se identifican picos, valores perdidos o puntos anómalos que se deben eliminar. Se realiza la limpieza de los datos mediante la eliminación de valores atípicos o errores. Se valida si los datos requieren aplicar un formato concreto o clasificación.

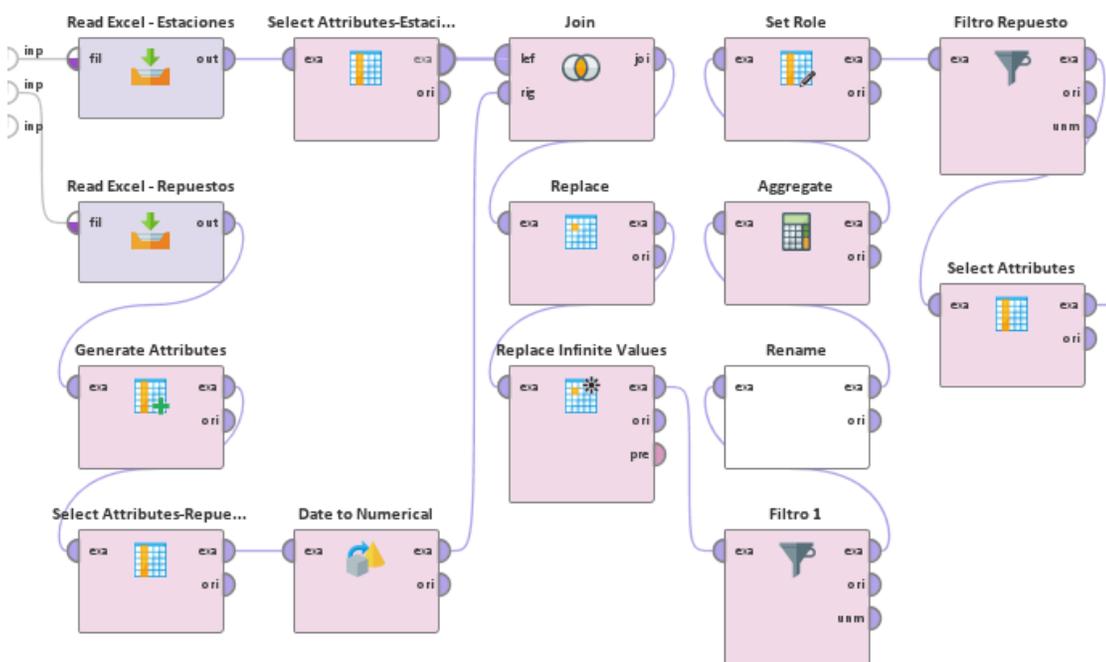
Para los algoritmos seleccionados (Regresión lineal, ARIMA y Holt Winters) se realiza el mismo pre procesamiento de datos como se observa en la Figura 11.

1. Lectura de archivos fuente Excel.
2. Selección y generación de atributos necesarios para el análisis.
3. Conversión del formato de datos.
4. Unión de los dos archivos fuente.
5. Reemplazo de valores erróneos o infinitos por valores perdidos.
6. Filtro de datos perdidos.
7. Renombramiento de atributos.
8. Agrupación de datos por tipo de repuesto y mes de salida de bodega.

9. Asignación de roles.
10. Filtro del repuesto para analizar.

Figura 11

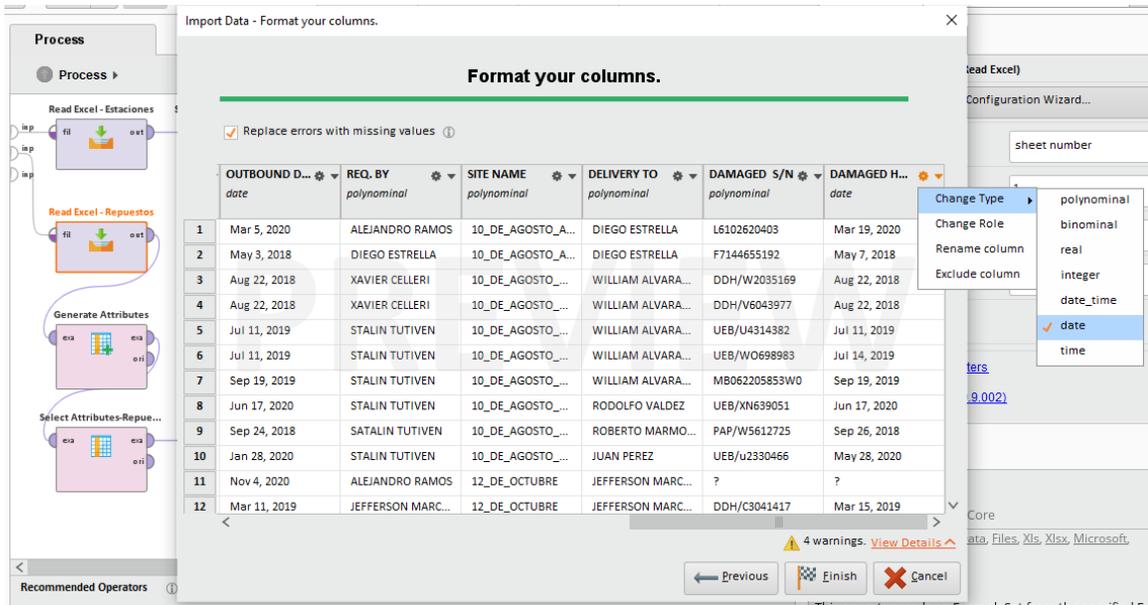
Pre procesamiento de los datos



En la Figura 12 se observa el proceso para realizar la lectura de los archivos ASIGNACION_DE_ESTACIONES_POR_CENTRO_DE_MANTENIMIENTO y DESPACHO_DE_REPUESTOS, en donde se puede seleccionar las columnas que se desea importar y dar formato a los datos (polynomial, binomial, real, integer, date_time, date y time).

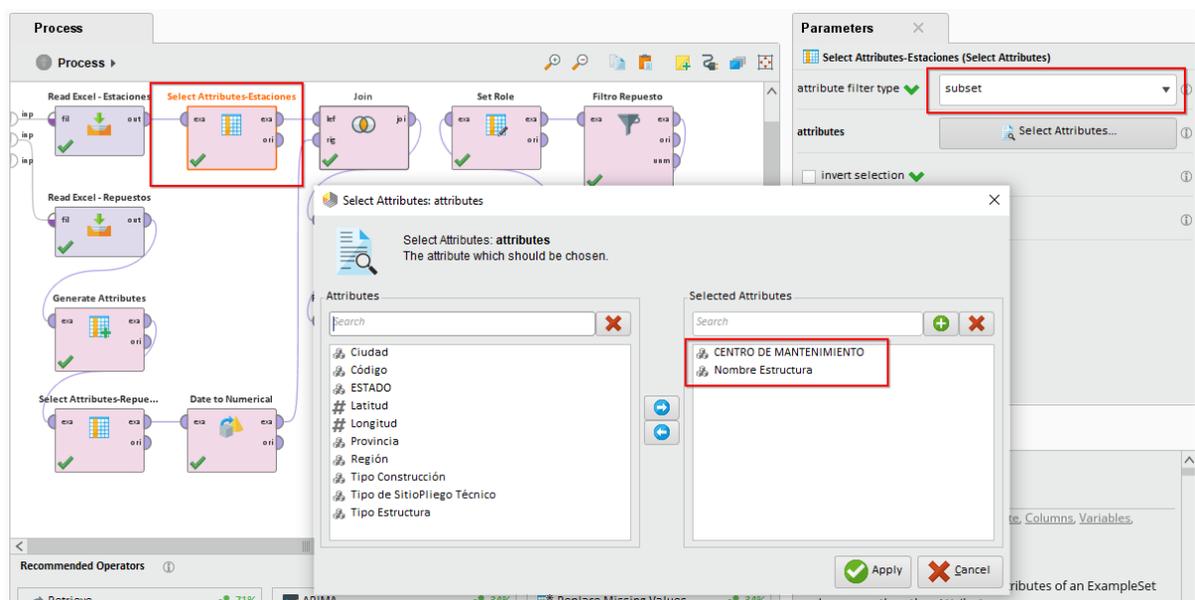
Para el archivo fuente que contiene los movimientos de los repuestos, Rapidminer detecta a la columna DAMAGED HW INBOUND DATE como polynomial, por lo tanto, se cambia el tipo de dato a date. Adicional, se selecciona la opción en donde aquellas celdas detectadas como errores sean reemplazadas con valores perdidos (Replace error with missing values).

Figura 12
Read Excel



En la Figura 13 se muestra cómo se selecciona únicamente los atributos Centro de Mantenimiento y Nombre Estructura con el objetivo de reducir la cantidad de datos innecesarios en el procesamiento.

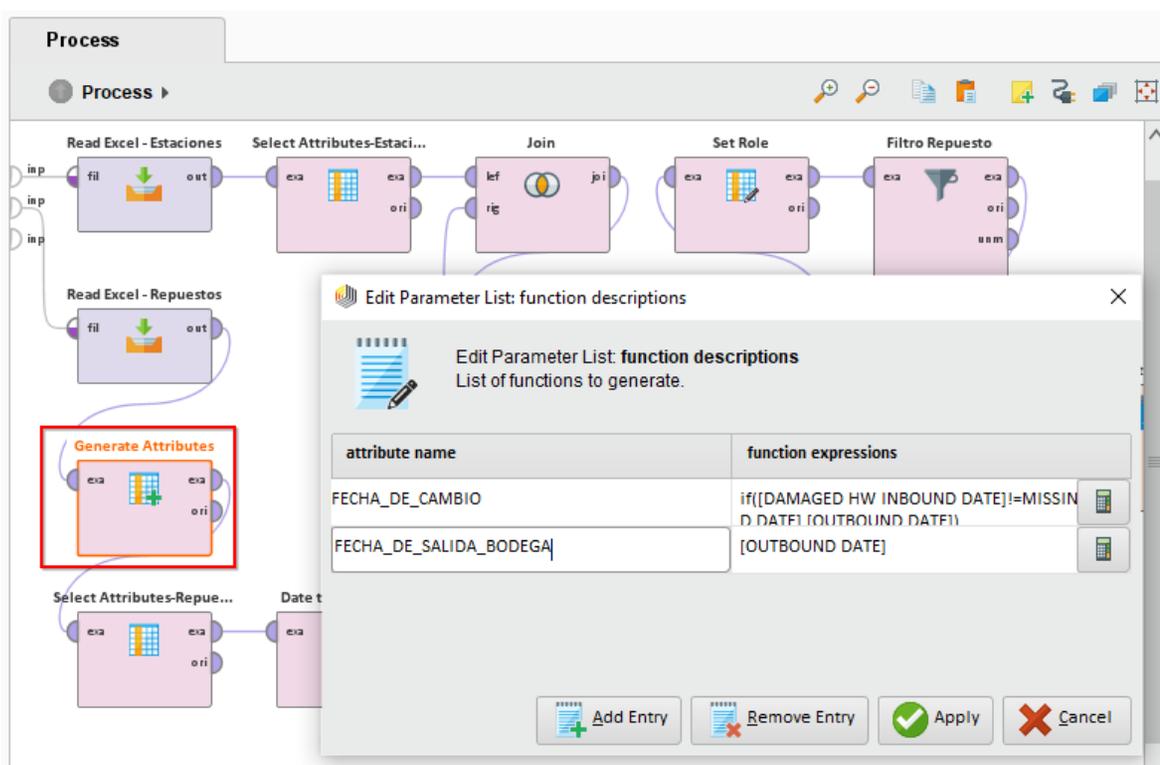
Figura 13
Select Attributes-Estaciones



En la Figura 14 se muestra cómo se generan 2 atributos adicionales, en donde a FECHA_DE_SALIDA_BODEGA se le asigna el valor de OUTBOUND DATE, mientras que a FECHA_DE_CAMBIO se le asigna el valor de DAMAGED HW INBOUND DATE y si este campo se encuentra vacío o detectado como missing value, es decir, que personal de bodega no registró la fecha en la que el técnico cambió el repuesto, se le asigna la fecha de OUTBOUND DATE dada la experiencia del personal en donde indican que los cambios con frecuencia se realizan el mismo día del despacho.

Figura 14

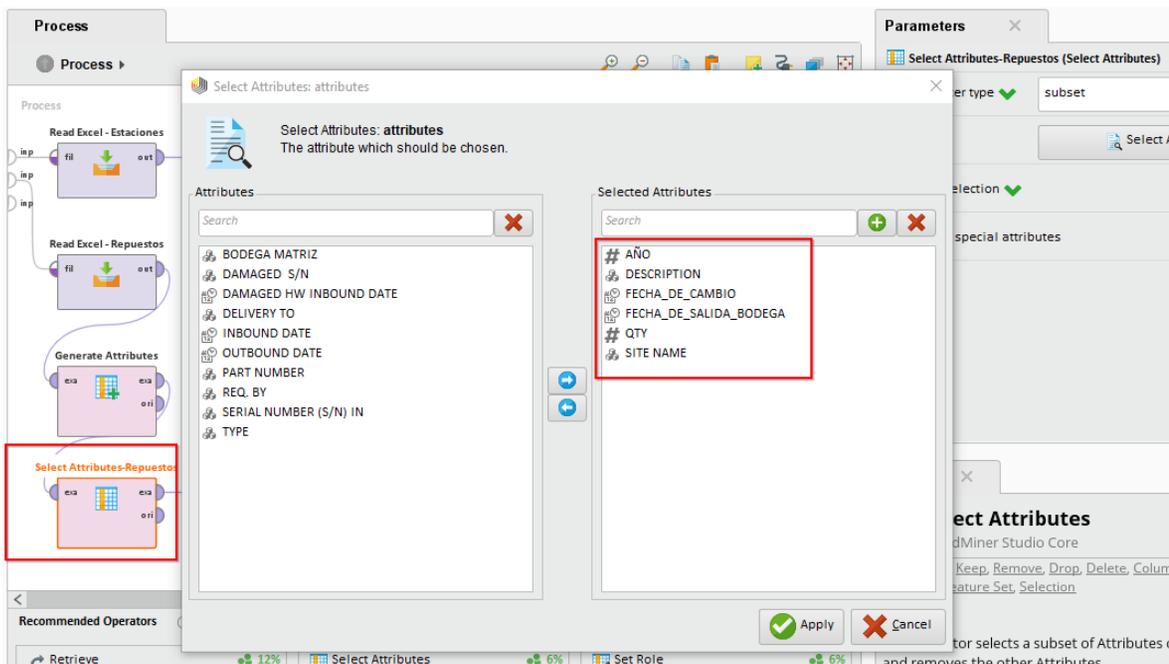
Generate Attributes



En la Figura 15 se muestra cómo se seleccionan los atributos Año, Description, Fecha_de_cambio, Fecha_de_salida_bodega, QTY (Cantidad), Site_name debido que los demás campos no son necesarios para el análisis.

Figura 15

Select Attributes-Repuestos



El operador Date to Numerical permite al campo Fecha_de_salida_bodega transformarlo en un número de acuerdo con el mes y la época, la configuración se muestra en la Figura 16.

Month_relative_to: este parámetro solo está disponible cuando el parámetro de unidad de tiempo se establece en 'mes'. Este parámetro especifica el componente relativo al cual se deben extraer los meses. Están disponibles las siguientes opciones: trimestre, año, época. (RapidMiner GmbH 2021, 2021)

En la Figura 17 se muestra el resultado posterior a la ejecución del Date to Numerical en donde, los repuestos cambiados en Enero/2018 adquieren el número 577, Febrero/2018 el número 578, de este modo el número incrementa conforme a las fechas.

Figura 16

Date to Numerical

The screenshot displays a RapidMiner workflow in the 'Process' view. The 'Date to Numerical' operator is highlighted with a red box. The 'Parameters' panel on the right shows the following settings:

- attribute name: FECHA_DE_SALIDA_BODEGA
- time unit: month
- month relative: epoch
- keep old attribute: checked

The 'Help' panel below shows the operator's name 'Date to Numerical' and its source 'RapidMiner Studio Core'. It also lists tags: Dates, Times, Datetimes, Continuous, Numbers, Weeks, Days, Months, Years, Quarters, Hours, Minutes, Seconds, Times.

El operador Date to Numerical detecta la fecha más antigua y le asigna el menor valor de acuerdo con la época.

Figura 17

Resultado de Date to Numerical

Row No.	AÑO	DESCRIPTION	QTY	SITE NAME	FECHA_DE_C...	FECHA_DE_SALIDA_BODEGA	FECHA_DE_SALIDA_BODEGA_month ↑
6908	2018	ZXSDR R8860E...	1	VIA_DURAN_B...	Jan 11, 2018 1...	Jan 11, 2018 12:00:00 AM COT	577
6920	2018	FXCB	1	VIA_ILALO	Jan 28, 2018 1...	Jan 26, 2018 12:00:00 AM COT	577
6951	2018	FDUAMCO 850...	1	VILLA_MARIA	Apr 4, 2018 12:...	Jan 8, 2018 12:00:00 AM COT	577
6952	2018	FDUAMCO 850...	1	VILLA_MARIA	Jan 8, 2018 12:...	Jan 8, 2018 12:00:00 AM COT	577
23	2018	FRCB	1	24_DE_MAYO	Feb 23, 2018 1...	Feb 23, 2018 12:00:00 AM COT	578
135	2018	AC/DCDV3	1	ALMAGRO	Feb 8, 2018 12:...	Feb 8, 2018 12:00:00 AM COT	578
136	2018	AC/DCDV3	1	ALMAGRO	Feb 9, 2018 12:...	Feb 9, 2018 12:00:00 AM COT	578
146	2018	AC/DCDV2	1	ALOAG_CENTRO	Feb 25, 2018 1...	Feb 25, 2018 12:00:00 AM COT	578
166	2018	CC16B	1	AMBATO	Feb 8, 2018 12:...	Feb 8, 2018 12:00:00 AM COT	578
167	2018	ZXSDR R8882 ...	1	AMBATO	Feb 8, 2018 12:...	Feb 8, 2018 12:00:00 AM COT	578
202	2018	AC/DCDV1	1	ANDINANET	Feb 8, 2018 12:...	Feb 4, 2018 12:00:00 AM COT	578
249	2018	AC/DCDV1	1	ASCAZUBI	Feb 14, 2018 1...	Feb 14, 2018 12:00:00 AM COT	578
320	2018	ACTPV3	1	AZOGUES	May 20, 2019 ...	Feb 16, 2018 12:00:00 AM COT	578
416	2018	IDU SIAE	1	BALAO	Feb 16, 2018 1...	Feb 16, 2018 12:00:00 AM COT	578

ExampleSet (7,075 examples, 0 special attributes, 7 regular attributes)

Para unir los datos de los dos archivos fuente se utiliza un Right Join, en donde el movimiento de los repuestos se ubica a la derecha y las estaciones con su respectivo centro de mantenimiento se ubican a la izquierda. La unión se realiza mediante el match del Site Name del primer archivo y el Nombre de la estructura del segundo archivo. La configuración se muestra en la Figura 18.

Figura 18

Operador Join

The screenshot displays a data processing workflow in a tool. The main canvas shows a sequence of operators: 'Read Excel - Estaciones', 'Select Attributos-Estaci...', 'Join', 'Set Role', and 'Filtro Repuesto'. The 'Join' operator is highlighted with a red box. A dialog box titled 'Edit Parameter List: key attributes' is open over the 'Join' operator, showing the configuration for key attributes. The left key attribute is 'Nombre Estructural' and the right key attribute is 'SITE NAME'. The 'Parameters' panel on the right shows the 'Join' operator's configuration, with 'join type' set to 'right'. The 'Help' panel on the right provides information about the 'right' join type.

left key attributes	right key attributes
Nombre Estructural	SITE NAME

Con el operador Replace Infinite Values aplicado a los campos mostrados en la Figura 19 se asegura que aquellos valores detectados como vacío o infinitos sean reemplazados como valores perdidos.

Se escogieron estos atributos debido a que son datos sensibles que posteriormente serán filtrados si se encuentran con errores a través del operador Filtro 1. A su vez también se descartan si el centro de mantenimiento o estación registrada para el envío del repuesto se encuentra Desinstalada o si el repuesto se categorizó como Devuelto.

Figura 19

Replace Infinite Values

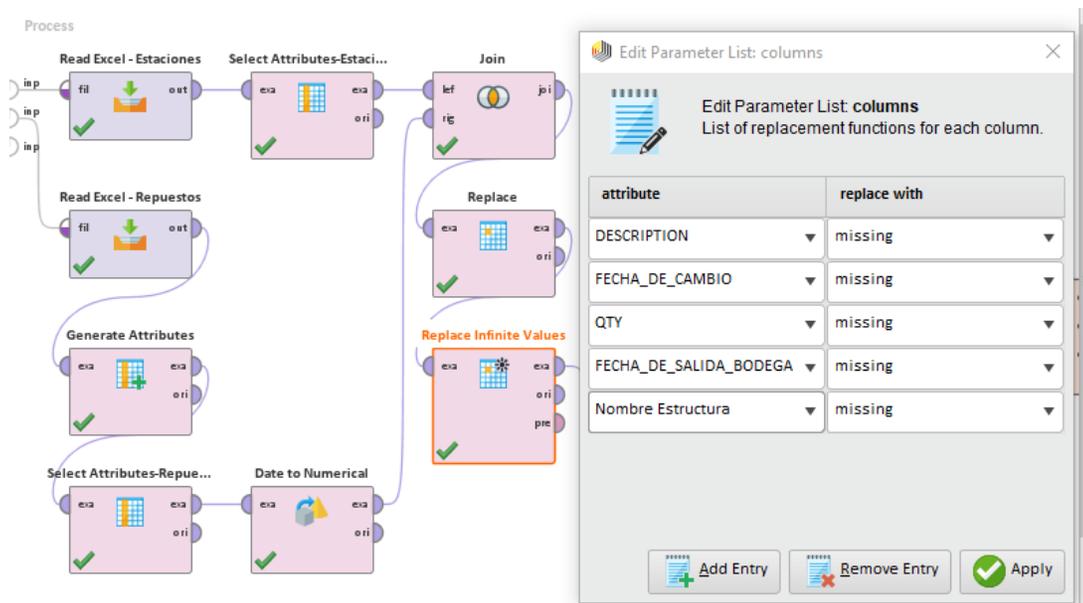
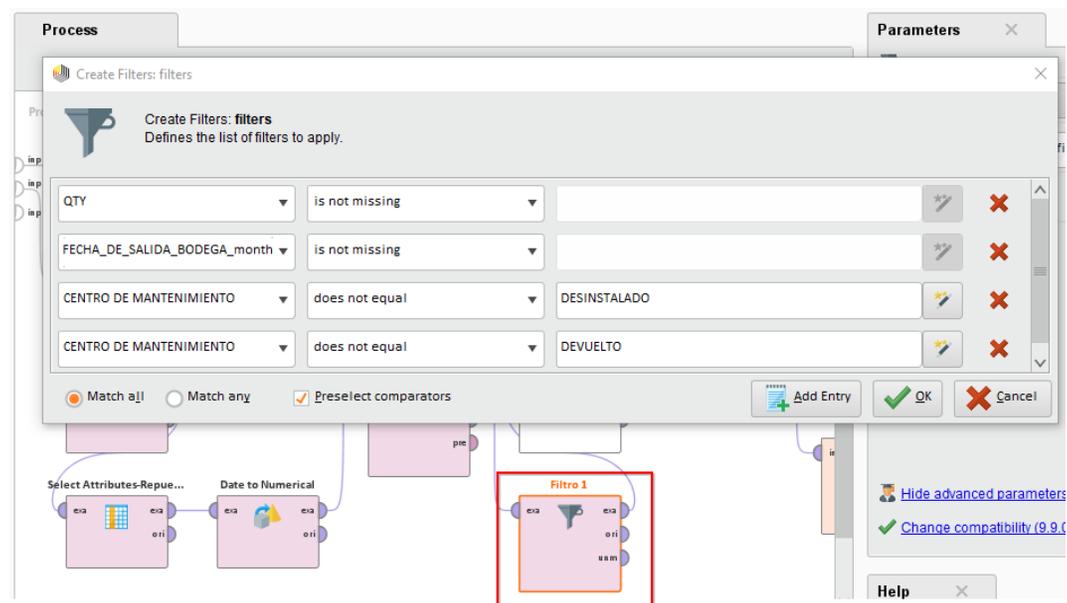


Figura 20

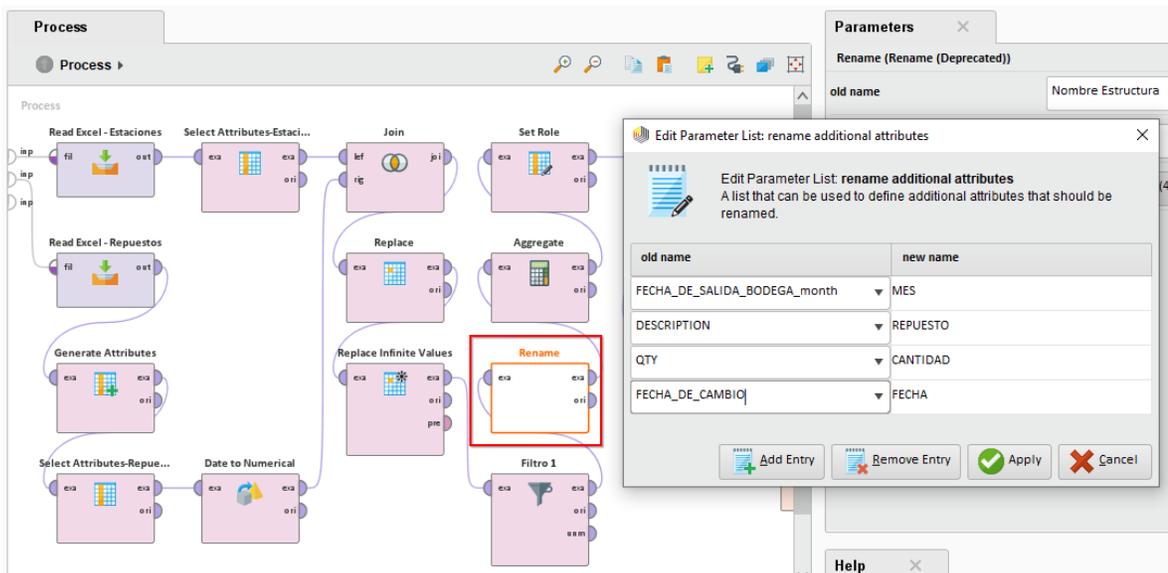
Filtro 1



Mediante el operador Rename se procede a renombrar los atributos mostrados en la Figura 21.

Figura 21

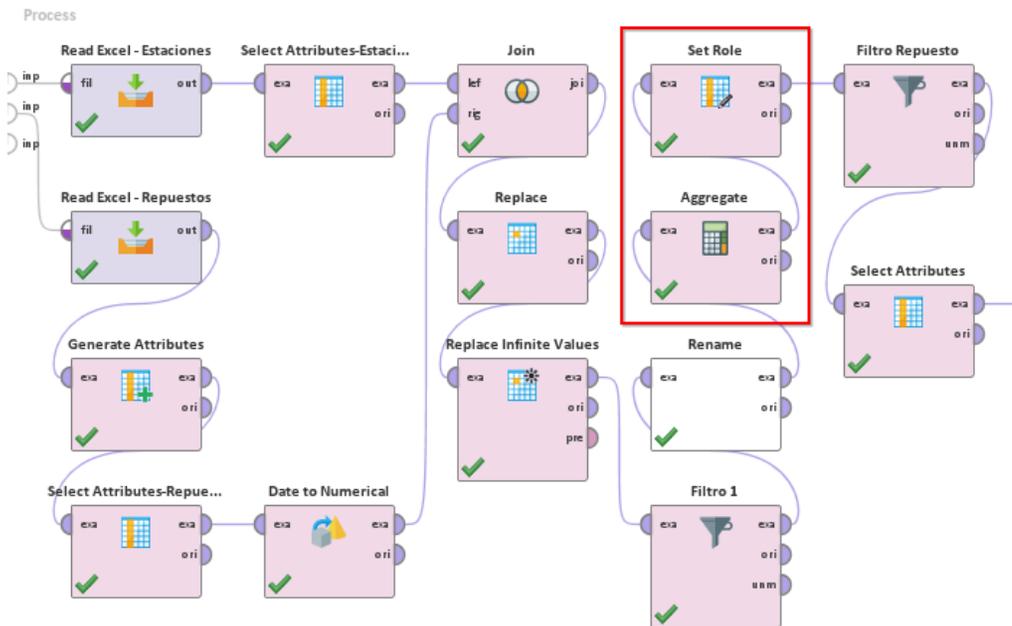
Operador Rename



A través del comando Aggregate se agrupan los datos acorde al repuesto y al mes de salida de bodega, adicional se suman las cantidades para obtener el total de envíos mensuales. Mediante Set Role se asigna al atributo MES como ID.

Figura 22

Operador Aggregate y Set Role



El atributo Filtro Repuesto mostrado en la Figura 23 permite escribir el nombre del repuesto que se desea analizar. Este debe ser escrito exactamente a cómo se encuentra en el archivo fuente.

Mediante el comando Select Attributes, se selecciona únicamente los atributos Mes y Cantidad como se observa en la Figura 24 dado que son las variables necesarias para implementar los algoritmos seleccionados para la predicción.

Figura 23

Filtro Repuesto

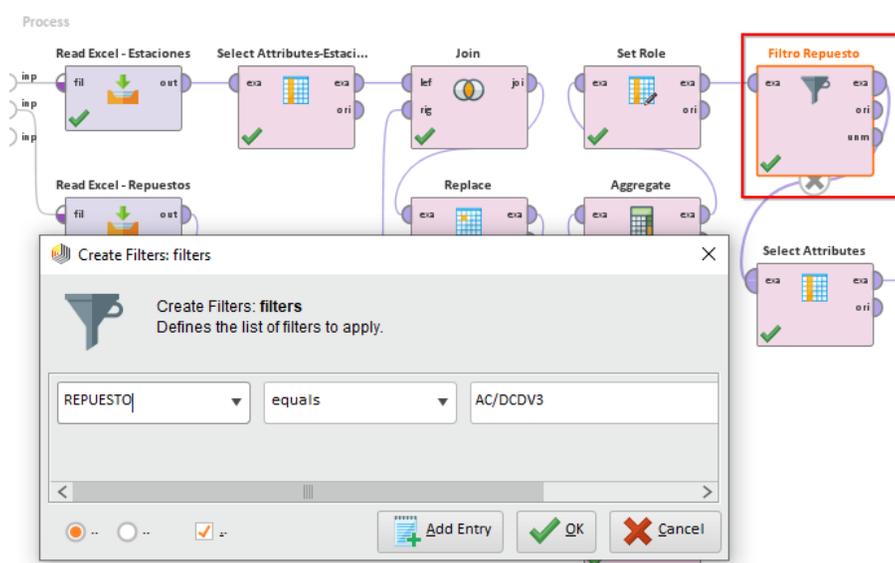


Figura 24

Resultado Select Attributes

Row No.	MES	sum(CANTIDA...
1	577	12
2	578	7
3	579	8
4	580	15
5	581	7
6	582	16
7	583	8
8	584	11
9	585	8

Fase 4: Diseño del modelo

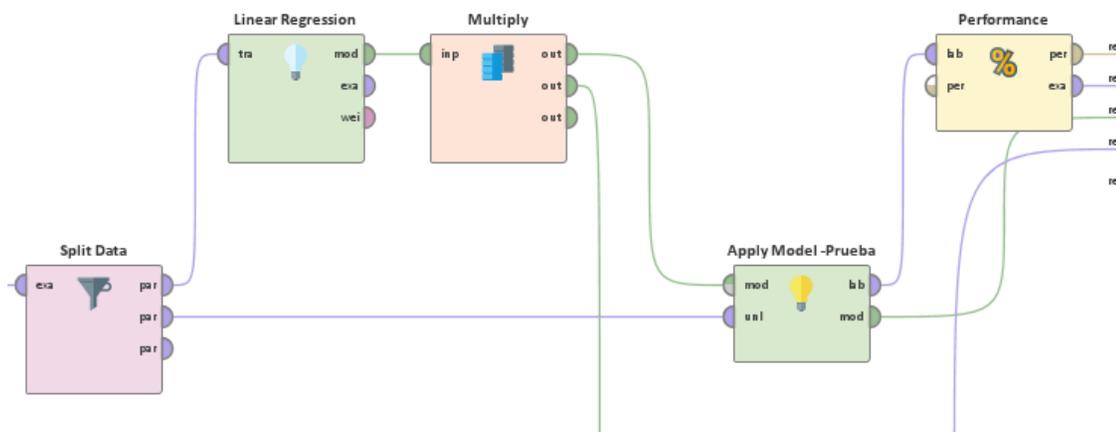
Se selecciona la técnica de modelado basado en los datos disponibles, los objetivos y los requisitos del proyecto. Se determina el uso de uno o más modelos para solucionar el problema desde diferentes perspectivas. Se genera un procedimiento para comprobar la calidad y validez del modelo. Se separan los datos en conjuntos de entrenamiento y prueba.

Diseño de Regresión Lineal

Para el diseño del modelo de regresión lineal se realiza una división de los datos en donde el 80% es destinada para el entrenamiento del algoritmo con el módulo Linear Regression y el 20% para la prueba de este. Se procede con la aplicación del algoritmo mediante el módulo Apply Model y la evaluación con Performance, el cual se configura para que presente Root Mean Squared Error (RMSE), Absolute Error y Relative Error.

Figura 25

Diseño Modelo Regresión Lineal



En la Figura 26 se muestra el resultado del modelo, en donde se predice los seis últimos meses que corresponden al período Julio-Diciembre 2020, la cantidad predicha se visualiza en la columna prediction(sum(CANTIDAD)) y el valor real en la columna sum(CANTIDAD). En la Figura 27 se muestran los parámetros para la evaluación del modelo con el repuesto AC/DCDV2. Este procedimiento debe repetirse 4 veces más con los repuestos faltantes: AC/DCDV1, FCU850V1, AC/DCDV3 y ACTPV3 como se muestra desde la Figura 28 hasta la Figura 34.

Figura 26

Resultado modelo Regresión Lineal con datos prueba AC/DCDV2

Row No.	MES	sum(CANTIDAD)	prediction(sum(CANTIDAD))
1	606	24	25.160
2	607	25	25.079
3	608	20	24.998
4	609	21	24.916
5	610	23	24.835
6	611	22	24.754
7	612	22	24.672

Figura 27

Vector de rendimiento Regresión Lineal AC/DCDV2

PerformanceVector
PerformanceVector: root_mean_squared_error: 2.922 +/- 0.000 absolute_error: 2.488 +/- 1.532 relative_error: 11.63% +/- 7.71%

Figura 28

Resultado modelo Regresión Lineal con datos prueba AC/DCDV1

Row No.	MES	sum(CANTIDAD)	prediction(sum(CANTIDAD))
1	606	14	14.776
2	607	15	14.600
3	608	16	14.424
4	609	12	14.248
5	610	16	14.072
6	611	17	13.897
7	612	14	13.721

Figura 29

Vector de rendimiento Regresión Lineal AC/DCDV1

```

PerformanceVector

PerformanceVector:
root_mean_squared_error: 1.762 +/- 0.000
absolute_error: 1.473 +/- 0.967
relative_error: 9.87% +/- 6.40%
  
```

Figura 30

Resultado modelo Regresión Lineal con datos prueba FCU850V1

Row No.	MES	sum(CANTIDAD)	prediction(sum(CANTIDAD))
1	606	20	8.635
2	607	12	8.216
3	608	12	7.796
4	609	16	7.376
5	610	12	6.957
6	611	12	6.537
7	612	13	6.117

Figura 31

Vector de rendimiento Regresión Lineal FCU850V1

```

PerformanceVector

PerformanceVector:
root_mean_squared_error: 6.950 +/- 0.000
absolute_error: 6.481 +/- 2.512
relative_error: 45.40% +/- 9.03%
  
```

Figura 32

Resultado modelo Regresión Lineal con datos prueba AC/DCDV3

Row No.	MES	sum(CANTIDAD)	prediction(sum(CANTIDAD))
1	606	14	8.599
2	607	10	8.528
3	608	12	8.458
4	609	10	8.387
5	610	13	8.317
6	611	10	8.246
7	612	13	8.176

Figura 33

Vector de rendimiento Regresión Lineal AC/DCDV3

PerformanceVector
PerformanceVector: root_mean_squared_error: 3.680 +/- 0.000 absolute_error: 3.327 +/- 1.571 relative_error: 27.09% +/- 9.88%

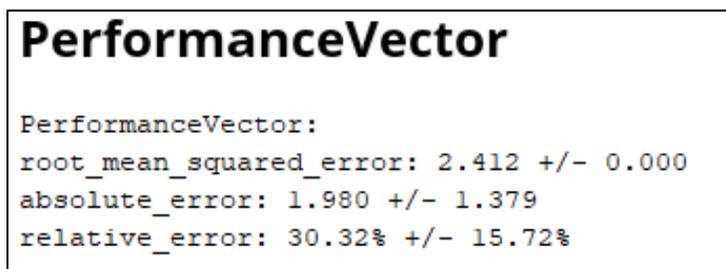
Figura 34

Resultado modelo Regresión Lineal con datos prueba ACTPV3

Row No.	MES	sum(CANTIDAD)	prediction(sum(CANTIDAD))
1	606	7	6.956
2	607	5	7.022
3	608	6	7.088
4	609	12	7.154
5	610	5	7.220
6	611	5	7.286
7	612	6	7.352

Figura 35

Vector de rendimiento Regresión Lineal ACTPV3

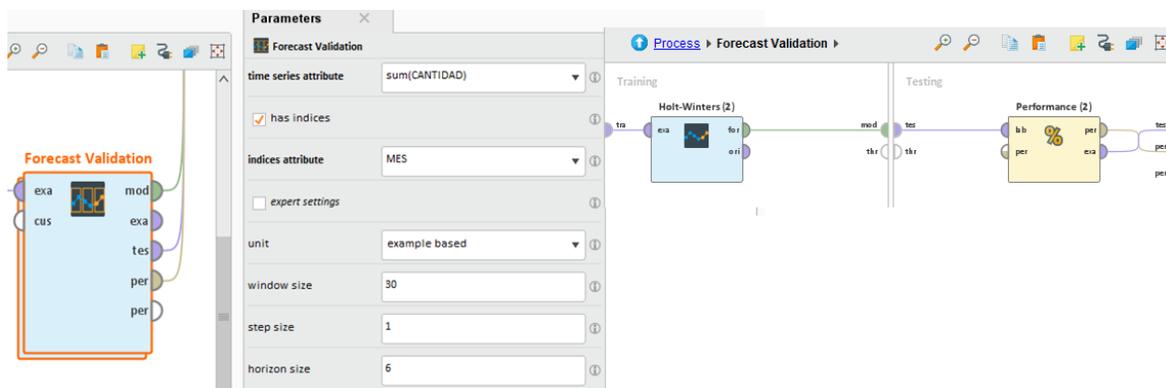


Diseño de Holt Winters

Para el diseño del modelo de Holt Winters, se selecciona el módulo Forecast Validation como se observa en la Figura 36. Se selecciona como atributo índice al número de mes. Para el entrenamiento se seleccionan las 30 primeras muestras (83%) que corresponden al período Enero 2018 – Junio 2020 y como datos de prueba los valores de los 6 últimos meses (17%).

Figura 36

Diseño Modelo Holt Winters



Para la configuración de los parámetros del modelo Holt Winters se selecciona como atributo de la serie de tiempo a sum(CANTIDAD) y como índice al MES. Los coeficientes de Alpha, beta y gamma por defecto están seteados con el valor 0.5, sin embargo, al realizar varias pruebas se determina que el modelo de estacionalidad seleccionado es el multiplicativo y los valores óptimos son:

Alpha: 0.35 Beta: 0.1 Gamma:0.5

Figura 37

Parámetros Holt Winters

Parameters
✕

Holt-Winters (2) (Holt-Winters)

time series attribute sum(CANTIDAD) ▼ ⓘ

has indices ⓘ

indices attribute MES ▼ ⓘ

alpha: coefficient for level smoothing 0.35 ⓘ

beta: coefficient for trend smoothing 0.1 ⓘ

gamma: coefficient for seasonality smoothing 0.5 ⓘ

period: length of one period 4 ⓘ

seasonality model multiplicative ▼ ⓘ

En la Figura 38 se muestra el resultado del modelo y en la Figura 39 se muestran los parámetros para la evaluación del modelo con el repuesto AC/DCDV2.

Este procedimiento se repite con los repuestos faltantes: AC/DCDV1, FCU850V1, AC/DCDV3 y ACTPV3 como se muestra desde la Figura 40 hasta la Figura 47.

Figura 38

Resultado modelo Holt Winters con datos de prueba AC/DCDV2

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	25	23.172
2	608	20	20.585
3	609	21	21.859
4	610	23	23.001
5	611	22	22.453
6	612	22	19.941

Figura 39

Vector de rendimiento Holt Winters AC/DCDV2

PerformanceVector

```
PerformanceVector:
root_mean_squared_error: 1.216 +/- 0.000
absolute_error: 0.964 +/- 0.740
relative_error: 4.29% +/- 3.16%
```

Figura 40

Resultado modelo Holt Winters con datos de prueba AC/DCDV1

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	15	13.198
2	608	16	12.684
3	609	12	13.170
4	610	16	13.090
5	611	17	12.402
6	612	14	11.907

Figura 41

Vector de rendimiento Holt Winters AC/DCDV1

PerformanceVector

```
PerformanceVector:
root_mean_squared_error: 2.875 +/- 0.000
absolute_error: 2.648 +/- 1.120
relative_error: 17.11% +/- 5.74%
```

Figura 42

Resultado modelo Holt Winters con datos de prueba FCU850V1

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	12	13.444
2	608	12	13.547
3	609	16	16.170
4	610	12	13.849
5	611	12	11.518
6	612	13	11.534

Figura 43

Vector de rendimiento Holt Winters FCU850V1

PerformanceVector
PerformanceVector: root_mean_squared_error: 1.311 +/- 0.000 absolute_error: 1.160 +/- 0.611 relative_error: 9.45% +/- 5.12%

Figura 44

Resultado modelo Holt Winters con datos de prueba AC/DCDV3

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	10	10.414
2	608	12	12.952
3	609	10	11.237
4	610	13	14.601
5	611	10	11.200
6	612	13	13.912

Figura 45

Vector de rendimiento Holt Winters AC/DCDV3

```

PerformanceVector

PerformanceVector:
root_mean_squared_error: 1.114 +/- 0.000
absolute_error: 1.053 +/- 0.364
relative_error: 9.29% +/- 3.15%
  
```

Figura 46

Resultado modelo Holt Winters con datos de prueba ACTPV3

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	5	6.531
2	608	6	4.946
3	609	12	5.073
4	610	5	6.526
5	611	5	6.714
6	612	6	5.084

Figura 47

Vector de rendimiento Holt Winters ACTPV3

```

PerformanceVector

PerformanceVector:
root_mean_squared_error: 3.097 +/- 0.000
absolute_error: 2.278 +/- 2.098
relative_error: 30.99% +/- 13.87%
  
```

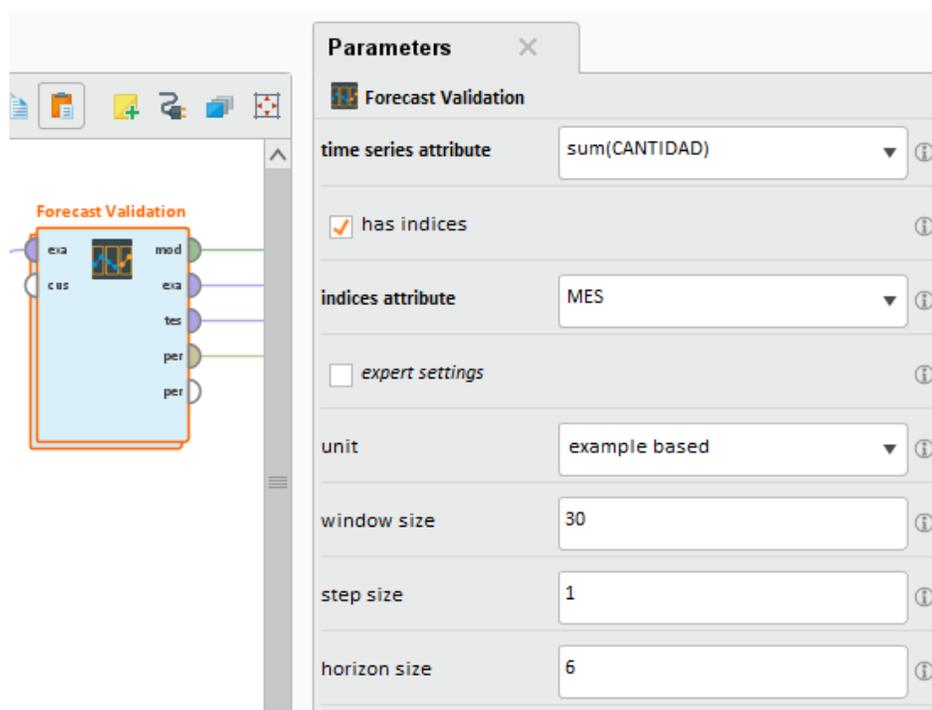
Diseño de ARIMA

Para el diseño del modelo de ARIMA, se selecciona el módulo Forecast Validation como se observa en la Figura 48. Se selecciona como atributo índice al número de mes.

Para el entrenamiento se seleccionan las 30 primeras muestras que corresponden al período Enero 2018 – Junio 2020 y como datos de prueba los valores de los 6 últimos meses.

Figura 48

Diseño Modelo ARIMA



Para la configuración de los parámetros del modelo ARIMA se selecciona como atributo de la serie de tiempo a sum(CANTIDAD) y como índice al MES. Los coeficientes de p,d y q se configuraron con los siguientes valores:

p: 1

d: 0

q: 1

Figura 49*Parámetros ARIMA*

En la Figura 50 se muestra el resultado del modelo y en la Figura 51 se muestran los parámetros para la evaluación del modelo con el repuesto AC/DCDV2.

Este procedimiento se repite con los repuestos faltantes: AC/DCDV1, FCU850V1, AC/DCDV3 y ACTPV3 como se muestra desde la Figura 52 hasta la Figura 59.

Figura 50*Resultado modelo ARIMA con datos de prueba AC/DCDV2*

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	25	25.713
2	608	20	26.181
3	609	21	26.380
4	610	23	26.464
5	611	22	26.500
6	612	22	26.515

Figura 51

Vector de rendimiento ARIMA AC/DCDV2

PerformanceVector	
PerformanceVector:	
root_mean_squared_error:	4.478 +/- 0.000
absolute_error:	4.126 +/- 1.740
relative_error:	19.24% +/- 8.81%

Figura 52

Resultado modelo ARIMA con datos de prueba AC/DCDV1

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	15	15.299
2	608	16	15.832
3	609	12	16.218
4	610	16	16.498
5	611	17	16.701
6	612	14	16.848

Figura 53

Vector de rendimiento ARIMA AC/DCDV1

PerformanceVector	
PerformanceVector:	
root_mean_squared_error:	2.096 +/- 0.000
absolute_error:	1.388 +/- 1.570
relative_error:	10.57% +/- 12.89%

Figura 54

Resultado modelo ARIMA con datos de prueba FCU850V1

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	12	15.055
2	608	12	14.235
3	609	16	14.254
4	610	12	14.253
5	611	12	14.253
6	612	13	14.253

Figura 55

Vector de rendimiento ARIMA FCU850V1

PerformanceVector
PerformanceVector: root_mean_squared_error: 2.202 +/- 0.000 absolute_error: 2.133 +/- 0.550 relative_error: 17.03% +/- 5.35%

Figura 56

Resultado modelo ARIMA con datos de prueba AC/DCDV3

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	10	8.684
2	608	12	10.450
3	609	10	9.268
4	610	13	10.059
5	611	10	9.530
6	612	13	9.884

Figura 57

Vector de rendimiento ARIMA AC/DCDV3

PerformanceVector	
PerformanceVector:	
root_mean_squared_error:	1.968 +/- 0.000
absolute_error:	1.688 +/- 1.014
relative_error:	14.12% +/- 7.15%

Figura 58

Resultado modelo ARIMA con datos de prueba ACTPV3

Row No.	MES	sum(CANTIDAD)	forecast of sum(CANTIDAD)
1	607	5	6.423
2	608	6	6.390
3	609	12	6.371
4	610	5	6.359
5	611	5	6.352
6	612	6	6.348

Figura 59

Vector de rendimiento ARIMA ACTPV3

PerformanceVector	
PerformanceVector:	
root_mean_squared_error:	2.505 +/- 0.000
absolute_error:	1.750 +/- 1.792
relative_error:	23.65% +/- 14.14%

Con los resultados obtenidos de las predicciones realizadas para los 5 tipos de repuestos y las métricas de error seleccionadas, se elabora una tabla resumen con el

objetivo de realizar una comparativa para determinar qué modelo se ajusta mejor a las necesidades.

Tabla 14

Rendimiento de los algoritmos

REPUESTO	REGRESION LINEAL			HOLT WINTERS			ARIMA		
	RMSE	Error absoluto	Error relativo	RMSE	Error absoluto	Error relativo	RMSE	Error absoluto	Error relativo
AC/DCDV2	2.922	2.488 +/- 1.532	11.63% +/- 7.71%	1.216	0.964 +/- 0.740	4.29% +/- 3.16%	4.478	4.126 +/- 1.740	19.24% + /- 8.81%
AC/DCDV1	1.762	1.473 +/- 0.967	9.87% +/- 6.40%	2.875	2.648 +/- 1.120	17.11% +/- 5.74%	2.096	1.388 +/- 1.570	10.57% +/- 12.89%
FCU850V1	6.950	6.481 +/- 2.512	45.40% +/- 9.03%	1.311	1.160 +/- 0.611	9.45% +/- 5.12%	2.202	2.133 +/- 0.550	17.03% +/- 5.35%
AC/DCDV3	3.680	3.327 +/- 1.571	27.09% +/- 9.88%	1.114	1.053 +/- 0.364	9.29% +/- 3.15%	1.968	1.688 +/- 1.014	14.12% +/- 7.15%
ACTPV3	2.412	1.980 +/- 1.379	30.32% +/- 15.72%	3.097	2.278 +/- 2.098	30.99% +/- 13.87%	2.505	1.750 +/- 1.792	23.65% +/- 14.14%

Como resultado se obtiene que Holt Winters es óptimo para predecir el movimiento de los repuestos AC/DCDV2, FCU850V1 y AC/DCDV3, mientras que la Regresión Lineal se utilizará para el AC/DCDV1.

Sin embargo, para la ACTPV3 no se encuentra una medida error aceptable para poder considerar un algoritmo válido para realizar las predicciones de los movimientos del repuesto.

Fase 5: Implementación del modelo

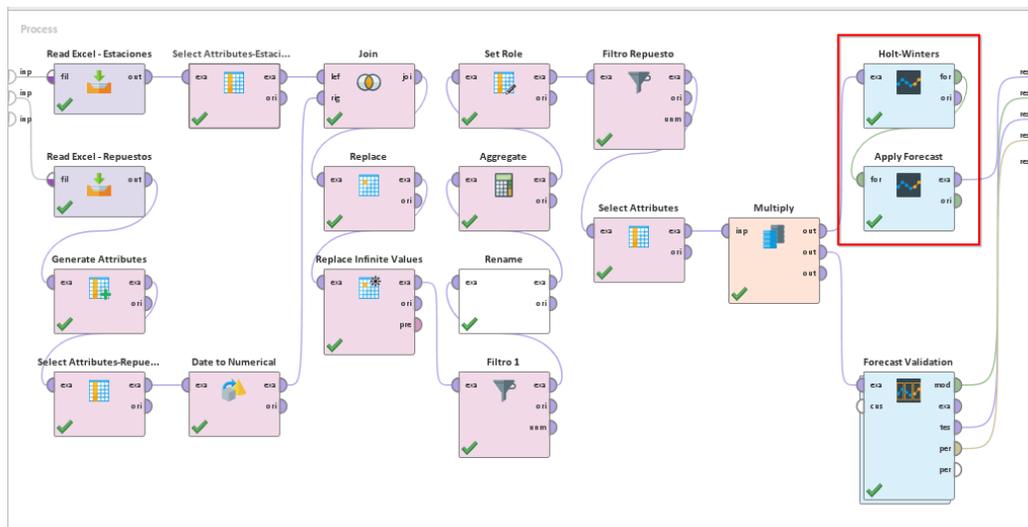
Se experimenta con los modelos que se consideraron en la fase anterior, se configura los parámetros, se describen los resultados obtenidos incluyendo problemas de datos y rendimiento durante la ejecución del modelo y exploración de resultados. Esta fase se puede reiterar hasta conseguir un ajuste de los parámetros que proporcionen resultados más precisos.

Predicción de movimientos de AC/DCDV2 con Holt Winters

En la fase de diseño se determinó que Holt Winters proporciona un error relativo de 4.29% +/- 3.16% para el repuesto AC/DCDV2, por lo tanto, mediante los módulos indicados en la Figura 60 se procede con la implementación para realizar la predicción de los 6 meses posteriores a la data utilizada para el diseño, lo que corresponde al período Enero 2021 – Junio 2021.

Figura 60

Implementación de Holt Winters-AC/DCDV2



El resultado obtenido se muestra en la Figura 61, en donde el mes 613 corresponde a Enero 2021 y la columna forecast of sum(CANTIDAD) indica la cantidad de repuestos que sería necesario mantener en stock en la bodega del rectificador AC/DCDV2.

Figura 61

Resultado Holt Winters-AC/DCDV2

Row No.	MES	forecast of sum(CANTIDAD)	sum(CANTIDAD)	sum(CANTIDAD) and forecast
29	605	?	19	19
30	606	?	24	24
31	607	?	25	25
32	608	?	20	20
33	609	?	21	21
34	610	?	23	23
35	611	?	22	22
36	612	?	22	22
37	613	21.490	?	21.490
38	614	23.125	?	23.125
39	615	22.859	?	22.859
40	616	20.657	?	20.657
41	617	21.062	?	21.062
42	618	22.662	?	22.662

ExampleSet (42 examples, 2 special attributes, 2 regular attributes)

Predicción de movimientos de AC/DCDV1 con Regresión Lineal

Se determinó que la Regresión Lineal proporciona un error relativo de 9.87% +/- 6.40% para el repuesto AC/DCDV1, por lo tanto, se procede con la implementación para realizar la predicción de los 6 meses posteriores a la data utilizada para el diseño, lo que corresponde al período Enero 2021 – Junio 2021. La Figura 62 muestra todo el proceso para la implementación.

La Figura 63 indica la cantidad de repuestos que sería necesario mantener en stock en la bodega del rectificador AC/DCDV1.

Figura 62

Implementación de Regresión Lineal-AC/DCDV1

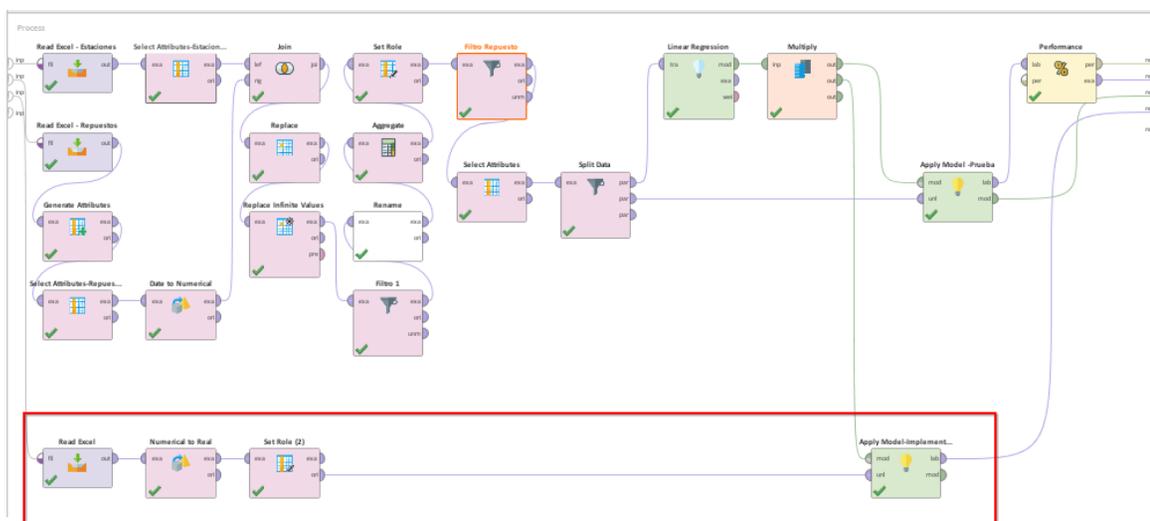


Figura 63

Resultado Regresión Lineal-AC/DCDV1

Row No.	MES	prediction(sum(CANTIDAD))	SUMA CANTIDAD
1	613	13.545	?
2	614	13.369	?
3	615	13.193	?
4	616	13.017	?
5	617	12.841	?
6	618	12.666	?

Predicción de movimientos de FCU850V1 con Holt Winters

Se determinó que Holt Winters proporciona un error relativo de 9.45% +/- 5.12% para el repuesto FCU850V1, por lo tanto, se procede con la implementación para realizar la predicción de los 6 meses posteriores a la data utilizada para el diseño, lo que corresponde al período Enero 2021 – Junio 2021. La Figura 64 indica la cantidad de repuestos que sería necesario mantener en stock en la bodega del módulo FCU850V1.

Figura 64

Resultado Holt Winters-FCU850V1

Row No.	MES	forecast of sum(CANTIDAD)	sum(CANTIDAD)	sum(CANTIDA...
29	605	?	16	16
30	606	?	20	20
31	607	?	12	12
32	608	?	12	12
33	609	?	16	16
34	610	?	12	12
35	611	?	12	12
36	612	?	13	13
37	613	14.464	?	14.464
38	614	11.815	?	11.815
39	615	10.301	?	10.301
40	616	10.436	?	10.436
41	617	12.202	?	12.202
42	618	9.892	?	9.892

ExampleSet (42 examples, 2 special attributes, 2 regular attributes)

Predicción de movimientos de AC/DCDV3 con Holt Winters

Se determinó que la Regresión Lineal proporciona un error relativo de 9.29% +/- 3.15% para el repuesto AC/DCDV3, por lo tanto, se procede con la implementación para realizar la predicción de los 6 meses posteriores a la data utilizada para el diseño, lo que corresponde al período Enero 2021 – Junio 2021.

Figura 65*Resultado Holt Winters-AC/DCDV3*

Row No.	MES	forecast of su...	sum(CANTIDA...	sum(CANTIDA...
29	605	?	12	12
30	606	?	14	14
31	607	?	10	10
32	608	?	12	12
33	609	?	10	10
34	610	?	13	13
35	611	?	10	10
36	612	?	13	13
37	613	10.784	?	10.784
38	614	14.081	?	14.081
39	615	10.732	?	10.732
40	616	13.430	?	13.430
41	617	11.328	?	11.328
42	618	14.783	?	14.783

ExampleSet (42 examples, 2 special attributes, 2 regular attributes)

La Figura 65 indica la cantidad de repuestos que sería necesario mantener en stock en la bodega del rectificador AC/DCDV3.

Capítulo IV

Análisis de Resultados

Fase 6: Evaluación del modelo

Se realiza la evaluación global del modelo, se ejecuta el procedimiento para comprobar la calidad y validez. Se verifica que los resultados cumplen y se ajustan a los objetivos y requisitos planteados en la primera fase.

Se procede a verificar los valores que predijo el algoritmo en el rango de Enero a Junio 2021 versus los valores reales de repuestos requeridos en esos meses.

Evaluación repuesto AC/DCDV2

La Figura 66 detalla la cantidad de repuestos del tipo AC/DCDV2 que se utilizaron desde Enero a Junio 2021. El mes 613 corresponde a Enero.

Figura 66

AC/DCDV2 Enero-Junio 2021

Row No.	MES	sum(CANTIDAD)
35	611	22
36	612	22
37	613	24
38	614	24
39	615	23
40	616	21
41	617	21
42	618	22

Tabla 15*Valor real vs predicción AC/DCDV2*

Mes	Valor Real	Valor de la predicción
Enero	24	21,490
Febrero	24	23,125
Marzo	23	22,859
Abril	21	20,657
Mayo	21	21,062
Junio	22	22,662

De la Figura 61 se obtiene el valor de la predicción y de la Figura 66 el valor real, con los cuales se procede a calcular el Error Relativo, obteniéndose como resultado 3.28%

Evaluación repuesto AC/DCDV1

La Figura 67 detalla la cantidad de repuestos del tipo AC/DCDV1 que se utilizaron desde Enero a Junio 2021.

Figura 67*AC/DCDV1 Enero-Junio 2021*

Row No.	MES	sum(CANTIDAD)
35	611	17
36	612	14
37	613	15
38	614	14
39	615	14
40	616	13
41	617	15
42	618	14

Tabla 16*Valor real vs predicción AC/DCDV1*

Mes	Valor Real	Valor de la predicción
Enero	15	13,545
Febrero	14	13,369
Marzo	14	13,193
Abril	13	13,017
Mayo	15	12,841
Junio	14	12,666

De la Figura 63 se obtiene el valor de la predicción y de la Figura 67 el valor real, con los cuales se procede a calcular el Error Relativo, obteniéndose como resultado 7.34%

Evaluación repuesto FCU850V1

La Figura 68 detalla la cantidad de repuestos del tipo FCU850V1 que se utilizaron desde Enero a Junio 2021.

Figura 68*FCU850V1 Enero-Junio 2021*

Row No.	MES	sum(CANTIDAD)
1	611	12
2	612	13
3	613	14
4	614	12
5	615	11
6	616	12
7	617	13
8	618	11

Tabla 17*Valor real vs predicción FCU850V1*

Mes	Valor Real	Valor de la predicción
Enero	14	14,464
Febrero	12	11,815
Marzo	11	10,301
Abril	12	10,436
Mayo	13	12,202
Junio	11	9,892

De la Figura 64 se obtiene el valor de la predicción y de la Figura 68 el valor real, con los cuales se procede a calcular el Error Relativo, obteniéndose como resultado 6.74%

Evaluación repuesto AC/DCDV3

La Figura 69 detalla la cantidad de repuestos del tipo AC/DCDV3 que se utilizaron desde Enero a Junio 2021.

Figura 69*AC/DCDV3 Enero-Junio 2021*

Row No.	MES	sum(CANTIDAD)
35	611	10
36	612	13
37	613	11
38	614	12
39	615	10
40	616	13
41	617	10
42	618	14

Tabla 18*Valor real vs predicción AC/DCDV3*

Mes	Valor Real	Valor de la predicción
Enero	11	10,784
Febrero	12	14,081
Marzo	10	10,732
Abril	13	13,43
Mayo	10	11,328
Junio	14	14,783

De la Figura 65 se obtiene el valor de la predicción y de la Figura 69 el valor real, con los cuales se procede a calcular el Error Relativo, obteniéndose como resultado 8.13%

Resumen de Resultados

En la Tabla 19 se presenta el resumen de resultados, en donde se muestra el Error relativo que presentó el algoritmo en la fase de modelamiento y de implementación. Con lo cual se demuestra que mediante la herramienta seleccionada RapidMiner es factible obtener la tendencia del inventario acorde a la gestión de repuestos de la empresa con un Error relativo menor al 10%.

Debido a que se trabajó con algoritmos diferentes en la fase de implementación se determinan errores relativos para cada uno (Holt Winters y Regresión lineal), de igual manera se enfatiza que cada repuesto tiene su propio comportamiento, por lo que tienen un algoritmo específico para su predicción.

El repuesto AC/DCDV2 obtuvo el menor valor de error relativo utilizando Holt Winters para su predicción con un porcentaje de 4.29% en la fase de modelamiento, mientras que en la fase de implementación obtuvo un error de 3.28%, lo que indica que el modelo es eficiente al predecir 6 meses posteriores a la información cargada.

Tabla 19*Resumen de resultados*

Repuesto	Algoritmo	Error Relativo (Modelamiento)	Error Relativo (Implementación)
AC/DCDV2	Holt Winters	4.29% +/- 3.16%	3.28%
AC/DCDV1	Regresión Lineal	9.87% +/- 6.40%	7.34%
FCU850V1	Holt Winters	9.45% +/- 5.12%	6.74%
AC/DCDV3	Holt Winters	9.29% +/- 3.15%	8.13%

Debido a que las predicciones de la cantidad de repuestos se implementaron desde el mes de Marzo 2021 para poder comprobar la calidad y validez, se evaluará si los tiempos de resolución han mejorado a partir de Abril 2021 hasta Junio 2021 para comprobar si la hipótesis “El modelo de estimación de gestión de repuestos basado en analítica de datos minimiza los tiempos de respuesta ante incidentes” es verdadera.

El KPI “Desviación en tiempos de entrega de repuestos al ingeniero de campo” es calculado por el encargado de la bodega de repuestos, debido a que es un valor sensible para la empresa, no se muestra su procedencia, sin embargo, se comprueba la veracidad de los indicadores mostrados en la Tabla 20 y Tabla 21 debido a que son entregados en los informes mensuales y son aprobados por el cliente.

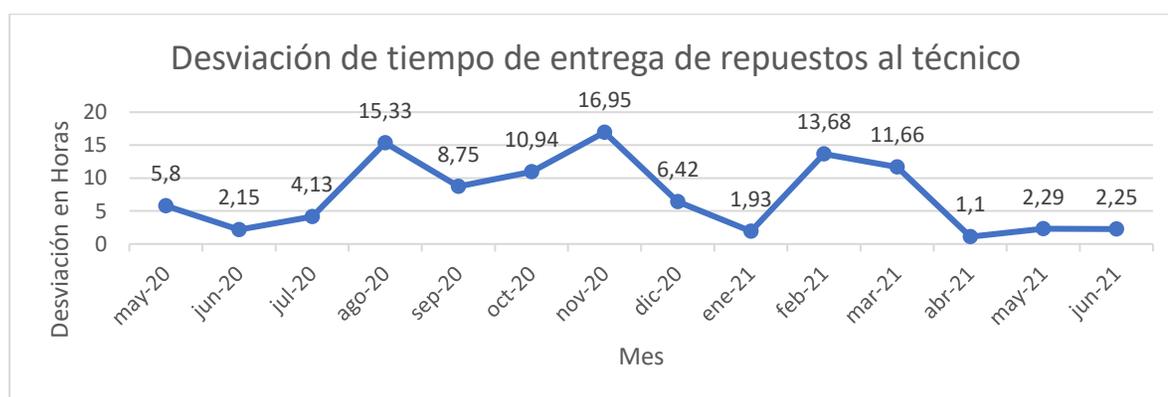
Se tiene como referencia que la empresa mantenía un promedio de 5 horas desde septiembre 2019 a abril 2020, incumpliendo el SLA de 2 horas.

Tabla 20*Desviación (horas) de entrega de repuestos al técnico Año 2020*

Año 2020							
Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
5.80	2.15	4.13	15.33	8.75	10.94	16.95	6.42

Tabla 21*Desviación (horas) de entrega de repuestos al técnico Año 2021*

Año 2021					
Enero	Febrero	Marzo	Abril	Mayo	Junio
1.93	13.68	11.66	1.10	2.29	2.25

Figura 70*Evolución de desviación (horas) de entrega de repuestos*

En la Figura 70 se puede observar la evolución del KPI desde Mayo 2020 hasta Marzo 2021, los valores no son constantes ni mantienen un promedio en los meses en los que se realizaba el abastecimiento de la bodega de acuerdo a la indisponibilidad del repuesto. Sin embargo, en los meses de Abril a Junio 2021, en donde se realizaron los pedidos de los 4 repuestos más solicitados se observa una disminución del tiempo de gestión (horas), por lo que se puede tomar la hipótesis “El modelo de estimación de gestión de repuestos basado en analítica de datos minimiza los tiempos de respuesta ante incidentes” como verdadera.

El mantener un stock adecuado en la bodega de repuestos disminuye el tiempo de solvencia de incidencias (horas), debido a que el flujo para la entrega al técnico de campo es más corto evitando la gestión con un proveedor externo y la movilización de personal.

Capítulo V

Conclusiones y Recomendaciones

Conclusiones

Del análisis de literatura se obtuvo que los algoritmos de estimación de inventario que se ajustan al problema planteado son Regresión lineal, Holt Winters y ARIMA, se seleccionaron los 3 debido a que recomiendan realizar comparaciones entre ellos cuando el catálogo de productos supera los 200 artículos, con el objetivo de determinar la tendencia de los productos más relevantes y con el algoritmo que proporcione un menor error, recalcando que cada repuesto tiene su propio comportamiento.

Se realizó un análisis del porcentaje de las 223 variantes de repuestos enviados desde Enero 2018 hasta Diciembre 2020 para determinar aquellos que tienen un porcentaje de rotación mayor al 3%, resultando seleccionados AC/DCDV2, AC/DCDV1, FCU850V1, AC/DCDV3 y ACTPV3.

Para determinar las características del inventario se realizó una exploración gráfica de los datos de los 5 repuestos seleccionados, determinando que las variables imperativas son la cantidad de envíos por mes y la fecha de despacho del repuesto, sin embargo, se optó por agrupar las fechas por mes de envío debido a que los abastecimientos se realizan mensualmente con el objetivo de reducir los costos de movilización.

Se diseñaron modelos con los algoritmos de Regresión lineal, Holt Winters y ARIMA, en donde se destinó el 80% de la data para el entrenamiento y el 20% para la prueba; los 3 modelos se aplicaron a los 5 repuestos seleccionados, en donde se determinó que el algoritmo con menor porcentaje de error para AC/DCDV2, FCU850V1, AC/DCDV3 es Holt Winters mientras que para AC/DCDV1 es Regresión lineal.

Los modelos se evaluaron los meses de Abril 2021 hasta Junio 2021 determinando que en la fase de implementación los porcentajes de error se redujeron en 1% respecto a la

fase de diseño, lo que indica que con el tiempo las predicciones de los algoritmos se afinan.

La empresa mantenía un promedio de 5 horas en el KPI denominado “Desviación en tiempos de entrega de repuestos al ingeniero de campo” en el período septiembre 2019 a abril 2020 incumpliendo el SLA de 2 horas, posterior a la implementación del trabajo en los meses de Abril a Junio 2021 el promedio se redujo a 1.88 horas, lo que indica que el flujo de entrega de repuestos al técnico disminuye al poder mantener un stock adecuado en las bodegas principales.

Recomendaciones

Se recomienda ampliar el alcance del proyecto e implementar los tres modelos en los repuestos de menor rotación para verificar si es factible determinar el stock mensual para reducir la desviación en tiempos de entrega de repuestos al ingeniero de campo.

Se recomienda trabajar con una data más depurada, ya que al ser la fuente un archivo Excel, se tiene errores en cuanto a la redacción del nombre de la estación de telefonía, la fecha de despacho o el nombre del repuesto, y esto a su vez ocasiona que el ítem sea eliminado y no se considere para el análisis predictivo.

Se recomienda realizar un análisis más profundo sobre el o los repuestos más demandados por cada centro de mantenimiento, para determinar la factibilidad de abastecer las bodegas en cada provincia.

Para trabajos futuros se recomienda utilizar algoritmos no considerados en el presente proyecto como redes neuronales y árboles de decisión para comparar su eficiencia.

Bibliografía

- Afifi, A. (2020). Demand Forecasting of Short Life Cycle Products Using Data Mining Techniques. *IFIP International Conference on Artificial Intelligence Applications and Innovations*. 583, págs. 151-162. IFIPAICT. doi:https://doi.org/10.1007/978-3-030-49161-1_14
- Alimardani, M. J. (2013). Bi-product inventory planning in a three-echelon supply chain with backordering, Poisson demand, and limited warehouse space. *J Ind Eng Int*, 22. Obtenido de <https://doi.org/10.1186/2251-712X-9-22>
- Bansal, K., & Gupta, A. (1998). Brief Application Description. Neural Networks Based Forecasting Techniques for Inventory Control Applications. *Data Mining and Knowledge Discovery*, 97-102. Obtenido de <https://doi.org/10.1023/A:1009769804855>
- Barrenechea García, L., & Félix, L. M. (2014). *Propuesta de mejora en la gestión de inventarios en la empresa importadora mercantil Laboratorios SAC*. Universidad Peruana de Ciencias Aplicadas (UPC), Lima. Obtenido de <http://hdl.handle.net/10757/550179>
- Bermeo, S., & Campoverde, M. (14 de Enero de 2020). Implementation of business intelligence, in the inventory of the GranSol Cooperative, with the Power BI tool. *FIPCAEC*, 5(16), 240-266. doi:<https://doi.org/10.23857/fipcaec.v5i14.169>
- Carhuaricra, M. E., & Gonzales, J. I. (2017). *Implementación de Business Intelligence para mejorar la eficiencia de la toma de decisiones en la gestión de proyectos*. Universidad San Ignacio de Loyola, Lima. Obtenido de <http://repositorio.usil.edu.pe/handle/USIL/3202>
- Castro Zuluaga, C. A., Uribe Cadavid, D. C., & Castro Urrego, J. A. (Junio de 2014). Marco de Referencia para el Desarrollo de un Sistema de Apoyo para la Toma de Decisiones para La Gestión De Inventarios. *INGE CUC*, 10(1), 32-44.
- Computerworld Ec. (2020). *Business Intelligence como un diferencial competitivo*. (Ekos, Editor) Recuperado el 17 de 06 de 2020, de Computerworld Ec: <https://computerworld.com.ec/actualidad/tendencias/1136-business-intelligence-como-un-diferencial-competitivo.html>

- Crespín Castillo, A. R. (2018). *Plan de mejora en la gestión de inventarios para una empresa de telecomunicaciones*. Guayaquil: Universidad de Guayaquil. Obtenido de <http://repositorio.ug.edu.ec/bitstream/redug/37337>
- Curto Díaz, J. (2012). *Introducción al Business Intelligence*. Editorial UOC.
- Flamarique, S. (2018). *Gestión de existencias en el almacén*. Marge Books.
- González Vega, S. (2020). Big data y analítica. *Datta Business Innovation*(332), 22-23. Obtenido de <http://revista.datta.com.ec/publication/e9da38ed/mobile/>
- Görgülü, Z.-K., & Pickl, S. (2013). Adaptive Business Intelligence: The Integration of Data Mining and Systems Engineering into an Advanced Decision Support as an Integral Part of the Business Strategy. En P. Rausch, A. Sheta, & A. Ayes, *Business Intelligence and Performance Management* (págs. 43-58). Springer, London. doi:https://doi.org/10.1007/978-1-4471-4866-1_4
- IBM. (2019). *IBM*. Obtenido de Analítica de Big Data: <https://www.ibm.com/analytics/es/es/hadoop/big-data-analytics/>
- Kreplak, G. (23 de Enero de 2018). Predicción de ventas de comestible corporación Favorita. Universitat Oberta de Catalunya. Obtenido de <http://hdl.handle.net/10609/74565>
- Lénárt, B., Grzybowska, K., & Cimer, M. (2012). Adaptive Inventory Control in Production Systems. *International Conference on Hybrid Artificial Intelligence Systems, 7209*, págs. 222-228. Springer, Berlin, Heidelberg. doi:https://doi.org/10.1007/978-3-642-28931-6_21
- Listanti, M. (2014). Proactive Supply Chain Performance Management with Predictive Analytics. *The Scientific World Journal*, 17. Obtenido de <https://doi.org/10.1155/2014/528917>
- López Montes, J. (2014). *Gestión de inventarios*. Editorial Elearning.
- Mora García, L. A. (2008). *Indicadores de la gestión logística*. Ecoe Ediciones.
- Morán Delgado, M. A., & Coronel Gómez, C. P. (2016). *Diseño de manual de control interno en el área de activos fijos de una empresa de telecomunicaciones fijo*. Guayaquil: Universidad Católica de Santiago de Guayaquil. Obtenido de <http://repositorio.ucsg.edu.ec/handle/3317/6900>

- Nisbet, R., Miner, G., & Yale, K. (2018). *Handbook of Statistical Analysis and Data Mining Applications*. Elsevier. Obtenido de <https://books.google.com.ec/books?id=QVgXAwAAQBAJ&printsec=frontcover&q=crisp+dm&hl=es-419&sa=X&ved=2ahUKEwj2xZXakefqAhVGZN8KHf66CjIQ6AEwAnoECAMQAg#v=onepage&q&f=false>
- Parmenter, D. (2019). *Key Performance Indicators: Developing, Implementing, and Using Winning KPIs*. John Wiley & Sons.
- Pillasagua Giler, T. E. (2019). *Modelo de predicción para la adquisición de medicamentos e insumos para el área de compras del Hospital Carlos Andrade Marín*. Universidad de las Fuerzas Armadas - ESPE, Sangolquí. Obtenido de <http://repositorio.espe.edu.ec/handle/21000/20970>
- QlikTech International AB. (2020). *Qlik*. Obtenido de Qlik Sense® | Plataforma de analítica de datos: <https://www.qlik.com/es-es/products/qlik-sense>
- Ramírez Moreno, T., & Michel Nava, R. M. (2019). Análisis del comportamiento de la predicción de ventas con diferentes técnicas de minería de datos. *Revista Iberoamericana de Ciencias*, 6(4), 126-136. doi:ISSN 2334-2501
- RapidMiner GmbH 2021. (2021). *Rapidminer Documentation*. Obtenido de Date to Numerical: https://docs.rapidminer.com/latest/studio/operators/blending/attributes/types/date_to_numerical.html
- Real Academia Española. (2020). Madrid. Obtenido de <https://dle.rae.es/>
- Recalde Suárez, D. (2014). *Modelo de administración de inventarios para una empresa de telecomunicaciones*. Escuela Politécnica Nacional, Facultad de ciencias administrativas, Quito. Obtenido de <https://bibdigital.epn.edu.ec/handle/15000/11995>
- Rojas, A. (2014). *Implementación de un data mart como solución de inteligencia de negocios, bajo la metodología de Ralph Kimball para optimizar la toma de decisiones en el departamento de finanzas de la contraloría general de la República*. Universidad San Martín de Porres, Chiclayo. Obtenido de <http://repositorio.usmp.edu.pe/handle/usmp/1061>

- SAS Institute Inc. (2019). SAS. Obtenido de Analítica predictiva: https://www.sas.com/es_mx/insights/analytics/predictive-analytics.html
- Stefanovic, N. (2015). Collaborative Predictive Business Intelligence Model for Spare Parts Inventory Replenishment. *Computer Science and Information Systems*, (pág. 34). doi:10.2298/CSIS141101034S
- Stefanovic, N., & Stefanovic, D. (2009). Supply Chain Business Intelligence: Technologies, Issues and Trends. En M. Bramer, *Artificial Intelligence An International Perspective* (págs. 217-245). Springer, Berlin, Heidelberg.
- Stefanovic, N., Stefanovic, D., & Radenkovic, B. (2007). Application of Data Mining for Supply Chain Inventory Forecasting. *Applications and Innovations in Intelligent Systems XV*, (págs. 175-188). Springer, London. doi:https://doi.org/10.1007/978-1-84800-086-5_13
- Tableau Software. (2020). *Tableau*. Obtenido de ¿Qué es la inteligencia de negocios y por qué es importante?: <https://www.tableau.com/es-mx/learn/articles/business-intelligence>
- The MathWorks. (2020). *MathWorks*. Obtenido de Predictive Analytics: <https://la.mathworks.com/discovery/predictive-analytics.html>
- Valencia Cárdenas, M., Díaz Serna, F. J., & Correa Morales, J. C. (2015). *Planeación de inventarios con demanda dinámica. Una revisión del estado del arte*. Obtenido de <https://www.redalyc.org/articulo.oa?id=496/49637154024>
- Vidal Holguín, C. J. (2010). *Fundamentos de control de gestión de inventarios*. Programa Editorial Univalle.
- Yin, R. K. (2009). *Case study Research. Design and Methods*. Sage.
- Zeng, Y., Wang, L., & Zhang, J. (2007). A Web-Based Fuzzy Decision Support System for Spare Parts Inventory Control. En *Fuzzy Information and Engineering* (Vol. 40, págs. 601-609). Springer, Berlin, Heidelberg. doi:https://doi.org/10.1007/978-3-540-71441-5_65