

**UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS**

**DISEÑO DE UN MODELO DE SEGMENTACIÓN Y CONTROL DE
INVENTARIOS PARA ALMACENES DE MANTENIMIENTO**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

AUTOR

FABIÁN IGNACIO ISRAEL MORAGA MUÑOZ

PROFESOR GUÍA

RODRIGO MENA

PROFESOR CO-REFERENTE

PABLO VIVEROS

SANTIAGO DE CHILE, AGOSTO 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título Tesis de Postgrado

Título del trabajo: Diseño de un modelo de segmentación y control de inventarios para almacenes de mantenimiento

Nombre del candidato(a): Fabión Ignacio Israel Moraga Muñoz

Carrera / Grado: Ingeniería Civil Industrial

Campus: Vitacura Departamento: Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Rodrigo Mena Bustos, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

6 meses 12 meses 2 años 3 años 5 años 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 10/10/2025

Firma: 

Estudiante o Candidato(a):

Fecha: 11 de Octubre 2025

Firma: 

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



Tabla de Contenidos

1. Agradecimientos	9
2. Resumen Ejecutivo	11
3. Abstract	13
4. Problema de Investigación	14
5. Objetivos	17
5.1. Objetivo General	17
5.2. Objetivos Específicos	17
6. Alcance	18
7. Marco teórico	19
7.1. Gestión de inventario	19
7.2. Políticas de inventario	21
7.2.1. Parámetros básicos de reposición	21
7.2.2. Tipos de políticas de reposición	22
7.2.3. Política (s,S) y niveles de inventario	22
7.3. Análisis de demanda en gestión de repuestos	23
7.3.1. Matriz ADI-CV ²	25
7.4. Clasificación de materiales	27
7.4.1. Clasificación ABC	28
7.4.2. Clasificación XYZ	30



7.4.3.	Limitaciones de enfoques univariabes	31
7.5.	Machine Learning	31
7.6.	Clustering	33
7.7.	K-Means	34
7.7.1.	Selección del número óptimo de clústeres: método del codo	35
7.7.2.	Estandarización de variables	36
7.7.3.	Tratamiento de valores atípicos (outliers)	37
7.8.	Juicio Experto	38
8.	Metodología	40
8.1.	Análisis de datos de consumo	41
8.1.1.	Obtención y limpieza de datos	42
8.1.2.	Variables clave y estructura de la base	43
8.1.3.	Análisis exploratorio de consumo	44
8.2.	Clasificación de materiales	46
8.2.1.	Preparación de datos para la clasificación	46
8.2.2.	Clasificación ABC	48
8.2.3.	Clasificación XYZ	50
8.2.4.	Clasificación multivariable mediante <i>K-Means</i>	52
8.3.	Clasificación de almacenes mecánicos	55
8.3.1.	Definición de variables y preparación de datos	55
8.3.2.	Preprocesamiento de datos	57
8.3.3.	Determinación del número óptimo de clústeres	57



8.3.4.	Implementación del modelo	58
8.3.5.	Caracterización de los clústeres	58
8.4.	Definición de límites de control (s, S)	58
8.4.1.	Análisis del tipo de demanda por cruce de clústeres	59
8.4.2.	Caracterización logística y operativa	61
8.4.3.	Asignación inicial de límites (s, S)	62
8.4.4.	Ajuste final mediante ponderadores	64
8.5.	Evaluación de propuesta de límites de control (s, S)	65
8.5.1.	Obtención del nivel de stock actual para los clústeres	66
8.5.2.	Evaluación de propuesta	66
8.5.3.	Evaluación de escenario conservador	68
9.	Resultados y discusión	69
9.1.	Análisis de datos de Consumo	69
9.2.	Clasificación de materiales	71
9.2.1.	Clasificación ABC	72
9.2.2.	Clasificación XYZ	73
9.2.3.	Clasificación multivariable mediante K-Means	75
9.3.	Clasificación de almacenes mecánicos	80
9.3.1.	Definición de variables y preparación de datos	80
9.3.2.	Determinación del número óptimo de clústeres	81
9.3.3.	Caracterización de los clústeres	82
9.4.	Definición de límites de control (s, S)	85



9.4.1.	Análisis de tipo de demanda por cruce de clústeres	85
9.4.2.	Caracterización logística y operativa	89
9.4.3.	Asignación de límites (s, S)	91
9.5.	Evaluación de propuesta de límites de control (s, S)	95
9.5.1.	Obtención del nivel de stock actual para los clústeres	95
9.5.2.	Evaluación de propuesta	96
9.5.3.	Evaluación de escenario conservador	99
10.	Conclusiones y recomendaciones	103



Lista de Tablas

1.	Ejemplo de DataFrame consolidado de consumo.	48
2.	Criterios utilizados para la clasificación ABC	49
3.	Criterios utilizados para la clasificación XYZ	51
4.	Ejemplo de estructura de datos para clasificación de almacenes	57
5.	Perfil de clústeres de materiales obtenidos mediante K-Means	78
6.	Perfil de clústeres de almacenes mecánicos obtenidos a través de K-Means	84

Lista de Figuras

1.	Clasificación de patrones de demanda según ADI y CV^2	27
2.	Curva de análisis ABC	29
3.	Diagrama de proceso de la estructura metodológica.	41
4.	Extracto de código para la corrección de formato de campos en <code>DataFrame</code>	43
5.	Extracto de código para la agrupación de consumos por material.	47
6.	Porcentaje de tipo de prioridad por negocio de la empresa.	48
7.	Extracto de código para la clasificación ABC	50
8.	Extracto de código para la clasificación XYZ de materiales	51
9.	Extracto de código para preprocesamiento de variables: winsorización y normalización	53
10.	Extracto de código para cálculo del número óptimo de clústeres mediante el método del codo	54
11.	Extracto de código de implementación de K-Means	55
12.	Extracto de código para Preprocesamiento de datos para clustering de almacenes	57
13.	Extracto de código para la clasificación de la demanda por combinación de clústeres utilizando ADI y CV^2	60
14.	Extracto de código para el cálculo inicial de límites (s, S)	64
15.	Extracto de código para la aplicación de ponderadores correctivos a límites (s, S)	65
16.	Extracto de código para el cálculo de semanas de cobertura del inventario actual	66
17.	Extracto de código para comparación de inventario actual y niveles propuestos	67
18.	Extracto de código de simulación del escenario conservador	68



19.	Cantidad de materiales consumidos por mes y año en almacenes mecánicos	69
20.	Entradas y salidas de repuestos distintos por año.	70
21.	Cantidad de materiales por clasificación ABC.	72
22.	Curva ABC de la clasificación	73
23.	Cantidad de materiales por clasificación XYZ	74
24.	Método del Codo para clasificación de repuestos	76
25.	Visualización de Clusters de materiales (K-Means)	77
26.	Método del Codo para clasificación de almacenes	81
27.	Visualización de Clusters de almacenes mecánicos (K-Means)	82
28.	Evolución de consumo semanal para el cruce 0-2 (ALM-MAT) - Demanda tipo errática	86
29.	Evolución de consumo semanal para el cruce 0-0 (ALM-MAT) - Demanda tipo grumosa	87
30.	Evolución de consumo semanal para el cruce 2-2 (ALM-MAT) - Demanda tipo suavizada	87
31.	Evolución de consumo semanal para el cruce 0-3 (ALM-MAT) - Demanda no clasificable	88
32.	Matriz de tipo de demanda cruce almacén- material	89
33.	Matriz de características principales por cruce almacén- material	91
34.	Evolución de consumo semanal para el cruce 2-1 (ALM-MAT) nivel de inventario 1	92
35.	Evolución de consumo semanal para el cruce 2-6 (ALM-MAT) nivel de inventario 2	93



36. Evolución de consumo semanal para el cruce 0-0 (ALM-MAT) nivel de inventario	
3	93
37. Matriz de nivel de inventario por cruce almacén- material	94
38. Semanas de cobertura por cruce ALM-MAT Nivel de inventario Actual	95
39. Semanas de cobertura por cruce ALM-MAT Nivel de inventario mínimo propuesto	97
40. Semanas de cobertura por cruce ALM-MAT Nivel de inventario máximo propuesto	98
41. Variación de Semanas de cobertura por cruce ALM-MAT entre nivel de inventario	
máximo propuesto y actual	99
42. Semanas de cobertura por cruce ALM-MAT Nivel de inventario mínimo propuesto	
(escenario conservador)	100
43. Semanas de cobertura por cruce ALM-MAT Nivel de inventario máximo propuesto	
(escenario conservador)	101
44. Variación de Semanas de cobertura por cruce ALM-MAT entre nivel de inventario	
máximo propuesto (escenario conservador) y actual	102

1. Agradecimientos

En primer lugar, deseo expresar mi más profundo agradecimiento a mi familia por el apoyo incondicional que me han brindado a lo largo de mi vida. Espero algún día poder retribuir todo su esfuerzo. A mi mamá Nancy, por sus cuidados y sacrificios, así como por inculcarme valores y enseñanzas que han guiado mi camino. A mis hermanas Jennifer y Valeria, por cuidarme, aconsejarme, enseñarme y confiar siempre en mis capacidades; su apoyo constante y la forma en que supieron aliviarme de presiones han sido fundamentales para alcanzar este logro. A mi papá Walter, por motivarme siempre a dar lo mejor de mí. Y a mi mamá Ana, por cuidarme y preocuparse de mis necesidades, incluso a la distancia.

A mi novia Fernanda, por su apoyo constante durante estos años, por estar presente en los momentos difíciles y celebrar conmigo cada logro, grande o pequeño. Gracias por tu paciencia, comprensión y por recordarme, incluso en los días más exigentes, la importancia de mantener el equilibrio. Tu cariño, motivación y confianza en mí hicieron posible llegar hasta aquí. A su familia, que me ha acogido como a un integrante más, brindándome afecto y respaldo en todo momento.

Agradezco sinceramente al profesor Rodrigo, por confiar en mí, enseñarme y darme la oportunidad de trabajar a su lado; así como a Javiera, quien me apoyó a lo largo de toda la carrera universitaria.

A la empresa donde desarrollé esta memoria, por abrirme las puertas y brindarme la oportunidad de crecer profesionalmente. A mi supervisor Benjamín, por su confianza, apoyo constante, enseñanzas y todas las facilidades otorgadas durante el proceso. A mi jefa Alejandra, por creer en mis capacidades, orientarme y transmitirme sus conocimientos. A Ricardo, por permitirme trabajar en este tema, y a todo el equipo y subgerencia por su apoyo, en especial a Sebastián, César,



Nicolás, Carolina y Asunción, quienes contribuyeron de manera significativa a mi desarrollo tanto personal como profesional.

A mis amigos de la universidad, quienes hicieron más ameno este camino y sin los cuales no habría llegado hasta aquí: Isadora, Gabriela, Trinidad, Catalina, Víctor y Carolina. También a mis amigos de la infancia, que me acompañaron y alentaron durante este proceso: Tomás, Nicolás, Álvaro, Cristian y Vicente.

Finalmente, a todas las personas que, de una u otra forma, me han apoyado a lo largo de mi vida y de mi carrera, contribuyendo a que hoy sea quien soy.

2. Resumen Ejecutivo

La gestión eficiente de inventarios en almacenes mecánicos es fundamental para garantizar la continuidad operativa y optimizar el uso de recursos. Este trabajo presenta un modelo de segmentación y control de inventarios que combina técnicas de clasificación multivariable y análisis de patrones de consumo, con el propósito de fortalecer la toma de decisiones y reducir costos operativos.

La metodología propuesta integra el análisis histórico del consumo de repuestos con la clasificación de materiales según su valor, criticidad y cantidad demandada, junto con la segmentación de almacenes considerando su ubicación, valor consumido y diversidad de negocios atendidos. Las clasificaciones multivariadas se desarrollan mediante el algoritmo *K-Means*, implementado en Python, lo que posibilita un procesamiento eficiente, replicable y escalable de grandes volúmenes de datos. A partir de esta segmentación, se definen límites de control (s, S) ¹ específicos para cada combinación material–almacén, aplicando criterios estadísticos y juicio experto, y posteriormente se evalúa su impacto frente a la situación actual y en un escenario conservador.

Los resultados evidencian que la aplicación del modelo permite reducir en un 91,18 % el valor total de inventarios, equivalente a un ahorro estimado de 1.702 millones de CLP, manteniendo niveles de cobertura adecuados para la operación. El escenario conservador, que incrementa los límites de inventario, alcanza un ahorro de 1.557 millones de CLP y asegura una cobertura más holgada.

Se concluye que la estrategia propuesta resulta altamente efectiva para optimizar el capital inmovilizado sin comprometer la continuidad del servicio. Se recomienda su implementación

¹Par de umbrales de la *política de reabastecimiento*: s (punto de reorden, inventario mínimo) y S (nivel máximo de inventario).



progresiva, estableciendo un nivel de servicio objetivo y fortaleciendo la clasificación con métodos adicionales, como series de tiempo o análisis de tasas de falla, para mejorar la precisión en la estimación de la demanda.

Palabras clave: Gestión de inventario, Repuestos, K-Means, Clasificación de repuestos, Python.

3. Abstract

Efficient inventory management in mechanical warehouses is essential to ensure operational continuity and optimize resource utilization. This work presents a segmentation and inventory control model that combines multivariable classification techniques with consumption pattern analysis, aiming to enhance decision-making and reduce operating costs.

The proposed methodology integrates the historical analysis of spare parts consumption with the classification of materials according to their value, criticality, and demand volume, along with the segmentation of warehouses based on location, consumed value, and diversity of business operations served. Multivariable classifications are performed using the *K-Means* algorithm, implemented in Python, enabling efficient, replicable, and scalable processing of large datasets. Based on this segmentation, (s, S) control limits are defined for each material–warehouse combination, applying both statistical criteria and expert judgment, and subsequently assessing their impact compared to the current situation and under a conservative scenario.

The results show that the implementation of the model can reduce the total inventory value by 91.18 %, equivalent to an estimated saving of CLP 1.702 MM, while maintaining adequate coverage levels for operations. The conservative scenario, which increases inventory limits for critical cases, achieves savings of CLP 1.557 MM and ensures more robust coverage.

It is concluded that the proposed strategy is highly effective in optimizing tied-up capital without compromising service continuity. Progressive implementation is recommended, establishing a target service level and strengthening classification with additional methods such as time series analysis or failure rate analysis to improve demand estimation accuracy.

Keywords: inventory management, Spare parts, K-Means, Spare parts classification, Python.

4. Problema de Investigación

La gestión eficiente de repuestos en el ámbito industrial es fundamental para garantizar la continuidad operativa y minimizar costos asociados al almacenamiento y la logística. La administración de inventarios es una de las actividades logísticas en donde se encuentran las mejores posibilidades de reducir costos para las empresas, mediante una mejor gestión de los materiales almacenados y su transporte (Zapata 2014)

En este contexto, se analiza una empresa industrial de gran envergadura, dedicada a la distribución de combustibles y lubricantes, que cuenta con una amplia red de estaciones de servicio y operaciones industriales a nivel nacional. La empresa posee una infraestructura logística distribuida a lo largo del territorio, lo cual la obliga a mantener altos niveles de disponibilidad de sus equipos. El mantenimiento es crucial para asegurar el funcionamiento continuo de sus instalaciones, especialmente en operaciones que demandan un alto nivel de disponibilidad de equipos.

Actualmente, en el área de mantenimiento de la empresa, no existe un modelo que permita optimizar la cantidad de inventario en los almacenes mecánicos.² El enfoque actual se centra principalmente en garantizar que los mecánicos no se queden sin implementos para realizar su trabajo. Sin embargo, este enfoque ha generado problemas como el sobrestock de algunos repuestos, lo que conlleva a capital inmovilizado y aumenta los costos operativos a largo plazo.

Uno de los principales desafíos es la falta de clasificación adecuada de los materiales. Actualmente, no existe una clasificación clara de los repuestos por criticidad y demanda, lo que dificulta la toma de decisiones informadas sobre cuánto inventario debe mantenerse en cada almacén. Clasificar los repuestos en función de su frecuencia de uso, criticidad y valor es crucial

²Los almacenes mecánicos son espacios administrados por contratistas externos donde se almacenan los repuestos necesarios para las labores de mantenimiento de los equipos de la empresa.

para determinar si es más rentable mantener stock o reponer el material con mayor frecuencia. Tal como señalan Moncrief, Schroder y Reynolds (2006), en un almacén típico de materiales para mantenimiento, cerca del 10 % de los materiales representan alrededor del 90 % del valor total del inventario; además, no todos los artículos tienen la misma criticidad. Por ello, la clasificación permite dirigir los recursos a aquellos ítems con mayor impacto financiero y operacional, reduciendo la inversión total sin afectar el nivel de servicio.

Además, la gestión de inventarios se complica debido a que existen almacenes de diferentes tamaños y con patrones de consumo distintos. Cada almacén tiene necesidades únicas de repuestos debido a las variaciones en los equipos que mantienen y los niveles de consumo de cada tipo de repuesto. Por lo tanto, no se puede aplicar una única estrategia de inventario a todos los almacenes, sino que será necesario desarrollar estrategias diferenciadas según el tipo de almacén. Cada almacén debe ser gestionado de acuerdo con sus características específicas para optimizar tanto los costos de almacenamiento como los de reabastecimiento.

En consecuencia, se requiere avanzar hacia un enfoque sistemático que permita diseñar una estrategia de gestión de inventario segmentada, basada en la clasificación combinada de repuestos y almacenes. Esta estrategia debe permitir definir límites de control $(s, S)^3$ ajustados a las condiciones reales de criticidad, consumo y logística de cada combinación, y facilitar su validación práctica mediante la comparación con el stock actualmente disponible. Con ello, se busca no solo mejorar la asignación de recursos, sino también evaluar el impacto operativo y económico de la propuesta frente a la situación actual. Ante esta problemática, surgen preguntas relevantes que orientarán el desarrollo de este estudio:

³Par de umbrales de la *política de reabastecimiento*: s (punto de reorden, inventario mínimo) y S (nivel máximo de inventario).



¿Cuál ha sido el comportamiento histórico del consumo de repuestos en los almacenes de mantenimiento y qué patrones relevantes pueden identificarse?

¿Cómo podrían categorizarse los repuestos de acuerdo a su costo, criticidad y consumo en el tiempo?

¿Cómo pueden caracterizarse los distintos tipos de almacenes mecánicos desde una perspectiva operativa y logística?

¿Qué criterios permiten definir límites de control (s,S) para cada combinación de tipo de repuesto y tipo de almacén?

¿Qué efectos tendría la aplicación de estos umbrales de reabastecimiento (s,S) sobre el stock actual y qué beneficios concretos podrían obtenerse en términos de cobertura y costos?

5. Objetivos

5.1. Objetivo General

Diseñar una estrategia de gestión de inventario para almacenes de mantenimiento mecánico, basada en segmentación de materiales y almacenes, con el fin de mejorar la toma de decisiones y reducir los costos operativos asociados al almacenamiento.

5.2. Objetivos Específicos

1. Analizar el comportamiento actual e histórico del consumo de repuestos, con el propósito de identificar patrones que orienten la gestión de inventarios.
2. Clasificar los repuestos en base a variables clave asociadas a su uso e impacto operativo, con el fin de establecer prioridades que faciliten su control y abastecimiento.
3. Categorizar los almacenes mecánicos según sus características operativas y logísticas, con el fin de definir estrategias de gestión diferenciadas.
4. Definir los límites de control (s,S) por combinación de tipo de repuesto y tipo de almacén, con el fin de ajustar la cobertura de stock a las condiciones reales de demanda y criticidad.
5. Evaluar el impacto potencial de la propuesta metodológica, con el fin de validar su utilidad práctica y su capacidad de mejora frente a la situación actual.

6. Alcance

El presente estudio se enfoca exclusivamente en los almacenes mecánicos pertenecientes a la red logística de la empresa. Su alcance se delimita específicamente a la gestión de inventario y a la optimización de la asignación de repuestos desde el centro de distribución hacia dichos almacenes, excluyendo los procesos relacionados con compras y planificación de abastecimiento.

Para garantizar la coherencia y relevancia de los resultados, el análisis se realiza únicamente sobre ítems del tipo repuesto que cuenten con una orden de trabajo (OT) asociada, es decir, que hayan sido utilizados en actividades de mantenimiento correctivo o preventivo. Además, se considera un horizonte temporal de dos años de datos históricos.

Por último, se eliminan aquellos registros correspondientes a materiales clasificados como “Materiales Varios”, ya que no aportan valor específico al análisis de repuestos y representan una práctica inadecuada que se busca dejar de utilizar.

7. Marco teórico

7.1. Gestión de inventario

La gestión de inventarios ha desempeñado históricamente un papel fundamental en la logística y la administración de operaciones, debido a su influencia directa tanto en la eficiencia de los procesos productivos como en el nivel de servicio ofrecido a los clientes. Además, constituye un área clave para la reducción de costos y la optimización del desempeño operativo.

Desde comienzos del siglo XXI, los enfoques tradicionales de control de inventarios han dado paso a modelos más dinámicos, capaces de adaptarse a entornos volátiles y caracterizados por altos niveles de incertidumbre, integrando tecnologías como el aprendizaje automático y el big data (Shuai Zhang, Huang y Yuan 2021).

Los inventarios existen para permitir la independencia operativa entre funciones como compras, producción, mantenimiento y distribución, funcionando como amortiguadores frente a interrupciones o incertidumbre en el abastecimiento (Contreras Márquez 2022). En términos generales, se distinguen cuatro tipos principales de inventario:

- Materias primas
- Productos en proceso
- Productos terminados
- Materiales MRO (Mantenimiento, Reparación y Operaciones)

En particular, los inventarios MRO han emergido como un ámbito especializado dentro de la gestión de inventarios, debido a sus características operativas singulares. A diferencia de

los inventarios destinados a la venta directa o al consumo regular, los repuestos están orientados a asegurar la continuidad operativa de activos productivos o equipos técnicos, lo que introduce desafíos adicionales en su administración (Kennedy, Patterson y Fredendall 2002).

Una de las principales dificultades asociadas a estos inventarios es la incertidumbre en la demanda. El consumo de repuestos suele ser esporádico, relacionado con fallas imprevistas o mantenimientos programados, y se alterna con extensos períodos sin movimiento. (Rego y Mesquita 2011). Además, existe una gran heterogeneidad en cuanto a sus características: algunos artículos son de muy bajo valor, como los insumos de ferretería, mientras que otros pueden superar varios miles de dólares, como ciertos componentes críticos de equipos industriales.

A esta variabilidad se suma la diferencia en los tiempos de entrega. Mientras algunos productos pueden adquirirse en pocas horas, otros requieren procesos de compra que deben iniciarse con varios meses, e incluso más de un año, de anticipación. Asimismo, la criticidad de un artículo no depende exclusivamente de su valor económico, sino de las consecuencias operativas que implica su ausencia. Desde el punto de vista de la gestión de inventario, la criticidad se evalúa en función del impacto que tendría no contar con el repuesto en el momento necesario (Contreras Márquez 2022).

Estas condiciones —incertidumbre en la demanda, diversidad de precios, variabilidad en tiempos de entrega y niveles dispares de criticidad— hacen que la gestión de repuestos se considere una de las funciones logísticas más complejas y críticas dentro de la cadena de suministro (Rego y Mesquita 2011).

7.2. Políticas de inventario

Una política de reposición define las reglas que determinan cuándo y cuánto reponer, buscando mantener un equilibrio entre la disponibilidad de materiales y la eficiencia en costos. Estas políticas se sustentan en una serie de parámetros esenciales, los cuales se presentan a continuación. (Abd El-Aal et al. 2010).

7.2.1. Parámetros básicos de reposición

Las políticas de inventario se apoyan en variables clave como el punto de pedido (PP), el stock mínimo, el stock de seguridad (SS), la cantidad de pedido (CP), y los niveles máximos (S) y mínimos (s) (Contreras Márquez 2022).

- El **punto de pedido (PP)** corresponde al nivel de inventario en el que se debe emitir una orden de compra. Este se estima como la demanda esperada durante el *lead time*⁴ más el SS.
- El **stock mínimo** se calcula a partir del tiempo medio de entrega multiplicado por la tasa media de uso.
- El **stock de seguridad (SS)** actúa como amortiguador frente a la variabilidad en la demanda y los tiempos de entrega.
- La **cantidad de pedido (CP)** puede fijarse mediante la Cantidad Económica de Pedido (EOQ), que minimiza los costos conjuntos de ordenar y mantener inventario.
- El **nivel de servicio** representa la probabilidad de satisfacer la demanda sin incurrir en faltantes, y depende de los valores definidos para PP, SS y el lead time.

⁴El *lead time* corresponde al tiempo transcurrido entre la emisión de un pedido y su recepción efectiva en el inventario.

7.2.2. Tipos de políticas de reposición

La literatura distingue entre dos grandes enfoques de políticas de inventario según la frecuencia con que se revisan los niveles:

- **Revisión continua:** El inventario es monitoreado constantemente y se toma acción en el momento en que se alcanzan ciertos umbrales. Ejemplos:
 - **(s,Q):** se realiza un pedido de cantidad fija Q cuando el inventario cae a s .
 - **(s,S) (MÍN/MÁX):** se repone hasta un nivel máximo S cuando el stock cae a un nivel mínimo s .
 - **(S-1,S):** se aplica para repuestos reparables, reponiendo de manera individual sincronizada con el ciclo de reparación (Shuai Zhang, Huang y Yuan 2021).

- **Revisión periódica:** El inventario se revisa en intervalos de tiempo fijos, y se decide si reponer o no. Ejemplos:
 - **(T,S):** se repone hasta S cada T períodos.
 - **(T,s,S):** solo se ordena si el inventario está por debajo de s , reponiendo hasta S (Contreras Márquez 2022).

En entornos complejos, también se han desarrollado modelos multiperíodo que integran decisiones estratégicas y tácticas dentro del proceso de abastecimiento (Brunaud et al. 2018).

7.2.3. Política (s,S) y niveles de inventario

La política (s, S) , también conocida como MÍN/MÁX, es especialmente relevante en el contexto de inventarios MRO, donde la demanda suele ser errática y los tiempos de reposición

prolongados o inciertos. Esta política define dos umbrales:

- s : nivel mínimo que gatilla una orden de reposición.
- S : nivel máximo hasta el cual se repone el inventario.

Cuando el inventario disponible cae por debajo de s , se ordena una cantidad suficiente para alcanzar el nivel S . Este enfoque permite mantener niveles de stock que amortigüen la variabilidad de la demanda y los tiempos de entrega, sin incurrir en excesos innecesarios.

La definición adecuada de estos niveles es una tarea crítica. El punto de pedido (PP) y el stock de seguridad (SS) deben calcularse considerando parámetros estadísticos como la demanda promedio, la desviación estándar y el nivel de servicio deseado (Priniotakis y Argyropoulos 2018).

En entornos con demanda inestable o baja rotación, la literatura propone enfoques más flexible, en los cuales el tamaño del stock objetivo se ajusta en función del comportamiento reciente del consumo (Tsou 2013). Asimismo, la gestión efectiva debe balancear los costos de mantener inventario (capital inmovilizado, almacenamiento) frente a los riesgos del desabastecimiento (interrupciones operativas, pérdida de confianza, retrasos en mantenimiento), buscando siempre adaptarse a las condiciones particulares de cada ítem (Kirmizi, Ceylan y Bulkan 2024). En consecuencia, la política (s, S) se presenta como una herramienta clave para definir estrategias diferenciadas de reposición que se ajusten al comportamiento específico de la demanda y la criticidad de los ítems MRO.

7.3. Análisis de demanda en gestión de repuestos

El análisis y la comprensión de la demanda representan un elemento fundamental dentro de la gestión de inventarios, ya que constituyen la base sobre la cual se construyen decisiones

estratégicas y operativas en la cadena de suministro. La precisión en el pronóstico de la demanda permite mantener un equilibrio adecuado entre la disponibilidad de productos y la eficiencia de costos, evitando tanto situaciones de escasez como de sobreabastecimiento (Oca Sánchez y Loza-Hernández 2022).

Uno de los principales desafíos en este contexto radica en que la demanda no siempre sigue patrones regulares. En particular, en el caso de los repuestos, los patrones de consumo pueden ser altamente variables, con comportamientos erráticos, intermitentes o poco frecuentes. Esta irregularidad complica la aplicación de métodos tradicionales de pronóstico, ya que la naturaleza aleatoria y discontinua del consumo exige enfoques más adaptativos y especializados.

La demanda de repuestos presenta características distintivas que la diferencian de otros productos. A menudo se trata de ítems con baja frecuencia de consumo, pero con alta criticidad operativa. En consecuencia, su falta de disponibilidad puede provocar consecuencias significativas, como interrupciones en los procesos, pérdidas económicas o disminución en los niveles de servicio (Costantino et al. 2018).

Además, la planificación de inventarios se ve desafiada por la gran variedad de referencias, la dispersión en el comportamiento de consumo y la dificultad para anticipar con precisión cuándo serán requeridos. Como señalan Oca Sánchez y Loza-Hernández (2022), la demanda de refacciones suele presentar un comportamiento altamente irregular, lo que limita la eficacia de los métodos convencionales de pronóstico y control. En este escenario, se vuelve fundamental utilizar herramientas analíticas que permitan caracterizar adecuadamente la demanda, con el fin de seleccionar estrategias de gestión e inventario más acordes a la realidad operativa.

7.3.1. Matriz ADI-CV²

Ante la variabilidad e irregularidad que caracteriza a la demanda de repuestos, se han desarrollado metodologías específicas para clasificar su comportamiento y facilitar la toma de decisiones en la gestión de inventarios. Una de las herramientas más utilizadas con este propósito es la matriz ADI-CV², también conocida como matriz de clasificación de patrones de demanda basada en ADI y CV², la cual permite segmentar los ítems según el comportamiento de su consumo.

El primer indicador utilizado es el ADI (Average inter-Demand Interval), que se define como el intervalo promedio entre dos demandas consecutivas distintas de cero, y se utiliza como medida de la intermitencia de la demanda (Sahin, Kizilaslan y Demirel 2013). Valores altos de ADI indican que las demandas ocurren con poca frecuencia y en períodos separados, mientras que valores bajos reflejan una ocurrencia más constante.

El segundo indicador es el CV² (coeficiente de variación al cuadrado), que representa la variabilidad del tamaño de la demanda. Se calcula como el cuadrado del cociente entre la desviación estándar y la media de las demandas no nulas. Un CV² elevado indica una alta variabilidad en las cantidades solicitadas, mientras que un CV² bajo refleja una demanda más estable (Costantino et al. 2018).

La combinación de ambos indicadores da origen a una matriz que permite clasificar los patrones de demanda en cuatro tipos principales, cada uno con implicancias distintas para la planificación del inventario y la selección de métodos de pronóstico. Estos patrones son:

- **Demanda suavizada (Smooth):** se caracteriza por un comportamiento estable tanto en frecuencia como en cantidad. Presenta baja intermitencia ($ADI \leq 1,32$) y baja variabilidad en el tamaño de los pedidos ($CV^2 \leq 0,49$). Es el tipo de demanda más predecible, lo que

facilita la aplicación de métodos clásicos de pronóstico.

- **Demanda errática (Erratic):** ocurre con frecuencia ($ADI \leq 1,32$), pero con grandes fluctuaciones en la magnitud de la demanda ($CV^2 > 0,49$). Aunque hay actividad constante, la variabilidad en las cantidades solicitadas dificulta el control y planificación eficiente del inventario.
- **Demanda intermitente (Intermittent):** presenta periodos prolongados sin consumo ($ADI > 1,32$), pero cuando la demanda ocurre, las cantidades son relativamente estables ($CV^2 \leq 0,49$). Es común en repuestos que se utilizan esporádicamente pero con cantidades previsibles.
- **Demanda grumosa (Lumpy):** combina una alta intermitencia ($ADI > 1,32$) con una alta variabilidad en el tamaño de la demanda ($CV^2 > 0,49$). Este patrón es el más complejo de gestionar, ya que no solo ocurre en forma esporádica, sino que también con magnitudes muy variables.

Estos patrones son representados visualmente en la figura 1, con base en los valores de corte propuestos por Syntetos, Boylan y Croston (2005) y la representación gráfica presentada por Costantino et al. (2018):

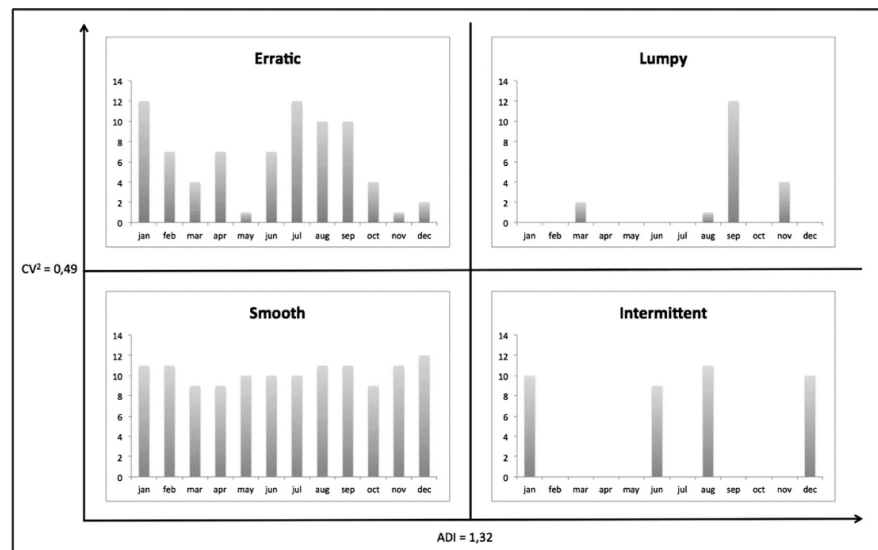


Figura 1: Clasificación de patrones de demanda según ADI y CV^2

Fuente: Adaptado de Costantino et al. (2018), con base en los valores de corte de Syntetos, Boylan y Croston (2005)

Esta clasificación ha sido ampliamente utilizada en estudios sobre repuestos, ya que permite identificar patrones que orientan tanto la selección de métodos de pronóstico como la definición de políticas de inventario acordes al comportamiento real de la demanda (Oca Sánchez y Loza-Hernández 2022; Costantino et al. 2018).

7.4. Clasificación de materiales

La clasificación de materiales es una herramienta clave para una gestión eficiente del inventario, especialmente en el caso de repuestos, donde la amplia variedad de ítems —en términos de criticidad, valor económico y comportamiento de demanda— impide aplicar estrategias homogéneas de control y reposición (Bhalla et al. 2021).

Su propósito principal es facilitar la toma de decisiones al permitir priorizar recursos, definir niveles de stock adecuados y diseñar políticas de reabastecimiento ajustadas a las particula-

ridades de cada grupo de materiales. Al segmentar los ítems según atributos relevantes, se evita una gestión uniforme que podría resultar ineficiente o costosa, promoviendo en cambio un enfoque alineado con los objetivos operativos y logísticos de la organización. (Contreras Márquez 2022)

Para responder a esta necesidad, se han desarrollado distintos métodos de clasificación que permiten agrupar materiales con características similares. Entre ellos destacan los enfoques tradicionales basados en un único criterio, como el valor de consumo, la criticidad o la rotación, ampliamente utilizados por su simplicidad y facilidad de implementación en sistemas existentes .

7.4.1. Clasificación ABC

La clasificación ABC es una técnica ampliamente utilizada en la gestión de inventarios que permite segmentar los ítems según su nivel de importancia relativa, considerando criterios como el valor económico, el volumen de consumo o su impacto operativo. En el caso de los repuestos, permite clasificar los repuestos según el nivel de importancia que tienen en la actividad productiva de la compañía, siendo relevante el valor total de consumo (Stoll, Heine y Schultmann 2014).

Este enfoque se fundamenta en el principio de Pareto, el cual sugiere que una pequeña proporción de elementos suele concentrar una gran parte del efecto total. El principio de Pareto indica relaciones 80/20 entre dos factores, en particular indicando que el 20 % de una fuerza provoca el 80 % de los resultados (Kenton 2023). Aunque no se trata de una regla estricta, esta relación sirve como guía para identificar los ítems más significativos dentro de un inventario.

Aplicado a inventarios, este principio se traduce en una clasificación en tres categorías:

- La clase A agrupa los ítems más importantes, que representan un pequeño porcentaje del total de artículos, pero concentran una proporción elevada del valor total de consumo.

- La clase B corresponde a artículos de importancia intermedia, tanto en términos de frecuencia como de valor.
- La clase C incluye la mayoría de los ítems, los cuales tienen bajo impacto económico individual, pero representan un volumen significativo del total de referencias.

Esta distribución se refleja gráficamente mediante la curva del análisis ABC, donde se observa que una fracción reducida de ítems genera la mayor parte del costo acumulado:




Figura 2: Curva de análisis ABC

Fuente: (Peiró 2017)

La utilidad de esta clasificación radica en su capacidad para enfocar los recursos de gestión y control sobre los materiales más críticos, permitiendo aplicar estrategias diferenciadas de planificación, reposición y monitoreo según la categoría asignada a cada ítem.

7.4.2. Clasificación XYZ

La clasificación XYZ es una técnica de segmentación de inventarios que agrupa los ítems en función de la regularidad o variabilidad de su consumo. A diferencia del enfoque ABC, que prioriza la importancia económica, esta metodología se centra en el comportamiento de la demanda a lo largo del tiempo, permitiendo identificar materiales con patrones estables, irregulares o impredecibles.

El criterio principal utilizado para esta clasificación es la predictibilidad de la demanda de cada repuesto (Stoll, Heine y Schultmann 2014). Para ello, se suele analizar la desviación estándar o el coeficiente de variación del consumo, a fin de determinar el grado de fluctuación asociado a cada ítem. Con base en este análisis, los materiales se dividen comúnmente en tres categorías:

- Clase X: ítems con demanda regular y predecible, cuya variación es mínima a lo largo del tiempo.
- Clase Y: ítems con cierto grado de variabilidad, pero que presentan cierta tendencia o estacionalidad identificable.
- Clase Z: ítems con demanda altamente errática o esporádica, que dificulta su pronóstico y planificación.

Este tipo de clasificación resulta particularmente útil para ajustar las estrategias de reposición y los niveles de stock de seguridad según el comportamiento de cada grupo. Los materiales con demanda estable pueden gestionarse con métodos de reaprovisionamiento más automatizados, mientras que aquellos con demanda incierta requieren monitoreo más frecuente o criterios de inventario más conservadores.

7.4.3. Limitaciones de enfoques univariados

A pesar de su utilidad operativa, los métodos tradicionales de clasificación presentan limitaciones importantes cuando se aplican a inventarios complejos como los de repuestos. En particular, su enfoque unidimensional puede resultar insuficiente para capturar la multiplicidad de factores que determinan la criticidad y el comportamiento de un ítem.

Tal como advierte la literatura, la clasificación basada en ABC y XYZ solo considera un único criterio. Sin embargo, un solo criterio generalmente no puede representar completamente la criticidad de un ítem. Por ejemplo, la falta de un repuesto de baja rotación puede tener un gran impacto en la productividad (Teixeira, Lopes y Figueiredo 2017). Este tipo de situaciones pone en evidencia la necesidad de incorporar enfoques multivariados, que integren variables operativas, técnicas y económicas en la definición de categorías, y permitan establecer políticas más ajustadas a la realidad de la operación.

7.5. Machine Learning

El aprendizaje automático, también conocido como Machine Learning (ML), se ha posicionado como una herramienta clave en la optimización de procesos logísticos, especialmente en contextos donde la gestión eficiente del inventario resulta crítica. Este enfoque se basa en el uso de algoritmos y modelos estadísticos capaces de analizar grandes volúmenes de datos, identificar patrones y generar predicciones, permitiendo que los sistemas computacionales ejecuten tareas de manera autónoma y mejoren su desempeño progresivamente. En este sentido, el aprendizaje automático se entiende como el estudio científico de técnicas que posibilitan que los sistemas aprendan y se adapten a partir de la experiencia contenida en los datos, sin requerir una programación explí-

cita para cada acción (Mahesh 2020).

Aplicado al ámbito de inventarios, el Machine Learning permite superar las limitaciones de los enfoques tradicionales mediante el análisis automatizado de grandes volúmenes de datos históricos, lo que facilita una gestión más dinámica y precisa. Entre sus beneficios se encuentran la mejora en los pronósticos de demanda, la optimización del inventario en tiempo real, la coordinación entre múltiples ubicaciones y socios, la reducción de riesgos asociados a quiebres o sobrestock, y una toma de decisiones más informada y eficiente (Chaudhary et al. 2023).

Una distinción fundamental dentro del aprendizaje automático es la que se establece entre los enfoques supervisado y no supervisado. En el aprendizaje supervisado, los algoritmos se entrenan a partir de conjuntos de datos previamente etiquetados, es decir, datos en los que se conoce la variable objetivo que se desea predecir o clasificar. Esto permite construir modelos que identifican relaciones explícitas entre variables de entrada y salida, siendo útiles en contextos donde existe información histórica estructurada y bien categorizada.

En contraste, el aprendizaje no supervisado se aplica en situaciones donde los datos carecen de etiquetas o clasificaciones predefinidas, por lo que el modelo debe descubrir por sí mismo patrones, agrupaciones o estructuras ocultas en los datos. En este enfoque, el sistema no recibe instrucciones sobre qué relaciones buscar, sino que debe inferirlas a partir de la estructura subyacente de los datos (Naeem et al. 2023).

Esta diferencia permite comprender que, en el caso no supervisado, el aprendizaje emerge a partir de la exploración autónoma de los datos, sin una guía explícita respecto a la variable de interés.

7.6. Clustering

El clustering, o análisis de conglomerados, es una de las técnicas más representativas del aprendizaje no supervisado. Su objetivo principal es identificar grupos naturales dentro de un conjunto de datos, sin requerir etiquetas o categorías predefinidas. En lugar de predecir una variable objetivo, este tipo de técnicas se aplica cuando las instancias deben dividirse en segmentos que comparten ciertas similitudes internas (Witten et al. 2017).

De forma general, el clustering se define como un proceso mediante el cual los objetos se agrupan en función de alguna similitud inherente entre ellos, permitiendo descubrir estructuras latentes y generar agrupaciones homogéneas dentro de un espacio multivariable (Saxena et al. 2017).

En el ámbito de la gestión de inventarios, esta metodología ha demostrado ser útil para clasificar materiales según múltiples dimensiones, como el valor económico, la frecuencia de uso, la criticidad operativa o el comportamiento histórico de consumo. Tal como se plantea en la literatura, la técnica de clustering permite agrupar los ítems considerando simultáneamente diversos criterios, identificando similitudes en sus características. La principal ventaja de este enfoque es que facilita la segmentación de datos en grupos con comportamientos o atributos comunes, lo que contribuye a una gestión más eficiente y focalizada de los inventarios (Raja, Ai y Astanti 2016).

A diferencia de los métodos de clasificación tradicionales basados en un único atributo, el clustering ofrece una visión más integral del comportamiento de los ítems, lo que facilita el diseño de estrategias diferenciadas de gestión, alineadas con las particularidades operativas de cada grupo.

7.7. K-Means

El algoritmo K-Means es una de las técnicas de agrupamiento más utilizadas dentro del aprendizaje no supervisado, debido a su eficiencia y facilidad de implementación en grandes volúmenes de datos. Se basa en la partición del conjunto de datos en K clústeres definidos previamente. Su funcionamiento consiste en inicializar centroides, asignar cada punto de datos al centroide más cercano, recalcular los centroides como el promedio de los puntos de cada grupo, y repetir este proceso iterativamente hasta que las asignaciones no cambien significativamente, es decir, hasta alcanzar la convergencia (M. Ahmed, Seraj e Islam 2020).

En términos operativos, K-Means busca minimizar la variación interna de cada clúster, generando agrupaciones homogéneas que capturan estructuras ocultas en los datos. Esta característica lo convierte en una herramienta idónea para entornos donde se requiere segmentar ítems en función de múltiples atributos simultáneos.

En el ámbito de la gestión de inventarios, el algoritmo ha sido ampliamente utilizado para clasificar materiales y repuestos en grupos que comparten características similares, permitiendo así establecer políticas diferenciadas de stock o mantenimiento. Por ejemplo, Shoujing Zhang et al. (2020) aplican un algoritmo de clustering mejorado, basado en K-Means, para clasificar repuestos según su comportamiento histórico y evaluar su grado de importancia en el sistema logístico, superando las limitaciones de los métodos subjetivos tradicionales (Shoujing Zhang et al. 2020). Este enfoque permite una segmentación más objetiva y eficiente, facilitando la toma de decisiones estratégicas en la asignación de recursos, la definición de niveles de inventario y la priorización de abastecimiento.

Más allá de la clasificación, K-Means también ha sido utilizado en estudios recientes para

apoyar la predicción de demanda y la optimización de procesos logísticos, al identificar patrones de consumo que permiten ajustar los niveles de stock en función de las tendencias operativas. Esta versatilidad convierte al algoritmo en una herramienta clave para la planificación táctica y estratégica en entornos de alta complejidad e incertidumbre.

7.7.1. Selección del número óptimo de clústeres: método del codo

La determinación del número adecuado de clústeres (K) constituye uno de los principales desafíos al aplicar el algoritmo K-Means, ya que este parámetro debe definirse antes de iniciar el proceso de agrupamiento. Una elección arbitraria puede derivar en segmentaciones poco representativas, lo que compromete tanto la interpretación como la utilidad práctica de los resultados.

Entre los métodos más tradicionales y utilizados se encuentra el método del codo (elbow method), el cual se basa en un análisis visual del comportamiento del costo de agrupamiento al variar el valor de K . Este enfoque consiste en ejecutar el algoritmo sucesivamente desde $K=2$ en adelante, calculando para cada caso la suma total de errores cuadráticos internos (within-cluster sum of squares, WCSS). A medida que aumenta el número de clústeres, el WCSS disminuye, ya que cada grupo contiene menos elementos y, por tanto, menos variabilidad interna. En algún valor de K el costo disminuye drásticamente, y luego alcanza una meseta al seguir incrementando K . Ese es el valor de K que se desea (Kodinariya y Makwana 2013)

La lógica detrás de este método es que, al graficar el WCSS frente a los distintos valores de k , la curva resultante suele presentar una caída abrupta seguida de una estabilización progresiva. El punto en el cual esta disminución deja de ser significativa genera una inflexión —visualizada como un “codo” en la curva— que sugiere el número óptimo de clústeres. En la práctica, este valor representa un equilibrio entre simplicidad y precisión en la segmentación.

Si bien el método del codo es ampliamente utilizado por su simplicidad, existen enfoques alternativos que pueden complementarlo en contextos más exigentes. Entre ellos destacan el coeficiente de silueta, que evalúa la coherencia interna y la separación entre grupos, y los criterios de información estadística como el AIC o el BIC, que penalizan modelos complejos para evitar el sobreajuste. Estas herramientas permiten validar la elección de k desde distintos enfoques, aumentando la robustez del proceso de agrupamiento.

7.7.2. Estandarización de variables

La estandarización de variables constituye un paso fundamental previo a la aplicación de algoritmos de agrupamiento como K-Means, especialmente cuando las variables utilizadas en el análisis presentan escalas o unidades diferentes. Dado que este tipo de algoritmos se basa en el cálculo de distancias entre los puntos y los centroides, la influencia relativa de cada variable en el resultado final puede estar sesgada por su magnitud si no se ajusta previamente su escala.

Una de las técnicas más utilizadas para este propósito es la normalización Min-Max, la cual transforma los valores originales de cada variable a un rango común comprendido entre 0 y 1. De acuerdo con la definición técnica, la normalización Min-Max es el proceso de tomar datos medidos en sus unidades originales y transformarlos a un valor entre 0 y 1, donde el valor mínimo se establece como 0 y el valor máximo como 1 (Mohamad y Usman 2013).

Esta transformación resulta especialmente relevante en contextos multivariados, donde las variables consideradas pueden estar expresadas en escalas heterogéneas, como unidades monetarias, frecuencias absolutas o medidas ordinales. En este sentido, la normalización es particularmente útil para algoritmos de clasificación que implican mediciones de distancia (como la clasificación por K vecinos más cercanos y el clustering), ya que los atributos pueden tener distintos rangos

(H. A. Ahmed et al. 2022).

La correcta estandarización garantiza que cada dimensión del análisis tenga un peso proporcional en la construcción de los clústeres, evitando distorsiones en la segmentación y asegurando que las agrupaciones reflejen patrones estructurales reales en los datos.

7.7.3. Tratamiento de valores atípicos (outliers)

En el análisis de datos, la presencia de valores atípicos —también conocidos como outliers— representa un desafío importante, especialmente en métodos estadísticos y algoritmos de agrupamiento que dependen de medidas de distancia o medias. Un outlier se define como un dato que está alejado de los demás puntos del conjunto. Puede tener un impacto considerable en los resultados. Por lo tanto, eliminarlo o resolverlo antes del análisis es esencial para evitar sesgos (Dash et al. 2023).

Estos valores extremos pueden distorsionar las métricas utilizadas por algoritmos como K-Means, alterando la posición de los centroides y generando agrupaciones artificiales o poco representativas. Por ello, el tratamiento adecuado de outliers es una etapa crítica en la preparación de los datos, ya que contribuye a mejorar la robustez, precisión e interpretabilidad de los modelos.

Existen diversas técnicas para abordar esta problemática. Entre las más comunes se encuentran la eliminación directa de los valores extremos, el uso de transformaciones estadísticas para suavizar su efecto (como logaritmos o raíces cuadradas), o la aplicación de métodos de imputación. Sin embargo, una alternativa especialmente útil cuando no se desea perder información es la técnica de winsorización (winsorization).

La winsorization consiste en reemplazar los valores extremos por un valor más cercano dentro de un rango aceptable, lo cual permite reducir su influencia sin eliminar completamente

la observación. Tal como se define, winsorizar significa asignar un menor peso al dato atípico o modificar su valor para acercarlo a los demás valores de la muestra (Ghosh y Vogt 2012). Este procedimiento mantiene la estructura general del conjunto de datos, pero limita el efecto desproporcionado que pueden tener los outliers sobre las medidas de tendencia central o dispersión.

El grado de winsorización se define generalmente por percentiles; por ejemplo, en una winsorización al 5 %, los valores por debajo del percentil 5 se reemplazan por el valor correspondiente a dicho percentil, y lo mismo ocurre con los valores por encima del percentil 95. Esta técnica es especialmente útil en contextos donde se busca conservar la muestra completa, pero controlando la distorsión provocada por valores extremos.

7.8. Juicio Experto

En contextos donde la disponibilidad de información cuantitativa es limitada o incierta, el juicio experto se constituye como una herramienta valiosa para la toma de decisiones. Su relevancia radica en la posibilidad de incorporar conocimiento tácito, experiencia acumulada y criterios profesionales que permiten complementar los resultados derivados de métodos estadísticos o algoritmos automatizados.

El juicio de expertos se define como una opinión informada de personas con trayectoria en el tema, que son reconocidas por otros como expertos cualificados en éste, y que pueden dar información, evidencia, juicios y valoraciones (Escobar-Pérez y Cuervo-Martínez 2008). Esta definición pone énfasis en el carácter validado y contextual del conocimiento que los expertos pueden aportar, lo que resulta especialmente útil en escenarios donde los datos disponibles no permiten modelar adecuadamente todas las variables relevantes, como es frecuente en entornos operativos



complejos.

En el ámbito de la gestión de inventarios de repuestos, el juicio experto resulta especialmente útil cuando los datos disponibles son incompletos, inconsistentes o no capturan adecuadamente las condiciones operativas. Además, cumple un rol clave en la validación de resultados obtenidos por métodos cuantitativos, permitiendo contrastar los outputs de modelos estadísticos o algoritmos de clasificación con la experiencia operativa acumulada. Esta combinación entre análisis de datos y evaluación experta permite construir modelos de decisión más robustos, adaptados a la realidad del entorno logístico y a las condiciones particulares de cada organización.

8. Metodología

La presente investigación adopta un enfoque mixto, combinando metodologías cuantitativas y cualitativas para abordar de manera integral los objetivos planteados. La dimensión cuantitativa se fundamenta en el análisis de datos históricos extraídos del sistema SAP de la empresa, principalmente relacionados con el consumo de repuestos y la operación de los almacenes mecánicos. Esta base de datos permite identificar patrones, evaluar el comportamiento de la demanda y diseñar estrategias de inventario sustentadas en evidencia empírica.

Complementariamente, se incorpora el juicio experto del personal técnico, con el fin de validar los resultados obtenidos mediante análisis de datos y orientar decisiones metodológicas clave. Este enfoque cualitativo permite incorporar conocimiento tácito y experiencia operativa al proceso analítico, especialmente en etapas donde los datos no capturan completamente la realidad logística o en contextos con alto grado de incertidumbre.

La metodología se estructura en cinco fases secuenciales, alineadas con los objetivos específicos del estudio. Esta organización permite mantener un flujo lógico de trabajo, garantizar la trazabilidad entre etapas y asegurar la coherencia en la toma de decisiones. A continuación, se presenta un diagrama que resume gráficamente esta estructura metodológica.

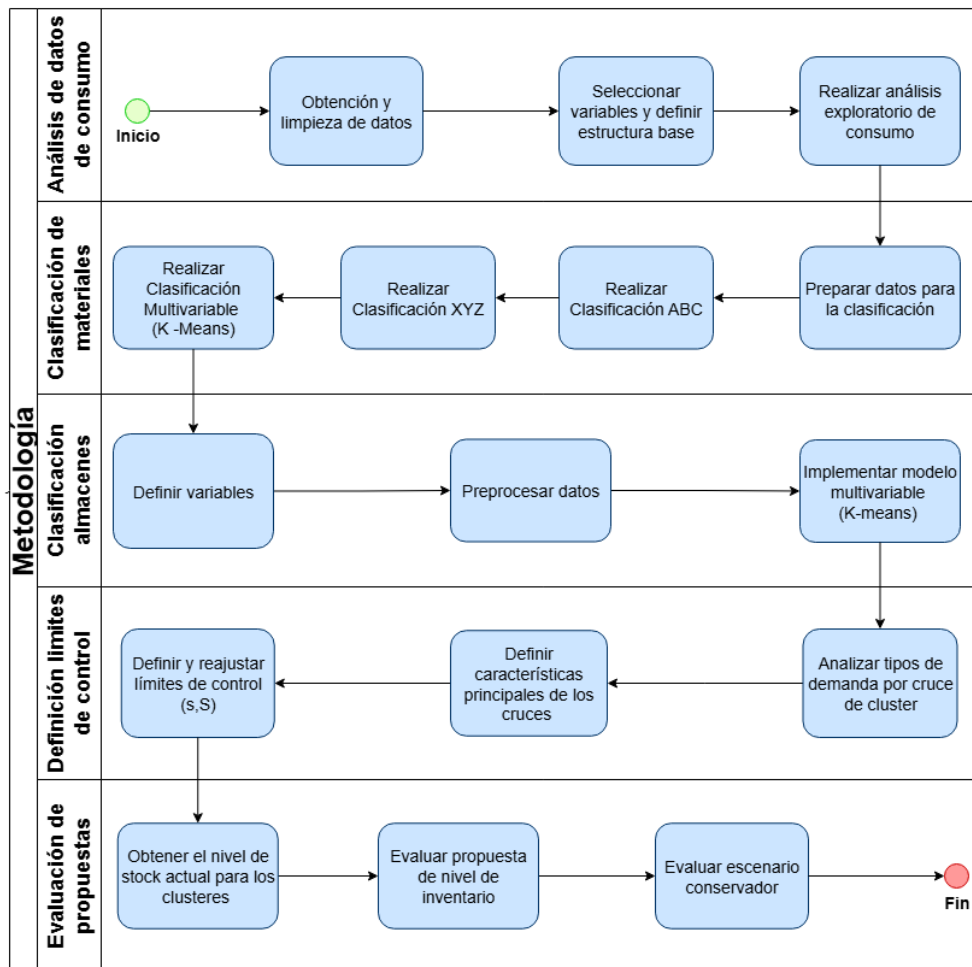


Figura 3: Diagrama de proceso de la estructura metodológica.

Fuente: Elaboración propia.

8.1. Análisis de datos de consumo

Esta etapa tiene como objetivo preparar y comprender la base de datos que sustenta el desarrollo del modelo de segmentación y control de inventarios. Para ello, se trabaja con los registros históricos de consumo de repuestos utilizados en actividades de mantenimiento, extraídos directamente desde el sistema SAP de la empresa.

La información recopilada constituye el insumo central del estudio, ya que permite analizar patrones de uso, caracterizar materiales y almacenes, y fundamentar la definición de políticas de

inventario. Dado que los datos originales provienen de operaciones reales, es necesario aplicar un proceso riguroso de depuración, estructuración y análisis exploratorio antes de su uso analítico.

8.1.1. Obtención y limpieza de datos

Los datos utilizados en este estudio fueron extraídos del sistema SAP de la empresa, específicamente desde los módulos vinculados a operaciones de mantenimiento y gestión de inventarios. La base corresponde a los consumos históricos de repuestos registrados entre los años 2020 y 2024, incluyendo todos los eventos de retiro de materiales desde los almacenes mecánicos para su utilización en tareas de mantenimiento correctivo o preventivo.

Como primer paso, se aplica un proceso de depuración destinado a asegurar que los datos fueran relevantes, consistentes y utilizables en las etapas posteriores del estudio. El tratamiento de los datos se realiza en formato `DataFrame`⁵, permitiendo una manipulación eficiente y estructurada mediante herramientas de análisis en Python. Los filtros aplicados son los siguientes:

- **Exclusión de materiales no representativos:** Se eliminan registros correspondientes a ítems clasificados como “materiales varios”, insumos administrativos u otros elementos sin relación directa con las actividades de mantenimiento.
- **Validación de campos clave:** Se descartan registros con valores nulos, vacíos o erróneos en variables fundamentales como código de material, cantidad o fecha.
- **Corrección de formatos:** Se estandarizan los formatos de fecha utilizando `datetime`, los campos de texto mediante el tipo `string`, y los valores numéricos como `int`, con el fin de facilitar su procesamiento automatizado.

⁵Estructura tipo tabla de la biblioteca pandas, usada para análisis y manipulación de datos en Python.

El tratamiento de datos se realiza utilizando el lenguaje de programación Python, en conjunto con las bibliotecas pandas y numpy. Estas herramientas permiten automatizar el filtrado, corregir inconsistencias y consolidar una base estructurada y coherente. A modo ilustrativo, el fragmento de código de la figura 4 muestra parte del procedimiento de estandarización de formatos:

```
1 df_rptos['Fe.contabilizacion'] = pd.to_datetime(df_rptos['Fe.
   contabilizacion'])
2 df_rptos['Material'] = df_rptos['Material'].astype('string')
3 df_rptos['Cantidad'] = df_rptos['Cantidad'].astype('int')
```

Figura 4: Extracto de código para la corrección de formato de campos en DataFrame.

Este proceso de obtención y limpieza permite consolidar una base de datos confiable y estandarizada, que constituye el insumo fundamental para las etapas siguientes del estudio.

8.1.2. Variables clave y estructura de la base

Una vez depurados y estandarizados los registros, se construye una base estructurada de datos que consolida la información relevante para el análisis. Esta base fue organizada en formato DataFrame y contiene, para cada registro, los datos asociados al retiro de un material desde un almacén, en el marco de una actividad de mantenimiento.

A continuación, se describen las principales variables utilizadas, junto con su función dentro del estudio:

- **Código de material (SKU):** Identificador único del repuesto, se utiliza para consolidar consumos, agrupar materiales y realizar las distintas clasificaciones.
- **Fecha de contabilización:** Fecha en que se registra el consumo, desagregada en día, mes y año. Esta variable permite construir series temporales y analizar estacionalidad, permanencia

y frecuencia de uso.

- **Cantidad:** Número de unidades consumidas en el evento. Es una variable central para las clasificaciones y el análisis de demanda.
- **Valor total:** Corresponde al costo total del material en la transacción (precio unitario multiplicado por cantidad). Se utiliza para análisis económicos y clasificaciones por valor.
- **Código de almacén:** Identificador único del almacén asociado al evento de consumo. Se utiliza para consolidar y agrupar consumos por ubicación.
- **Prioridad:** Nivel de urgencia asociado al consumo, que refleja la criticidad operativa del evento de mantenimiento. Se utiliza como criterio de segmentación.
- **Negocio:** Área operativa o unidad de negocio que solicitó el repuesto. Sirve para caracterizar el tipo de operación y evaluar patrones de consumo.

Estas variables permiten una caracterización integral de los consumos de repuestos. A partir de esta base, se construyen nuevas variables derivadas que serán utilizadas y definidas en las etapas siguientes del estudio.

8.1.3. Análisis exploratorio de consumo

Finalizado el proceso de estructuración de la base, se realiza un análisis exploratorio con el objetivo de comprender el comportamiento general del consumo de repuestos en los distintos almacenes y períodos de tiempo. Esta etapa es fundamental para identificar patrones, validar la calidad de los datos y orientar decisiones metodológicas en las fases posteriores.

El análisis se lleva a cabo utilizando herramientas de programación en Python, principalmente las librerías `pandas`, `matplotlib` y `seaborn`. Estas permiten generar visualizaciones y estadísticas descriptivas que facilitan la comprensión de la dinámica de consumo en distintos niveles de agregación.

En primer lugar, se explora la cantidad de valores distintos por variable, con el fin de conocer el rango de categorías presentes y dimensionar la diversidad de datos disponibles. Para ello, se utilizan gráficos y la función `value_counts()` de Python, aplicada sobre variables como código de material, almacén, negocio y prioridad.

Posteriormente, se analiza la **distribución temporal del consumo**. Para ello, se construye una serie temporal a partir de los registros históricos. Se genera una columna con la fecha en formato "Mes-Año", a partir de las variables `Ejercicio`⁶ y `Período`⁷. Luego, se agrupan las cantidades consumidas por mes y año, reorganizando la información en una tabla de resumen con los meses como filas y los años como columnas. Finalmente, esta información se representa mediante un gráfico de líneas, lo que permite visualizar la evolución del consumo mensual a lo largo del tiempo.

Por último, se analiza la **permanencia de los materiales** a lo largo del tiempo. El objetivo es identificar cuáles repuestos se mantienen en uso entre un año y otro, y cuáles ingresan o salen del catálogo. Para ello, se agrupan los códigos de material por año (ejercicio) y se convierten en conjuntos, lo que permite comparar interanualmente qué materiales se conservan, cuáles se incorporan y cuáles dejan de utilizarse. Los resultados se resumen en una tabla y se representan mediante un gráfico de barras, lo que facilita el análisis de la rotación y estabilidad del portafolio

⁶Corresponde al año asociado a la fecha de contabilización.

⁷Representa el mes en que se registra la transacción en SAP.

de materiales.

8.2. Clasificación de materiales

La clasificación de los materiales tiene como objetivo identificar grupos con características similares, con el propósito de establecer estándares y definir criterios de priorización que faciliten la optimización de la gestión de inventarios y contribuyan a una toma de decisiones más eficiente.

Para ello, se transforma la base de registros históricos de consumo en un conjunto agregado por material, sobre el cual se calculan indicadores relevantes. Esta sección describe el procedimiento utilizado para construir dicha base y enriquecerla con variables clave para la posterior segmentación.

8.2.1. Preparación de datos para la clasificación

El proceso comienza a partir del `DataFrame` que contiene todos los registros históricos de consumo. Este se agrupa por código de material (`SKU`), con el objetivo de consolidar el total de unidades consumidas y el valor económico total asociado a cada ítem. A partir de estos datos, se estima el precio unitario promedio, calculado como el cociente entre valor total y cantidad, redondeado al entero más cercano. Este valor representa una aproximación del costo unitario basada en consumos históricos.

Este procedimiento se implementa mediante la función `groupby . agg ()`, como se muestra en la figura 5.

```
1 # Agrupar por material y sumar cantidad y valor total
2 df_agrupado = df.groupby("Material").agg({
3     'Cantidad': 'sum',
4     'Valor total': 'sum'
5 }).reset_index()
6
7 # Calcular precio unitario
8 df_agrupado['Precio unitario'] = (df_agrupado['Valor total'] /
    df_agrupado['Cantidad']).round().fillna(0)
```

Figura 5: Extracto de código para la agrupación de consumos por material.

Adicionalmente, se incorpora la variable **prioridad**, que representa el nivel de criticidad operativa asociado a cada material. Dado que cada evento de consumo posee su propia prioridad, se define un criterio para asignar una prioridad representativa a cada material:

- Si existe una prioridad predominante (mayoría simple de al menos 50 % + 1) entre los consumos asociados a un material, se adopta dicha prioridad como representativa.
- En caso contrario, se recurre a la prioridad predominante del negocio que concentra el mayor porcentaje de consumo del material. Para ello, se agrupan los consumos por negocio⁸ y se identifica la prioridad más frecuente en cada uno. La figura 6 ilustra la distribución de prioridades por negocio.

⁸Por motivos de confidencialidad, los nombres específicos de los negocios no se presentan en este documento.




Figura 6: Porcentaje de tipo de prioridad por negocio de la empresa.

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023–2024).

Una vez aplicados estos pasos, la base consolidada presenta una estructura como la mostrada en la Tabla 1, donde cada fila corresponde a un material único con sus atributos principales ya calculados.

Tabla 1: Ejemplo de DataFrame consolidado de consumo.

Material	Cantidad	Valor total	Precio unitario	Prioridad
MAT001	150	1.200.000	8.000	Muy elevado
MAT002	60	900.000	15.000	Prioritario
MAT003	10	10.000	1.000	Bajo

Fuente: Elaboración propia a partir de registros de consumo.

Con esta base preparada, se procede a aplicar las técnicas de clasificación de materiales.

8.2.2. Clasificación ABC

Se realiza una clasificación ABC con base en el valor acumulado de los consumos históricos por material, considerando únicamente las columnas `Material` y `Valor total` del

DataFrame consolidado. Este enfoque permite segmentar los repuestos según su importancia relativa en términos de valor de consumo, lo que resulta útil para priorizar su control y gestión dentro del inventario.

La lógica del método se basa en el principio de Pareto, el cual establece que una proporción reducida de los materiales tiende a concentrar la mayor parte del valor total consumido. En este caso, se agrupan los materiales en tres clases, tal como se detalla en la Tabla 2.

Tabla 2: Criterios utilizados para la clasificación ABC

Clasificación	Definición	Valor total de consumo (%)	Porcentaje de materiales (%)
A	Repuestos muy usados	70	10
B	Repuestos frecuentemente usados	20	20
C	Repuestos poco usados	10	70

Fuente: Adaptado desde Syntactics Inc. (Labis 2023).

Esta segmentación sirve como insumo para la toma de decisiones diferenciadas en cuanto a políticas de control, reposición y seguimiento, enfocando mayores esfuerzos de gestión en los materiales clasificados como A, y menores en los de clase C.

El proceso se implementa en Python, tal como se muestra en la Figura 7. Primero, se ordenan los materiales en orden descendente por su valor total. Luego, se calcula el porcentaje acumulado que representa cada uno respecto al total general, y con base en este valor se asigna su clase ABC como se muestra en la Figura 7.

```
1 # Ordenar por valor total
2 df = df.sort_values(by='Valor total', ascending=False)
3
4 # Calcular porcentaje acumulado
5 df['% Acumulado'] = (df['Valor total'] / df['Valor total'].sum() *
6     100).cumsum()
7
8 # Asignar clase ABC
9 df['Clase ABC'] = df['% Acumulado'].apply(
10     lambda x: 'A' if x <= 70 else ('B' if x <= 90 else 'C')
```

Figura 7: Extracto de código para la clasificación ABC

Posteriormente, se generan visualizaciones que permiten evidenciar y analizar los resultados obtenidos a partir de la clasificación. Estas gráficas facilitan la interpretación del peso relativo de cada grupo y refuerzan la utilidad de esta segmentación para la toma de decisiones estratégicas en la gestión de inventarios.

8.2.3. Clasificación XYZ

Se aplica una clasificación XYZ con el objetivo de evaluar la variabilidad en el consumo de los materiales. Esta segmentación permite distinguir entre materiales de consumo estable, moderadamente variable o altamente errático, facilitando la definición de estrategias de reposición y control adecuadas para cada grupo.

La metodología se basa en el análisis del comportamiento temporal de la demanda, considerando dos indicadores clave: el **coeficiente de variación (CV)** y la **frecuencia de consumo**. El CV se calcula como el cociente entre la desviación estándar y el promedio del consumo por material, lo que permite medir la dispersión relativa de la demanda. Por su parte, la frecuencia representa el número de períodos en los que se registra consumo.

A partir de estos indicadores, se definen las clases mostradas en la Tabla 3.

Tabla 3: Criterios utilizados para la clasificación XYZ

Clasificación	Criterio basado en CV	Descripción
X	$CV \leq 0,2$	Consumo constante y predecible
Y	$0,2 < CV \leq 0,5$	Variabilidad moderada
Z	$CV > 0,5$	Consumo irregular y errático
1 Consumo	Frecuencia = 1	Solo un evento de consumo registrado

Fuente: Adaptado desde Stoll (Stoll, Heine y Schultmann 2014).

La implementación en Python se muestra en la Figura 8. Primero se agrupan los consumos por material para calcular el promedio, la desviación estándar y la frecuencia. Luego, se determina el coeficiente de variación y se asigna la clase correspondiente.

```
1 # Calcular estadísticas por material
2 prom = df.groupby('Material')['Valor total'].mean()
3 std = df.groupby('Material')['Valor total'].std()
4 freq = df.groupby('Material')['Valor total'].count()
5
6 # Calcular CV y clasificar
7 cv = std / prom
8 clasificacion = [
9     '1 Consumo' if f == 1 else
10     ('X' if c <= 0.2 else 'Y' if c <= 0.5 else 'Z')
11     for c, f in zip(cv, freq)
12 ]
13
14 # Crear DataFrame clasificado
15 df_xyz = pd.DataFrame({
16     'Promedio': prom,
17     'CV': cv,
18     'Frecuencia': freq,
19     'Clasificacion XYZ': clasificacion
20 })
```

Figura 8: Extracto de código para la clasificación XYZ de materiales

8.2.4. Clasificación multivariable mediante *K-Means*

Una vez calculadas las variables de interés para cada material, se aplica un algoritmo de agrupamiento no supervisado con el objetivo de segmentar los repuestos en grupos con características similares. Esta clasificación multivariable permite una segmentación más robusta y personalizada, facilitando la definición de estrategias diferenciadas de inventario.

Se utiliza el algoritmo *K-Means*, ampliamente empleado en tareas de *clustering* por su simplicidad y eficacia. Este método agrupa los materiales de manera que los ítems dentro de cada clúster sean lo más parecidos posible entre sí, y lo más distintos posible respecto de los de otros clústeres.

8.2.4.1. Definición de variables y preprocesamiento

Para realizar la clasificación multivariable, primero se definen las variables de análisis, utilizando como base los resultados obtenidos en el análisis preliminar de consumos y el criterio técnico del ingeniero a cargo. A partir de este análisis, se determinan tres variables relevantes que permiten explicar el comportamiento y la criticidad de los materiales.

- **Cantidad:** Representa el volumen total consumido por cada SKU durante el período analizado.
- **Precio del material:** Precio unitario promedio estimado a partir de los registros históricos de consumo.
- **Prioridad:** Nivel de criticidad asignado a cada material, definido a partir de su comportamiento agregado.

8.2.4.2. Preprocesamiento de datos

Antes de aplicar el algoritmo de agrupamiento, se realiza una etapa de preprocesamiento para garantizar la calidad del análisis. En primer lugar, se recortan los valores extremos mediante winsorización, técnica que limita el impacto de valores atípicos sobre el modelo sin eliminar observaciones. En este estudio, la winsorización se aplica únicamente al extremo superior de la distribución, fijando un límite equivalente al 1 % más alto de los datos (`limits=[0, 0.01]`). Este valor se selecciona en base a la literatura, que recomienda umbrales reducidos cuando existen observaciones atípicas de gran magnitud que pueden sesgar el cálculo de distancias, preservando al mismo tiempo la integridad del resto de la información (Ghosh y Vogt, 2012; Rego y Mesquita, 2011). Posteriormente, se aplica una normalización con `MinMaxScaler`, que transforma las variables al rango `[0, 1]`, asegurando que ninguna domine en el cálculo de distancias euclidianas. Este procedimiento se implementa mediante el código presentado en la Figura 9.

```
1 # Recortar valores extremos (winsorizacion)
2 from scipy.stats.mstats import winsorize
3 df['Cantidad_W'] = winsorize(df['Cantidad'], limits=[0, 0.01])
4 df['Precio_W'] = winsorize(df['Precio'], limits=[0, 0.01])
5 df['Prioridad_W'] = winsorize(df['Prioridad'], limits=[0, 0.01])
6
7 # Normalizar variables
8 from sklearn.preprocessing import MinMaxScaler
9 X = df[['Cantidad_W', 'Precio_W', 'Prioridad_W']]
10 X_scaled = MinMaxScaler().fit_transform(X)
```

Figura 9: Extracto de código para preprocesamiento de variables: winsorización y normalización

8.2.4.3. Determinación del número óptimo de clústeres

Para determinar la cantidad óptima de grupos (K), se aplica el método del codo (*elbow method*), que evalúa la inercia total del modelo (WCSS) a medida que se incrementa K . El valor

óptimo corresponde al punto donde la ganancia marginal en reducción de inercia comienza a ser mínima. Este análisis se complementa con criterio experto, iterando entre diferentes cantidades de clústeres hasta identificar la segmentación más coherente desde el punto de vista operativo. El procedimiento es implementado mediante el código mostrado en la Figura 10.

```
1 # Metodo del codo para elegir el numero optimo de clusters
2 inertia = []
3 for k in range(1, 11):
4     modelo = KMeans(n_clusters=k, random_state=42)
5     modelo.fit(X_scaled)
6     inertia.append(modelo.inertia_)
7
8 # Graficar la curva de inercia
9 plt.plot(range(1, 11), inertia, marker='o')
10 plt.xlabel("Numero de clusters (K)")
11 plt.ylabel("WCSS")
12 plt.show()
```

Figura 10: Extracto de código para cálculo del número óptimo de clústeres mediante el método del codo

8.2.4.4. Implementación del modelo

Una vez definido el número óptimo de clústeres, se implementa el algoritmo *K-Means* utilizando la librería `scikit-learn`. El modelo asigna un grupo a cada material, lo cual permite incorporar esta clasificación multivariable al `DataFrame` como una nueva columna. Esta segmentación constituye un insumo clave para definir políticas diferenciadas de inventario, considerando de forma simultánea la criticidad, el volumen y el valor de cada ítem. El código correspondiente se presenta en la Figura 11.

```
1 # Clustering con K-Means
2 from sklearn.cluster import KMeans
3 kmeans = KMeans(n_clusters=7, random_state=42)
4 df['Cluster'] = kmeans.fit_predict(X_scaled)
```

Figura 11: Extracto de código de implementación de K-Means

8.2.4.5. Caracterización de los clústeres

Una vez obtenida la asignación de clústeres, se procede a la revisión de los resultados por parte del ingeniero responsable, con el fin de validar su coherencia con el contexto operativo y estratégico de la organización. Este análisis considera tanto las métricas de las variables originales como observaciones cualitativas sobre el uso real de los materiales.

A partir de esta validación, se determina la cantidad final de clústeres a utilizar y se elabora un perfil descriptivo de cada grupo, identificando sus principales atributos.

8.3. Clasificación de almacenes mecánicos

La clasificación de los almacenes mecánicos tiene como propósito caracterizar sus particularidades operativas y ajustar las políticas de inventario a las necesidades específicas de cada uno. Este análisis permite adaptar las estrategias de gestión y optimización a las distintas realidades logísticas presentes en la red de la empresa.

8.3.1. Definición de variables y preparación de datos

En primer lugar, se identifican y seleccionan los almacenes mecánicos vigentes, excluyendo aquellos que ya no forman parte de la dotación actual de la empresa. Esta exclusión garantiza que la clasificación se aplique únicamente a los almacenes relevantes para el análisis. Una vez definidos

los almacenes a clasificar, se procede a la preparación de los datos y a la recopilación de las principales variables de análisis.

Estas variables permiten caracterizar cada almacén de acuerdo con su nivel de actividad y su función dentro de la red logística de la empresa. La selección de las variables se realiza en base al criterio técnico del ingeniero a cargo, con el objetivo de lograr una caracterización precisa y ajustada a la realidad operativa. Las variables consideradas son las siguientes:

1. **Cantidad consumida por almacén:** Se calcula agrupando los consumos de cada almacén para obtener el volumen total de consumo, lo que permite dimensionar la magnitud de las operaciones y el tamaño relativo de cada almacén.
2. **Tipo de ubicación:** Esta variable categoriza los almacenes según su ubicación geográfica y su modalidad de abastecimiento de materiales, considerando la clasificación previa en tres categorías:
 - Santiago: Almacenes ubicados en la capital, donde los materiales son retirados directamente desde el centro de distribución.
 - Región: Almacenes situados fuera de Santiago, que reciben los materiales desde el centro de distribución.
 - Región extrema: Almacenes ubicados en zonas remotas, donde el envío de materiales es más complejo que en el resto de las regiones.
3. **Cantidad de negocios:** Esta variable mide la diversidad de materiales que gestiona cada almacén. Se calcula contabilizando la cantidad de materiales diferentes consumidos por cada almacén y la cantidad de negocios a los cuales están asociados.

La Tabla 4 muestra un ejemplo simplificado del DataFrame resultante para la clasificación.

Tabla 4: Ejemplo de estructura de datos para clasificación de almacenes

Código almacén	Valor total	Negocios distintos	Tipo de ubicación
A001	152,500,000	12	Santiago
A014	87,300,000	9	Región
A020	65,800,000	7	Región extrema

8.3.2. Preprocesamiento de datos

Previo a la aplicación del algoritmo de agrupamiento, la variable categórica *Tipo de ubicación* se convierte en valores numéricos, siguiendo el mapeo *Santiago=1*, *Región=2* y *Región extrema=3*. Posteriormente, todas las variables se escalan al rango [0, 1] mediante `MinMaxScaler`, garantizando que ninguna domine el cálculo de distancias en el modelo. El procedimiento se presenta en la Figura 12.

```
1 # Mapear ubicacion a valores numericos
2 mapa = {'REGION EXTREMA': 3, 'REGION': 2, 'SANTIAGO': 1}
3 df['Ubicacion_num'] = df['Tipo de Ubicacion'].map(mapa)
4
5 # Escalar variables
6 from sklearn.preprocessing import MinMaxScaler
7 X = df[['Valor Total', 'Cantidad Negocios distintos', 'Ubicacion_num']]
8 X_scaled = MinMaxScaler().fit_transform(X)
```

Figura 12: Extracto de código para Preprocesamiento de datos para clustering de almacenes

8.3.3. Determinación del número óptimo de clústeres

Para definir el número óptimo de grupos (K), se aplica el método del codo (*elbow method*), que analiza la variación de la inercia interna (WCSS) al incrementar progresivamente el valor de K .

El punto en el que la reducción marginal de la inercia comienza a estabilizarse se identifica como el valor más adecuado, el cual se valida posteriormente mediante criterio experto para asegurar su coherencia con la realidad operativa. Este procedimiento es análogo al utilizado en la clasificación de materiales mostrada en la Figura 10.

8.3.4. Implementación del modelo

Con el valor de k determinado, se entrena el modelo *K-Means* de la librería `scikit-learn`, asignando a cada almacén su correspondiente etiqueta de clúster. Esta segmentación permite agruparlos según características operativas y geográficas, constituyendo una base para la definición de políticas de inventario diferenciadas. La implementación sigue el mismo procedimiento aplicado en la clasificación de materiales, ilustrado en la Figura 11.

8.3.5. Caracterización de los clústeres

Una vez obtenida la asignación de clústeres, se procede a la revisión de los resultados por parte del ingeniero responsable, con el fin de validar su coherencia con el contexto operativo y estratégico de la organización. Este análisis considera tanto las métricas de las variables originales como observaciones cualitativas sobre el uso real de los materiales.

A partir de esta validación, se determina la cantidad final de clústeres a utilizar y se elabora un perfil descriptivo de cada grupo, identificando sus principales atributos.

8.4. Definición de límites de control (s, S)

El objetivo de esta etapa es establecer los valores de los límites de control de inventario —punto de reorden (s) y nivel máximo (S)— para cada combinación entre clúster de material y

clúster de almacén. Estos límites se determinan a partir del análisis conjunto del comportamiento histórico de la demanda y de las características logísticas y operativas de cada grupo.

8.4.1. Análisis del tipo de demanda por cruce de clústeres

Para establecer límites de control (s, S) adecuados, se realiza un análisis detallado de la demanda en cada combinación de clúster de almacén y clúster de material. Esta etapa cruza los resultados obtenidos en las clasificaciones previas, generando una matriz de $n_a \times n_m$ celdas (donde n_a es la cantidad de clústeres de almacenes y n_m la de clústeres de materiales). En cada celda se consolida la serie histórica de consumo **semanal** (período 2023–2024), lo que permite suavizar el ruido de materiales de baja rotación y obtener una visión agregada del patrón de demanda.

Con estas series consolidadas, se caracteriza el patrón de demanda de cada cruce mediante la matriz **ADI–CV²**, que combina dos métricas clave:

- **ADI (Average Demand Interval):** intervalo promedio entre semanas con demanda positiva.
- **CV² (coeficiente de variación al cuadrado):** medida de variabilidad relativa de la demanda.

Con base en estos indicadores, cada combinación se clasifica en uno de cuatro tipos de patrón de demanda descritos en la literatura: *Suavizada*, *Intermitente*, *Errática* o *Grumosa*. La implementación se muestra en la Figura 13.

```
1 # Clasificación de la demanda por cruce ALM-MAT usando ADI y CV2
2 import numpy as np
3 stats = []
4
5 for cruce, df_c in df.groupby('Cruce ALM-MAT'):
6     demanda = df_c['Cantidad'].values
7
8     # Coeficiente de variación (CV)
9     mean_ = demanda.mean()
10    cv = demanda.std() / mean_ if mean_ > 0 else np.nan
11
12    # ADI: intervalo promedio entre semanas con demanda > 0
13    semanas_pos = df_c.loc[df_c['Cantidad'] > 0, 'Semana'].
14        sort_values()
15    if len(semanas_pos) >= 2:
16        # Promedio de diferencias en semanas
17        adi = (semanas_pos.diff().dropna().mean() / np.timedelta64
18            (7, 'D')).item()
19    else:
20        adi = np.nan
21
22    # CV2
23    cv2 = cv**2 if not np.isnan(cv) else np.nan
24
25    # Clasificación según ADI y CV2 (Syntetos et al.)
26    if (not np.isnan(adi)) and (not np.isnan(cv2)):
27        if adi <= 1.32 and cv2 <= 0.49:
28            tipo = 'Suavizada'
29        elif adi > 1.32 and cv2 <= 0.49:
30            tipo = 'Intermitente'
31        elif adi <= 1.32 and cv2 > 0.49:
32            tipo = 'Erratica'
33        else:
34            tipo = 'Grumosa'
35    else:
36        tipo = 'No clasificable'
37
38    stats.append({'Cruce ALM-MAT': cruce, 'CV': cv, 'ADI': adi, 'CV2
39        ': cv2, 'Tipo': tipo})
40
41 df_stats = pd.DataFrame(stats)
```

Figura 13: Extracto de código para la clasificación de la demanda por combinación de clústeres utilizando ADI y CV²

Este análisis proporciona una caracterización precisa del patrón de consumo para cada com-

binación clúster material–clúster almacén, lo que permite definir límites de control (s, S) coherentes con la naturaleza de la demanda y alineados con las condiciones operativas reales.

8.4.2. Caracterización logística y operativa

Tras el análisis del patrón de demanda descrito en la sección anterior, se integran variables adicionales que influyen directamente en la definición de límites de control (s, S) . Estas variables permiten incorporar al modelo consideraciones logísticas y operativas que no se reflejan únicamente en el comportamiento histórico del consumo.

En el caso de los **materiales**, se consideran dos atributos clave:

- **Criticidad operativa:** nivel de prioridad asignado en función de su importancia para el mantenimiento y la continuidad operativa. Este indicador proviene del análisis previo de prioridades y permite diferenciar materiales críticos, medios y de baja relevancia.
- **Valor económico:** costo promedio por unidad, calculado a partir del precio histórico de consumo. Este valor permite evaluar el impacto económico de mantener stock para cada material.

En el caso de los **almacenes**, se incorpora como variable principal la **ubicación geográfica**, categorizada en tres grupos:

- *Santiago:* almacenes abastecidos directamente desde el centro de distribución principal, con tiempos de reposición reducidos.
- *Región:* almacenes ubicados fuera de Santiago, con plazos de reposición más prolongados.

- *Región extrema:* almacenes en zonas remotas, donde la reposición implica mayores tiempos y complejidad logística.

La combinación de estas características con la tipología de demanda (obtenida mediante la matriz ADI–CV²) permite construir una **matriz de caracterización logística y operativa** para cada cruce clúster material–clúster almacén. Esta matriz constituye un insumo fundamental para establecer límites de control (s, S) diferenciados, alineados tanto con el comportamiento de la demanda como con las condiciones logísticas y económicas reales de operación.

8.4.3. Asignación inicial de límites (s, S)

Con la matriz de caracterización definida para cada combinación de clúster almacén–material, se procede a establecer los límites de control de inventario iniciales, diferenciando las combinaciones en grupos con condiciones y patrones de demanda similares. Este enfoque permite asignar valores de s (punto de reorden) y S (nivel máximo) adaptados al contexto operativo y al riesgo logístico de cada caso.

La asignación de los niveles de cobertura se fundamenta en el estudio de curvas de consumo, en los análisis previos de características logísticas y de demanda, y en el juicio experto aportado por personal con experiencia en la gestión operativa. Con base en estos criterios, se establecen tres esquemas de cálculo que permiten ajustar el nivel de cobertura según sus características:

- **Nivel 1 – Conservador:** s igual a la demanda máxima semanal histórica; S igual a s más un 10 %. Brinda alta cobertura para minimizar el riesgo de quiebre.
- **Nivel 2 – Estable:** s igual al promedio histórico de semanas con consumo positivo; S igual al promedio más una desviación estándar. Adecuado para demandas estables o suavizadas.

- **Nivel 3 – Variable:** s igual al percentil 80 y S igual al percentil 90 del consumo semanal.

Enfocado a demandas erráticas o grumosas, evitando distorsión por valores atípicos.

La selección del esquema se realiza combinando el tipo de patrón de demanda (ADI–CV²) con la criticidad y ubicación geográfica del cruce, siguiendo reglas predefinidas.

Para garantizar coherencia operativa, se aplican las siguientes consideraciones:

- El promedio se calcula únicamente considerando los periodos en que hubo consumo real, descartando semanas sin movimiento. Por ejemplo, si hubo consumo en 3 de 5 semanas, solo se utilizan esos 3 valores.
- Los valores de s y S se ajustan al número entero inmediatamente superior, para facilitar su aplicación operativa. (función `ceil` de NumPy).
- Se establece como regla que debe existir una diferencia mínima de al menos una unidad entre S y s .

El siguiente extracto muestra la aplicación de las reglas y cómo se definieron los límites iniciales:

```
1 # Calcular stock base por reglas
2 def stock_base(r):
3     if r['nivel'] == 1: # Conservador
4         return pd.Series({'s_min': r['maximo'],
5                             's_max': r['maximo']*1.1})
6     elif r['nivel'] == 2: # Estable
7         return pd.Series({'s_min': r['promedio_positivo'],
8                             's_max': r['promedio_positivo'] + r['
9                                 desviacion_positivo']})
10    else: # Variable
11        return pd.Series({'s_min': r['p80'],
12                            's_max': r['p90']})
13 df[['s_min', 's_max']] = df.apply(stock_base, axis=1)
14
15 # Redondeo hacia arriba y diferencia minima
16 df['stock_min_final'] = np.ceil(df['s_min']).astype(int)
17 df['stock_max_final'] = np.ceil(df['s_max']).astype(int)
18 df.loc[df['stock_max_final'] <= df['stock_min_final'],
19         'stock_max_final'] = df['stock_min_final'] + 1
```

Figura 14: Extracto de código para el cálculo inicial de límites (s, S)

8.4.4. Ajuste final mediante ponderadores

El reajuste se implementa mediante la aplicación de ponderadores correctivos, que modifican los niveles mínimos y máximos de inventario definidos previamente, ajustándolos según características clave previamente consolidadas. Estos ponderadores se aplican de forma proporcional tanto al límite inferior como al superior del rango definido para cada combinación.

- Para los almacenes clasificados como de región extrema, se incrementan ambos límites de inventario en un 50 %, utilizando un ponderador multiplicativo de 1,5. Esta medida busca compensar los mayores tiempos de reposición y la complejidad logística asociada a estas ubicaciones.
- Para los materiales clasificados como de alto valor económico o de baja prioridad, se reduce

el nivel de inventario en un 5 %, aplicando un ponderador de 0,95. Esta decisión responde al objetivo de disminuir el capital inmovilizado en repuestos de menor criticidad o alto costo unitario.

```
1 # Ponderadores por cluster
2 def ponderar(r):
3     p = 1.0
4     if r['Cluster_Almacen'] == 4: # Region extrema
5         p *= 1.5
6     if r['Cluster_Material'] in [0,3,4]: # Alto valor / baja
7         prioridad
8         p *= 0.95
9     return pd.Series({'s_min_p': r['s_min']*p,
10                      's_max_p': r['s_max']*p})
11 df[['s_min_p', 's_max_p']] = df.apply(ponderar, axis=1)
```

Figura 15: Extracto de código para la aplicación de ponderadores correctivos a límites (s, S)

Este procedimiento integrado asegura que los valores finales de (s, S) no solo se basen en la demanda histórica, sino que también estén ajustados a las restricciones logísticas y al impacto económico de cada combinación clúster material–almacén.

8.5. Evaluación de propuesta de límites de control (s, S)

Una vez definidos los niveles de inventario (s, S) sugeridos para cada combinación entre clúster de material y clúster de almacén, se procede a comparar con la situación real del inventario. Este análisis permite dimensionar el impacto potencial de aplicar los nuevos límites de control, tanto en términos de reducción de unidades como de ahorro económico. Adicionalmente, se considera un escenario alternativo de mayor cobertura, con el objetivo de explorar estrategias más conservadoras.

8.5.1. Obtención del nivel de stock actual para los clústeres

Se recopila la información de inventario disponible en los almacenes al momento del análisis, clasificando los datos según las combinaciones definidas por el cruce de clústeres de materiales y almacenes.

Para asegurar coherencia con el análisis de consumo, se excluyen todos los materiales que no registraron consumo durante el período 2023–2024, ya que no forman parte del estudio de patrones de demanda. De este modo, se considera únicamente el stock de aquellos ítems efectivamente analizados.

A partir de este filtrado, se calculan los valores actuales de inventario por combinación clúster–clúster, expresados en unidades, y se construye una matriz de semanas de cobertura. Esta última se obtiene dividiendo el stock disponible por el consumo promedio semanal histórico de cada combinación, permitiendo estimar cuántas semanas de operación podrían sostenerse bajo condiciones de consumo similares a las observadas (Figura 16).

```
1 # Calcular semanas de cobertura actual
2 df_comparacion['cobertura_actual'] = (
3     df_comparacion['stock_disponible'] /
4     df_comparacion['promedio_positivo']
5 )
```

Figura 16: Extracto de código para el cálculo de semanas de cobertura del inventario actual

8.5.2. Evaluación de propuesta

El impacto de los niveles de inventario definidos metodológicamente se analiza mediante una comparación directa entre los límites propuestos y los inventarios actuales. Este proceso se desarrolla en tres etapas complementarias:

1. **Cálculo de cobertura propuesta:** se determina la cantidad de semanas de abastecimiento que se alcanzarían en cada combinación clúster-clúster, dividiendo los niveles máximos y mínimos propuestos por el consumo promedio semanal histórico.
2. **Variación de inventario:** se calcula la diferencia porcentual entre el stock actual y los niveles propuestos (mínimo y máximo), identificando los ajustes requeridos, ya sean reducciones o incrementos.
3. **Impacto económico:** se estima el valor monetario asociado a la variación en unidades, multiplicando la diferencia obtenida por un precio promedio calculado para cada clúster de material.

La implementación de estos cálculos se ilustra en la Figura 17. El mismo procedimiento se aplica tanto a los niveles máximos como a los mínimos, lo que permite evaluar el comportamiento del sistema en todo el rango de control definido.

```
1 # Cobertura con niveles propuestos (maximos)
2 df_comparacion['cobertura_propuesta'] = (
3     df_comparacion['stock_max_final'] /
4     df_comparacion['promedio_positivo']
5 )
6
7 # Variacion porcentual de inventario
8 df_comparacion['variacion_pct'] = (
9     (df_comparacion['stock_max_final'] - df_comparacion['
10     stock_disponible'])
11 ) * 100
```

Figura 17: Extracto de código para comparación de inventario actual y niveles propuestos

8.5.3. Evaluación de escenario conservador

Con el fin de analizar la sensibilidad del modelo ante políticas más precautorias, se plantea un escenario alternativo en el que se incrementan de forma uniforme los niveles mínimos propuestos, aumentando la cobertura sin modificar la clasificación ni los patrones de consumo definidos.

Este ajuste se implementa multiplicando los niveles mínimos (s) por un ponderador constante y recalculando en consecuencia los niveles máximos (S). El procedimiento se muestra en la

Figura 18.

```
1 # Escenario conservador: aumento uniforme de cobertura
2 ponderador_conservador = 2
3 df_conservador = df_comparacion.copy()
4 df_conservador['stock_min_final'] *= ponderador_conservador
5 df_conservador['stock_max_final'] *= ponderador_conservador
6
7 # Recalcular cobertura
8 df_conservador['cobertura_conservador'] = (
9     df_conservador['stock_max_final'] /
10    df_conservador['promedio_positivo']
11 )
```

Figura 18: Extracto de código de simulación del escenario conservador

Finalmente, se aplica el mismo procedimiento de comparación que en el análisis base, evaluando cobertura, variación de unidades e impacto económico. Este análisis permite determinar si, aun con mayores niveles de inventario, se logran reducciones relevantes de stock y beneficios económicos, ofreciendo una alternativa intermedia entre eficiencia y seguridad logística.

9. Resultados y discusión

9.1. Análisis de datos de Consumo

El análisis del comportamiento histórico de consumo permite identificar tendencias, estacionalidades y anomalías que fundamentan el diseño de estrategias de gestión de inventario más eficientes.

La Figura 19 presenta la evolución mensual de la cantidad total de materiales entregados en los almacenes mecánicos durante el periodo 2021-2024. Se observa una marcada variabilidad en el consumo, tanto a lo largo de los meses como entre distintos años. Destaca el mes de mayo de 2022, con un pico significativamente superior al resto de los meses, lo cual sugiere una demanda atípica posiblemente asociada a campañas intensivas de mantenimiento o a errores de registro. Esta irregularidad subraya la importancia de validar la consistencia de los datos antes de su uso en modelos analíticos.




Figura 19: Cantidad de materiales consumidos por mes y año en almacenes mecánicos

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2021-2024).

Además, se identifican patrones estacionales, como un incremento recurrente en mayo y

cierta disminución durante los meses de invierno (junio-julio), lo que puede estar asociado a factores operativos o presupuestarios. La estacionalidad evidenciada constituye un insumo clave para ajustar las políticas de reposición y definir niveles de stock de seguridad diferenciados por período.

La Figura 20 complementa este análisis al mostrar la rotación anual de materiales, distinguiendo entre ítems que ingresan, salen y se mantienen en inventario. Se aprecia una tendencia decreciente en la cantidad total de ítems nuevos ingresados año a año, lo cual es coherente con la estrategia de reducir la diversidad de repuestos. El año 2024 evidencia un mayor énfasis en el uso de materiales ya existentes en stock, lo que se refleja en una menor proporción de ingresos y una mayor persistencia de materiales mantenidos en inventario.




Figura 20: Entradas y salidas de repuestos distintos por año.

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2021-2024).

Este comportamiento refleja una tendencia hacia la racionalización del catálogo de repuestos, orientada a reducir el sobrestock y promover el uso de referencias comunes entre distintas operaciones. Desde una perspectiva operativa, esta consolidación de materiales no solo facilita la

gestión logística, sino que también contribuye a una asignación más eficiente de los recursos.

Sin embargo, la Figura 20 revela que, a pesar de estos esfuerzos, persiste una rotación constante, con un volumen considerable de materiales que ingresan y salen del inventario cada año. Esta dinámica evidencia una alta dispersión del catálogo, lo cual genera un entorno de gestión complejo y fragmentado. La incorporación continua de nuevos ítems dificulta la aplicación de políticas estandarizadas y limita la capacidad de anticipación en la toma de decisiones.

Ante este escenario, se vuelve indispensable contar con un sistema de clasificación que permita agrupar los repuestos según sus características operativas y de consumo, estableciendo criterios homogéneos de control y abastecimiento. Esta clasificación busca no solo facilitar la gestión de materiales existentes, sino también servir como marco de referencia para definir políticas consistentes desde el momento en que un nuevo material es incorporado al sistema.

9.2. Clasificación de materiales

El análisis del consumo histórico evidenció un recambio constante entre materiales que dejan de demandarse y nuevos que ingresan al consumo, lo cual dificulta la aplicación de políticas de inventario homogéneas. En este contexto, la clasificación de materiales se presenta como una herramienta fundamental para agrupar los ítems según sus características operativas y de consumo, permitiendo priorizar recursos, mejorar la gestión logística y facilitar la toma de decisiones.

En esta sección se aplican distintos enfoques de clasificación con el objetivo de segmentar el inventario y abordar su complejidad de forma estructurada.

9.2.1. Clasificación ABC

La Figura 21 muestra la distribución de materiales según la clasificación ABC, donde se observa una alta concentración de ítems en la clase C (652 materiales), mientras que las clases B y A agrupan 75 y 45 materiales, respectivamente. Este resultado evidencia la existencia de una gran cantidad de repuestos con bajo impacto económico individual.

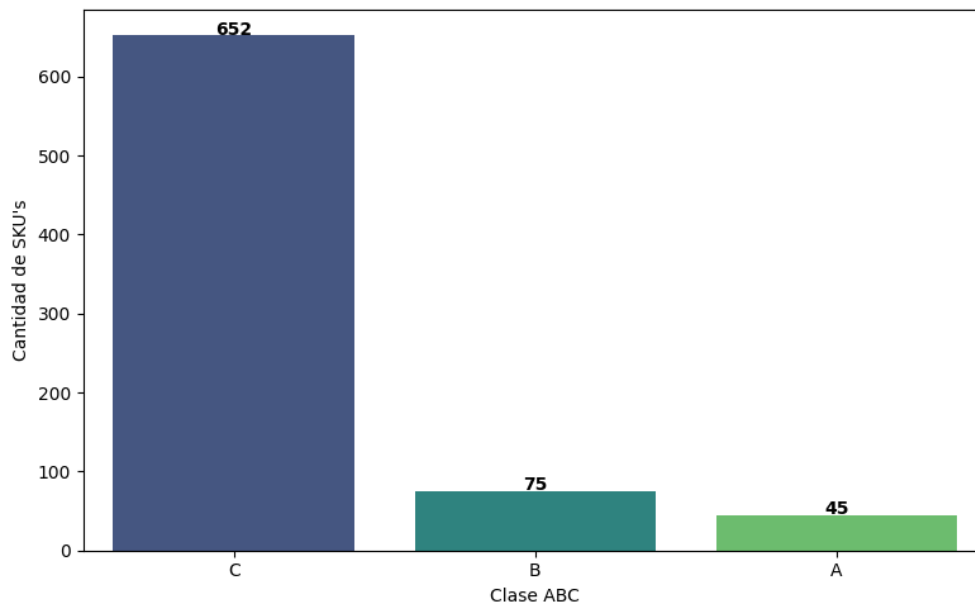


Figura 21: Cantidad de materiales por clasificación ABC.

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

La Figura 22 muestra la curva acumulada de consumo, donde se verifica que los materiales de clase A concentran aproximadamente el 70 % del valor total, mientras que los de clase B completan hasta el 90 %. Esta distribución concuerda con el comportamiento teórico del principio de Pareto, donde una pequeña proporción de ítems representa la mayor parte del consumo agregado.




Figura 22: Curva ABC de la clasificación

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

Este resultado permite identificar los materiales que requieren mayor atención en términos de control y seguimiento, justificando la implementación de políticas diferenciadas por clase.

Sin embargo, al tratarse de una clasificación basada en una única variable —el valor de consumo—, no contempla otras dimensiones relevantes como la criticidad operativa o la frecuencia de uso. Por ello, si bien aporta una primera segmentación útil, resulta insuficiente para capturar la complejidad completa de la gestión de repuestos y requiere ser complementada con enfoques adicionales.

9.2.2. Clasificación XYZ

La Figura 23 presenta la distribución de materiales según la clasificación XYZ, la cual evalúa la variabilidad del consumo a lo largo del tiempo. Se observa que la clase X, correspondiente a materiales con demanda más regular y predecible, agrupa la mayor cantidad de ítems (295).

Por su parte, las clases Z e Y concentran 104 y 216 materiales, respectivamente, reflejando una proporción significativa de ítems con comportamiento más errático o variable.

Un aspecto relevante que surge del análisis es la alta cantidad de materiales (157) con un único registro de consumo en el periodo evaluado. Este comportamiento evidencia la necesidad de incorporar un criterio de clasificación adicional que permita distinguir este tipo de casos, dado que su patrón de demanda no se ajusta adecuadamente a las categorías convencionales de la clasificación XYZ.

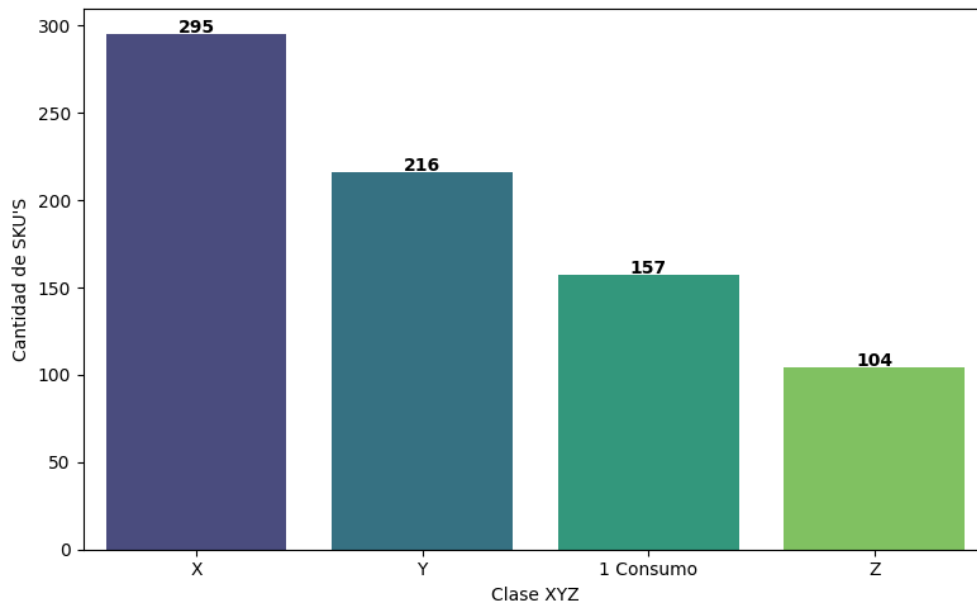


Figura 23: Cantidad de materiales por clasificación XYZ

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

Esta clasificación permite tener una visión general sobre la estabilidad en la demanda de los repuestos, lo que resulta fundamental para definir niveles de stock de seguridad y métodos de reposición en etapas posteriores. En particular, los materiales clasificados como Z —con alta irregularidad— requerirán estrategias de control más conservadoras y flexibles frente a la incertidumbre de consumo.

Así, la segmentación XYZ complementa la visión económica entregada por la clasificación ABC, aportando una dimensión operativa clave que será integrada en las siguientes secciones del estudio para la definición de políticas y agrupamientos multivariados.

9.2.3. Clasificación multivariable mediante K-Means

9.2.3.1. Definición de variables y preprocesamiento

Para aplicar el algoritmo de agrupamiento, se utilizaron tres variables que representan distintas dimensiones del comportamiento de los repuestos:

- Cantidad total consumida: refleja la frecuencia y volumen de uso de cada material, lo que permite identificar repuestos con alta rotación operativa.
- Precio unitario promedio: capta el peso económico relativo de cada ítem, considerando su costo individual.
- Prioridad operacional: sintetiza la criticidad del material en función de su uso en distintos tipos de orden de trabajo, permitiendo distinguir ítems de mayor impacto en la continuidad operativa.

9.2.3.2 Determinación del número óptimo de clústeres

Para estimar un número adecuado de agrupaciones, se utilizó el método del codo, el cual permite identificar el punto a partir del cual agregar más clústeres no produce una mejora significativa en la reducción de la inercia. La Figura 24 muestra la curva resultante del análisis, donde se aprecia una disminución pronunciada hasta aproximadamente el punto 5, seguida de una pendiente más atenuada.




Figura 24: Método del Codo para clasificación de repuestos

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

A partir de esta curva se definió un punto de partida con cinco clústeres, el cual fue posteriormente ajustado mediante iteraciones sucesivas, evaluando la coherencia de los resultados junto al ingeniero a cargo. Este proceso permitió validar la segmentación no solo en términos estadísticos, sino también en relación con la realidad operativa y las necesidades de clasificación de la empresa.

Como resultado, se definió un total de siete clústeres como la configuración óptima, ya que permitió una adecuada diferenciación de los materiales sin generar sobrefragmentación, facilitando además su interpretación y futura gestión.

9.2.3.3. Caracterización de Clusters

La Figura 25 muestra la segmentación obtenida a partir del modelo K-Means en un espacio tridimensional, donde se observa la distribución de los materiales según las variables normalizadas:

cantidad consumida, precio unitario y prioridad operacional.




Figura 25: Visualización de Clusters de materiales (K-Means)

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

En términos generales, el modelo logró establecer divisiones claras entre grupos de materiales con características diferenciadas. En la variable cantidad consumida, el modelo tiende a segmentar en dos grandes grupos: materiales de muy alto consumo y el resto. Esta separación responde a la marcada asimetría en los datos, donde un número reducido de ítems presenta consumos extraordinariamente altos.

Por otro lado, la prioridad operacional se posiciona como una de las principales variables

discriminantes. Se observa una separación consistente entre materiales críticos y no críticos, lo que permite distinguir clústeres con niveles de prioridad diferenciados. Esto es especialmente relevante, ya que la prioridad no solo refleja el uso en órdenes de trabajo, sino que, además, se asocia con el impacto que un repuesto tiene sobre la continuidad operativa.

En cuanto al precio unitario, también se identifican agrupaciones que reflejan niveles de costo claramente distintos, diferenciando repuestos de bajo, medio y alto valor. Esta división resulta útil para detectar ítems que, si bien no son consumidos con alta frecuencia, representan una carga económica importante y podrían requerir estrategias específicas de abastecimiento.

La Tabla 5 presenta los perfiles numéricos de los siete clústeres obtenidos mediante el modelo K-Means, considerando para cada grupo el número de materiales asignados, el consumo promedio (en unidades), el precio unitario promedio y la prioridad promedio asociada.

Tabla 5: Perfil de clústeres de materiales obtenidos mediante K-Means

Nº Clúster	Nombre del Clúster	Cantidad de SKU'S	Consumo Prom. (unidades)	Precio Unitario Prom. (CLP)	Prioridad Prom.
0	Repuesto Estándar Costoso	83	29	571.226	2,0
1	Repuesto Estándar Prioritario	87	29	279.637	3,0
2	Repuesto Alto Consumo	21	12.084	35.520	1,9
3	Repuesto Alto Valor	17	12	2.498.952	2,4
4	Repuesto No Críticos	56	76	176.041	1,0
5	Repuesto Críticos	45	6	326.844	4,0
6	Repuesto Estándar	463	90	65.915	2,0

Fuente: Elaboración propia con datos históricos del sistema SAP (2023-2024).

Desde una mirada general, el clúster 6 —Repuesto Estándar— contiene la mayor cantidad de materiales (463), caracterizándose por un consumo promedio alto y un precio unitario bajo. Este grupo representa una gran parte del inventario y corresponde a ítems de uso frecuente, pero con impacto económico moderado, lo que sugiere la necesidad de políticas de reposición regulares y eficientes.

Por otro lado, el clúster 2 —Repuestos de Alto Consumo— agrupa solo 21 ítems, pero con un consumo promedio superior a 12.000 unidades. Aunque su precio unitario es bajo, su volumen implica una participación significativa en el flujo operativo, por lo que su disponibilidad es crítica.

El clúster 3 —Repuestos de Alto Valor— presenta el precio unitario más elevado del conjunto, superando los 2 millones de pesos por unidad, aunque con bajo nivel de rotación. Estos ítems, por su alto costo, requieren políticas de stock muy ajustadas y un control riguroso para evitar inmovilización innecesaria de capital.

El clúster 5 —Repuestos Críticos— es particularmente relevante, ya que contiene materiales con alta prioridad operativa (4,0), pero con bajo consumo promedio, lo que refleja ítems de emergencia o de alta criticidad técnica. Este grupo debe ser gestionado con políticas conservadoras de seguridad, pese a su baja rotación.

Finalmente, los clústeres 0 y 1 representan materiales con consumo medio, pero diferenciados principalmente por su nivel de prioridad y precio. El clúster 1, denominado Repuesto Estándar Prioritario, destaca por su mayor criticidad relativa, lo que puede justificar un tratamiento diferenciado respecto al clúster 0, que agrupa ítems costosos pero de menor urgencia operativa.

En conjunto, esta clasificación multivariable entrega una segmentación más representativa del inventario, incorporando simultáneamente el valor, la criticidad y el uso operativo de cada material. Estos grupos permitirán definir políticas de inventario más específicas y alineadas con la

realidad operativa de la empresa.

9.3. Clasificación de almacenes mecánicos

La heterogeneidad operativa de los almacenes mecánicos plantea la necesidad de una segmentación que permita diferenciar su rol logístico y definir políticas ajustadas a sus características. Algunos almacenes concentran altos volúmenes de consumo, otros operan en contextos geográficos más exigentes o abastecen una mayor cantidad de negocios.

En este contexto, se aplicó un modelo de agrupamiento K-Means para clasificar los almacenes en función de variables que representan su nivel de actividad, complejidad logística y alcance operativo. Esta segmentación busca servir como base para proponer estrategias de inventario diferenciadas según el tipo de almacén.

9.3.1. Definición de variables y preparación de datos

Para aplicar el modelo de agrupamiento K-Means a los almacenes mecánicos, se definieron tres variables que capturan aspectos clave de su funcionamiento logístico:

- **Cantidad consumida:** refleja el volumen total de materiales gestionados por cada almacén, permitiendo dimensionar su nivel de actividad.
- **Ubicación:** variable categórica transformada a formato numérico, que distingue entre almacenes ubicados en Santiago, regiones o zonas extremas, considerando las diferencias logísticas que implica cada contexto.
- **Cantidad de negocios atendidos:** representa la diversidad operativa del almacén, según la cantidad de instalaciones o estaciones que abastece.

Todas las variables fueron estandarizadas mediante normalización Min-Max para asegurar que tengan un peso comparable en el análisis y evitar sesgos derivados de diferencias de escala. Este tratamiento permite una segmentación más precisa y coherente con las particularidades operativas de cada almacén.

9.3.2. Determinación del número óptimo de clústeres

Para estimar la cantidad adecuada de agrupaciones, se utilizó el método del codo, visualizado en la Figura 26. En la curva se observa una disminución progresiva de la inercia a medida que aumenta el número de clústeres, con un punto de inflexión visible cercano al valor 4.




Figura 26: Método del Codo para clasificación de almacenes

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

Si bien se inició con una configuración de cuatro clústeres, se realizaron iteraciones posteriores y validaciones cualitativas junto al equipo a cargo, considerando la diversidad logística y operativa de los almacenes. Como resultado, se estableció una segmentación final con seis clúste-

res, la cual entregó una clasificación más representativa y alineada con el contexto de la empresa.

9.3.3. Caracterización de los clústeres

La Figura 27 muestra la segmentación de los almacenes mecánicos obtenida mediante el modelo K-Means, representada en un espacio tridimensional con variables escaladas. Se visualiza la distribución de los almacenes según tres dimensiones clave: valor total de consumo, cantidad de negocios distintos atendidos y tipo de ubicación geográfica.




Figura 27: Visualización de Clusters de almacenes mecánicos (K-Means)

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

A nivel general, el modelo permitió diferenciar con claridad distintos tipos de almacenes.

Se observa una segmentación geográfica evidente, donde los almacenes ubicados en Santiago, regiones y zonas extremas tienden a agruparse en clústeres específicos, reflejando las diferencias operativas y logísticas propias de cada contexto territorial.

Además, la cantidad de negocios atendidos se comporta como un eje clave de diferenciación. Algunos clústeres agrupan almacenes con un alcance operativo limitado —vinculados a uno o a pocos negocios—, mientras que otros concentran almacenes de carácter más transversal, que abastecen a múltiples instalaciones.

El valor total consumido permite distinguir entre almacenes con bajo movimiento de materiales y aquellos con volúmenes significativamente mayores, generando así clústeres que reflejan distintos niveles de intensidad operativa.

En conjunto, esta clasificación general entrega una segmentación funcional de los almacenes mecánicos, capturando tanto su escala operativa como su rol dentro de la red logística de la empresa. Esta diferenciación permite entender mejor las dinámicas propias de cada grupo de almacenes y constituye un insumo clave para el diseño de políticas de inventario ajustadas a sus características.

A continuación, la Tabla 6 presenta la caracterización específica de los seis clústeres obtenidos mediante K-Means, considerando variables como el consumo promedio, la ubicación geográfica y la cantidad promedio de negocios atendidos por cada tipo de almacén.

N° Clúster	Nombre del Clúster	Cantidad de Almacenes	Consumo Prom. (MM CLP)	Ubicación	Negocios Prom.
0	Almacén Regional Multinegocio	3	46,2	Región	6,7
1	Almacén Regional Especializado	25	21,5	Región	2,0
2	Macro-Almacén Regional Multinegocio	19	199,8	Región	4,5
3	Almacén Metropolitano Especializado	21	43,4	Santiago	2,0
4	Almacén Extremo	6	48,5	Región Extrema	3,5
5	Macro-Almacén Metropolitano	9	224,2	Santiago	3,8

Tabla 6: Perfil de clústeres de almacenes mecánicos obtenidos a través de K-Means

Fuente: Elaboración propia con datos históricos del sistema SAP (2023-2024).

El clúster 5, denominado Macro-Almacén Metropolitano, agrupa almacenes con el consumo promedio más alto (224,2 MM CLP), ubicados en la región Metropolitana y con un nivel intermedio de diversidad operativa (3,8 negocios en promedio). Estos almacenes tienen un rol central en el abastecimiento y requieren políticas de inventario robustas, con altos niveles de cobertura y eficiencia.

El clúster 2, Macro-Almacén Regional Multinegocio, presenta también un alto volumen de consumo (199,8 MM CLP), con una mayor cantidad de almacenes asociados y un perfil multinegocio (4,5). Se trata de instalaciones clave fuera de Santiago que cumplen funciones logísticas amplias dentro de sus respectivas zonas.

En contraste, el clúster 1, Almacén Regional Especializado, representa el grupo más numeroso (25 almacenes), pero con consumo promedio significativamente menor (21,5 MM CLP) y bajo alcance operativo (2,0 negocios). Estos almacenes tienen funciones específicas y concentradas, por lo que sus políticas podrían centrarse en reposición focalizada y eficiencia de stock.

El clúster 0, Almacén Regional Multinegocio, es pequeño en tamaño (3 almacenes) pero muestra una alta diversidad operativa (6,7 negocios promedio), con un nivel de consumo moderado. Su gestión debe considerar tanto el volumen como la complejidad de atención a múltiples instalaciones.

El clúster 4, Almacén Extremo, agrupa almacenes ubicados en zonas geográficamente más exigentes. A pesar de tener consumo moderado, su ubicación condiciona la logística de abastecimiento, por lo que puede requerir políticas más conservadoras con mayores niveles de seguridad de stock.

Finalmente, el clúster 3, Almacén Metropolitano Especializado, presenta una configuración similar al clúster 1, aunque ubicado en Santiago. Su nivel de consumo y alcance operativo son contenidos, lo que sugiere un foco en funciones de soporte a negocios específicos dentro del área metropolitana.

En conjunto, esta clasificación permite distinguir claramente entre almacenes de escala amplia y funciones transversales, y aquellos de operación más localizada o especializada. Esta diferenciación es clave para diseñar políticas de inventario alineadas con el rol logístico real de cada grupo.

9.4. Definición de límites de control (s, S)

9.4.1. Análisis de tipo de demanda por cruce de clústeres

Con el objetivo de definir niveles de inventario acordes al comportamiento real de consumo, se clasificaron los patrones de demanda de los materiales utilizando el enfoque ADI-CV² (Average Demand Interval y Coefficient of Variation squared), que permite caracterizar la regularidad e

intensidad de los consumos a lo largo del tiempo.

El análisis se aplicó a la totalidad de combinaciones almacén-material derivadas de los clústeres previamente definidos, obteniendo así una clasificación por tipo de demanda para cada caso. A continuación, se presentan ejemplos representativos de los principales tipos identificados.

La Figura 28 muestra una demanda clasificada como errática, correspondiente al cruce 0-2. En este caso, se observa una frecuencia relativamente constante de consumo a lo largo del tiempo, aunque existen casos de cantidades reducidas, combinada con una alta variabilidad en los volúmenes por período. Este comportamiento dificulta la estimación precisa de necesidades y complica la asignación de niveles de inventario adecuados.




Figura 28: Evolución de consumo semanal para el cruce 0-2 (ALM-MAT) - Demanda tipo errática

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

En contraste, la Figura 29 representa una demanda grumosa, caracterizada por un bajo número de semanas con consumo y una variabilidad elevada. Se trata de un patrón intermitente e irregular, considerado uno de los más complejos de gestionar por el alto nivel de incertidumbre que introduce en los procesos de planificación.




Figura 29: Evolución de consumo semanal para el cruce 0-0 (ALM-MAT) - Demanda tipo grumosa

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

Por otro lado, la Figura 30 muestra una demanda suavizada, con un comportamiento estable tanto en frecuencia como en volumen. Este tipo de patrón favorece la proyección de necesidades y permite aplicar políticas de reposición estándar con menor riesgo de quiebres o sobrestock.




Figura 30: Evolución de consumo semanal para el cruce 2-2 (ALM-MAT) - Demanda tipo suavizada

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

En el caso del cruce 0-3, como se observa en la Figura 31, se identificó un comportamiento particular con un único evento de consumo durante todo el periodo analizado, lo cual impidió clasificarlo bajo el esquema ADI-CV². Este tipo de casos, aunque poco frecuentes, requieren un

tratamiento especial debido a la falta de representatividad histórica.




Figura 31: Evolución de consumo semanal para el cruce 0-3 (ALM-MAT) - Demanda no clasificable

Fuente: Elaboración propia con datos históricos del sistema SAP de la empresa (2023-2024).

Cabe destacar que, dentro del conjunto analizado, no se identificaron demandas del tipo intermitente, entendidas como aquellas con bajo consumo pero una frecuencia relativamente regular. Este patrón, aunque reconocido teóricamente, no estuvo presente en los cruces observados para este caso de estudio.

Una vez clasificadas todas las combinaciones ALM–MAT, se consolidaron los resultados en una matriz resumen que cruza los tipos de material (según su clúster) con los tipos de almacén definidos. La Figura 32 presenta la distribución final de los distintos tipos de demanda.

	Alm. Reg. Multinegocio 0	Alm. Reg. Especializado 1	Macro-Alm. Reg. Multinegocio 2	Alm. Metro. Especializado 3	Alm. Extremo 4	Macro-Alm. Metropolitano 5
Rep. Estándar Costoso 0	Grumosa	Grumosa	Suavizada	Errática	Grumosa	Suavizada
Rep. Estándar Prioritario 1	Grumosa	Errática	Grumosa	Suavizada	Grumosa	Errática
Rep. Alto Consumo 2	Errática	Errática	Suavizada	Suavizada	Suavizada	Suavizada
Rep. Alto Valor 3	No clasificable	Grumosa	Grumosa	Grumosa	Grumosa	Grumosa
Rep. No Críticos 4	Grumosa	Grumosa	Grumosa	Errática	Grumosa	Grumosa
Rep. Críticos 5	Grumosa	Grumosa	Grumosa	Grumosa	Grumosa	Grumosa
Rep. Estándar 6	Errática	Errática	Suavizada	Suavizada	Suavizada	Suavizada

Demanda tipo Errática ■

Demanda tipo Grumosa ■

Demanda tipo Suavizada ■

Demanda NO Clasificable ■

Figura 32: Matriz de tipo de demanda cruce almacén- material

Fuente: Elaboración propia.

Los resultados muestran una alta prevalencia de demandas grumosas y erráticas, especialmente en materiales de alto valor, tanto críticos como no críticos. En cambio, las demandas suavizadas se concentran en los macro-almacenes, tanto regionales como metropolitanos, lo que evidencia una mayor estabilidad operativa en dichos puntos de la red. Por su parte, solo se identificó un caso no clasificable debido a la falta de datos consistentes.

Esta caracterización constituye un insumo fundamental para la definición de políticas de inventario adaptadas, permitiendo alinear los niveles de stock con la naturaleza de la demanda y el rol operativo de cada almacén.

9.4.2. Caracterización logística y operativa

Con el objetivo de avanzar hacia una definición contextualizada de niveles de inventario, se consolidaron los resultados del análisis de demanda con otras características relevantes que inciden

directamente en la necesidad de mantener mayor o menor cobertura de stock.

En particular, se consideraron tres factores adicionales, además del tipo de demanda previamente clasificado:

- Criticidad del material, representada por los clústeres de repuestos prioritarios (1), críticos (5) y no críticos (4). Estos grupos reflejan distintos niveles de impacto sobre la continuidad operativa en caso de quiebre de stock.
- Valor del material, representado por el clúster 3 (repuestos de alto valor). Estos ítems, por su alto costo unitario, requieren una evaluación cuidadosa entre disponibilidad y costos financieros por sobrestock.
- Condición logística del almacén, identificada a través del clúster 4 (almacenes extremos), que agrupa instalaciones ubicadas en zonas geográficas más aisladas, con mayores tiempos de reposición y menor flexibilidad operativa.

La Figura 33 muestra la matriz de consolidación de estas variables, integrando por cada combinación almacén–material tanto el tipo de demanda como la presencia o no de las características mencionadas. Esto permite visualizar de forma simultánea los factores que justifican ajustes particulares en la política de inventario.

	Alm. Reg. Multinegocio 0	Alm. Reg. Especializado 1	Macro-Alm. Reg. Multinegocio 2	Alm. Metro. Especializado 3	Alm. Extremo 4	Macro-Alm. Metropolitano 5
Rep. Estándar Costoso 0	Grumosa	Grumosa	Suavizada	Errática	Grumosa Alm. extremo	Suavizada
Rep. Estándar Prioritario 1	Grumosa Rep. prioritarios	Errática Rep. prioritarios	Grumosa Repuestos prioritarios	Suavizada Rep. prioritarios	Grumosa Alm. extremo Rep. prioritarios	Errática Rep. prioritarios
Rep. Alto Consumo 2	Errática	Errática	Suavizada	Suavizada	Suavizada Alm. extremo	Suavizada
Rep. Alto Valor 3	No clasificable Rep. alto valor	Grumosa Rep. alto valor	Grumosa Rep. alto valor	Grumosa Rep. alto valor	Grumosa Alm. extremo Rep. alto valor	Grumosa Rep. alto valor
Rep. No Críticos 4	Grumosa Rep. NO Críticos	Grumosa Rep. NO Críticos	Grumosa Rep. NO Críticos	Errática Rep. NO Críticos	Grumosa Alm. extremo Rep. NO Críticos	Grumosa Rep. NO Críticos
Rep. Críticos 5	Grumosa Rep. críticos	Grumosa Rep. críticos	Grumosa Rep. críticos	Grumosa Rep. críticos	Grumosa Rep. críticos Alm. extremo	Grumosa Rep. críticos
Rep. Estándar 6	Errática	Errática	Suavizada	Suavizada	Suavizada Alm. extremo	Suavizada

Figura 33: Matriz de características principales por cruce almacén- material

Fuente: Elaboración propia.

Esta segmentación combinada constituye un insumo clave para definir estrategias diferenciadas, permitiendo identificar cruces que, por su nivel de riesgo o complejidad operativa, requieren políticas de stock más conservadoras, así como aquellos donde es posible aplicar modelos de reposición más ajustados.

9.4.3. Asignación de límites (s , S)

A partir de la segmentación desarrollada y la consolidación de características operativas clave, se definieron tres esquemas de cálculo de inventario diseñados para adaptarse a distintos contextos de demanda y niveles de criticidad. Más allá de su formulación metodológica, se evaluó su comportamiento frente a datos históricos reales con el objetivo de validar su aplicabilidad práctica y capacidad de respuesta.

La Figura 34 ilustra el caso de un material clasificado como crítico y con demanda errá-

tica, al cual se le asignó un nivel de inventario tipo 1 (conservador). Se evidencia que los valores mínimos y máximos definidos —basados en la demanda semanal máxima y un margen adicional del 10 %— permiten cubrir adecuadamente los picos de consumo, incluso en presencia de eventos aislados de alta demanda. Este enfoque garantiza una alta disponibilidad, aunque con un mayor nivel promedio de inventario.

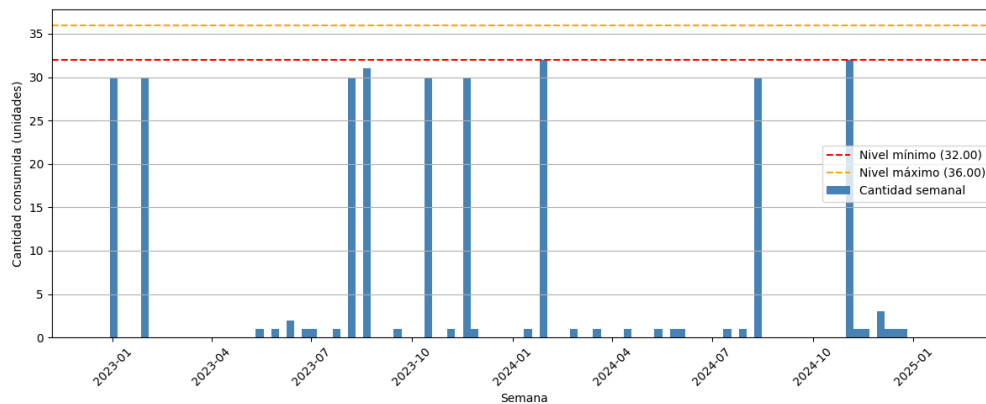


Figura 34: Evolución de consumo semanal para el cruce 2-1 (ALM-MAT) nivel de inventario 1

Fuente: Elaboración propia.

En la Figura 35, correspondiente a un ítem con demanda suavizada, se aplica el nivel tipo 2 (estable). El rango definido entre el promedio de consumo y su desviación estándar logra cubrir eficazmente las variaciones normales de la demanda, evitando tanto quiebres como excesos de stock. La mayoría de los valores semanales se sitúan dentro del rango propuesto, lo cual valida su utilidad para materiales con comportamiento regular y predecible.

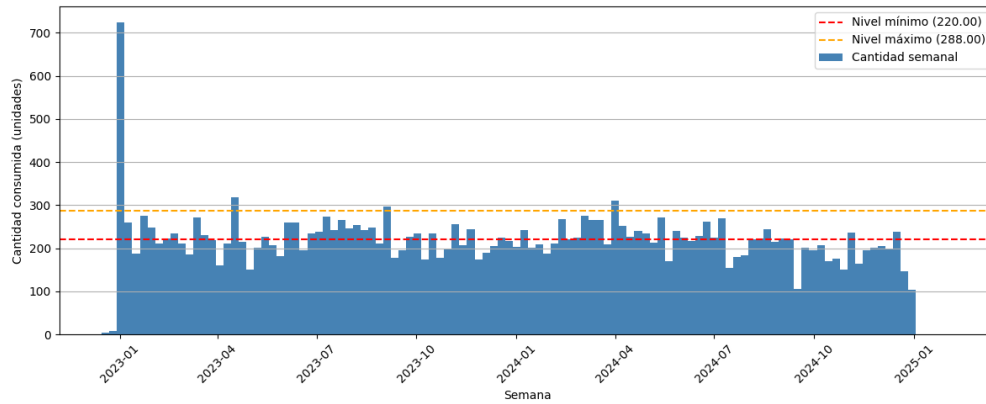


Figura 35: Evolución de consumo semanal para el cruce 2-6 (ALM-MAT) nivel de inventario 2

Fuente: Elaboración propia.

Por otro lado, la Figura 36 presenta un caso con demanda grumosa, gestionado bajo un nivel tipo 3 (variable). Este enfoque, basado en los percentiles 80 % y 90 % de la distribución histórica, permite establecer límites ajustados que reflejan el patrón real de consumo sin estar sesgados por valores atípicos. Aunque el rango definido es más acotado, resulta suficiente para absorber la mayoría de los eventos de consumo efectivo.




Figura 36: Evolución de consumo semanal para el cruce 0-0 (ALM-MAT) nivel de inventario 3

Fuente: Elaboración propia.

En conjunto, los tres esquemas muestran un comportamiento coherente con los objetivos definidos: asegurar cobertura para materiales críticos o de alta incertidumbre, optimizar el inventa-

rio en ítems estables y controlar el riesgo en materiales de baja frecuencia de uso. Esta validación empírica respalda la consistencia del modelo y confirma su aplicabilidad a las condiciones reales del sistema logístico analizado. Cabe señalar que el enfoque propuesto busca establecer niveles de inventario capaces de cubrir, en promedio, un horizonte de dos semanas de consumo, en línea con la frecuencia semanal de abastecimiento definida en el caso de estudio que es de una semana.

Finalmente, la Figura 37 presenta la matriz general con los niveles de inventario asignados a cada combinación clúster almacén–material, incorporando los ajustes aplicados mediante ponderadores según características logísticas y estratégicas previamente identificadas.

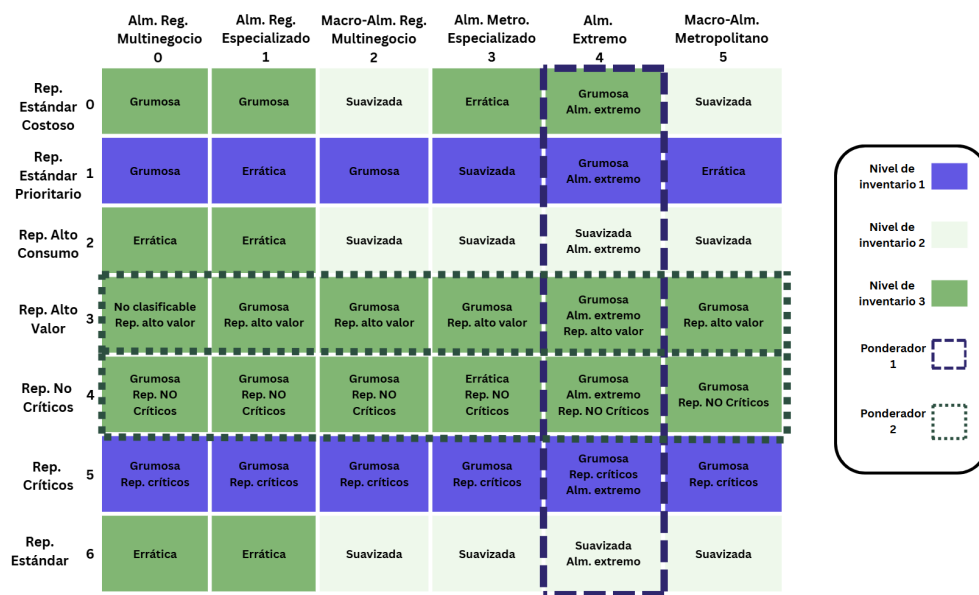


Figura 37: Matriz de nivel de inventario por cruce almacén- material

Fuente: Elaboración propia.

9.5. Evaluación de propuesta de límites de control (s, S)

9.5.1. Obtención del nivel de stock actual para los clústeres

Con el fin de dimensionar la magnitud del stock actualmente mantenido y su coherencia con los patrones de consumo observados, se analizó la cobertura promedio en semanas para cada combinación clúster almacén–material. La Figura 38 presenta los resultados obtenidos al calcular el cociente entre el stock disponible y el consumo semanal promedio para cada cruce.




Figura 38: Semanas de cobertura por cruce ALM-MAT Nivel de inventario Actual

Fuente: Elaboración propia.

En términos globales, el análisis revela un promedio de cobertura de 67,7 semanas, lo que equivale a mantener inventario disponible para más de un año de consumo, considerando que los envíos se realizan de forma semanal. Esta cifra evidencia una política de almacenamiento altamente conservadora y posiblemente sobredimensionada en relación con la demanda real.

En particular, se identifican varios casos con coberturas excesivas, como el clúster de ma-

teriales estándar (6) en almacenes regionales multinegocio (0) y especializados (1), con 276,6 y 206,6 semanas respectivamente, así como materiales de bajo consumo o baja prioridad con coberturas superiores a las 100 semanas. Estas situaciones reflejan una acumulación de stock que no responde necesariamente a criterios de criticidad o complejidad logística.

Por otro lado, también se observan combinaciones con niveles considerablemente más ajustados, especialmente en materiales de alto valor o en almacenes metropolitanos donde las coberturas oscilan entre 8 y 40 semanas, lo que sugiere cierta racionalización en algunos segmentos específicos.

En conjunto, la cobertura actual promedio, junto con un valor total de stock de 3.606 millones de CLP, pone en evidencia un potencial de mejora importante en términos de eficiencia de inventario. La ausencia de una política diferenciada por tipo de material y almacén ha derivado en una estrategia uniforme que, en la práctica, genera sobreinversión en ítems de baja rotación sin mejorar significativamente la disponibilidad de aquellos más críticos.

Este diagnóstico inicial refuerza la necesidad de implementar un modelo de inventario segmentado como el propuesto en esta investigación, que permita alinear los niveles de stock con las características reales de la demanda, la criticidad del material y las condiciones logísticas de cada almacén.

9.5.2. Evaluación de propuesta

Una vez definidos los niveles mínimos y máximos de inventario para cada combinación clúster almacén–material, se evaluó el comportamiento global de la propuesta en términos de semanas de cobertura y su impacto sobre el stock total.

La Figura 39 muestra las semanas de cobertura asociadas al nivel mínimo propuesto. En

promedio, el sistema operaría con 1,9 semanas de inventario mínimo, lo que representa una cobertura ajustada al ritmo de consumo real. Destaca que varios cruces operan con exactamente una semana de cobertura mínima, especialmente en los almacenes ubicados en Santiago, donde es posible reponer materiales en un plazo de tres días mediante envíos express. Esta condición logística permite reducir inventario sin comprometer la continuidad operativa.




Figura 39: Semanas de cobertura por cruce ALM-MAT Nivel de inventario mínimo propuesto

Fuente: Elaboración propia.

Por su parte, la Figura 40 presenta las semanas de cobertura para los niveles máximos recomendados, alcanzando un promedio general de 2,6 semanas. Este rango ofrece un margen operativo razonable, permitiendo absorber variaciones de corto plazo sin incurrir en niveles excesivos de stock.




Figura 40: Semanas de cobertura por cruce ALM-MAT Nivel de inventario máximo propuesto

Fuente: Elaboración propia.

La Figura 41 muestra la variación porcentual del stock propuesto respecto al inventario actual. Se observan reducciones significativas en todos los cruces, con valores que en su mayoría superan el 90%. La mayor reducción se concentra en materiales estándar o de baja criticidad, actualmente sobredimensionados. En conjunto, la implementación del modelo implicaría una disminución del stock del 91,18%, lo que se traduce en un ahorro potencial de 1.702 millones de CLP.




Figura 41: Variación de Semanas de cobertura por cruce ALM-MAT entre nivel de inventario máximo propuesto y actual

Fuente: Elaboración propia.

Estos resultados reflejan el alto grado de sobrestock presente en el sistema actual y validan la eficacia del modelo propuesto. Al introducir una política de inventario diferenciada, basada en características operativas y patrones de consumo reales, se logra alinear la disponibilidad con las necesidades logísticas, optimizando simultáneamente la cobertura y el uso de recursos.

9.5.3. Evaluación de escenario conservador

Además de la propuesta base, se evaluó una alternativa conservadora. Esta propuesta se construyó aplicando un factor multiplicativo sobre los niveles de inventario mínimos y máximos definidos inicialmente, buscando alcanzar coberturas aproximadas de cuatro semanas.

La Figura 42 presenta las semanas de cobertura asociadas a los niveles mínimos bajo esta propuesta. El promedio se eleva a 3,7 semanas, alcanzando el objetivo de extender el horizonte de

abastecimiento respecto al modelo base. La mayoría de las combinaciones se encuentran entre 2,5 y 5 semanas, lo que entrega un rango de seguridad razonable para contextos con menor frecuencia de reposición o mayor variabilidad.




Figura 42: Semanas de cobertura por cruce ALM-MAT Nivel de inventario mínimo propuesto (escenario conservador)

Fuente: Elaboración propia.

Por su parte, la Figura 43 muestra la cobertura correspondiente a los niveles máximos, con un promedio de 4,7 semanas. Este nivel permite mantener holgura operativa sin incurrir en excesos como los observados en la situación actual.




Figura 43: Semanas de cobertura por cruce ALM-MAT Nivel de inventario máximo propuesto (escenario conservador)

Fuente: Elaboración propia.

Finalmente, la Figura 44 resume el impacto de esta propuesta en términos de reducción de inventario respecto al stock actual. Si bien el efecto es menos pronunciado que en la propuesta base, se sigue observando una disminución generalizada, con un ahorro estimado de 1.557 millones de CLP, lo que representa una reducción global del 82,39 % en el inventario mantenido.




Figura 44: Variación de Semanas de cobertura por cruce ALM-MAT entre nivel de inventario máximo propuesto (escenario conservador) y actual

Fuente: Elaboración propia.

Esta alternativa conserva los principios de segmentación y diferenciación por clúster, pero con una mayor tolerancia a eventos de demanda inesperados. Se presenta como una opción de implementación gradual o para unidades críticas del negocio, en las que el riesgo de quiebre de stock tiene un impacto operacional elevado. De esta forma, se entrega flexibilidad a la estrategia de gestión, permitiendo adaptar los niveles de inventario a distintos perfiles de riesgo y capacidades logísticas.

10. Conclusiones y recomendaciones

En concordancia con los objetivos planteados y los resultados obtenidos, se concluye que el diseño de una estrategia de gestión de inventario segmentada para almacenes de mantenimiento mecánico permite mejorar la toma de decisiones logísticas mediante una caracterización diferenciada de materiales y almacenes. La integración de técnicas como la clasificación ABC/XYZ, el análisis multivariable mediante clustering y el estudio de patrones de demanda a partir de la matriz ADI-CV², posibilita una comprensión más profunda del comportamiento del inventario, favoreciendo la definición de niveles adecuados de stock.

El análisis histórico de consumo, complementado con el juicio experto y criterios logísticos, permitió establecer límites de control (s, S) a las condiciones reales de cada combinación clúster de material–almacén. La evaluación de esta propuesta frente al inventario actual evidenció una reducción significativa del stock total, con ahorros económicos relevantes y sin comprometer la cobertura operativa.

Particularmente, se recomienda la adopción de la alternativa conservadora, ya que, pese a relajar parcialmente los niveles mínimos, sigue proporcionando una cobertura alta, lo cual es especialmente pertinente considerando que en el contexto de la empresa los costos de mantener inventario son bajos. Esta opción representa una solución equilibrada entre seguridad operativa y eficiencia económica.

Asimismo, se plantea como línea de mejora futura la validación del comportamiento de los clústeres mediante el análisis de casos individuales. Esto permitiría confirmar si los niveles definidos a partir de agrupamientos generalizados son coherentes con el comportamiento real de materiales críticos en situaciones particulares. Se destaca también la necesidad de robustecer la

segmentación en torno a la variable de cantidad consumida, dado que su alta variabilidad podría ocultar materiales con quiebres de stock frecuentes, afectando la disponibilidad operativa.

En términos metodológicos, se sugiere complementar el análisis de demanda con técnicas basadas en series de tiempo o modelos de tasa de falla, así como incorporar información relativa a planes de mantenimiento preventivo. Estas herramientas permitirían anticipar mejor los requerimientos de repuestos y optimizar aún más los niveles de inventario.

Finalmente, se recomienda que la organización defina explícitamente el nivel de servicio al cual desea orientar su gestión de inventarios. Este parámetro resulta esencial para establecer, de manera cuantitativa, cuánta demanda se está dispuesto a no satisfacer en función de criterios de riesgo, criticidad y costo. Contar con este objetivo operacional permitiría alinear las decisiones de stock con las expectativas de desempeño logístico y de continuidad operativa, fortaleciendo la coherencia entre la planificación estratégica y la ejecución táctica.

En definitiva, la propuesta metodológica desarrollada demuestra ser efectiva para mejorar la gestión de inventarios en entornos logísticos complejos, ofreciendo una herramienta flexible, adaptable y basada en evidencia que permite avanzar hacia una administración más eficiente, alineada con los objetivos operativos y estratégicos de la organización.

Referencias

- Abd El-Aal, Mohammad et al. (mar. de 2010). “A Framework for Evaluating and Comparing Inventory Control Policies in Supply Chains”. En: *Journal of Engineering Sciences, Assiut University* 38.2, págs. 449-465.
- Ahmed, Haval A. et al. (sep. de 2022). “An Investigation on Disparity Responds of Machine Learning Algorithms to Data Normalization Method”. En: *ARO-THE SCIENTIFIC JOURNAL OF KOYA UNIVERSITY* 10 (2), págs. 29-37. ISSN: 2410-9355. DOI: 10.14500/aro.10970.
- Ahmed, Mohiuddin, Raihan Seraj y Syed Mohammed Shamsul Islam (ago. de 2020). *The k-means algorithm: A comprehensive survey and performance evaluation*. DOI: 10.3390/electronics9081295.
- Bhalla, Swapnil et al. (2021). “Advances in spare parts classification and forecasting for inventory control: A literature review”. En: *IFAC-PapersOnLine*. Vol. 54. Elsevier B.V., págs. 982-987. DOI: 10.1016/j.ifacol.2021.08.118.
- Brunaud, Braulio et al. (2018). “Inventory Policies and Safety Stock Optimization for Supply Chain Planning”. En: *AIChE Journal*. Accepted article. DOI: 10.1002/aic.16421.
- CGMA (n.d.). *Demand classification models*. Chartered Global Management Accountant. Retrieved from <https://www.cgma.org/resources/tools/cost-transformation-models/demand-classification.html>. (Visitado 18-05-2025).
- Chaudhary, Vijesh et al. (2023). “Exploring the use of machine learning in inventory management for increased profitability”. En: *BioGecko* 12 (1), págs. 658-666. ISSN: 2230-5807. URL: <https://orcid.org/0000-0001-9167-9159>.

- Contreras Márquez, José Neptalí (2022). *Gestión y Optimización de Inventarios para Mantenimiento*. 3. a ed. mejorada. Ciudad Autónoma de Buenos Aires: José Neptalí Contreras Márquez. ISBN: 978-987-88-3389-7.
- Costantino, Francesco et al. (2018). “Spare parts management for irregular demand items”. En: *Omega* 81, págs. 57-66. DOI: 10.1016/j.omega.2017.09.009.
- Dash, Ch Sanjeev Kumar et al. (mar. de 2023). “An outliers detection and elimination framework in classification task of data mining”. En: *Decision Analytics Journal* 6. ISSN: 27726622. DOI: 10.1016/j.dajour.2023.100164.
- Escobar-Pérez, Jazmine y Ángela Cuervo-Martínez (ene. de 2008). “Validez de contenido y juicio de expertos: una aproximación a su utilización”. En: *Avances en Medicina* 6, págs. 27-36.
- Ghosh, Dhiren y Andrew Vogt (2012). “Outliers: An Evaluation of Methodologies”. En: págs. 3455-3460. URL: <http://www.itl.nist.gov/>.
- Kennedy, W J, J Wayne Patterson y Lawrence D Fredendall (2002). “An overview of recent literature on spare parts inventories”. En: *Int. J. Production Economics* 76, págs. 201-215.
- Kenton, Will (31 de jul. de 2023). *Pareto Principle: Definition and How It Helps You Do More in Less Time*. Accessed 2025-05-15. URL: <https://www.investopedia.com/terms/p/paretoprinciple.asp>.
- Kirmizi, Sema Demiray, Zeynep Ceylan y Serol Bulkan (2024). “Enhancing Inventory Management through Safety-Stock Strategies—A Case Study”. En: *Systems* 12.7, pág. 260. DOI: 10.3390/systems12070260.
- Kodinariya, Trupti M y Prashant R Makwana (2013). “Review on determining number of Cluster in K-Means Clustering”. En: *International Journal of Advance Research in Computer Science and Management Studies* 1 (6). ISSN: 2321-7782. URL: www.ijarcsms.com.

- Labis, Xenia (2023). *Inventory Analysis Methods: Types and Benefits*. Publicado por Xenia Labis; cubre métodos como ABC, FSN, VED, HML y SDE. URL: <https://www.syntacticsinc.com/news-articles-cat/inventory-analysis-methods/> (visitado 18-05-2025).
- Mahesh, Batta (ene. de 2020). “Machine Learning Algorithms - A Review”. En: *International Journal of Science and Research (IJSR)* 9 (1), págs. 381-386. DOI: 10.21275/art20203995.
- Mohamad, Ismail Bin y Dauda Usman (2013). “Standardization and its effects on K-means clustering algorithm”. En: *Research Journal of Applied Sciences, Engineering and Technology* 6 (17), págs. 3299-3303. ISSN: 20407467. DOI: 10.19026/rjaset.6.3638.
- Moncrief, Eugene, Ronald Schroder y Michael Reynolds (2006). *Optimizing the MRO Inventory Asset: Production Spare Parts*. New York: Industrial Press Inc. ISBN: 978-0831132228.
- Naeem, Samreen et al. (2023). “An Unsupervised Machine Learning Algorithms: Comprehensive Review”. En: *International Journal of Computing and Digital Systems* 13 (1), págs. 911-921. ISSN: 2210142X. DOI: 10.12785/ijcds/130172.
- Oca Sánchez, Erika Montes de y Lourdes Loza-Hernández (2022). “Identificación de patrones de demanda de refacciones automotrices”. En: *Entreciencias: Diálogos en la Sociedad del Conocimiento* 10.24, págs. 1-12. DOI: 10.22201/enesl.20078064e.2022.24.81259.
- Peiró, Rosario (jul. de 2017). *Análisis ABC*. Redactado por Rosario Peiró, revisado por José Francisco López; actualizado el 5 de julio de 2017. URL: <https://economipedia.com/definiciones/analisis-abc.html> (visitado 18-05-2025).
- Priniotakis, G. y P. Argyropoulos (2018). “Inventory management concepts and techniques”. En: *IOP Conference Series: Materials Science and Engineering*. Vol. 459. 1, pág. 012060. DOI: 10.1088/1757-899X/459/1/012060.

- Raja, Anton Meri Lumban, The Jin Ai y Ririn Diar Astanti (mar. de 2016). “A Clustering Classification of Spare Parts for Improving Inventory Policies”. En: *IOP Conference Series: Materials Science and Engineering*. Vol. 114. Institute of Physics Publishing. DOI: 10.1088/1757-899X/114/1/012075.
- Rego, José Roberto do y Marco Aurélio de Mesquita (ene. de 2011). “Spare parts inventory control: a literature review”. En: *Producao* 21 (4), págs. 645-655. ISSN: 19805411. DOI: 10.1590/S0103-65132011005000002.
- Sahin, R., C. Kizilaslan y T. Demirel (2013). “A new approach for demand classification based on demand pattern”. En: *International Journal of Business and Management Studies* 5.1, págs. 11-20.
- Saxena, Amit et al. (dic. de 2017). “A review of clustering techniques and developments”. En: *Neurocomputing* 267, págs. 664-681. ISSN: 18728286. DOI: 10.1016/j.neucom.2017.06.053.
- Stoll, Heiko, Thomas Heine y Frank Schultmann (2014). “Inventory classification based on multi-criteria ABC analysis”. En: *International Journal of Production Economics* 147, págs. 381-387. DOI: 10.1016/j.ijpe.2013.05.025.
- Syntetos, Aris A., John E. Boylan y John D. Croston (2005). “On the categorization of demand patterns”. En: *Journal of the Operational Research Society* 56.5, págs. 495-503. DOI: 10.1057/palgrave.jors.2601841.
- Tanioka, Kensuke e Hiroshi Yadohisa (2012). “Effect of Data Standardization on the Result of k-Means Clustering”. En: *Challenges at the Interface of Data Analysis, Computer Science, and Optimization*. Ed. por Wolfgang A. Gaul et al. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 59-67. ISBN: 978-3-642-24466-7.

- Teixeira, Catarina, Isabel Lopes y Manuel Figueiredo (2017). “Multi-criteria Classification for Spare Parts Management: A Case Study”. En: *Procedia Manufacturing*. Vol. 11. Elsevier B.V., págs. 1560-1567. DOI: 10.1016/j.promfg.2017.07.295.
- Tsou, Chi-Ming (2013). “On the strategy of supply chain collaboration based on dynamic inventory target level management: A theory of constraint perspective”. En: *Applied Mathematical Modelling* 37.6, págs. 5204-5214. DOI: 10.1016/j.apm.2012.10.031.
- Turrini, Laura y Joern Meissner (feb. de 2019). “Spare parts inventory management: New evidence from distribution fitting”. En: *European Journal of Operational Research* 273 (1), págs. 118-130. ISSN: 03772217. DOI: 10.1016/j.ejor.2017.09.039.
- Witten, Ian H et al. (2017). *Data Mining Practical Machine Learning Tools and Techniques Fourth Edition*. Fourth Edition. ISBN: 9780128042915. URL: <https://www.elsevier.com>.
- Zapata, Julián Andrés (2014). *Fundamentos de la gestión de inventarios*. Medellín, Colombia: Centro Editorial Esumer. ISBN: 978-958-8599-73-1. URL: <https://www.esumer.edu.co>.
- Zhang, Shoujing et al. (2020). “Importance Degree Evaluation of Spare Parts Based on Clustering Algorithm and Back-Propagation Neural Network”. En: *Mathematical Problems in Engineering* 2020. ISSN: 15635147. DOI: 10.1155/2020/6161825.
- Zhang, Shuai, Kai Huang y Yufei Yuan (mar. de 2021). “Spare parts inventory management: A literature review”. En: *Sustainability (Switzerland)* 13 (5), págs. 1-23. ISSN: 20711050. DOI: 10.3390/su13052460.