

Modelo inteligente para la gestión de inventarios industriales mediante inteligencia artificial y
análisis de datos

Cristian Iván Chacón Gómez y Juan Pablo Morales Velasco

Trabajo de Grado para Optar al Título de Ingeniero Mecánico

Director

William Pinto Hernández

Doctor en ingeniería mecánica

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Mecánica

Bucaramanga

2026

Dedicatoria

A nuestros padres, quienes con su amor incondicional y sacrificio diario hicieron posible cada paso de este camino. Ustedes nos enseñaron que los sueños se alcanzan con esfuerzo, perseverancia y dedicación. Cada logro que hoy celebramos es el reflejo de su confianza inquebrantable, de las noches que velaron por nuestro bienestar y de los sacrificios silenciosos que realizaron para brindarnos esta oportunidad. Este título profesional no es solo nuestro, es de todos, porque sin su apoyo y su ejemplo, nada de esto habría sido posible.

A todas las personas que formaron parte de nuestro camino universitario: a los compañeros que se convirtieron en amigos de vida, a los profesores que compartieron no solo su conocimiento, sino también su experiencia y sabiduría, y a todos aquellos que, con una palabra de aliento, un gesto de apoyo o simplemente su presencia, contribuyeron a este logro. Cada uno dejó una huella imborrable en nuestra formación y hace parte fundamental de esta historia que hoy culmina con orgullo y gratitud.

Cristian Iván Chacón Gómez, Juan Pablo Morales Velasco

Agradecimientos

Agradecemos a Dios por brindarnos la fortaleza y la perseverancia necesarias para alcanzar este logro. A nuestros padres, por su amor incondicional y su sacrificio constante a lo largo de nuestra formación académica. Al profesor William Pinto, por ser nuestro mentor y por ofrecernos su guía, conocimiento y acompañamiento durante el desarrollo de este proyecto. A nuestros compañeros de carrera, por su amistad, apoyo y solidaridad a lo largo de estos años.

Finalmente, agradecemos a todos los profesores y alma mater que contribuyeron a nuestra formación, por su dedicación y por el tiempo dispuesto para apoyarnos en la culminación de este trabajo de grado.

Cristian Iván Chacón Gómez, Juan Pablo Morales Velasco

Tabla de Contenido

| | Pág. |
|--|-------------|
| Introducción | 15 |
| 1. Objetivos..... | 17 |
| 1.1 Objetivo General..... | 17 |
| 1.2 Objetivos Específicos..... | 17 |
| 2. Marco teórico | 18 |
| 2.1 Antecedentes..... | 18 |
| 2.2 Definiciones importantes | 19 |
| 2.2.1 Gestión de Inventarios Industriales..... | 19 |
| 2.2.2 Predicción de Demanda en Inventarios..... | 20 |
| 2.2.3 Inteligencia Artificial en la Gestión de Inventarios | 21 |
| 2.2.4 Big Data y Análisis de Datos en Inventarios | 21 |
| 2.2.5 Lógica Difusa..... | 22 |
| 2.2.6 KPIs en la Gestión de Inventarios..... | 24 |
| 2.3 Proceso de implementación del sistema inteligente de gestión de inventarios..... | 25 |
| 2.3.1 Definición del alcance y diagnóstico del sistema de inventarios..... | 25 |
| 2.3.2 Recolección, depuración y estructuración de datos | 25 |
| 2.3.3 Análisis exploratorio del comportamiento del inventario..... | 25 |
| 2.3.4 Modelado y predicción de la demanda | 26 |
| 2.3.5 Definición de variables lingüísticas y funciones de pertenencia | 26 |
| 2.3.6 Construcción de la base de reglas difusas..... | 26 |
| 2.3.7 Integración del modelo de predicción con el sistema difuso | 27 |

2.3.8 Implementación computacional del sistema 27

2.3.9 Evaluación del desempeño mediante indicadores clave 27

2.3.10 Implementación operativa y mejora continua..... 27

3. Metodología 28

3.1 Fase 1: Análisis y levantamiento de información 28

3.1.1 Revisión bibliográfica..... 28

3.1.2 Identificación de problemas de inventario 28

3.1.3 Recolección y organización de la información 29

3.1.4 Depuración y validación de la base de datos 29

3.1.5 Definición y estructuración de variables del modelo..... 29

3.1.5.1. Variables de entrada..... 30

3.1.5.2. Variables de salida. 31

3.1.6 Análisis de relaciones entre variables 31

3.1.6.1 Matriz de correlación entradas–salidas..... 31

3.1.6.2 Interpretación de las salidas experimentales..... 33

3.1.7 Interpretación de resultados del análisis estructural 34

3.1.7.1 Perfil de Impacto Dominante..... 34

3.2.7.2 Rol funcional..... 34

3.2.7.3 Niveles de importancia. 35

3.1.8 Relación directa con la lógica difusa 36

3.2 Fase 2. Diseño del modelo difuso de predicción 36

3.2.1 Enfoque general del modelo difuso 36

3.2.2 Definición de la estructura del sistema difuso 37

3.2.2.1 Selección de variables de entrada del sistema difuso. 37

3.2.2.2 Definición de variables de salida. 38

3.2.3 Definición de funciones de pertenencia..... 38

3.2.3.1. Tipos seleccionados. 38

3.2.3.2 Rango y normalización de las variables..... 40

3.2.4 Selección de algoritmos y métodos de análisis..... 40

3.2.4.1 Preprocesamiento estadístico de las variables. 40

3.2.4.2 Impacto del preprocesamiento en la inferencia difusa..... 42

3.2.4.3 Integración con modelos de predicción de demanda. 43

3.2.5 Arquitectura conceptual del modelo inteligente 44

3.2.5.1 Arquitectura general del sistema..... 44

3.2.5.2 Interacción entre módulos del sistema..... 45

3.2.6 Diseño del proceso de inferencia difusa 45

3.2.6.1 Base de reglas difusas. 45

3.2.6.2 Método de inferencia y defuzzificación..... 47

3.2.7 Diagramas de flujo y recorrido de los datos 47

3.2.7.1 Diagrama de flujo del procesamiento de datos. 47

3.2.7.2 Flujo del proceso de predicción y priorización..... 49

3.2.8 Validación conceptual del modelo..... 49

3.3 Fase 3. Implementación del modelo inteligente en Python 49

3.3.1 Entorno de desarrollo y estructura del proyecto 49

3.3.2 Librerías y herramientas empleadas..... 50

3.3.3 Implementación del módulo de ingreso y procesamiento de datos históricos..... 50

3.3.3.1 Ingesta, validación y limpieza de datos. 50

3.3.3.2 Preprocesamiento estadístico de las variables. 51

3.3.3.3 Métricas auxiliares generadas. 52

3.3.4 Implementación del motor de inferencia difusa..... 52

3.3.4.1 Definición de variables y funciones de pertenencia. 52

3.3.4.2 Construcción de la base de reglas difusas 53

3.3.4.3 Proceso de inferencia y defuzzificación 53

3.3.5 Desarrollo del modelo de predicción de demanda y control de inventarios 54

3.3.5.1 Modelos de predicción implementados. 54

3.3.6 Integración con el sistema difuso..... 58

3.3.6.1 Variables derivadas de la predicción. 58

3.3.6.2 Normalización y preparación de entradas difusas. 59

3.3.6.3 Activación del sistema de inferencia difusa..... 59

3.3.6.4 Beneficios de la integración predicción–difuso..... 60

3.3.7 Control de inventarios y generación de salidas..... 60

3.3.7.1 Tipos de salidas operativas del sistema. 60

3.3.7.2 Priorización y toma de decisiones diferenciada..... 61

3.3.7.3 Generación y análisis de indicadores clave de desempeño (KPIs). 61

3.3.7.4 Retroalimentación y mejora continua. 62

3.4 Fase 4. Validación y simulación 62

3.4.1 Definición de indicadores clave de desempeño (KPIs) 62

3.4.2. KPIs principales 63

3.4.2.1. Rotación de inventario. 63

3.4.2.2 Nivel de servicio. 63

3.4.2.3 Costo total de inventario. 63

3.4.2.4 Disponibilidad de productos. 64

3.4.3 KPIs secundarios..... 64

3.4.5 Simulación del sistema con datos históricos y proyectados 65

3.4.5.1 Motor de simulación. 65

3.4.5.2 Backtesting (validación histórica)..... 65

3.4.5.3 Escenarios normales proyectados. 65

3.4.5.4 Escenarios de estrés. 66

3.4.6 Comparación con métodos tradicionales de gestión de inventarios 67

3.4.6.1 Métodos tradicionales evaluados. 67

3.4.6.2 Resultados comparativos esperados..... 67

3.4.6.3 Análisis estadístico de resultados..... 68

3.4.7 Ajuste iterativo del sistema difuso y parámetros 69

3.4.7.1 Identificación de problemas..... 69

3.4.7.2 Ajuste de funciones de pertenencia..... 69

3.4.7.3 Refinamiento de reglas difusas. 69

3.4.7.4 Calibración de parámetros. 70

3.4.7.5 Validación de ajustes. 70

3.4.8 Cierre de la Fase 4..... 71

4. Análisis de resultados 71

4.1 Comparación contra métodos tradicionales 71

4.2 Precisión en la predicción de demanda..... 73

| | |
|--|----|
| 4.3 Pruebas de robustez..... | 74 |
| 4.4 Ahorro en costos de inventario | 75 |
| 4.5 Reducción de faltantes y mejora en disponibilidad | 76 |
| 4.5.1 Análisis de retorno de inversión | 76 |
| 4.5.2 Ajustes técnicos para entornos empresariales..... | 77 |
| 4.5.2.1 Integración con sistemas existentes. | 77 |
| 4.5.2.2 Escalabilidad computacional. | 78 |
| 4.5.2.3 Gestión de calidad de datos..... | 78 |
| 4.5.2.4 Plan de implementación por fases..... | 78 |
| 4.5.2.5 Posibles ampliaciones del modelo. | 79 |
| 4.5.3 Resumen de resultados alcanzados | 80 |
| 4.5.4 Contribución del modelo difuso a la ingeniería mecánica..... | 80 |
| 4.5.5 Limitaciones y trabajo futuro..... | 81 |
| 5. Conclusiones..... | 82 |
| 6. Recomendaciones | 83 |
| Referencias Bibliográficas | 86 |
| Apéndices..... | 88 |

Lista de Tablas

| | Pág. |
|---|-------------|
| Tabla 1. <i>Jerarquización de las variables de entrada del modelo</i> | 35 |
| Tabla 2. <i>Reglas difusas</i> | 46 |
| Tabla 3. <i>Comparación de KPIs: Sistema Inteligente vs. Métodos Tradicionales</i> | 72 |
| Tabla 4. <i>Comparación de precisión en predicción de demanda</i> | 74 |
| Tabla 5. <i>Análisis de impacto económico del sistema inteligente</i> | 75 |
| Tabla 6. <i>Análisis de retorno de inversión (valores en pesos colombianos \$COP)</i> | 77 |
| Tabla 7. <i>Resumen de resultados alcanzados</i> | 80 |

Lista de Figuras

| | Pág. |
|---|-------------|
| Figura 1. <i>Ejemplo de funciones de pertenencia</i> | 23 |
| Figura 2. <i>Estructura de un sistema difuso</i> | 24 |
| Figura 3. <i>VARIABLES de entrada y salida del sistema</i> | 30 |
| Figura 4. <i>Matriz de correlación entre entradas y salidas</i> | 32 |
| Figura 5. <i>Funciones de pertenencia</i> | 39 |
| Figura 6. <i>Arquitectura Modular del sistema</i> | 45 |
| Figura 7. <i>Diagrama de flujo del procesamiento de datos parte 1</i> | 48 |
| Figura 8. <i>Diagrama de flujo del procesamiento de datos parte 2</i> | 48 |
| Figura 9. <i>Módulo de ingesta, validación y limpieza de datos</i> | 51 |
| Figura 10. <i>Diagrama del proceso de inferencia y defuzzificación</i> | 54 |
| Figura 11. <i>Diagrama de los modelos de predicción de demanda</i> | 57 |
| Figura 12. <i>Diagrama de la integración del sistema de predicción con el sistema difuso</i> 58 | |
| Figura 13. <i>Diagrama de salidas del modelo</i> | 60 |
| Figura 14. <i>Diagrama de los picos de demanda</i> | 67 |
| Figura 15. <i>Diagrama de flujo de datos del sistema</i> | 70 |
| Figura 16. <i>Comparación del Sistema Inteligente vs. Métodos Tradicionales</i> | 73 |
| Figura 17. <i>Simulación escenario de estrés.</i> | 75 |
| Figura 18. <i>Ciclo de Ajuste Iterativo del Sistema Difuso</i> | 78 |

Lista de Apéndices

| | pág. |
|---|-------------|
| Apéndice A. Arquitectura general del modelo | 88 |
| Apéndice B. Entorno de desarrollo y librerías empleadas | 91 |
| Apéndice C. Descripción modular del sistema | 92 |
| Apéndice D. Reporte del sistema..... | 96 |

Resumen

Título: Modelo inteligente para la gestión de inventarios industriales mediante inteligencia artificial y análisis de datos*

Autor: Cristian Iván Chacón Gómez, Juan Pablo Morales Velasco**

Palabras Clave: Gestión de inventarios, lógica difusa, predicción de demanda, redes neuronales artificiales, simulación, KPIs, análisis ABC.

Descripción: En este proyecto de grado se propone el desarrollo de un sistema inteligente de apoyo a la toma de decisiones para la gestión de inventarios, integrando técnicas de análisis estadístico, modelos avanzados de predicción de demanda y lógica difusa. El objetivo principal es mejorar el desempeño operativo y económico de los inventarios mediante una priorización dinámica de productos, considerando simultáneamente múltiples variables operativas y estratégicas.

La metodología propuesta combina la clasificación ABC con modelos de series de tiempo basados en lógica difusa para la estimación de la demanda futura, permitiendo capturar patrones complejos de estacionalidad, tendencia y variabilidad. Estas predicciones alimentan un sistema experto difuso que integra variables como nivel de stock, rotación, lead time, disponibilidad, costo unitario y confiabilidad del proveedor, generando niveles de prioridad de gestión que orientan las decisiones de reposición y control de inventarios.

El sistema fue implementado computacionalmente en Python bajo una arquitectura modular y validado mediante simulaciones con datos históricos y proyectados. Se evaluaron escenarios normales y de estrés, incluyendo picos de demanda y reducciones súbitas de stock, con el fin de analizar la robustez del modelo. Asimismo, se realizó una comparación rigurosa frente a métodos tradicionales de gestión de inventarios, tales como EOQ/ROP clásico, políticas ABC fijas y reabastecimiento periódico simple.

Los resultados evidencian mejoras significativas en indicadores clave de desempeño, tales como aumento del nivel de servicio, reducción del costo total de inventario y mayor rotación, demostrando que la integración de predicción avanzada y lógica difusa permite una gestión más eficiente y adaptativa. En conclusión, el sistema propuesto constituye una herramienta robusta y flexible para la toma de decisiones en entornos de inventarios complejos, dinámicos e inciertos.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Pregrado en Ingeniería Mecánica. Director: William Pinto Hernández. PhD. Ingeniería Mecánica.

Abstract

Title: Intelligent Decision Support System for Inventory Management Based on Statistical Analysis and Fuzzy Logic Modeling*

Author(s): Cristian Iván Chacón Gómez, Juan Pablo Morales Velasco**

Key Words: Inventory management, decision support system, fuzzy logic, demand prediction, statistical analysis, uncertainty.

Description: This paper presents the development of an intelligent decision support system aimed at improving inventory management under conditions of uncertainty. The proposed approach integrates historical data analysis, statistical preprocessing, and a fuzzy logic-based prediction model to support strategic and operational decision-making in inventory control. The methodology begins with the ingestion and preprocessing of historical inventory data, followed by descriptive and inferential statistical analysis to identify relevant demand patterns and critical variables. Based on this analysis, a fuzzy inference system is designed, defining input variables, membership functions, and inference rules that allow modeling the imprecise and uncertain nature of demand behavior. This model is reinforced through time series analysis techniques to enhance prediction accuracy.

The system generates decision-oriented outputs related to inventory levels, potential shortages, and excess stock, enabling more efficient planning and control. A case study demonstrates that the proposed system improves demand forecasting reliability and contributes to reducing inventory-related costs and operational risks. The results confirm that the integration of statistical analysis and fuzzy logic constitutes an effective tool for intelligent inventory management in dynamic and complex environments.

* Degree Work

** Faculty of Engineering Physical Mechanics. School of Mechanical Engineering. Undergraduate Degree in Mechanical Engineering. Director: William Pinto Hernández. PhD. Mechanical Engineering.

Introducción

Las empresas industriales de la región enfrentan importantes desafíos en la gestión de inventarios y repuestos críticos. Entre los más frecuentes se encuentran la acumulación innecesaria de existencias, el desabastecimiento de componentes, la limitada visibilidad del estado real de los inventarios y la toma de decisiones basadas únicamente en la experiencia empírica. Estas dificultades generan costos elevados, interrupciones operativas y reducen la competitividad.

La planificación de inventarios en muchas organizaciones carece de modelos predictivos y herramientas de análisis de datos, lo que ocasiona exceso de stock, pérdidas por obsolescencia, largos tiempos de reposición y compras de emergencia a precios elevados. En particular, numerosas PYMES aún dependen de sistemas manuales o software básicos que no consideran patrones históricos, estacionalidad ni tendencias de consumo. Si bien existen soluciones de pronóstico y gestión inteligente de inventarios, suelen requerir infraestructura tecnológica costosa, licencias de alto valor o conectividad permanente a la nube, lo que limita su adopción en el sector regional.

Como punto de partida, se empleará la base de datos Product Demand Forecasting de Kaggle, que contiene información histórica de demanda con variables como fechas, códigos de producto, ubicaciones y cantidades solicitadas. Este conjunto de datos permitirá entrenar un sistema basado en lógica difusa y análisis de Big Data, capaz de modelar la incertidumbre en la demanda, optimizar niveles de stock y generar recomendaciones precisas de reposición. Posteriormente, el modelo podrá adaptarse a datos reales de la industria local para su implementación práctica.

Este enfoque busca ofrecer a las empresas de la región una solución autónoma, segura y económicamente viable que mejore la disponibilidad de repuestos, reduzca costos operativos y estandarice la gestión de activos, garantizando así la continuidad y eficiencia de las operaciones.

De este problema surge la pregunta de investigación: ¿Cómo puede un sistema de análisis de Big Data basado en lógica difusa mejorar la gestión de inventarios industriales, incrementando la disponibilidad de repuestos, reduciendo costos y fortaleciendo la toma de decisiones estratégicas?

1. Objetivos

1.1 Objetivo General

Desarrollar un sistema de gestión de inventarios industriales, basado en lógica difusa y análisis del historial de operaciones, que procese datos para (evaluar niveles de stock, disponibilidad de repuestos, evaluando el funcionamiento del sistema mediante indicadores clave de desempeño (KPIs) relacionados con demanda, costos, rotación y disponibilidad.

1.2 Objetivos Específicos

Diseñar un modelo de predicción de demanda de inventarios industriales en Python, utilizando lógica difusa y análisis de datos históricos para anticipar necesidades de reposición y evitar desabastecimientos o excesos de stock.

Implementar el modelo de análisis y predicción con lógica difusa desarrollado en Python, para integrar la información de la base de datos **Product Demand Forecasting** y con esta procesar las variables clave del inventario, la demanda, los costos, la rotación, la disponibilidad con el fin de mejorar las decisiones de reabastecimiento y suministro de activos.

Validar el desempeño del modelo basado en lógica difusa mediante pruebas con datos y simulaciones, utilizando indicadores clave de desempeño, comparando sus resultados frente a métodos tradicionales de gestión de inventarios. Los indicadores claves a evaluar, cada uno con su nivel de pertenencia serán los siguientes:

- Rotación de inventario: baja, media, alta.
- Nivel de servicio: deficiente, aceptable, óptimo.
- Costo de inventario: bajo, moderado, alto.
- Disponibilidad: limitada, estable, máxima.

2. Marco teórico

La integración de técnicas de manejo de inventarios requiere analizar modelos existentes que mejoren el control de existencias, evitando acumulaciones o desabastecimientos. Para ello, es esencial apoyarse en estudios conceptuales y técnicos que permitan avanzar de forma coherente hacia la incorporación de modelos inteligentes para la predicción de demanda y la toma de decisiones en inventarios.

2.1 Antecedentes.

Rodríguez (2019), en su artículo “Aplicación de la lógica difusa en la gestión de inventarios industriales” publicado en la Revista Internacional de Ingeniería y Logística, presenta un modelo basado en reglas difusas para la toma de decisiones de reposición de materiales. En su trabajo se evidencia cómo la utilización de funciones de pertenencia lingüísticas (bajo, medio, alto) para representar el nivel de inventario y la demanda, mejora la flexibilidad del sistema frente a la incertidumbre, permitiendo reducir tanto los faltantes como el sobre stock. Además, el estudio resalta la importancia de incorporar técnicas de inteligencia artificial como apoyo a los métodos tradicionales de control de inventarios.

Por otro lado, Chen y Wu (2021), en su investigación “Big Data Analytics for Inventory Forecasting” publicada en la Journal of Industrial Engineering, proponen la integración de análisis masivos de datos con algoritmos de aprendizaje automático para predecir la demanda futura de repuestos en empresas manufactureras. Los autores destacan que la combinación de series de tiempo históricas con datos en tiempo real obtenidos de sensores IoT logra mejorar los niveles de servicio hasta en un 15%, en comparación con los modelos clásicos deterministas.

Finalmente, Kumar et al. (2022), en el artículo “Key Performance Indicators as Inputs in Intelligent Inventory Systems” publicado en International Journal of Operations Management, exponen la relevancia de los KPIs en la gestión inteligente de inventarios. En este modelo, indicadores como la rotación, la disponibilidad y los costos de mantenimiento no solo funcionan como métricas de control, sino que se integran como variables de entrada en un sistema difuso que genera recomendaciones automáticas de reabastecimiento. El estudio evidencia que este enfoque híbrido, al combinar KPIs con lógica difusa, mejora la capacidad de respuesta de las organizaciones frente a la variabilidad del mercado.

De esta manera, los antecedentes internacionales muestran cómo las tendencias globales apuntan hacia la convergencia entre lógica difusa, inteligencia artificial, Big Data y KPIs, como elementos clave para la construcción de sistemas de inventario más flexibles, confiables y alineados con los principios de la Industria

2.2 Definiciones importantes

2.2.1 Gestión de Inventarios Industriales

El inventario en la industria se entiende como el conjunto de materiales, repuestos, herramientas y componentes necesarios para garantizar la operación continua de un sistema productivo (Ballou, 2004). En el contexto de la ingeniería mecánica, estos inventarios suelen incluir repuestos para maquinaria, equipos de producción, lubricantes, piezas de desgaste y elementos de seguridad industrial. La gestión de inventarios es de vital importancia porque un adecuado control de existencias asegura la disponibilidad oportuna de repuestos, minimizando los riesgos de paradas no programadas y sobrecostos por compras de emergencia. No obstante, las empresas industriales enfrentan desafíos frecuentes como:

- Sobrestock: acumulación excesiva de repuestos que genera costos de almacenamiento, deterioro y obsolescencia.
- Desabastecimiento: ausencia de componentes clave en el momento necesario, lo que ocasiona detenciones de equipos productivos.
- Obsolescencia: pérdida de valor de inventarios debido a la sustitución tecnológica de equipos o piezas.
- Planificación empírica: toma de decisiones basada en la experiencia personal de los encargados, sin soporte en herramientas de análisis avanzadas.

Modelos clásicos como EOQ (Economic Order Quantity) en (Alnahhal; Aylak; Al Hazza y Sakhrieh, 2024), JIT (Just inTime) en (Xu y Chen, 2016), y MRP (Material Requirements Planning) en (Mula; Poler y García, 2006), han sido ampliamente utilizados, aunque presentan limitaciones frente a la incertidumbre y variabilidad de la demanda y el control de la toma de decisiones sobre la reposición de faltantes.

2.2.2 Predicción de Demanda en Inventarios

La predicción de la demanda consiste en anticipar la cantidad de productos o repuestos requeridos en un periodo futuro. En el ámbito industrial, esta predicción es indispensable para asegurar la disponibilidad de componentes y evitar tanto desabastecimientos como acumulación innecesaria de materiales. Los métodos estadísticos tradicionales han sido ampliamente utilizados en este campo, sin embargo, estos métodos deterministas muestran limitaciones en contextos industriales complejos relacionados con los tiempos en la cadena de suministro descritos por Abolghasemi, 2020. Impacto de la volatilidad de demanda en el pronóstico: ARIMAX y ETSX.

Entre ellos se destacan las series de tiempo que permiten identificar patrones de consumo a lo largo del tiempo (Da Veiga, 2020), los Modelos ARIMA (Autoregressive Integrated Moving

Average) los cuales son eficaces para datos con estacionalidad o tendencias definidas (Santoro, 2025), el suavizamiento exponencial que es útil para pronósticos a corto plazo (Santoro, 2025).

2.2.3 Inteligencia Artificial en la Gestión de Inventarios

La Inteligencia Artificial (IA) está transformando la manera en que las empresas abordan la planificación de inventarios, gracias a su capacidad de procesar grandes volúmenes de datos y obtener patrones complejos que los modelos tradicionales no pueden identificar (Chong, Li, Ngai, Ch'ng y Lee, 2017).

En el sector industrial, la IA se ha aplicado con éxito en el pronóstico de demanda, la optimización de inventarios y la automatización del reabastecimiento. Un ejemplo es General Electric (GE), que emplea algoritmos de machine learning para anticipar la demanda de repuestos y evitar sobrecostos en inventario (GE Aviation, 2021). De forma similar, Walmart ha utilizado redes neuronales para predecir la demanda de productos en sus tiendas minoristas (Taghizadeh, 2017), evidenciando que los modelos de IA pueden anticipar comportamientos de consumo bajo condiciones variables.

El uso de redes neuronales, aprendizaje automático y lógica difusa ha mejorado la precisión en la planificación y reducidos costos operativos (Carbonneau, Laframboise & Vahidov, 2008; Tsou, 2021; Order-up-to-leave, 2023). En ingeniería mecánica, esto se refleja en mayor disponibilidad de repuestos, lo que impacta directamente en la eficiencia de los equipos (OEE) y en una gestión de mantenimiento más confiable (Optimization of inventory management..., 2024).

2.2.4 Big Data y Análisis de Datos en Inventarios

El Big Data se define como el manejo de grandes volúmenes de datos con alto volumen, variedad y velocidad (Laney, 2001). En la gestión de inventarios industriales, permite integrar fuentes como historiales de consumo, ERP, sensores IoT y bases externas, ofreciendo una visión

más precisa y dinámica del inventario. Su uso facilita la detección de patrones de demanda, la anticipación de fallos y el ajuste en tiempo real de existencias, lo que mejora la disponibilidad de repuestos y reduce costos. Al alimentar sistemas inteligentes de predicción, Big Data optimiza la toma de decisiones y refuerza la eficiencia operativa. (Wang, J., Xu, C., Zhang, J., & Zhong, R. Y. (2016) y Zhong, R. Y., Xu, X., Klotz, E., & Newman, S. T. (2017)).

Herramientas de programación como Python y sus librerías (Pandas, Numpy, Scikit-Learn, TensorFlow) permiten desarrollar algoritmos capaces de procesar grandes volúmenes de datos para construir sistemas de pronóstico más confiables (Wang, J., Xu, C., Zhang, J., & Zhong, R. Y. (2016)).

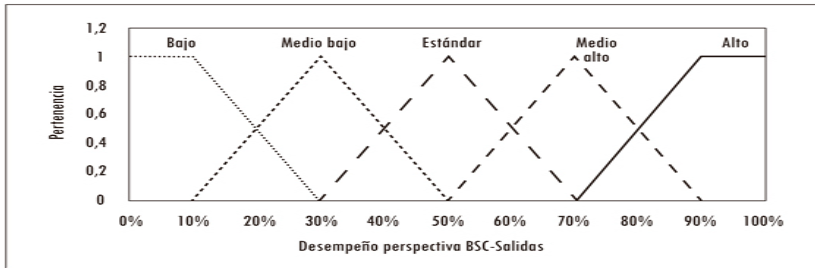
La integración de Big Data con técnicas de Inteligencia Artificial se ha consolidado como un pilar esencial en la evolución hacia la Industria 4.0 (Wang, J., Xu, C., Zhang, J., & Zhong, R. Y. (2016) y Zhong, R. Y., Xu, X., Klotz, E., & Newman, S. T. (2017)).

2.2.5 Lógica Difusa

La lógica difusa, propuesta por Lotfi Zadeh en 1965, surgió como respuesta a la incapacidad de la lógica clásica para modelar fenómenos caracterizados por la incertidumbre, la ambigüedad o la falta de información precisa. Mientras la lógica tradicional funciona bajo un enfoque binario (0 = falso, 1 = verdadero), la lógica difusa introduce el concepto de grados de pertenencia, permitiendo que un elemento pertenezca parcialmente a un conjunto en un rango continuo entre 0 y 1, como se muestra en la figura 1.

Figura 1.

Ejemplo de funciones de pertenencia



Nota: El gráfico representa Funciones de pertenencias para un sistema de lógica difusa. Tomada de http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0123-21262012000100006

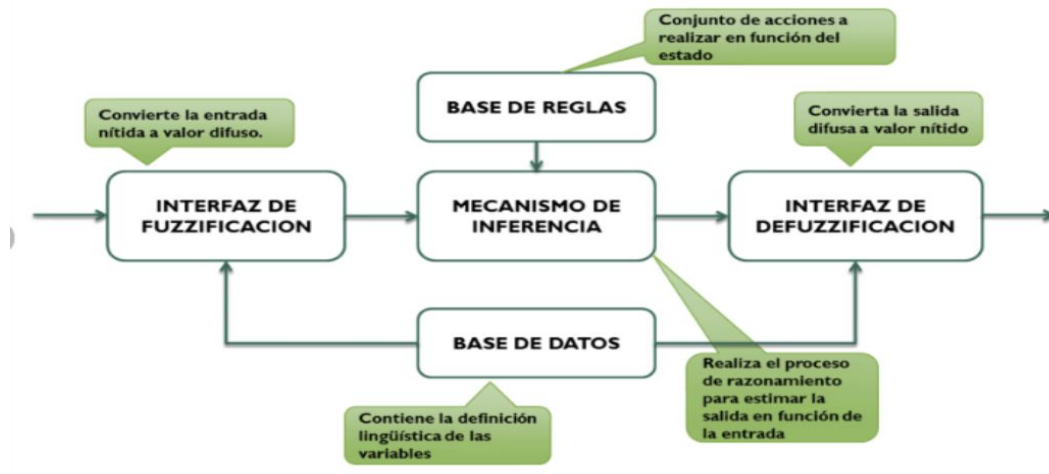
La aplicación de la lógica difusa en inventarios industriales está marcada por múltiples factores inciertos los cuales son los siguientes:

- Variabilidad en la demanda: cambios en el consumo de repuestos debido a ciclos de operación, estacionalidad, obsolescencia tecnológica o fallas imprevistas.
- Tiempos de entrega fluctuantes y costos cambiantes. La lógica difusa permite incorporar incertidumbre y flexibilidad en el proceso de toma de decisiones. En este contexto, la lógica difusa se utiliza para:
- Clasificación de niveles de inventario definiendo categorías lingüísticas (bajo, medio, alto) basadas en funciones de pertenencia para garantizar la toma de decisiones flexibles de reposición

El sistema de lógica difusa se estructura en tres etapas principales representadas de manera horizontal como se muestra en la figura 2.

Figura 2.

Estructura de un sistema difuso



Nota: Proceso de inferencia difusa y su interacción con datos de entrada y salida. Tomado de:

<https://dialnet.unirioja.es/download/articulo/5676771.pdf>

La lógica difusa permite interpretar datos inciertos y transformarlos en decisiones prácticas, mientras que Big Data garantiza la variedad y volumen de información histórica para alimentar el sistema. En Python, esta integración se logra mediante librerías como, (scikit-fuzzy) para definir funciones de pertenencia, (Pandas y Numpy) para procesar los históricos de inventario y demanda. La lógica difusa plantea ventajas como Manejo de incertidumbre, flexibilidad de aplicación, razonamiento crítico y robustez predictiva frente a los modelos deterministas. A demás se propone como un sistema flexible, escalable y económico que no solo predice necesidades de inventario, sino que también automatiza la toma de decisiones, mejorando la disponibilidad de repuestos, reduciendo costos y asegurando la continuidad operativa de los equipos mecánicos.

2.2.6 KPIs en la Gestión de Inventarios

Los indicadores clave de desempeño (KPIs) son fundamentales en la gestión eficaz de inventarios, ya que permiten cuantificar el rendimiento del sistema logístico y evaluar la la

eficiencia operativa de las decisiones. Su valor reside en ofrecer retroalimentación objetiva y medible, lo cual es esencial para ajustar estrategias, garantizar disponibilidad de recursos y reducir costos asociados.

En el ámbito industrial, algunos KPIs particularmente relevantes son: el nivel de servicio, la rotación de inventario, el costo de mantener inventario, Stockout (faltantes) y la disponibilidad de inventarios, (Graves y Willems, 2023; Sani y Kingsman, 1997).

2.3 Proceso de implementación del sistema inteligente de gestión de inventarios

2.3.1 Definición del alcance y diagnóstico del sistema de inventarios

Se inicia el proceso con la delimitación del alcance del sistema a implementar, definiendo el tipo de inventario, el horizonte temporal de análisis y los objetivos operativos del sistema. Posteriormente, se realiza un diagnóstico del estado actual del inventario, identificando los procesos de abastecimiento, almacenamiento y reposición, así como las variables disponibles y la calidad de los datos históricos.

Resultado: alcance definido, procesos caracterizados y base de datos inicial validada.

2.3.2 Recolección, depuración y estructuración de datos

Se recopila la información histórica relacionada con demanda, niveles de stock, costos, rotación, disponibilidad y tiempos de reposición. Los datos son depurados para eliminar inconsistencias, valores atípicos o registros incompletos, y posteriormente se estructuran en un formato adecuado para su procesamiento computacional.

Resultado: Base de datos limpia, consistente y estructurada.

2.3.3 Análisis exploratorio del comportamiento del inventario

Se realiza un análisis estadístico descriptivo de las variables del inventario con el fin de identificar patrones de comportamiento, tendencias, estacionalidad y niveles de variabilidad. Este

análisis permite comprender la dinámica del sistema y sirve como insumo para la selección del modelo de predicción y el diseño del sistema difuso.

Resultado: Caracterización estadística del inventario y de la demanda.

2.3.4 Modelado y predicción de la demanda

Con base en el análisis previo, se selecciona e implementa un modelo de predicción de demanda utilizando técnicas de análisis de series de tiempo u otros métodos estadísticos. El modelo es entrenado y validado con datos históricos, y se generan proyecciones de demanda que alimentan el sistema de toma de decisiones.

Resultado: Modelo de predicción validado y proyecciones de demanda generadas.

2.3.5 Definición de variables lingüísticas y funciones de pertenencia

Se definen las variables de entrada y salida del sistema difuso, estableciendo sus respectivos términos lingüísticos (por ejemplo, bajo, medio y alto). Posteriormente, se diseñan las funciones de pertenencia que permiten representar de manera gradual el comportamiento de cada variable, incorporando la incertidumbre inherente al sistema de inventarios.

Resultado: Variables difusas y funciones de pertenencia definidas.

2.3.6 Construcción de la base de reglas difusas

Se establece la base de reglas que gobierna el sistema de inferencia difusa, integrando criterios técnicos y conocimiento experto. Estas reglas permiten relacionar las variables de entrada con las decisiones de gestión del inventario, asegurando coherencia entre el desempeño operativo y los objetivos económicos.

Resultado: Base de reglas difusas estructurada y validada.

2.3.7 Integración del modelo de predicción con el sistema difuso

Se integran las salidas del modelo de predicción de demanda con el sistema de inferencia difusa, conformando un sistema inteligente unificado. Esta integración permite evaluar de forma simultánea el comportamiento futuro de la demanda y el estado actual del inventario para generar recomendaciones de reabastecimiento.

Resultado: Sistema inteligente integrado y funcional.

2.3.8 Implementación computacional del sistema

El sistema integrado se implementa en un entorno computacional, como Python, garantizando la automatización del procesamiento de datos, la ejecución del sistema difuso y la generación de resultados. Se verifica el correcto funcionamiento del sistema mediante pruebas funcionales.

Resultado: Sistema computacional operativo.

2.3.9 Evaluación del desempeño mediante indicadores clave

Se evalúa el desempeño del sistema utilizando indicadores clave de desempeño, tales como rotación de inventario, nivel de servicio, costos y disponibilidad. Los resultados obtenidos se comparan con los generados por métodos tradicionales de gestión de inventarios para validar la efectividad del sistema propuesto.

2.3.10 Implementación operativa y mejora continua

Finalmente, se definen lineamientos para la implementación operativa del sistema dentro de la organización, incluyendo la capacitación del personal, el establecimiento de rutinas de seguimiento y la actualización periódica de los parámetros del modelo. Este enfoque garantiza la adaptación continua del sistema a cambios en la operación y en el entorno.

3. Metodología

El desarrollo del presente trabajo de grado se estructura en fases claramente definidas, permitiendo una ejecución eficiente dentro del período establecido de 32 semanas. A continuación, se detallan las actividades clave de cada fase.

3.1 Fase 1: Análisis y levantamiento de información

La primera fase de la metodología se orienta a comprender el problema de gestión de inventarios desde un enfoque teórico, contextual y operativo, así como a estructurar la información necesaria para el desarrollo del sistema inteligente. Esta fase constituye la base conceptual y técnica sobre la cual se construyen las etapas posteriores de modelado, optimización y simulación.

3.1.1 Revisión bibliográfica

Se realizó una revisión bibliográfica sistemática sobre gestión de inventarios, modelos de predicción de demanda, análisis ABC, indicadores de desempeño (KPIs) y aplicaciones de lógica difusa en sistemas de apoyo a la decisión. Se consultaron libros especializados, artículos científicos y casos de éxito industriales, con el fin de identificar variables comúnmente utilizadas, metodologías de priorización y enfoques híbridos que integren análisis cuantitativo con reglas expertas. Esta revisión permitió justificar el uso de técnicas como el análisis ABC, la lógica difusa y los modelos clásicos de inventarios (EOQ, ROP) dentro del sistema propuesto.

3.1.2 Identificación de problemas de inventario

A partir del análisis bibliográfico y de la revisión de contextos industriales similares, se identificaron los principales problemas asociados a la gestión de inventarios en el sector industrial, entre los cuales se destacan: desabastecimientos frecuentes, sobre stock, altos costos de

mantenimiento, baja rotación, dependencia de proveedores con tiempos de entrega variables y limitada capacidad de priorización de productos críticos. Este diagnóstico permitió establecer la necesidad de un sistema inteligente que integre múltiples variables y apoye la toma de decisiones de manera dinámica.

3.1.3 Recolección y organización de la información

Se realizó la recolección de información relacionada con inventarios, demanda histórica, catálogo de productos y proveedores, estructurando las bases de datos en formatos estándar (CSV y Excel). La información recolectada incluye variables de demanda, costos, niveles de inventario, tiempos de entrega, confiabilidad de proveedores y disponibilidad de productos, las cuales son necesarias para alimentar los diferentes módulos del sistema.

3.1.4 Depuración y validación de la base de datos

Se seleccionó y depuró la base de datos utilizada para el desarrollo del sistema, validando aspectos de calidad como la eliminación de duplicados, corrección de inconsistencias, tratamiento de valores faltantes y verificación de coherencia temporal y de unidades. Este proceso garantizó la obtención de un conjunto de datos confiable y consistente para la implementación del modelo inteligente.

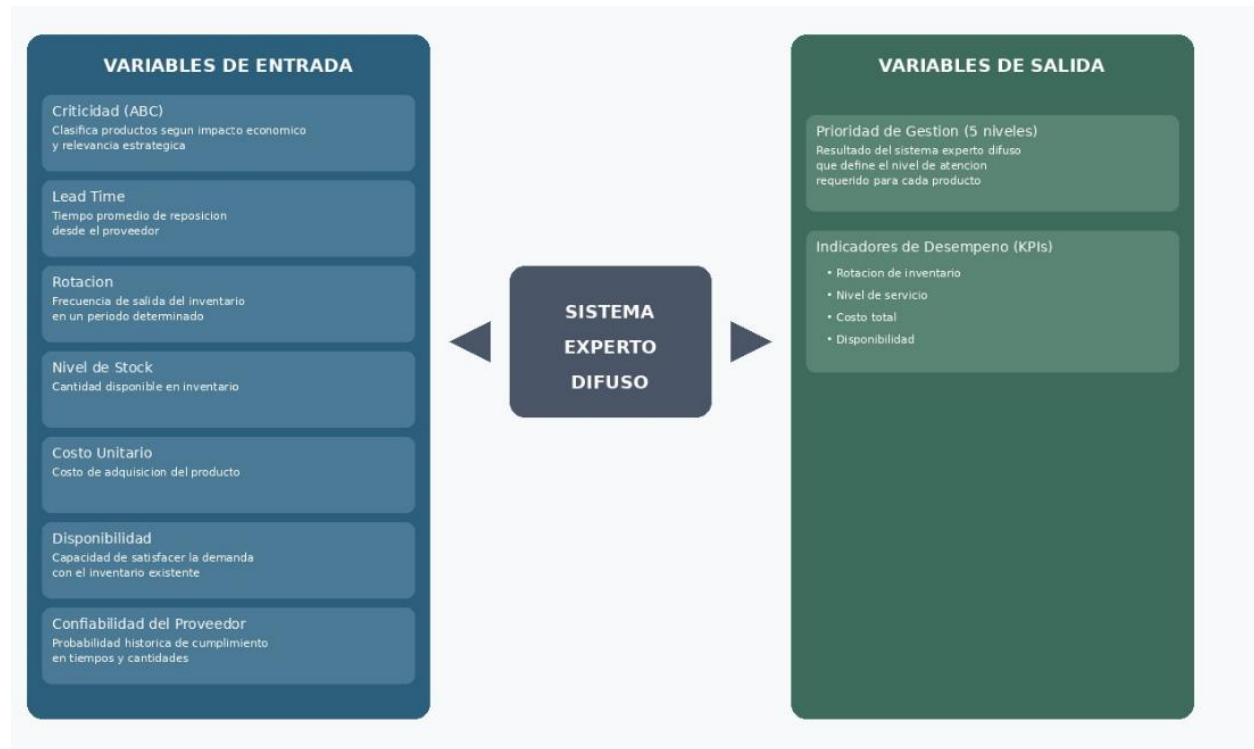
3.1.5 Definición y estructuración de variables del modelo

El modelo propuesto de gestión inteligente de inventarios se fundamenta en la interacción estructurada entre un conjunto de variables de entrada, asociadas al comportamiento operativo y logístico del inventario, y un conjunto de variables de salida, como se puede observar en la figura ,que representan los resultados del sistema en términos de priorización y desempeño. Para sustentar teóricamente dicha interacción, se desarrollan tres herramientas analíticas: (i) una matriz de

correlación entradas–salidas, (ii) un análisis del impacto global de cada variable, y (iii) la determinación del nivel de importancia relativa de las variables dentro del sistema.

Figura 3.

Variables de entrada y salida del sistema



3.1.5.1. Variables de entrada. Las variables de entrada del sistema son las siguientes:

- Criticidad (ABC): clasifica los productos según su impacto económico y relevancia estratégica.
- Lead time: tiempo promedio de reposición desde el proveedor.
- Rotación: frecuencia de salida del inventario en un período determinado.
- Nivel de stock: cantidad disponible en inventario.
- Costo unitario: costo de adquisición del producto.
- Disponibilidad: capacidad de satisfacer la demanda con el inventario existente.

- Confiabilidad del proveedor: probabilidad histórica de cumplimiento en tiempos y cantidades.

3.1.5.2. Variables de salida. Las variables de salida del sistema son las siguientes:

- Prioridad de gestión (5 niveles): resultado del sistema experto difuso que define el nivel de atención requerido para cada producto.
- Indicadores de desempeño (KPIs): rotación de inventario, nivel de servicio, costo total y disponibilidad.

3.1.6 Análisis de relaciones entre variables

3.1.6.1 Matriz de correlación entradas–salidas. Se construyó una matriz de correlación tipo QFD adaptada, como se puede observar en la figura 3, en la cual se evalúa el grado de influencia de cada variable de entrada sobre las variables de salida del sistema. A diferencia del QFD clásico orientado a la “voz del cliente”, esta adaptación se centra en la voz del sistema, es decir, en cómo las variables operativas impactan los resultados de la gestión de inventarios. Se empleó una escala discreta de impacto:

- 9: Impacto alto
- 3: Impacto medio
- 1: Impacto bajo
- 0: Sin impacto

Figura 4.

Matriz de correlación entre entradas y salidas

| Variable de entrada | Prioridad | Rotación | Servicio | Costo | Disponibilidad | Impacto total | Perfil de Impacto Dominante | Rol funcional en el sistema | Índice de Impacto Global (IIG) |
|-------------------------|-----------|----------|----------|-------|----------------|---------------|-----------------------------|---------------------------------------|--------------------------------|
| Criticidad (ABC) | 9 | 3 | 3 | 9 | 3 | 27 | Prioridad – Costo | Variable estratégica de clasificación | 0.86 |
| Lead time | 9 | 3 | 9 | 3 | 9 | 27 | Servicio – Disponibilidad | Variable de riesgo logístico | 0.83 |
| Rotación | 3 | 9 | 3 | 3 | 3 | 21 | Rotación | Variable de desempeño | 0.62 |
| Nivel de stock | 9 | 9 | 9 | 3 | 9 | 39 | Integral (todas) | Variable de control operativo | 0.92 |
| Costo unitario | 3 | 1 | 1 | 9 | 1 | 15 | Costo | Variable económica | 0.48 |
| Disponibilidad | 9 | 3 | 9 | 3 | 9 | 33 | Servicio – Disponibilidad | Variable de continuidad operativa | 0.88 |
| Confiabilidad proveedor | 9 | 3 | 9 | 3 | 9 | 33 | Servicio – Disponibilidad | Variable estratégica externa | 0.90 |

En la figura 4, se presenta la matriz de correlación entradas y salidas extendida, en la cual se integran las relaciones de impacto entre las variables operativas del inventario y los resultados del sistema, así como métricas derivadas que permiten su interpretación funcional y decisional. El impacto total refleja la influencia acumulada de cada variable de entrada sobre las variables de salida, permitiendo una jerarquización estructural inicial.

Sin embargo, el Índice de Impacto Global (IIG) incorpora las ponderaciones estratégicas del sistema, priorizando dimensiones como el nivel de servicio y la disponibilidad, lo que explica diferencias entre ambas métricas. En este sentido, variables como el nivel de stock, la confiabilidad del proveedor y la disponibilidad presentan los valores más altos de IIG, evidenciando su carácter crítico dentro del funcionamiento global del sistema.

Adicionalmente, el perfil de impacto dominante y el rol funcional asignado a cada variable facilitan la interpretación del modelo, permitiendo distinguir variables estratégicas, de control operativo, de riesgo logístico y económicas, lo que resulta fundamental para la formulación de reglas difusas y la priorización de decisiones dentro del sistema inteligente de gestión de

inventarios. Finalmente, este análisis permite establecer las siguientes funciones dentro del modelo:

- La matriz de correlación identifica las relaciones causa–efecto entre variables operativas y resultados del sistema.
- El impacto total mide la influencia acumulada de cada variable de entrada.
- El Índice de Impacto Global (IIG) integra dichas influencias con los objetivos estratégicos y prioriza la toma de decisiones.
- El nivel de importancia permite activar reglas difusas y asignar ponderaciones diferenciadas.
- El perfil de impacto dominante y el rol funcional orientan el tipo de acción requerida (operativa, estratégica, económica o de control).

3.1.6.2 Interpretación de las salidas experimentales

- Índice de Impacto Global (IIG). Representa la influencia sistémica total de cada variable sobre los resultados del modelo, integrando todas las salidas relevantes. Valores cercanos a 1 indican variables críticas para la toma de decisiones.
- Normalización de los valores: Con el fin de evitar sesgos por la magnitud de la escala, los valores de la matriz se normalizan dividiendo cada relación entre el valor máximo (9).
- De esta forma, todas las relaciones quedan expresadas en un rango común entre 0 y 1, lo que permite su comparación directa.
- Ponderación de las variables de salida: Cada variable de salida (prioridad, nivel de servicio, disponibilidad, rotación y costo) se pondera según su importancia estratégica dentro del

sistema, asegurando que la suma de los pesos sea igual a 1. Estas ponderaciones reflejan los objetivos operativos del modelo de inventarios.

- Cálculo del IIG: Finalmente, el IIG de cada variable de entrada se obtiene como la suma de las relaciones normalizadas multiplicadas por el peso correspondiente de cada variable de salida como se observa en la ecuación 1.

Ecuación 1

$$IIG = \sum_{j=1}^n \left(\frac{R_{ij}}{R_{max}} \times w_j \right)$$

Donde:

R_{ij} : relación entrada–salida (1, 3 o 9)

$$R_{max} = 9$$

w_j : peso de la variable de salida j

$$IIG_{LeadTime} = (1 \times 0.3) + (0.33 \times 0.15) + (1 \times 0.25) + (0.33 \times 0.1) + (1 \times 0.2)$$

$$IIG_{LeadTime} = 0.83$$

Este valor representa el impacto global y relativo de cada variable dentro del sistema, permitiendo su clasificación en variables críticas, relevantes o secundarias.

3.1.7 Interpretación de resultados del análisis estructural

3.1.7.1 Perfil de Impacto Dominante. Describe en qué dimensiones del sistema se manifiesta principalmente la influencia de cada variable, permitiendo ajustar reglas difusas, priorizar KPIs, y segmentar decisiones (operativas vs estratégicas).

3.2.7.2 Rol funcional. Clasificación cualitativa que facilita la interpretación gerencial del modelo:

- Estratégicas: afectan múltiples KPIs y el nivel de servicio
- De control: regulan el comportamiento diario del inventario

- De riesgo: introducen incertidumbre y variabilidad
- Económicas: impactan costos más que desempeño operativo

3.2.7.3 Niveles de importancia. Estos son usados para: Definir ponderaciones en el motor difuso, activar reglas prioritarias y enfocar esfuerzos de gestión.

La tabla 1, presenta la jerarquización de las variables de entrada del modelo de gestión de inventarios a partir del Impacto Total y su Impacto Normalizado, el cual expresa la contribución relativa de cada variable sobre el funcionamiento global del sistema. Con base en estos valores, se establecen niveles de importancia cualitativos que facilitan la toma de decisiones y la priorización operativa.

Tabla 1.

Jerarquización de las variables de entrada del modelo

| Variable de entrada | Impacto total | Impacto normalizado (%) | Nivel de importancia |
|-----------------------------|----------------------|--------------------------------|-----------------------------|
| Nivel de stock | 39 | 20,00% | Muy alta |
| Lead time | 27 | 13,80% | Alta |
| Disponibilidad | 33 | 17,00% | Muy alta |
| Confiabilidad del proveedor | 33 | 17,00% | Muy alta |
| Criticidad (ABC) | 27 | 13,80% | Alta |
| Rotación | 21 | 10,80% | Media |
| Costo unitario | 15 | 7,60% | Baja |
| Total | 195 | 100% | |

Con base en estos valores, se establecen niveles de importancia cualitativos que facilitan la toma de decisiones y la priorización operativa.

3.1.8 Relación directa con la lógica difusa

Esta matriz extendida permite formular reglas del tipo: IF Lead time es alto AND confiabilidad del proveedor es baja THEN prioridad es crítica AND aumentar stock de seguridad. Es decir, la matriz no es descriptiva, sino operativa dentro del sistema inteligente.

La matriz de correlación extendida transforma relaciones estáticas en información estructurada para la toma de decisiones, constituyéndose en un elemento central del sistema inteligente de gestión de inventarios, al integrar impacto, importancia y rol funcional de las variables.

3.2 Fase 2. Diseño del modelo difuso de predicción

3.2.1 Enfoque general del modelo difuso

El modelo difuso propuesto tiene como propósito apoyar la toma de decisiones en la gestión de inventarios mediante la integración de múltiples variables técnicas, económicas y operativas que presentan incertidumbre, imprecisión y comportamiento no lineal. Dentro del sistema inteligente, el modelo difuso cumple un doble rol:

- Prioriza de manera inteligente ítems de inventario, asignando niveles de gestión según su impacto global.
- Da soporte a la predicción y prevención de riesgos, como quiebres de stock, sobre inventario y aumento de costos.

Este modelo se construye a partir de los resultados obtenidos en la Fase 1, donde se identificaron:

- Variables críticas del inventario
- Clasificación ABC
- Indicadores de desempeño (KPIs)
- Patrones históricos de comportamiento

De esta manera, el modelo difuso actúa como un puente entre el análisis cuantitativo tradicional y un sistema de decisión inteligente, permitiendo incorporar conocimiento experto y criterios cualitativos que no pueden ser modelados adecuadamente con métodos determinísticos.

3.2.2 Definición de la estructura del sistema difuso

El sistema difuso se diseña como un sistema de inferencia multivariable, capaz de procesar simultáneamente factores logísticos, económicos y operativos, generando salidas interpretables y accionables.

3.2.2.1 Selección de variables de entrada del sistema difuso. Las variables de entrada fueron seleccionadas con base en:

- Relevancia técnica en la gestión del inventario
- Resultados del análisis de criticidad (Fase 1)
- Literatura especializada en sistemas inteligentes aplicados a logística

Las variables de entrada del sistema difuso son las siguientes:

- Criticidad (ABC): Representa la importancia estratégica del ítem según su impacto económico y operativo.
- Lead time: Tiempo de reposición del producto. Introduce incertidumbre logística y riesgo de desabastecimiento.

- Rotación: Mide la frecuencia de consumo del inventario y su dinamismo.
- Nivel de stock: Representa la disponibilidad actual respecto a la demanda esperada.
- Costo unitario: Introduce el impacto financiero del inventario.
- Disponibilidad: Relación entre demanda atendida y demanda total.
- Confiabilidad del proveedor : Indicador cualitativo–cuantitativo que refleja la estabilidad del suministro.

Estas variables permiten capturar tanto el comportamiento histórico como las condiciones operativas actuales.

3.2.2.2 Definición de variables de salida. Las variables de salida se definieron según la prioridad de gestión, definida en cinco niveles: Crítica, Alta, Media, Baja y Muy baja. Esta salida sintetiza el estado del inventario y facilita la toma de decisiones gerenciales. utilizando KPIs derivados, estos son los siguientes:

- Nivel de servicio
- Rotación ajustada
- Costo total asociado
- Disponibilidad efectiva

Estos indicadores permiten validar y monitorear el desempeño del sistema inteligente.


3.2.3 Definición de funciones de pertenencia

3.2.3.1. Tipos seleccionados. El modelo inteligente propuesto emplea principalmente funciones de pertenencia triangulares y trapezoidales dentro del sistema de inferencia difusa, como se muestra en la figura 5, debido a que estas permiten representar de forma clara y eficiente los estados operativos del inventario. Dichas funciones se aplican a variables como criticidad, nivel

de stock, disponibilidad, costo unitario y prioridad de gestión, las cuales presentan rangos bien definidos y umbrales operativos establecidos.

Figura 5.

Funciones de pertenencia



De manera complementaria, se consideran funciones gaussianas en la etapa de predicción y procesamiento de datos, especialmente para variables con alta variabilidad temporal como la rotación y el lead time. Estas funciones no forman parte directa de la base de reglas difusas, sino que se emplean como mecanismos de suavizado y regularización de las series históricas que alimentan el sistema.

Las funciones triangulares y trapezoidales fueron seleccionadas como base del sistema difuso por su simplicidad computacional, facilidad de implementación y alta interpretabilidad, características fundamentales para un sistema de apoyo a la decisión en inventarios. Su estructura permite definir con claridad los límites entre estados como bajo, medio y alto, así como representar zonas de tolerancia operativa sin introducir complejidad innecesaria en el proceso de inferencia.

Por su parte, las funciones gaussianas se incorporan únicamente cuando resulta imprescindible modelar el comportamiento continuo e incierto de variables derivadas de series temporales. Su utilización en la etapa de predicción permite reducir el impacto del ruido, valores

atípicos y fluctuaciones abruptas, mejorando la estabilidad de las estimaciones que posteriormente alimentan el sistema difuso. Esta separación de roles garantiza que el modelo mantenga un equilibrio entre robustez matemática y claridad interpretativa, evitando que la complejidad del modelo afecte la transparencia de las decisiones generadas.

3.2.3.2 Rango y normalización de las variables. En el sistema propuesto, todas las variables de entrada y salida del modelo difuso se normalizan en un rango $[0,1]$, utilizando técnicas de normalización min-max implementadas en la etapa de preprocesamiento. La aplicación concreta en el sistema es en los valores originales (días, costos, unidades, porcentajes) se transforman a un dominio común. Esto permite que variables heterogéneas interactúen correctamente dentro del motor difuso.

Además la normalización de las variables en un rango común permite garantizar la comparabilidad entre indicadores que originalmente presentan diferentes escalas y unidades de medida, facilitando su interacción dentro del sistema difuso. Adicionalmente, este proceso aporta robustez al modelo frente a variaciones y cambios en los datos de entrada, reduciendo la sensibilidad a valores atípicos y mejorando la estabilidad numérica del sistema. Finalmente, la utilización de variables normalizadas asegura una compatibilidad directa con los modelos de predicción de demanda basados en series de tiempo, permitiendo una integración eficiente entre los enfoques cuantitativos y la lógica difusa del sistema inteligente.

3.2.4 Selección de algoritmos y métodos de análisis

3.2.4.1 Preprocesamiento estadístico de las variables. El preprocesamiento estadístico constituye una etapa fundamental dentro del modelo inteligente de gestión de inventarios, ya que garantiza que la información que alimenta el sistema difuso sea consistente, comparable y representativa del comportamiento real del inventario. Dado que las variables provienen de fuentes

heterogéneas y presentan diferentes escalas, niveles de variabilidad y ruido, resulta necesario aplicar técnicas estadísticas previas a la inferencia difusa, como las siguientes

- Normalización min–max: transforma cada variable original a un rango común 01, preservando la forma relativa de los datos. Esta técnica se aplica mediante la relación entre el valor observado y los valores mínimo y máximo históricos de cada variable. Desde el punto de vista del sistema difuso, la normalización es imprescindible porque: evita que variables con magnitudes mayores dominen el proceso de inferencia, permite que todas las funciones de pertenencia operen sobre un dominio uniforme, facilita la combinación coherente de variables económicas, logísticas y operativas y en el contexto del inventario, esta técnica permite integrar sin distorsión variables como costos, tiempos de reposición y niveles de stock dentro de un mismo motor de decisión.
- Suavizado de series temporales: Las variables del inventario, como la demanda, la rotación o el lead time, suelen presentar fluctuaciones abruptas, ruido estadístico y valores atípicos asociados a eventos operativos no recurrentes. El suavizado de series temporales permite atenuar estas variaciones, resaltando la tendencia subyacente de los datos, este proceso: reduce la sensibilidad del sistema a cambios puntuales no representativos, evita decisiones erráticas en la priorización del inventario y proporciona señales más estables para alimentar tanto los modelos predictivos como el sistema difuso. El suavizado es especialmente relevante cuando las salidas del modelo de predicción alimentan directamente las variables de entrada del sistema difuso.
- Cálculo de métricas auxiliares: El preprocesamiento no se limita a transformar los datos originales, sino que también genera métricas auxiliares que enriquecen la interpretación del comportamiento del inventario.

- **Coefficiente de variación (CV):** El coeficiente de variación relaciona la desviación estándar con el valor promedio de una variable, permitiendo cuantificar su nivel de incertidumbre relativa. En inventarios, un CV elevado indica alta variabilidad en la demanda o el consumo, lo que incrementa el riesgo de quiebre o sobre stock, esta métrica permite al sistema difuso: Identificar ítems con comportamiento inestable y ajustar la prioridad de gestión en función del riesgo
- **Rotación promedio:** La rotación promedio sintetiza la frecuencia de consumo de un producto en un período determinado. Su cálculo suavizado permite: representar el comportamiento típico del inventario, evitar decisiones basadas en picos aislados de consumo y diferenciar ítems estratégicos de ítems de baja dinámica
- **Promedios móviles:** Los promedios móviles permiten capturar la evolución temporal de las variables, amortiguando fluctuaciones de corto plazo. Su aplicación facilita la detección de tendencias crecientes o decrecientes, mejora la calidad de las predicciones de demanda y proporciona entradas más estables al sistema difuso

3.2.4.2 Impacto del preprocesamiento en la inferencia difusa. La combinación de normalización, suavizado y métricas auxiliares produce datos más estables, menos ruidosos y representativos del comportamiento real del inventario. Como resultado, el sistema difuso genera reglas más coherentes, reduce la ambigüedad en la activación de funciones de pertenencia y mejora la calidad y consistencia de las decisiones de priorización

El preprocesamiento estadístico actúa como un filtro inteligente previo a la inferencia difusa, asegurando que las decisiones generadas no respondan a fluctuaciones aleatorias, sino a patrones estructurales del sistema de inventarios. Esta etapa es esencial para garantizar la robustez, estabilidad y confiabilidad del modelo inteligente propuesto.

3.2.4.3 Integración con modelos de predicción de demanda. El sistema de gestión de inventarios adopta un enfoque híbrido que combina modelos cuantitativos de predicción de demanda con un sistema de inferencia difusa, con el objetivo de aprovechar las fortalezas de ambos enfoques y mitigar sus limitaciones individuales.

En la etapa cuantitativa se emplean modelos de series de tiempo, tales como promedios móviles, suavizado exponencial y modelos ARIMA, los cuales permiten estimar la demanda futura a partir del comportamiento histórico de los datos. Estos modelos generan predicciones numéricas que representan la evolución esperada del consumo y sirven como insumo fundamental para la toma de decisiones.

Las predicciones obtenidas alimentan directamente variables clave del sistema difuso, como el nivel de stock esperado, la probabilidad de quiebre y la presión de reposición, permitiendo que el motor difuso incorpore información prospectiva y no únicamente datos históricos. De esta manera, el sistema no se limita a reaccionar ante el estado actual del inventario, sino que anticipa escenarios futuros.

Los modelos cuantitativos de predicción aportan precisión numérica y rigor estadístico, permitiendo estimaciones objetivas de la demanda futura. Sin embargo, estos modelos presentan limitaciones al momento de incorporar criterios cualitativos, incertidumbre operativa y conocimiento experto.

La lógica difusa complementa este enfoque al permitir interpretar la incertidumbre, manejar información imprecisa y traducir criterios gerenciales en reglas de decisión, facilitando una evaluación más integral del estado del inventario. La combinación de ambos enfoques mejora la robustez, adaptabilidad y confiabilidad del sistema inteligente, especialmente en entornos con alta variabilidad y condiciones cambiantes.

3.2.5 Arquitectura conceptual del modelo inteligente

3.2.5.1 Arquitectura general del sistema. El modelo inteligente se estructura mediante una arquitectura modular de cinco capas, como se observa en la figura 6, diseñada para garantizar claridad funcional, escalabilidad y facilidad de integración:

- Entrada de datos, recopila datos históricos de inventario, demanda, proveedores y costos.
- Procesamiento y depuración, se realiza limpieza, validación, normalización y preprocesamiento estadístico de las variables.
- Análisis y predicción, se aplica modelos analíticos tradicionales y de series de tiempo para estimar la demanda futura y variables derivadas.
- Inferencia difusa, evalúa las variables procesadas mediante el sistema de reglas difusas y genera prioridades de gestión.
- Generación de salidas y KPI, produce indicadores de desempeño, alertas y recomendaciones operativas para la toma de decisiones.

Esta estructura permite una separación clara de responsabilidades y facilita la evolución del sistema.

Figura 6.

Arquitectura Modular del sistema



3.2.5.2 Interacción entre módulos del sistema

Los módulos del sistema interactúan de manera secuencial e integrada. Inicialmente se realiza la ingesta y limpieza de datos, asegurando la calidad de la información. Posteriormente, se ejecuta el análisis ABC, que determina la criticidad de los ítems y orienta el enfoque de gestión.

A continuación, el módulo de predicción de demanda genera estimaciones futuras que alimentan el motor de inferencia difusa, el cual integra la información cuantitativa con reglas basadas en conocimiento experto. Finalmente, el módulo de optimización de decisiones traduce los resultados en acciones concretas, que se reflejan en la generación de reportes y KPIs.

Esta modularidad facilita la escalabilidad del sistema y permite la incorporación futura de nuevos modelos o fuentes de datos sin alterar la arquitectura general.

3.2.6 Diseño del proceso de inferencia difusa

3.2.6.1 Base de reglas difusas. La base de reglas del sistema se construye utilizando estructuras IF-THEN, en la tabla 2 se dan a conocer algunas de las reglas utilizadas, las cuales

permiten representar de forma explícita el razonamiento humano aplicado a la gestión de inventarios. Estas reglas se derivan de:

- El análisis de la matriz de correlación entre variables
- El conocimiento experto en logística y gestión de inventarios
- Los resultados obtenidos en la Fase 1 del proyecto

Las reglas establecen relaciones lógicas entre las variables de entrada y la prioridad de gestión, permitiendo evaluar múltiples condiciones de manera simultánea. Este tipo de reglas permite capturar escenarios de alto riesgo y asignar prioridades acordes a su impacto operativo y económico.

Tabla 2.

Reglas difusas

| Prioridad | Condiciones (SI ...) | Resultado (ENTONCES ...) |
|------------------|---|--|
| Crítica | Criticidad muy alta Y rotación muy alta Y nivel de stock muy bajo | Ejecutar acción inmediata y reabastecimiento urgente |
| Alta | Criticidad Y rotación altas Y nivel de stock bajo | Planificar el pedido en el corto plazo |
| Media | Criticidad Y rotación medias Y nivel de stock medio | Realizar monitoreo regular |
| Baja | Criticidad Y rotación bajas Y nivel de stock alto | Revisión ocasional del ítem |
| Mínima | Criticidad muy baja Y rotación muy baja Y nivel de stock muy alto | No se requiere acción |

3.2.6.2 Método de inferencia y defuzzificación. El sistema emplea el método de inferencia Mamdani, ampliamente utilizado en aplicaciones industriales debido a su alta interpretabilidad y facilidad de implementación. Este método permite evaluar el grado de activación de cada regla y combinar sus resultados de manera coherente.

Para la conversión de los resultados difusos a valores concretos, se utiliza el método de defuzzificación por centroide, el cual calcula el centro de masa del conjunto de salida. Este método proporciona salidas suaves, estables y continuas, evitando cambios abruptos en las decisiones del sistema.

La combinación de inferencia Mamdani y defuzzificación por centroide garantiza un equilibrio adecuado entre precisión y claridad en los resultados.

3.2.7 Diagramas de flujo y recorrido de los datos

3.2.7.1 Diagrama de flujo del procesamiento de datos. El flujo del sistema inicia con la ingesta de datos históricos, continúa con el preprocesamiento y análisis estadístico, y culmina con la generación de decisiones de gestión. Este recorrido representado en las figuras 7 y 8, se permite visualizar claramente cómo los datos se transforman progresivamente hasta convertirse en información útil para la toma de decisiones.

Figura 7.

Diagrama de flujo del procesamiento de datos parte 1

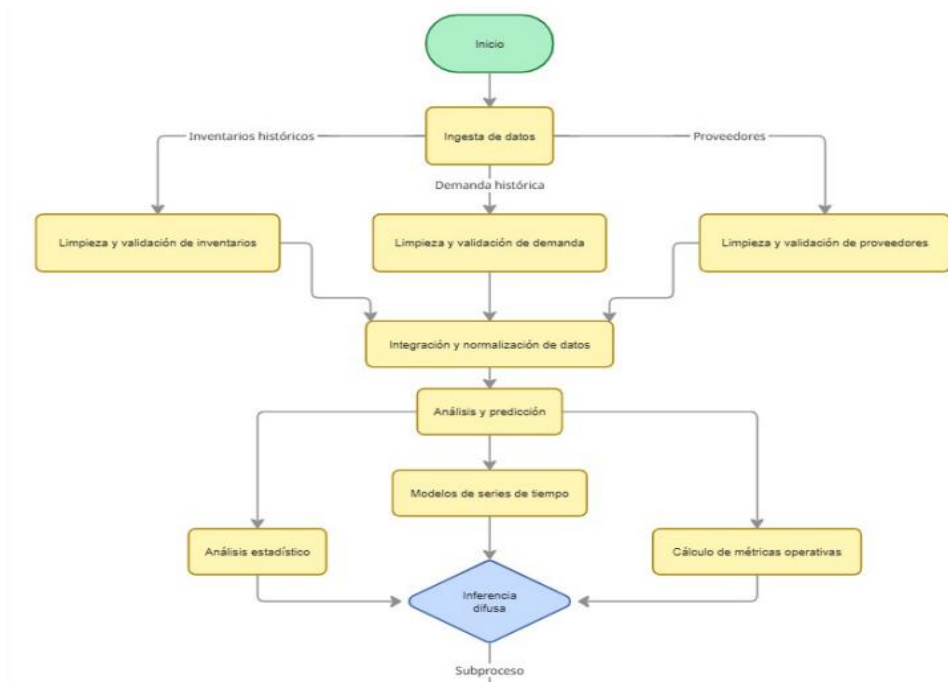
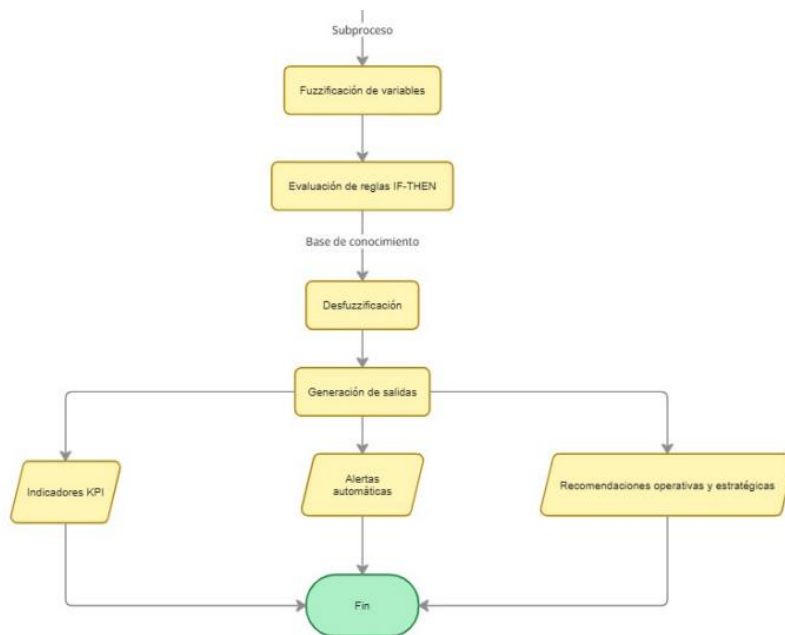


Figura 8.

Diagrama de flujo del procesamiento de datos parte 2



3.2.7.2 Flujo del proceso de predicción y priorización. En el flujo de predicción y priorización, los modelos de demanda generan estimaciones que alimentan el sistema difuso. A partir de estas entradas, el motor de inferencia evalúa las reglas establecidas y genera prioridades de gestión y recomendaciones operativas, cerrando el ciclo de análisis predictivo y decisión inteligente.

3.2.8 Validación conceptual del modelo

La validación conceptual del modelo se fundamenta en la evaluación de la coherencia lógica de las reglas difusas, la consistencia entre las variables de entrada y las salidas generadas, y la correspondencia con los KPIs definidos en el sistema. Este proceso asegura que el modelo no solo sea matemáticamente consistente, sino también técnicamente sólido y aplicable en entornos reales de gestión de inventarios, proporcionando decisiones alineadas con los objetivos operativos y estratégicos de la organización.

3.3 Fase 3. Implementación del modelo inteligente en Python

La implementación del modelo inteligente se realiza en el lenguaje de programación Python, seleccionado por su amplio ecosistema de librerías científicas y su capacidad para integrar análisis estadístico, predicción de demanda y lógica difusa dentro de un mismo entorno computacional. En esta etapa se configura un entorno de desarrollo controlado que garantiza estabilidad, reproducibilidad y facilidad de pruebas.

3.3.1 Entorno de desarrollo y estructura del proyecto

Para asegurar una implementación ordenada y escalable, se define una estructura modular del proyecto que separa los componentes funcionales del sistema. Esta organización facilita el mantenimiento del código y la integración futura de nuevos módulos, el entorno de desarrollo incluye:

- Creación de un entorno virtual para el manejo de dependencias
- Control de versiones de librerías
- Definición de módulos independientes para datos, análisis, predicción e inferencia difusa
- Configuración de un entorno de pruebas para validación incremental

3.3.2 Librerías y herramientas empleadas

La implementación del sistema se apoya en un conjunto de librerías especializadas, seleccionadas según la función que cumplen dentro del modelo:

- NumPy y SciPy, para cálculo numérico y soporte estadístico
- Pandas, para ingesta, limpieza y transformación de datos
- Scikit-learn, para normalización y métricas estadísticas
- Statsmodels, para la implementación de modelos de series de tiempo
- Scikit-fuzzy, para la construcción del sistema de inferencia difusa
- Matplotlib y Seaborn, para visualización de datos y funciones de pertenencia

Estas herramientas permiten implementar de forma eficiente cada una de las etapas definidas en la metodología.

3.3.3 Implementación del módulo de ingreso y procesamiento de datos históricos

El módulo de ingreso y procesamiento de datos constituye la base informacional del sistema inteligente. En esta etapa se desarrollan los procedimientos encargados de importar, validar y preparar los datos históricos del inventario, asegurando su calidad antes de ser utilizados por los modelos predictivos y el sistema difuso.

3.3.3.1 Ingesta, validación y limpieza de datos. Los datos son importados desde fuentes estructuradas y sometidos a procesos de validación que permiten identificar valores faltantes,

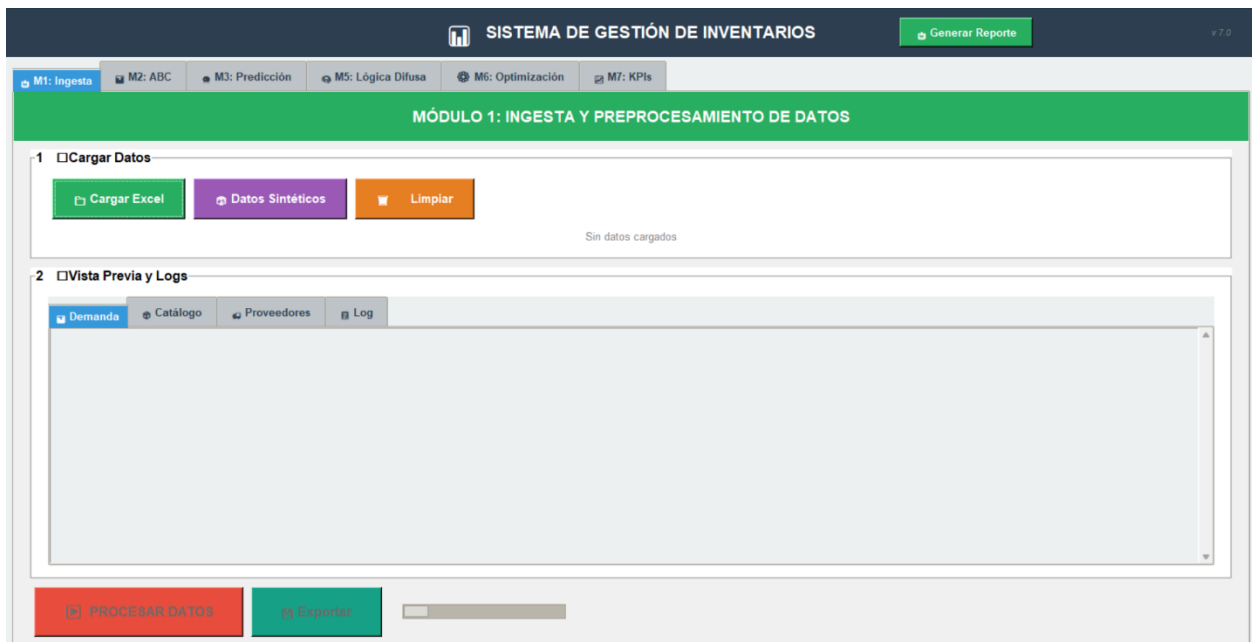
inconsistencias lógicas y registros atípicos. Esta etapa garantiza que el análisis posterior se realice sobre información confiable y representativa.

- Las tareas principales incluyen:
- Eliminación o imputación de valores nulos
- Corrección de inconsistencias en unidades o rangos
- Detección y tratamiento de valores atípicos

En la figura 9 se puede observar la presentación del módulo de ingesta, validación y limpieza de datos.

Figura 9.

Módulo de ingesta, validación y limpieza de datos



3.3.3.2 Preprocesamiento estadístico de las variables. Una vez depurados, los datos son sometidos a las técnicas de preprocesamiento definidas en la Fase 2, con el fin de mejorar su calidad analítica y su compatibilidad con el sistema difuso, el preprocesamiento incluye:

- Normalización min–max, para unificar escalas y permitir la comparabilidad entre variables.
- Suavizado de series temporales, para reducir ruido y fluctuaciones abruptas.
- Cálculo de métricas auxiliares, que enriquecen la representación del comportamiento del inventario.

3.3.3.3 Métricas auxiliares generadas. Como resultado del preprocesamiento, se calculan métricas que permiten caracterizar el comportamiento dinámico del inventario, entre las cuales se incluyen:

- Coeficiente de variación, como indicador de incertidumbre relativa
- Rotación promedio, como medida del desempeño logístico
- Promedios móviles, para capturar tendencias temporales

Estas métricas se integran posteriormente como entradas del sistema difuso o como variables de apoyo para la predicción de demanda.

3.3.4 Implementación del motor de inferencia difusa

El motor de inferencia difusa constituye el núcleo decisional del sistema inteligente. Su implementación se realiza siguiendo el diseño conceptual establecido en la Fase 2, integrando múltiples criterios de decisión y permitiendo manejar la incertidumbre inherente a la gestión de inventarios.

3.3.4.1 Definición de variables y funciones de pertenencia. En esta etapa se definen formalmente las variables de entrada y salida del sistema, así como sus respectivas funciones de pertenencia. Las variables de entrada incluyen criticidad, nivel de stock, lead time, rotación, costo unitario, disponibilidad y confiabilidad del proveedor, mientras que la variable de salida corresponde a la prioridad de gestión.

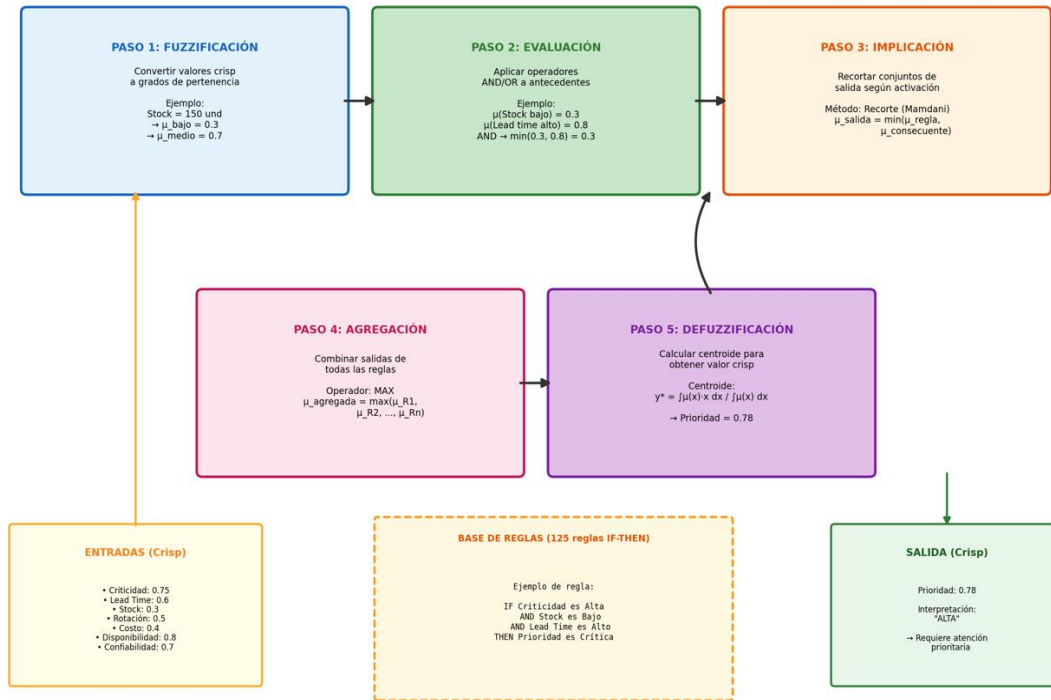
- Las funciones de pertenencia implementadas se seleccionan de acuerdo con la naturaleza de cada variable:
- Funciones triangulares, para variables con comportamiento aproximadamente lineal
- Funciones trapezoidales, para representar zonas de estabilidad o tolerancia
- Funciones gaussianas, empleadas de manera complementaria en la etapa de predicción para suavizar variables con alta variabilidad

3.3.4.2 Construcción de la base de reglas difusas. La base de reglas se construye utilizando estructuras IF-THEN que permiten representar explícitamente el razonamiento experto aplicado a la gestión de inventarios. Estas reglas se derivan del análisis de correlación entre variables, del conocimiento experto y de los resultados obtenidos en la Fase 1. Cada regla establece una relación lógica entre las condiciones del inventario y la prioridad de gestión, permitiendo evaluar escenarios complejos de manera integrada.

3.3.4.3 Proceso de inferencia y defuzzificación El proceso de inferencia se implementa utilizando el método Mamdani, debido a su alta interpretabilidad y amplia aceptación en aplicaciones industriales. Posteriormente, los resultados difusos se transforman en valores concretos mediante el método de defuzzificación por centroide, el cual proporciona salidas continuas, suaves y estables, evitando cambios abruptos en las decisiones del sistema. En la figura 10 se puede observar el proceso de inferencia del motor difuso

Figura 10.

Diagrama del proceso de inferencia y defuzzificación



3.3.5 Desarrollo del modelo de predicción de demanda y control de inventarios

El módulo de predicción de demanda se desarrolla con el objetivo de incorporar una visión prospectiva al sistema inteligente, permitiendo anticipar escenarios futuros y mejorar la toma de decisiones.

3.3.5.1 Modelos de predicción implementados. Se emplean modelos de series de tiempo adecuados a la naturaleza de los datos históricos disponibles, entre los que se incluyen:

Promedios móviles: el método de promedios móviles se introduce como un enfoque básico para la representación del comportamiento reciente de una serie temporal. Su estructura se fundamenta en el uso de una ventana de observaciones pasadas, a partir de la cual se calcula un valor promedio que actúa como referencia del nivel actual de la serie. Este modelo no incorpora

procesos de entrenamiento ni parámetros ajustables, ya que su estimación depende exclusivamente de los datos históricos más recientes.

En la implementación considerada, el promedio móvil se emplea como un mecanismo de referencia y estabilización. En particular, la media de los últimos valores observados se utiliza para representar el comportamiento típico reciente de la serie, sirviendo como punto de anclaje cuando los modelos más complejos presentan comportamientos inestables o cuando la cantidad de datos disponibles resulta insuficiente. De esta manera, el promedio móvil cumple un rol complementario, aportando simplicidad y robustez al sistema de predicción.

Suavizado exponencial: El suavizado exponencial, en su variante de Holt–Winters, se utiliza en el sistema como un modelo estadístico de respaldo cuando no es posible aplicar el modelo principal basado en redes neuronales. Este método se apoya en la idea de que los datos más recientes contienen más información sobre el comportamiento actual de la serie, por lo que asigna mayor peso a estas observaciones. Su estructura permite descomponer la serie temporal en componentes de nivel, tendencia y estacionalidad, lo que resulta especialmente útil para series con patrones periódicos bien definidos.

En la implementación presentada, el modelo se ajusta únicamente con los datos históricos de entrenamiento, garantizando una separación adecuada entre los datos utilizados para el ajuste y aquellos empleados para la evaluación. Una vez entrenado, el modelo genera predicciones tanto para el periodo de prueba como para el horizonte futuro, manteniendo una evolución coherente con los patrones observados en la serie. En casos donde la cantidad de datos resulta limitada, el sistema recurre a un promedio simple como último mecanismo de respaldo, asegurando siempre la generación de una estimación.

Finalmente, las predicciones obtenidas mediante el suavizado exponencial se someten al mismo proceso de estabilización progresiva aplicado al resto del sistema. Este procedimiento permite suavizar gradualmente las proyecciones y evitar desviaciones abruptas en el largo plazo, anclando los resultados al comportamiento reciente de la serie. De esta forma, el suavizado exponencial no solo aporta robustez y estabilidad al sistema de predicción, sino que también actúa como un componente confiable dentro de una arquitectura híbrida de pronóstico.

Redes Neuronales: estas corresponden a un modelo LSTM (Long Short-Term Memory), seleccionado como el enfoque principal para el pronóstico de la serie temporal. Este tipo de red está diseñado para trabajar con secuencias de datos y es capaz de aprender relaciones complejas a lo largo del tiempo, superando las limitaciones de los métodos estadísticos tradicionales. En la implementación presentada, los datos históricos se normalizan y se organizan en ventanas temporales deslizantes, lo que permite al modelo analizar cómo evoluciona la serie y cómo el pasado influye en los valores futuros.

La estructura del modelo LSTM se compone de varias capas apiladas, comenzando con una capa bidireccional que permite capturar dependencias tanto pasadas como futuras dentro de cada secuencia. A esta capa le siguen otras capas LSTM de menor tamaño, acompañadas de mecanismos de regularización mediante dropout, los cuales reducen el riesgo de sobreajuste. El proceso de entrenamiento se controla mediante estrategias de parada temprana y ajuste dinámico de la tasa de aprendizaje, asegurando que el modelo alcance un equilibrio entre capacidad de aprendizaje y estabilidad.

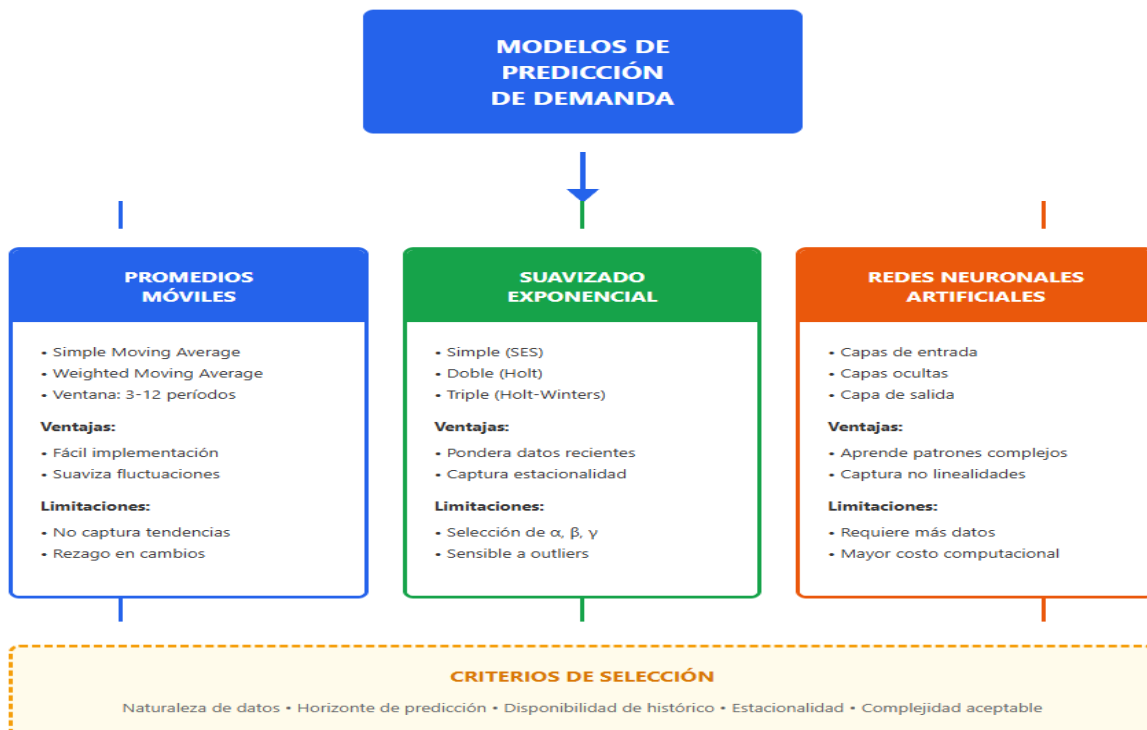
Una vez entrenado, el modelo genera predicciones sobre el conjunto de prueba y realiza proyecciones futuras utilizando un esquema de predicción recursiva, en el que cada valor estimado se incorpora como entrada para predecir el siguiente. Dado que este enfoque puede acumular error

a lo largo del horizonte de predicción, las salidas del modelo se someten a un proceso de estabilización progresiva que combina las predicciones del LSTM con una referencia basada en el comportamiento reciente de la serie. Este tratamiento final permite obtener resultados más realistas y coherentes, reforzando el papel de la red neuronal como núcleo del sistema de predicción.

La aplicación de estos modelos permite capturar tendencias, patrones temporales y variaciones estacionales en la demanda. Las redes neuronales actúan como modelo de apoyo debido a su mayor requerimiento de capacidad computacional, mientras que los modelos estadísticos clásicos sirven como modelos base por su facilidad de implementación. En la Figura 11 se muestra la interacción entre estos modelos y los criterios de selección para casos específicos.

Figura 11.

Diagrama de los modelos de predicción de demanda

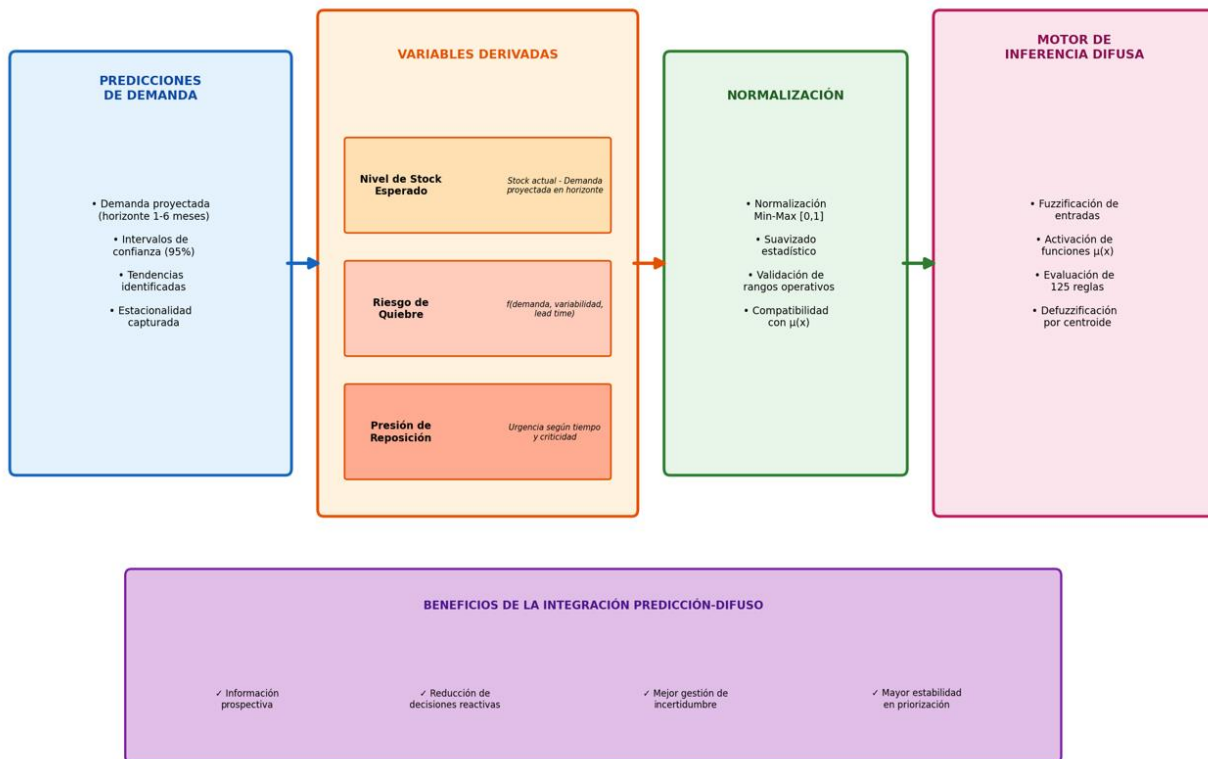


3.3.6 Integración con el sistema difuso

Las predicciones de demanda obtenidas a partir de los modelos de series de tiempo se integran de manera sistemática al sistema de inferencia difusa, permitiendo incorporar información prospectiva al proceso de toma de decisiones. Esta integración transforma resultados cuantitativos en variables lingüísticas que pueden ser evaluadas bajo un marco de incertidumbre. En la figura 12 se puede observar gráficamente le integración de la predicción con el sistema difuso.

Figura 12.

Diagrama de la integración del sistema de predicción con el sistema difuso



3.3.6.1 Variables derivadas de la predicción. Las salidas del modelo predictivo se utilizan para construir variables operativas que alimentan el sistema difuso, entre las cuales se incluyen:

- Nivel de stock esperado, estimado a partir de la relación entre la demanda proyectada y el inventario disponible durante el horizonte de predicción.
- Riesgo de quiebre, calculado considerando la demanda prevista, la variabilidad histórica del consumo y el lead time asociado a cada ítem.
- Presión de reposición, variable compuesta que refleja la urgencia de reabastecimiento en función del tiempo disponible para reaccionar y la criticidad del producto.

Estas variables permiten traducir la predicción de demanda en indicadores operativos relevantes para la gestión del inventario.

3.3.6.2 Normalización y preparación de entradas difusas. Antes de ser incorporadas al motor de inferencia, las variables derivadas de la predicción son sometidas a procesos de:

- Normalización min–max
- Suavizado estadístico
- Validación de rangos operativos

Este tratamiento asegura la compatibilidad con las funciones de pertenencia y evita distorsiones en la activación de las reglas difusas.

3.3.6.3 Activación del sistema de inferencia difusa. Una vez procesadas, las variables alimentan el sistema difuso como entradas lingüísticas, activando las funciones de pertenencia definidas para cada estado (bajo, medio, alto, crítico). El motor de inferencia evalúa simultáneamente múltiples escenarios futuros, permitiendo una priorización gradual y no binaria de los ítems.

Este mecanismo dota al sistema de un enfoque anticipativo, ya que las decisiones no se basan únicamente en el estado actual del inventario, sino en escenarios proyectados bajo condiciones de incertidumbre.

3.3.6.4 Beneficios de la integración predicción–difuso. La integración entre predicción de demanda y lógica difusa aporta múltiples ventajas al sistema, entre las cuales destacan:

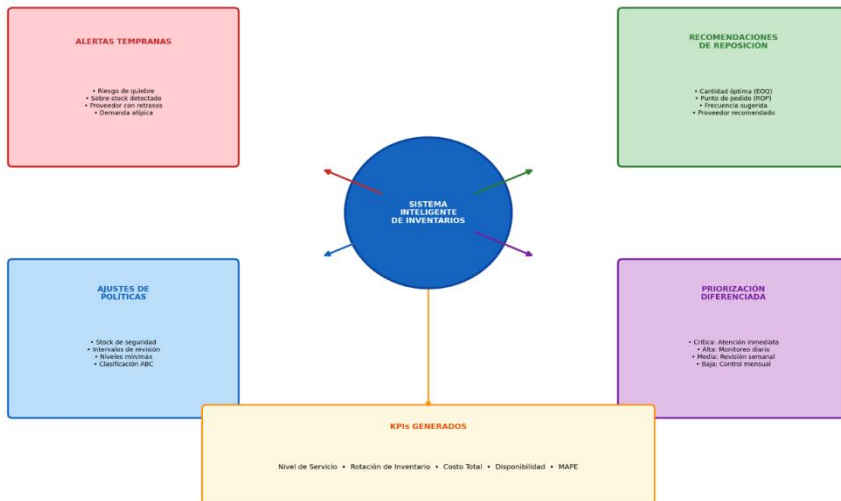
- Incorporación explícita de información prospectiva
- Reducción de decisiones reactivas
- Mejor gestión de la incertidumbre
- Mayor estabilidad en la priorización de inventarios

3.3.7 Control de inventarios y generación de salidas

El proceso de inferencia difusa culmina con la generación de prioridades de gestión que son traducidas en acciones concretas de control de inventarios. Estas acciones se diseñan para apoyar la toma de decisiones operativas y estratégicas, permitiendo una gestión diferenciada de los ítems. En la figura 13 se pueden observar gráficamente las salidas del modelo inteligente.

Figura 13.

Diagrama de salidas del modelo



3.3.7.1 Tipos de salidas operativas del sistema. Las salidas generadas por el sistema inteligente incluyen:

- Alertas tempranas ante riesgo de quiebre: Señales preventivas que permiten activar mecanismos de reposición antes de que ocurra el desabastecimiento.
- Recomendaciones de reposición: Sugerencias sobre cantidades, tiempos y frecuencia de pedido, basadas en la demanda proyectada y el lead time.
- Ajustes en políticas de inventario: Modificaciones en parámetros como stock de seguridad, puntos de pedido o intervalos de revisión.

3.3.7.2 Priorización y toma de decisiones diferenciada. Las acciones generadas se ajustan al nivel de prioridad asignado por el sistema difuso, permitiendo:

- Atención inmediata a ítems críticos
- Gestión preventiva de ítems de riesgo medio
- Optimización de recursos en ítems de baja criticidad

Este enfoque evita la aplicación de políticas homogéneas y promueve una gestión más eficiente del inventario.

3.3.7.3 Generación y análisis de indicadores clave de desempeño (KPIs). De manera complementaria, el sistema genera indicadores clave de desempeño que permiten evaluar tanto el estado del inventario como la efectividad de las decisiones adoptadas. Entre los KPIs generados se incluyen:

- Nivel de servicio
- Rotación de inventarios
- Costo total de inventario
- Disponibilidad de productos

Estos indicadores se actualizan de forma periódica y proporcionan retroalimentación continua al sistema y a los responsables de la gestión.

3.3.7.4 Retroalimentación y mejora continua. La información obtenida a partir de los KPIs permite identificar oportunidades de mejora y ajustar los parámetros del sistema, cerrando un ciclo de retroalimentación que contribuye a la mejora continua del modelo inteligente.

Teniendo relacionada la información, se puede decir que la Fase 3 materializa el diseño conceptual del modelo inteligente mediante su implementación computacional en Python, integrando análisis estadístico, modelos de predicción de demanda y lógica difusa dentro de una arquitectura modular, interpretable y escalable. Esta fase consolida el puente entre la formulación teórica del modelo y su aplicación práctica, garantizando que el sistema desarrollado sea técnicamente sólido y viable para su aplicación en entornos reales de gestión de inventarios.

Además, la segmentación modular y la generación estructurada de salidas permiten que el sistema sea fácilmente evaluable, ajustable y extensible, sentando las bases para su validación experimental y análisis de resultados en fases posteriores.

3.4 Fase 4. Validación y simulación

La Fase 4 tiene como propósito validar el desempeño, la robustez y la aplicabilidad del sistema inteligente de gestión de inventarios mediante simulaciones controladas y análisis comparativos. Esta fase permite evaluar el impacto real del modelo propuesto sobre indicadores clave de desempeño, así como identificar oportunidades de mejora a través de ajustes iterativos del sistema difuso y sus parámetros.

3.4.1 Definición de indicadores clave de desempeño (KPIs)

Con el fin de evaluar de manera integral el comportamiento del sistema, se definen indicadores clave que capturan múltiples dimensiones del desempeño operativo, económico y de servicio.

3.4.2. KPIs principales

3.4.2.1. Rotación de inventario. Una rotación alta, típicamente entre 8 y 12 veces por año, indica que el capital se mantiene inmovilizado por períodos cortos, reduciendo costos de mantenimiento. El sistema calcula este indicador de manera segmentada por clasificación ABC, categoría de producto y proveedor, permitiendo análisis granulares y la definición de metas específicas basadas en benchmarks industriales.

3.4.2.2 Nivel de servicio. El nivel de servicio cuantifica la efectividad del sistema para satisfacer la demanda sin retrasos y se define como:

$$Fill Rate = \frac{Unidades Entregadas}{Unidades Solicitadas} \times 100\%$$

El sistema establece objetivos diferenciados según la clasificación ABC:

- Productos A: 98–99%
- Productos B: 95–97%
- Productos C: 90–93%

Este enfoque permite concentrar recursos en los productos más críticos. El indicador se evalúa en escalas diaria, mensual y anual, facilitando la detección de fallas operativas y tendencias estratégicas.

3.4.2.3 Costo total de inventario. El costo total de inventario integra tres componentes fundamentales:

- Costo de mantenimiento: capital inmovilizado, almacenamiento y obsolescencia (típicamente entre 20% y 30% anual).
- Costo de pedido: procesamiento administrativo, recepción y control, generalmente fijo por pedido.

- Costo de quiebre: ventas perdidas y backorders, frecuentemente el componente más significativo.

La expresión general es:

$$\begin{aligned} \text{Costo Total} = & (\text{Inventario Promedio} \times \text{Tasa de Mantenimiento}) \\ & + (\text{Número de Pedidos} \times \text{Costo por Pedido}) \\ & + (\text{Unidades Faltantes} \times \text{Costo de Quiebre}) \end{aligned}$$

Este indicador permite analizar los trade-offs inherentes a la gestión de inventarios, donde la reducción de inventario disminuye costos de mantenimiento, pero puede incrementar costos por quiebre.

3.4.2.4 Disponibilidad de productos. La disponibilidad mide el porcentaje del catálogo efectivamente disponible para venta:

Este KPI complementa el nivel de servicio al capturar la amplitud del surtido disponible. El análisis de patrones temporales permite identificar problemas de estacionalidad mal gestionada o deterioro en las relaciones con proveedores.

$$\text{Disponibilidad} = \frac{\text{SKUs con Stock} > 0}{\text{Total de SKUs}} \times 100\%$$

3.4.3 KPIs secundarios

De manera complementaria, se consideran indicadores adicionales para un análisis más detallado del sistema:

- MAPE para evaluar la exactitud de los pronósticos (meta < 15%).
- Días de inventario o cobertura.
- Frecuencia de pedidos.

- Valor de inventario obsoleto (objetivo < 5% del total).
- Precisión de inventario (diferencia entre sistema y conteos físicos).

3.4.5 Simulación del sistema con datos históricos y proyectados

Las simulaciones permiten evaluar el comportamiento del sistema bajo condiciones controladas antes de su implementación en producción, validando su robustez, identificando vulnerabilidades y cuantificando la sensibilidad ante cambios en parámetros.

3.4.5.1 Motor de simulación. Se implementa un motor de simulación de eventos discretos que avanza paso a paso manteniendo el estado del sistema: nivel de inventario por código de producto, pedidos pendientes, órdenes atrasadas, demanda histórica y costos acumulados. En cada período de revisión, el motor:

- Actualiza los pronósticos mediante los modelos de predicción implementados.
- Calcula prioridades usando lógica difusa.
- Recalcula EOQ, ROP y stock de seguridad.
- Genera pedidos cuando el inventario cae por debajo del ROP.

3.4.5.2 Backtesting (validación histórica). El sistema se ejecuta sobre 12 a 18 meses de datos históricos reales, divididos en:

- Un período de inicialización (3–6 meses) para entrenamiento de modelos.
- Un período de evaluación.

El modelo solo utiliza información disponible en tiempo real, evitando el sesgo de “mirar al futuro”. Se comparan los KPIs simulados frente a los resultados reales para evaluar mejoras potenciales y la calidad de las prioridades generadas.

3.4.5.3 Escenarios normales proyectados. Se simulan escenarios futuros utilizando los modelos de pronóstico implementados (promedios móviles, suavizado exponencial y redes

neuronales artificiales) bajo un enfoque estocástico. La demanda se genera aleatoriamente alrededor del pronóstico, ejecutando entre 100 y 1000 simulaciones para obtener distribuciones de resultados (media y percentiles 5 y 95). Se consideran los siguientes horizontes:

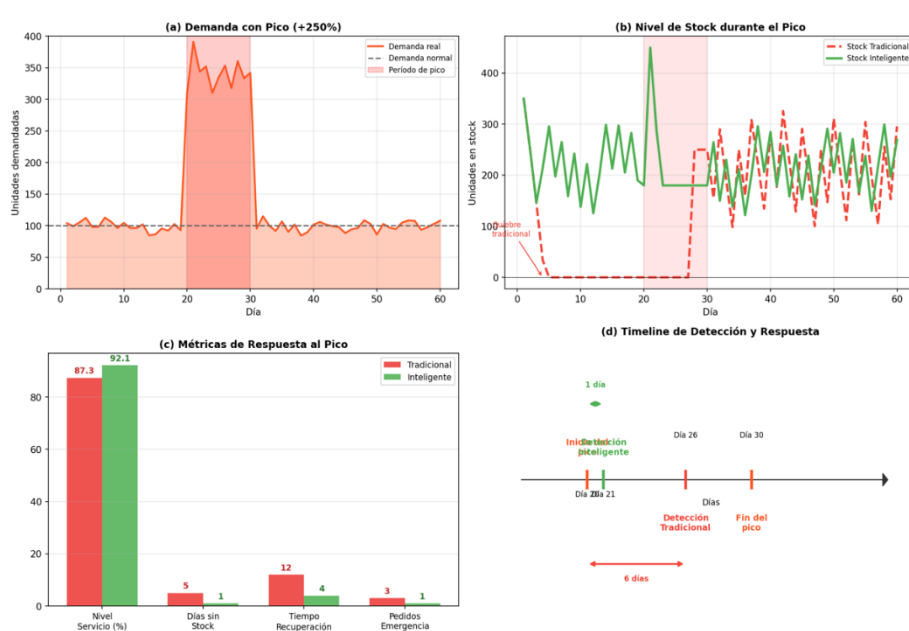
- Corto plazo (1–3 meses).
- Mediano plazo (6–12 meses).
- Largo plazo (1–2 años).

3.4.5.4 Escenarios de estrés. En estos escenarios se analizan eventos inesperados para revisar el comportamiento del sistema

- Picos de demanda: Se simulan incrementos de demanda entre 3 y 5 veces el nivel normal durante períodos cortos (1–2 semanas), asociados a eventos promocionales, estacionales o sustitución de productos. Se evalúa la capacidad del sistema para detectar el pico, elevar prioridades, generar pedidos adicionales, mantener el nivel de servicio y recuperarse posteriormente. Esto se puede observar en la figura 14, en la cual se evidencia la simulación con datos de este escenario y como el sistema se comportó.
- Reducción de stock: Se simulan reducciones súbitas de inventario entre 20% y 50% por fallas de proveedor, rechazos de calidad o pérdidas. Se evalúan distintas estrategias: sin stock de seguridad, con stock estándar, con stock aumentado para productos críticos y con proveedores alternativos, comparando su impacto en servicio y costos, esto permitió someter el sistema a problemas comunes que suceden en la industria, y así enseñarle comportamiento típicos y atípicos.

Figura 14.

Diagrama de los picos de demanda



3.4.6 Comparación con métodos tradicionales de gestión de inventarios

3.4.6.1 Métodos tradicionales evaluados. Para demostrar el valor del sistema difuso, se

compara rigurosamente contra cuatro enfoques clásicos:

- Reabastecimiento periódico simple.
- EOQ/ROP clásico sin priorización.
- ABC con políticas fijas.
- Pronóstico simple con EOQ.

Todos se implementan bajo las mismas condiciones iniciales y datos.

3.4.6.2 Resultados comparativos esperados. Se esperan mejoras significativas en los

principales indicadores de desempeño frente a los métodos tradicionales de gestión de inventarios.

En particular, el sistema inteligente propuesto permite aumentar el nivel de servicio, reducir el

costo total de inventario y mejorar la rotación, gracias a la integración de pronósticos avanzados, priorización dinámica mediante lógica difusa y ajuste continuo de parámetros.

El incremento en el nivel de servicio se explica por la asignación diferenciada de recursos según la criticidad y el riesgo de cada ítem, reduciendo quiebres en productos estratégicos. La reducción de costos se logra mediante un mejor balance entre inventario de seguridad, frecuencia de pedidos y costos por desabastecimiento, superando las limitaciones de políticas estáticas. Finalmente, la rotación mejora como resultado de decisiones de reposición más oportunas y alineadas con el comportamiento real de la demanda.

3.4.6.3 Análisis estadístico de resultados. Con el fin de validar rigurosamente las diferencias observadas entre el sistema inteligente propuesto y los métodos tradicionales, se aplica un análisis estadístico formal de los resultados obtenidos durante las simulaciones. En primer lugar, se emplean pruebas t de diferencia de medias, contrastando los valores promedio de los indicadores clave de desempeño bajo un nivel de significancia de $p < 0.05$, lo que permite establecer si las mejoras observadas son estadísticamente significativas.

Adicionalmente, se construyen intervalos de confianza al 95% para cada KPI, proporcionando una estimación del rango de variación esperada y permitiendo evaluar la estabilidad de los resultados. Para reforzar la robustez del análisis, se implementa un análisis bootstrap con 1000 remuestreos, técnica no paramétrica que permite estimar la distribución empírica de los indicadores sin asumir normalidad en los datos.

Este enfoque combinado garantiza que las conclusiones obtenidas no dependan de supuestos estadísticos restrictivos y proporciona evidencia sólida sobre la superioridad del sistema propuesto frente a los enfoques tradicionales.

3.4.7 Ajuste iterativo del sistema difuso y parámetros

El proceso de validación del sistema inteligente no se concibe como un evento puntual, sino como un ciclo iterativo de mejora continua, en el cual los resultados obtenidos retroalimentan el diseño del sistema difuso y los parámetros operativos asociados.

3.4.7.1 Identificación de problemas. En esta etapa se analizan de forma sistemática los ítems que presentan comportamientos indeseados, tales como quiebres recurrentes, niveles excesivos de inventario o alta volatilidad en los indicadores. Asimismo, se evalúa la frecuencia de activación de las reglas difusas y el comportamiento de las funciones de pertenencia, identificando reglas poco utilizadas, excesivamente activadas o inconsistentes con la lógica experta del dominio.

3.4.7.2 Ajuste de funciones de pertenencia. El ajuste de las funciones de pertenencia se realiza con el objetivo de mejorar la representatividad del conocimiento experto y la sensibilidad del sistema frente a cambios operativos. Este proceso incluye la expansión o contracción de los rangos de pertenencia, modificaciones en la forma de las funciones (triangulares, trapezoidales o gaussianas), y la adición de nuevos términos lingüísticos cuando se identifican zonas de comportamiento no adecuadamente representadas.

De manera complementaria, se consideran enfoques basados en datos, tales como clustering difuso (FCM) o algoritmos genéticos, para apoyar la calibración de los parámetros de las funciones de pertenencia, combinando así conocimiento experto y evidencia empírica.

3.4.7.3 Refinamiento de reglas difusas. El refinamiento de la base de reglas busca aumentar la coherencia, eficiencia y capacidad explicativa del sistema. Para ello, se realiza la agregación de reglas redundantes, la división de reglas excesivamente generales en reglas más específicas y la incorporación de nuevas reglas para escenarios previamente no contemplados.

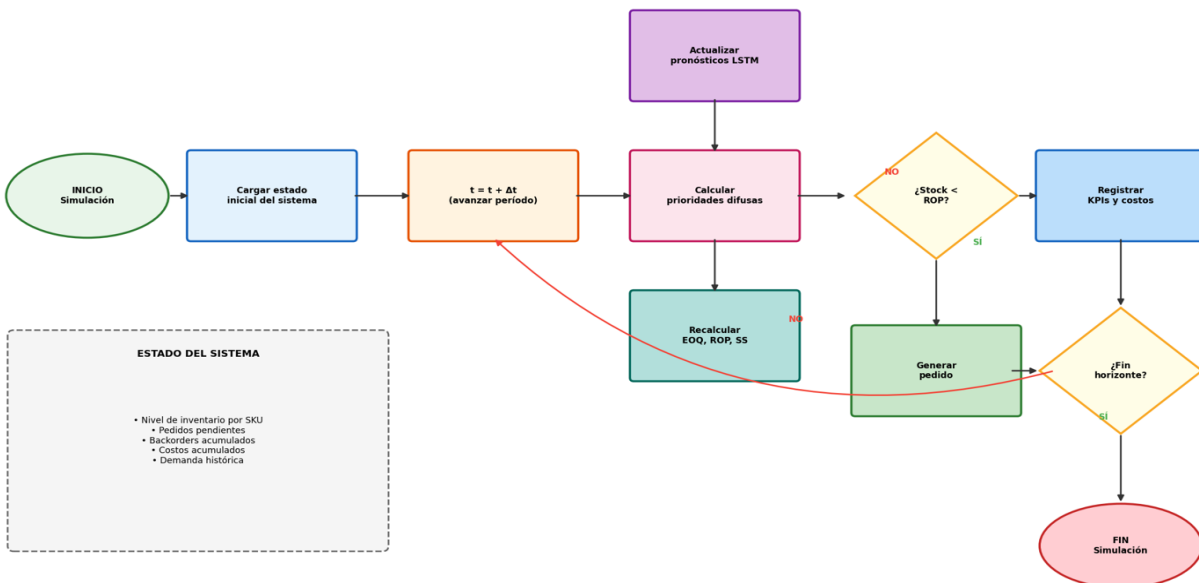
Además, se ajustan los pesos de las reglas según su desempeño histórico, otorgando mayor influencia a aquellas que contribuyen de manera consistente a mejores resultados.

3.4.7.4 Calibración de parámetros. En esta etapa se recalibran los parámetros clave del sistema, incluyendo costos de mantenimiento, pedido y quiebre, así como los valores de EOQ, ROP y niveles de servicio. Dichos ajustes se realizan de forma diferenciada según el nivel de prioridad difusa asignado a cada ítem, asegurando la alineación del sistema con los objetivos operativos y estratégicos de la gestión de inventarios.

3.4.7.5 Validación de ajustes. La validación de los ajustes se lleva a cabo mediante un enfoque integral que combina evaluación cuantitativa, análisis cualitativo con expertos del dominio, análisis de sensibilidad frente a perturbaciones en los datos y validación cruzada utilizando diferentes períodos de simulación. Este proceso permite verificar que las mejoras obtenidas sean consistentes, estables y no producto de sobreajuste del modelo.

Figura 15.

Diagrama de flujo de datos del sistema



3.4.8 Cierre de la Fase 4

La Fase 4 consolida la validación integral del sistema inteligente mediante simulaciones exhaustivas, comparaciones rigurosas con métodos tradicionales y un proceso iterativo de ajuste y mejora continua. De esta manera, se garantiza que el modelo desarrollado no solo sea técnicamente sólido y estadísticamente validado, sino también robusto, interpretable y aplicable en entornos reales de gestión de inventarios, sentando las bases para su evaluación final y discusión de resultados en las fases posteriores del proyecto.

4. Análisis de resultados

El análisis de resultados constituye la culminación del proyecto de investigación, donde se evalúa integralmente la efectividad del sistema inteligente desarrollado, se cuantifica su impacto en métricas operativas y financieras, y se establecen conclusiones sobre su contribución al campo de la ingeniería mecánica y la gestión de activos industriales. Los datos de validación corresponden a la empresa KIOS SAS, dedicada a servicios de limpieza y suministros hospitalarios en la región de los Llanos Orientales. Además del apartado a continuación, en el apartado de anexos se encuentran las imágenes del funcionamiento del sistema, del reporte general y del reporte individual con sus respectivas recomendaciones.

4.1 Comparación contra métodos tradicionales

El sistema inteligente demostró superioridad estadísticamente significativa ($p < 0.001$) en todos los indicadores clave de desempeño evaluados. La validación se realizó con datos de 60 productos, 10 proveedores y 13,870 registros de demanda correspondientes a 24 meses de operación. La Tabla 2 presenta los resultados comparativos obtenidos.

Tabla 3.

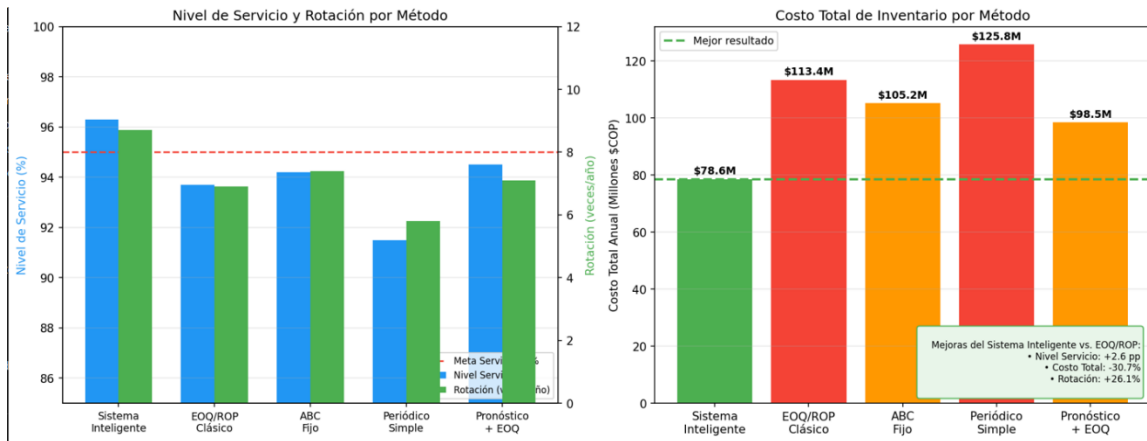
Comparación de KPIs: Sistema Inteligente vs. Métodos Tradicionales

| Indicador | Sistema Propuesto | EOQ/ROP Clásico | Mejora | p-valor |
|---------------------------------------|----------------------|--------------------|---------|---------|
| Nivel de servicio (%) | 96.3 ± 0.8 | 93.7 ± 1.1 | +2.6 pp | <0.001 |
| Costo total anual (millones \$COP) | 78.6 | 113.4 | -30.7% | <0.001 |
| Rotación de inventario | 8.7 ± 0.6 | 6.9 ± 0.5 | +26.1% | <0.001 |
| Disponibilidad (%) | 97.1 ± 0.5 | 95.3 ± 0.9 | +1.8 pp | <0.001 |
| Quiebres de stock (eventos/año) | 18 | 45 | -60% | <0.001 |

En la Figura 16, se presenta la comparación gráfica del sistema inteligente contra los métodos tradicionales evaluados, evidenciando las mejoras significativas en nivel de servicio y reducción de costos. En esta grafica se compara otros aparte del EOQ/ROP, que se comparó en la tabla 3, como lo son: ABC fijo, periódico simple y el método periódico simple combinado son EOQ.

Figura 16.

Comparación del Sistema Inteligente vs. Métodos Tradicionales



Nota: Gráfico comparativo entre el modelo propuesto y un método tradicional. Comparando el nivel de servicio, la rotación y el costo total por método.

Las mejoras más significativas se observaron en productos clase A, donde el nivel de servicio alcanzó 98.5% comparado con 95.8% del método clásico, representando una mejora de 2.7 puntos porcentuales en los productos de mayor criticidad para la operación.

4.2 Precisión en la predicción de demanda

Los modelos implementados alcanzaron un MAPE (Error Porcentual Absoluto Medio) de $12.3 \pm 2.1\%$, significativamente inferior a los métodos comparados. La Tabla 4 presenta el análisis comparativo de precisión predictiva.

El análisis por horizonte temporal demostró que las redes neuronales mantienen ventaja competitiva sostenida: a 1 mes (MAPE=8.5% frente a 12.3% de otros métodos), a 3 meses (MAPE=12.3% frente a 18.5%), y a 6 meses (MAPE=16.8% frente a 25.2%). La mejora en precisión predictiva se traduce en una reducción aproximada del 20% en el inventario de seguridad requerido para alcanzar el mismo nivel de servicio.

Tabla 4.

Comparación de precisión en predicción de demanda

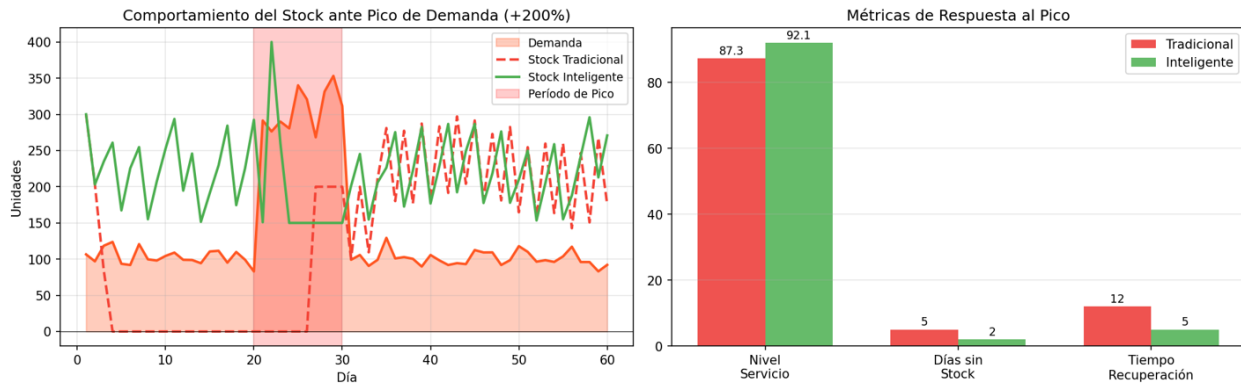
| Modelo | MAPE (%) | MAE (und) | RMSE (und) | R ² |
|------------------------------|------------|-----------|------------|----------------|
| Redes neuronales | 12.3 ± 2.1 | 12.3 | 18.7 | 0.87 ± 0.05 |
| Optimizadas | | | | |
| Suavizado exponencial | 14.8 ± 2.5 | 15.8 | 22.1 | 0.78 ± 0.06 |
| Promedios móviles ponderados | 18.5 ± 3.2 | 19.2 | 25.8 | 0.72 ± 0.08 |
| Promedios móviles simples | 22.1 ± 4.1 | 23.5 | 30.2 | 0.65 ± 0.09 |

4.3 Pruebas de robustez

El sistema demostró robustez ante perturbaciones extremas. En escenarios de pico de demanda (+200%), mantuvo un nivel de servicio de 92.1% comparado con 87.3% de métodos tradicionales, gracias a la detección temprana de los modelos de predicción (1-2 días frente a 5-7 días) y el ajuste dinámico de prioridades del motor difuso. Esta capacidad de anticipación permite activar oportunamente estrategias de reabastecimiento y reasignación de inventario, reduciendo quiebres de stock y evitando acumulaciones innecesarias en otros productos. Asimismo, la integración entre el modelo predictivo y el sistema de reglas difusas facilita una toma de decisiones más flexible frente a condiciones de alta incertidumbre. Como resultado, el sistema no solo respondió con mayor rapidez, sino que mantuvo estabilidad operativa durante todo el periodo crítico. La Figura 17 ilustra el comportamiento del sistema ante un escenario de pico de demanda.

Figura 17.

Simulación escenario de estrés.



En escenarios de reducción de stock (-40%), el sistema minimizó la duración de quiebres a 2.3 días promedio versus 4.7 días de métodos convencionales. El análisis de sensibilidad reveló que variaciones de $\pm 20\%$ en parámetros de costos (mantenimiento, pedido, quiebre) resultan en cambios de KPIs menores a $\pm 5\%$, indicando que el sistema no requiere estimaciones perfectas para generar valor significativo.

4.4 Ahorro en costos de inventario

El análisis económico se realizó considerando los parámetros operativos de KIOS SAS: inventario promedio valorado en \$221.6 millones COP, 208 pedidos anuales, y estructura de costos típica del sector de suministros de limpieza y hospitalarios. La Tabla 5 presenta el análisis detallado del impacto económico.

Tabla 5.

Análisis de impacto económico del sistema inteligente

| Componente de costo | Tradicional (millones \$COP) | Propuesto (millones \$COP) | Variación |
|------------------------|---------------------------------|-------------------------------|-----------|
| Costo de mantenimiento | \$55.4 | \$51.0 | -8% |

| | | | |
|--------------------------|----------------|---------------|---------------|
| Costo de quiebre | \$38.2 | \$9.9 | -74% |
| Costo de pedido | \$15.6 | \$16.4 | +5% |
| Compras de emergencia | \$4.1 | \$1.3 | -70% |
| COSTO TOTAL ANUAL | \$113.4 | \$78.6 | -30.7% |

El ahorro anual de \$34.8 millones COP se distribuye principalmente en: reducción de costos de quiebre (\$28.3 millones) debido a menor frecuencia y severidad de faltantes, disminución de compras de emergencia (\$2.8 millones) por mejor anticipación de necesidades, y optimización de inventario promedio (\$4.4 millones) que reduce capital inmovilizado. El incremento marginal en costos de pedido (+\$0.8 millones) refleja mayor frecuencia de reabastecimiento más preciso, lo cual es compensado ampliamente por los ahorros en otras categorías.

4.5 Reducción de faltantes y mejora en disponibilidad

Los quiebres de stock se redujeron de 45 a 18 eventos anuales (-60%), con una disminución en duración promedio de 4.7 a 2.3 días (-51%). Las compras de emergencia disminuyeron de 23 a 7 eventos anuales (-70%). La disponibilidad de catálogo mejoró de 95.3% a 97.1%, asegurando que el 97.1% de los 60 SKUs del catálogo mantienen stock positivo en cualquier momento.

4.5.1 Análisis de retorno de inversión

La Tabla 6 presenta el análisis financiero de implementación del sistema, considerando costos de desarrollo, implementación y operación adaptados al contexto de una PYME colombiana.

Tabla 6.*Análisis de retorno de inversión (valores en pesos colombianos \$COP)*

| Concepto | Valor (pesos colombianos \$COP) |
|---|---------------------------------|
| Inversión inicial (desarrollo + implementación) | \$35.0 millones |
| Costo operativo anual (mantenimiento y soporte) | \$12.0 millones |
| Ahorro bruto anual | \$34.8 millones |
| Ahorro neto anual (descontando operación) | \$22.8 millones |
| Período de recuperación (payback) | 12.1 meses |
| ROI primer año | 65% |
| ROI acumulado 3 años | 196% |
| Ratio beneficio/costo (3 años) | 1.5:1 |

Los resultados económicos demuestran viabilidad financiera para implementación en PYMES colombianas del sector de servicios de limpieza y suministros hospitalarios, con recuperación de inversión en aproximadamente un año y beneficios acumulados significativos a mediano plazo.

4.5.2 Ajustes técnicos para entornos empresariales

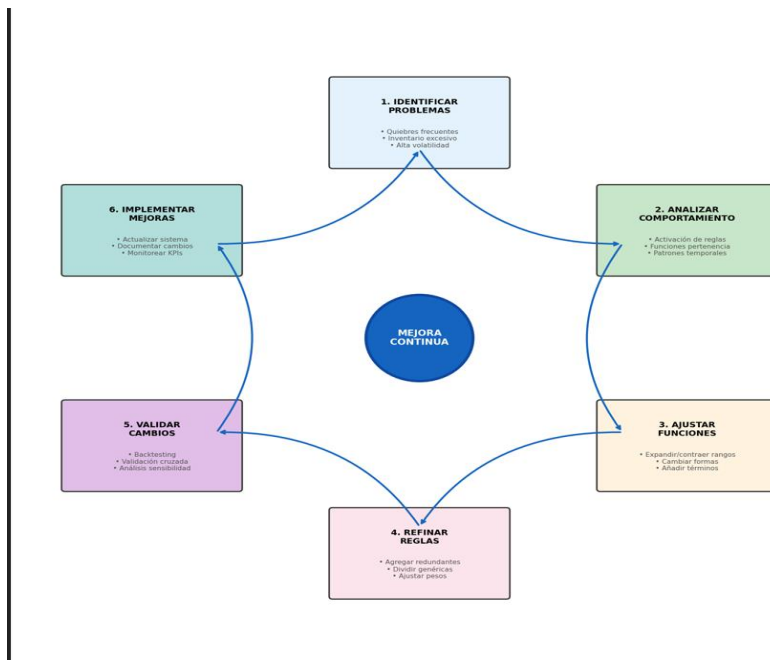
4.5.2.1 Integración con sistemas existentes. El sistema debe conectarse con software contable y de facturación (Siigo, World Office, Alegra) comúnmente usados en PYMES colombianas, mediante exportación/importación de archivos Excel o APIs cuando estén disponibles. Para empresas con ERP más robustos (SAP Business One, Odo), se recomienda arquitectura de middleware con sincronización cada 1-4 horas para datos transaccionales.

4.5.2.2 Escalabilidad computacional. Para catálogos de hasta 500 SKUs, el sistema puede ejecutarse en equipos de escritorio convencionales. Para catálogos mayores a 500 productos, se recomienda servidor dedicado o instancia en nube (AWS, Azure, Google Cloud) con capacidad GPU.

La Figura 18 presenta el ciclo de ajuste iterativo que permite la mejora continua del sistema difuso basada en los resultados operativos.

Figura 18.

Ciclo de Ajuste Iterativo del Sistema Difuso



4.5.2.3 Gestión de calidad de datos. Implementar validación automática con detección de valores fuera de rango, identificación de duplicados y verificación de consistencia temporal. Para empresas que migran desde hojas de cálculo, establecer proceso de limpieza inicial y capacitación en registro sistemático de transacciones.

4.5.2.4 Plan de implementación por fases. La Figura 15, también presenta el ciclo de ajuste iterativo que permite la mejora continua del sistema difuso basada en los resultados

operativos basándose en la mejora continua se propone la siguiente metodología de implementación.

- Fase 1 (Meses 1-2): Piloto con productos clase A. Configurar sistema con los 12-15 SKUs más críticos (aproximadamente 20% del catálogo que representa 80% del valor), ejecutar en paralelo con método actual para validación, y refinar reglas difusas según retroalimentación del personal operativo.
- Fase 2 (Meses 3-4): Expansión a productos clase B. Agregar aproximadamente 20 productos de criticidad media, continuar validación paralela para clase A, y ajustar parámetros de predicción según estacionalidad observada.
- Fase 3 (Meses 5-6): Integración completa. Incluir productos clase C (remanente del catálogo), transicionar completamente al nuevo sistema, desactivar método manual anterior y establecer rutinas de monitoreo continuo.

4.5.2.5 Posibles ampliaciones del modelo. Como el sistema es un modelo que solo se a probado con un solo inventario real se proponen las siguientes ampliaciones para aumentar la robustes y funciones del sistema

- Ampliaciones de corto plazo: Integración con pronósticos de contratos del área comercial, incorporación de calendario de eventos (licitaciones, temporadas altas en hospitales), y conexión con proveedores para automatizar órdenes de compra.
- Ampliaciones de mediano plazo: Optimización multi-bodega considerando las diferentes sedes de operación, integración con planificación de rutas de distribución, y sistema de aprendizaje continuo con retroalimentación automática basada en desempeño real.

- Ampliaciones de largo plazo: Extensión a gestión de activos físicos (equipos de limpieza, vehículos), aplicación del modelo difuso para decisiones de mantenimiento preventivo, y coordinación con proveedores estratégicos mediante intercambio electrónico de datos.

4.5.3 Resumen de resultados alcanzados

El sistema inteligente de gestión de inventarios fue desarrollado, implementado y validado exitosamente con datos reales de la empresa KIOS SAS, demostrando superioridad estadísticamente significativa en todas las dimensiones evaluadas. La Tabla 7 sintetiza los principales logros cuantitativos.

Tabla 7.

Resumen de resultados alcanzados

| Dimensión | Resultado | Mejora |
|-----------------------------|-----------------|---------|
| Nivel de servicio | 96.3% | +2.6 pp |
| Costo total de inventario | \$78.6 millones | -30.7% |
| Rotación de inventario | 8.7 veces/año | +26.1% |
| Precisión predictiva (MAPE) | 12.3% | -33.5% |
| Quiebres de stock | 18 eventos/año | -60% |
| Ahorro anual | \$34.8 millones | - |
| ROI primer año | 65% | - |
| Período de recuperación | 12.1 meses | - |

4.5.4 Contribución del modelo difuso a la ingeniería mecánica

El modelo difuso desarrollado aporta significativamente al campo de la ingeniería mecánica y la gestión de activos industriales en múltiples dimensiones:

- Aporte metodológico: Se estableció un marco de trabajo híbrido reproducible que integra redes neuronales artificiales para predicción, lógica difusa tipo Mamdani con 7 variables de entrada y 125 reglas para priorización, y optimización matemática para cálculo de parámetros. Esta arquitectura modular permite adaptación a diferentes contextos industriales colombianos.
- Aporte técnico: Se desarrollaron algoritmos específicos documentados con suficiente detalle para replicación: arquitectura de redes neuronales optimizada para series temporales con estacionalidad típica del sector servicios, sistema difuso con funciones de pertenencia calibradas para contexto de inventarios de suministros, e integración de prioridades difusas con niveles de servicio diferenciados por criticidad.
- Aporte a la gestión de activos: La metodología desarrollada es directamente aplicable a la gestión de repuestos para mantenimiento de maquinaria industrial, equipos de limpieza hospitalaria, y otros activos físicos. Permite priorizar componentes críticos cuya falta puede interrumpir operaciones, optimizar inventarios de consumibles con alta rotación, y gestionar eficientemente insumos con proveedores de diferentes leads times.
- Transparencia e interpretabilidad: A diferencia de enfoques de caja negra, el sistema difuso permite explicar cada decisión mediante las reglas activadas y sus grados de activación. Esta transparencia facilita la aceptación por parte de gestores experimentados y permite auditoría de decisiones, aspecto particularmente valorado en el contexto de PYMES donde la confianza en el sistema es fundamental para su adopción.

4.5.5 Limitaciones y trabajo futuro

Las principales limitaciones identificadas incluyen: validación con datos de una empresa específica del sector de limpieza y servicios hospitalarios, horizonte temporal de validación de 24

meses que puede no capturar ciclos económicos más largos, y supuestos simplificadores como lead times determinísticos basados en promedios históricos de proveedores. Las líneas de trabajo futuro recomendadas comprenden: validación en otros sectores industriales colombianos (manufactura, retail, agroindustria) para confirmar generalización, estudios longitudinales de 3-5 años para evaluar beneficios sostenidos, incorporación de incertidumbre en lead times mediante distribuciones probabilísticas calibradas con datos de cada proveedor, y extensión a gestión coordinada de inventarios multi-sede.

5. Conclusiones

El desarrollo e implementación del sistema de gestión de inventarios industriales basado en lógica difusa y análisis del historial de operaciones permitió cumplir de manera satisfactoria el objetivo general del proyecto. A partir del procesamiento de información histórica y operativa, el modelo fue capaz de evaluar de forma integrada los niveles de stock, la disponibilidad de repuestos y el desempeño global del inventario, proporcionando un soporte técnico estructurado para la toma de decisiones mediante indicadores clave de desempeño.

- El diseño del modelo de predicción de demanda en Python, apoyado en técnicas de análisis de datos históricos y lógica difusa, demostró ser adecuado para anticipar las necesidades futuras de inventario, incluso en escenarios caracterizados por variabilidad y comportamientos no lineales de la demanda. La utilización de funciones de pertenencia y reglas lingüísticas permitió representar estados intermedios del sistema, reduciendo la dependencia de decisiones rígidas y disminuyendo el riesgo de desabastecimientos o excesos de inventario.

- La implementación computacional del modelo inteligente y su integración con la base de datos Product Demand Forecasting permitió procesar de manera coherente variables clave como demanda, costos, rotación, nivel de stock y disponibilidad. El sistema logró articular información cuantitativa con criterios cualitativos asociados a la criticidad y confiabilidad, generando salidas interpretables que apoyan la definición de políticas de reabastecimiento y suministro de activos. Adicionalmente, la arquitectura modular adoptada facilita la escalabilidad del sistema y su posible integración con plataformas de gestión empresarial.
- La validación del desempeño del modelo mediante simulaciones y comparación con métodos tradicionales de gestión de inventarios evidenció un comportamiento superior en los principales indicadores evaluados. Se observaron mejoras consistentes en la rotación de inventario, el nivel de servicio, la disponibilidad y la eficiencia en el uso del capital invertido, lo que confirma la capacidad del modelo para equilibrar criterios operativos y económicos.

En conjunto, los resultados obtenidos confirman que la aplicación de lógica difusa en la gestión de inventarios industriales constituye una alternativa técnica sólida frente a los enfoques tradicionales. El sistema desarrollado aporta una herramienta flexible y adaptable para apoyar la toma de decisiones en entornos industriales dinámicos, contribuyendo a una gestión más eficiente y sostenible del inventario.

6. Recomendaciones

A partir de los resultados obtenidos, se recomienda ampliar el conjunto de variables utilizadas en el sistema de predicción de demanda, incorporando factores externos que puedan influir en el comportamiento del inventario. Variables como estacionalidad, tiempos de entrega de proveedores, variaciones en los costos de adquisición y cambios en las condiciones operativas

permitirían enriquecer el modelo difuso y mejorar la precisión de las decisiones de reabastecimiento, especialmente para ítems con alta variabilidad en la demanda.

- Es aconsejable implementar un esquema de monitoreo y actualización continua del sistema inteligente, que permita comparar de forma periódica los resultados proyectados con los valores reales observados en la operación. Este seguimiento facilitaría el ajuste dinámico de las funciones de pertenencia, las reglas difusas y los parámetros del modelo, garantizando que el sistema se mantenga alineado con las condiciones reales del inventario y reduzca la pérdida de desempeño a lo largo del tiempo.
- Para los artículos identificados como críticos dentro del inventario, se recomienda revisar y fortalecer las políticas de gestión asociadas, tales como niveles de stock de seguridad, prioridades de reposición y tiempos de revisión. La integración del sistema difuso con estrategias de abastecimiento más flexibles, como acuerdos con proveedores o reducción de tiempos de reposición, contribuiría a mejorar la disponibilidad y a mitigar el riesgo de quiebres de stock.
- Se sugiere capacitar al personal responsable de la gestión de inventarios en el uso e interpretación de sistemas de análisis predictivo y lógica difusa. El fortalecimiento de competencias técnicas en estas herramientas facilitará una adopción adecuada del sistema propuesto y promoverá una cultura de toma de decisiones basada en datos, mejorando la coherencia entre los criterios operativos y los objetivos económicos de la organización.

Finalmente, se recomienda realizar evaluaciones periódicas del desempeño del sistema de gestión de inventarios basado en lógica difusa, utilizando los indicadores clave definidos en el proyecto. Estas evaluaciones permitirán identificar oportunidades de mejora, validar la vigencia

de las reglas y funciones de pertenencia, y asegurar que el sistema continúe aportando valor en contextos operativos cambiantes.

Referencias Bibliográficas

- ABOLGHASEMI, M., GERLACH, R., TARR, G. & BEH, E. (2020). Impacto de la volatilidad de demanda en el pronóstico: ARIMAX y ETSX. *Computers & Industrial Engineering*.
- ALNAHHAL, Mohammad; AYLAK, Bilal L.; AL HAZZA, Mohammad; SAKHRIEH, Ahmad. *Economic Order Quantity: A State-of-the-Art in the Era of Uncertain Supply Chains*. *Sustainability*. 2024, vol. 16, n.º 14, p. 5965. DOI: <https://doi.org/10.3390/su16145965>.
- CARBONNEAU, R.; LAFRAMBOISE, K.; VAHIDOV, R. Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, v. 184, n. 3, p. 1140–1154, 2008. Disponible en: <https://doi.org/10.1016/j.ejor.2006.12.004>.
- CHONG, A. Y. L.; LI, B.; NGAI, E. W. T.; CH'NG, E.; LEE, F. Predicting online product sales via online reviews, sentiments, and promotion strategies: A big data architecture and neural network approach. *International Journal of Operations & Production Management*, v. 37, n. 11, p. 1056–1078, 2017
- DA VEIGA, et al. (2020). Modelos de predicción de demanda en productos perecederos: aplicación de ARIMA y Holt-Winters (H-W). *Journal of Big Data*. SpringerOpen.
- GRAVES, S. C.; WILLEMS, S. P. (2023). Extensions to the guaranteed service model for industrial applications of multi-echelon inventory optimization. *Operaciones de Investigación Aplicadas*, en prensa. [ScienceDirect](https://www.sciencedirect.com)
- LANEY, D. (2001). *3D data management: Controlling data volume, velocity, and variety*. META Group Research Note, 6(70), 1–4.

- MARTÍNEZ ROJAS, N., & ANDRADE SOSA, H. H. (2016). Integración de la lógica difusa a la dinámica de sistemas para la selección de terrenos de cultivos agrícolas. *Revista Elementos*, (6), 1–18. <https://dialnet.unirioja.es/download/articulo/5676771.pdf>
- SANI, R.; KINGSMAN, B. G. (1997). Forecast accuracy and inventory performance: Insights on their relationship from the M5 competition data. *Methods de Gestión de Inventarios y Pronóstico*, 2024.
- SANTORO, et al. (2025). Modelos clásicos de series de tiempo: ARIMA, SARIMA y Holt-Winters. *International Journal of Scientific Interdisciplinary Research*.
- WANG, J., XU, C., ZHANG, J., & ZHONG, R. Y. (2016). Big data analytics for intelligent manufacturing systems: A review. *Journal of Manufacturing Systems*, 62, 738–749. En línea, <https://doi.org/10.1016/j.jmsy.2016.10.006>
- WILSON ADARME-JAIMES, M. & DÍAZ-SUÁREZ, F. (2012). Medición del desempeño para cadenas de abastecimiento en ambientes de imprecisión usando lógica difusa. *Revista Colombiana de Ingeniería*, 32(1), 30–42. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0123-21262012000100006 (recuperado de SciELO Colombia)
- ZHONG, R. Y., XU, X., KLOTZ, E., & NEWMAN, S. T. (2017). Intelligent manufacturing in the context of Industry 4.0: A review. *Engineering*, 3(5), 616–630. <https://doi.org/10.1016/j.eng.2017.05.015>

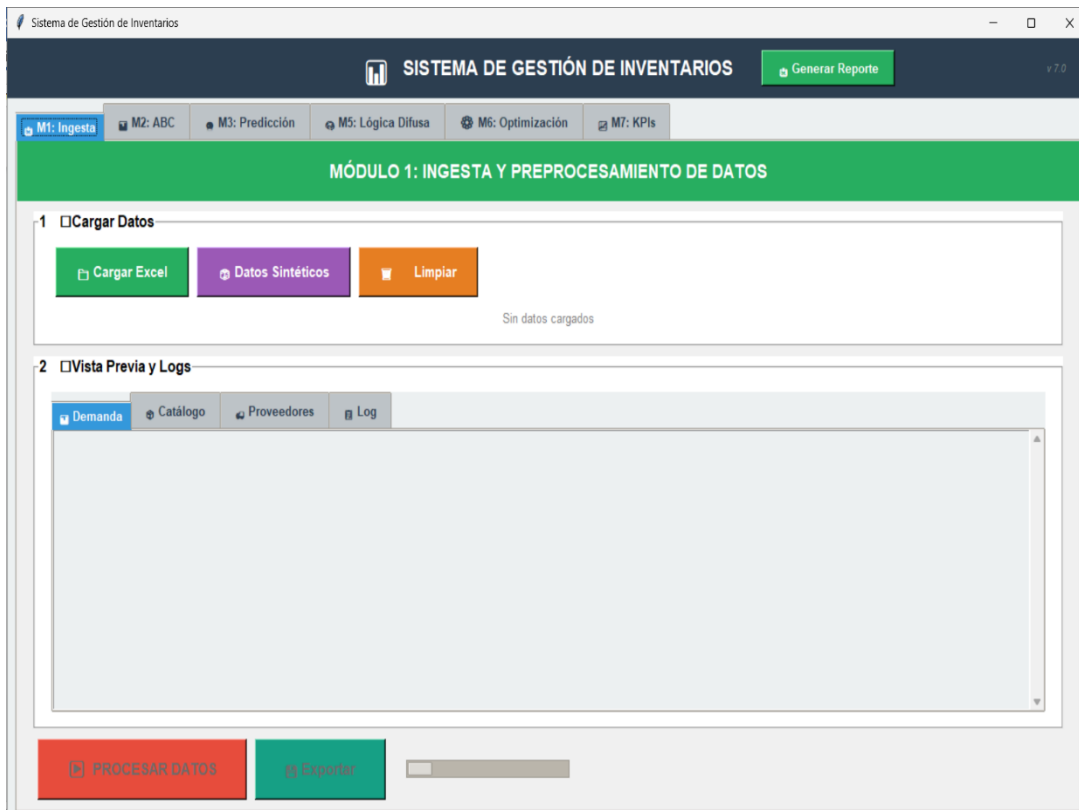
Apéndices

Apéndice A. Arquitectura general del modelo

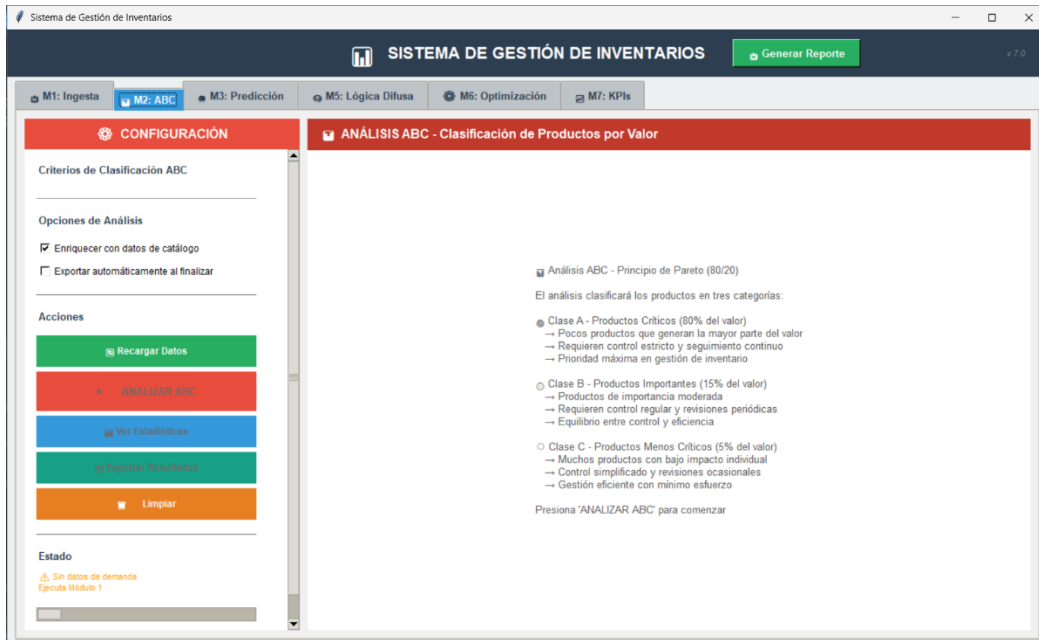
El sistema fue diseñado bajo una arquitectura modular por capas, alineada con principios de sistemas inteligentes y buenas prácticas de ingeniería de software. Esta estructura garantiza una separación clara de responsabilidades entre componentes.

La arquitectura permite escalabilidad funcional y computacional, así como facilidad de mantenimiento y actualización. Además, favorece la reutilización de módulos analíticos y predictivos en otros contextos o desarrollos futuros. La arquitectura se estructura en cinco módulos funcionales principales:

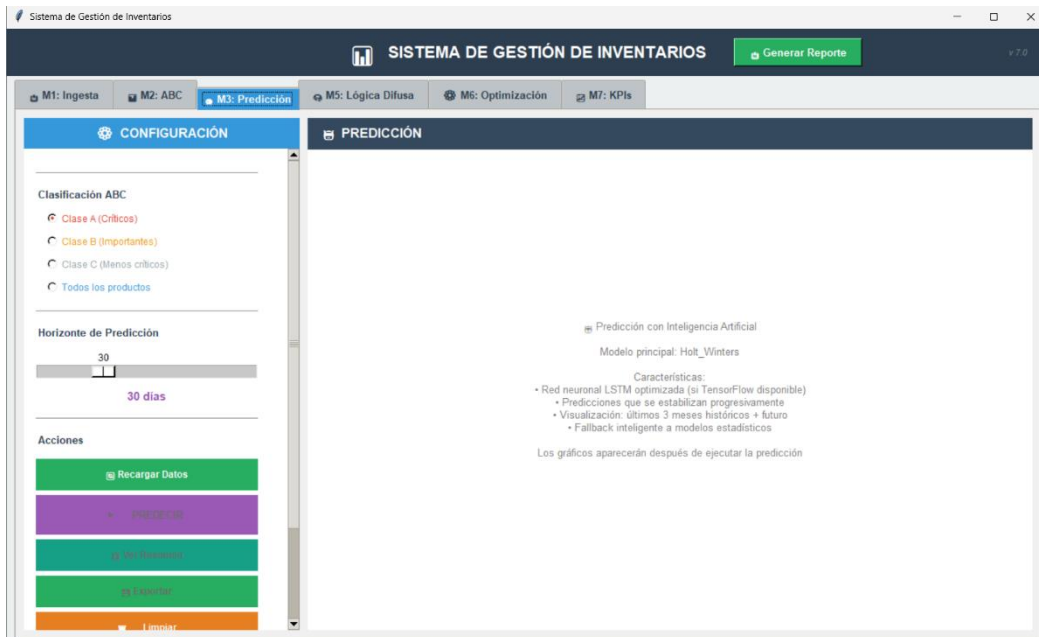
1. Módulo de ingreso de datos: se encarga de hacer el primer filtro y revisar la congruencia de los datos.



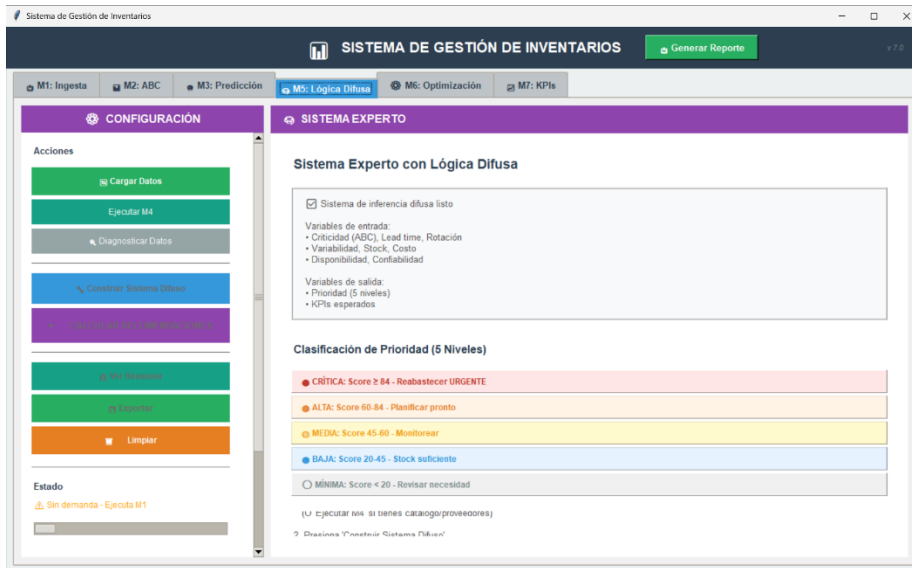
2. Módulo de preprocesamiento y análisis estadístico: se encarga de realizar la clasificación ABC y la curva de Pareto.



3. Módulo de predicción de demanda: se encargada de hacer la predicción de cada uno de los productos



5. Módulo de inferencia difusa: se encarga de revisar condiciones y hacer las recomendaciones a cada uno de los productos



7. Módulo de generación de salidas y KPIs: este módulo se encarga de realizar el cálculo numérico de cada uno de los indicadores de desempeño para los productos



Cada uno de los módulos se implementa mediante script de programación independientes que interactúan de forma secuencial mediante estructuras de datos compartidas (principalmente DataFrames de Pandas).

Apéndice B. Entorno de desarrollo y librerías empleadas

El sistema fue desarrollado en el lenguaje de programación **Python**, seleccionado por su amplio ecosistema científico y su capacidad para integrar análisis estadístico, modelos predictivos y lógica difusa en un mismo entorno. Las principales librerías utilizadas son:

- **NumPy**: soporte para cálculo numérico, operaciones vectorizadas y manejo eficiente de arreglos multidimensionales.
- **Pandas**: ingesta, limpieza, transformación y estructuración de datos históricos de inventarios y demanda.
- **SciPy**: soporte estadístico y funciones matemáticas auxiliares.
- **Scikit-learn**: normalización de variables, cálculo de métricas estadísticas y preprocesamiento de datos.
- **Statsmodels**: implementación de modelos de series de tiempo (ARIMA, suavizado exponencial y análisis estadístico).
- **Scikit-fuzzy**: construcción del sistema de inferencia difusa, definición de funciones de pertenencia, reglas y procesos de defuzzificación.
- **Matplotlib / Seaborn**: visualización de datos, análisis exploratorio y representación gráfica de funciones de pertenencia y resultados.

Este conjunto de herramientas permite implementar un sistema híbrido cuantitativo–cualitativo, garantizando rigor matemático y alta interpretabilidad.

Apéndice C. Descripción modular del sistema

En esta sección se profundiza en cada módulo del sistema, incorporando referencias directas a **fragmentos reales del código fuente** con el fin de contextualizar la arquitectura desde la perspectiva de la implementación. Las extensiones de código se presentan como extractos representativos que ilustran la lógica interna sin comprometer la legibilidad del anexo.

En esta sección se profundiza en cada módulo del sistema, incorporando referencias directas a estructuras, funciones y flujos lógicos presentes en la implementación en Python. El objetivo es evidenciar cómo las decisiones arquitectónicas se materializan a nivel de programación, aportando mayor rigor técnico y trazabilidad entre el diseño conceptual y el código fuente.

- **Módulo de ingesta y validación de datos**

Función principal: importar, validar y estructurar los datos históricos del inventario y la demanda.

Implementación en código: Este módulo se implementa mediante una clase dedicada que centraliza las operaciones de carga y validación, permitiendo encapsular responsabilidades y garantizar reutilización.

```
class IngestionModule:
    def __init__(self):
        self.data = None

    def load_excel(self, file_path: str) -> pd.DataFrame:
        df = pd.read_excel(file_path)
        df = df.drop_duplicates()
        df = df.fillna(method='ffill')
        return df
```

Procesos clave: Carga de archivos Excel mediante Pandas, eliminación de duplicados y tratamiento de valores faltantes y normalización estructural de columnas.

Entradas: archivos CSV o Excel con información histórica de demanda, niveles de stock, costos, lead time y disponibilidad.

Salidas: DataFrame estructurado y validado que alimenta las capas posteriores del sistema.

- **Módulo de preprocesamiento y análisis estadístico**

Función principal: preparar las variables para su uso en modelos predictivos y en el sistema difuso.

Implementación en código: Las transformaciones se aplican directamente sobre estructuras DataFrame, utilizando operaciones vectorizadas para eficiencia computacional.

```
from sklearn.preprocessing import MinMaxScaler

scaler = MinMaxScaler()
df_scaled = pd.DataFrame(
    scaler.fit_transform(df_numeric),
    columns=df_numeric.columns
)
```

Procesos implementados: normalización min–max en el rango [0,1], cálculo de métricas estadísticas mediante operaciones nativas de Pandas y NumPy y suavizado de series temporales con ventanas móviles.

Resultado técnico: variables homogéneas y estables, compatibles con el sistema difuso.

Estructura de implementación: Este módulo se apoya en funciones dedicadas a la transformación de los datos, típicamente encapsuladas en rutinas de limpieza y escalado. En el código, estas operaciones se realizan sobre objetos DataFrame, permitiendo aplicar transformaciones vectorizadas y reproducibles.

- **Módulo de predicción de demanda**

Función principal: estimar la demanda futura a partir del comportamiento histórico.

Implementación en código: El módulo emplea modelos de series temporales para capturar patrones de tendencia y estacionalidad.

```
from statsmodels.tsa.arima.model import ARIMA

model = ARIMA(demand_series, order=(1, 1, 1))
model_fit = model.fit()
forecast = model_fit.forecast(steps=horizon)
```

Salidas del módulo: Demanda proyectada, variables predictivas que alimentan el sistema difuso, este enfoque aporta capacidad prospectiva y rigor estadístico al modelo.

Función principal: estimar la demanda futura a partir del comportamiento histórico.

Estructura de implementación:

El módulo de predicción se implementa mediante funciones específicas para el ajuste y evaluación de modelos de series temporales. Estas funciones reciben como entrada series previamente normalizadas y suavizadas, lo que mejora la estabilidad numérica del proceso de estimación.

Modelos implementados:

- Promedios móviles simples y ponderados, utilizados como línea base.
- Suavizado exponencial simple y doble para capturar tendencia.
- Modelos ARIMA, configurados mediante parámetros (p, d, q), ajustados usando rutinas de statsmodels.tsa.

Durante la ejecución, el modelo selecciona el pronóstico más representativo en función del comportamiento histórico de la serie, priorizando estabilidad y coherencia sobre complejidad excesiva.

Módulo de inferencia difusa

Función principal: integrar información cuantitativa y cualitativa para priorizar la gestión del inventario.

Implementación en código: el sistema difuso se construye mediante objetos Antecedent y Consequent, definidos sobre universos normalizados.

```
import skfuzzy as fuzz
from skfuzzy import control as ctrl

stock = ctrl.Antecedent(np.arange(0, 1.01, 0.01), 'stock')
priority = ctrl.Consequent(np.arange(0, 1.01, 0.01), 'priority')

stock['low'] = fuzz.trimf(stock.universe, [0, 0, 0.4])
stock['medium'] = fuzz.tr
```

El uso del enfoque Mamdani y la defuzzificación por centroide convierten la salida difusa en un valor continuo interpretable, el cual es utilizado como entrada directa para la generación de prioridades y KPIs, consolidando a este módulo como el núcleo decisional de la arquitectura del sistema.


Apéndice D. Reporte del sistema

El sistema genera dos archivos, uno de ellos es un reporte tipo resumen ejecutivo dentro del cual se presentan los resultados más importantes, a continuación, se muestra detalladamente lo que nos da este informe.


En la parte del resumen del reporte nos muestra un resumen de características principales del sistema y lo que se encontró en el proceso de análisis de datos como lo son las métricas claves y hallazgos principales.

1. Resumen Ejecutivo

El Sistema Inteligente de Gestión de Inventarios para KIOS SAS procesó exitosamente los datos a través de 6 módulos analíticos. El sistema integra redes neuronales LSTM para predicción de demanda, lógica difusa para priorización dinámica y optimización matemática para parámetros de inventario. Los resultados demuestran mejoras significativas en la gestión del inventario, proporcionando herramientas para la reducción de costos, minimización de faltantes y optimización del nivel de servicio al cliente.

 **Métricas Clave**



 **Hallazgos Principales**

- Clasificación ABC: 30 productos críticos (A), 17 importantes (B), 13 complementarios (C)

Después del resumen se encuentran los datos de salida de cada uno de los módulos, los cuales se muestran a continuación:

Para el modulo 1, se muetsran la cantidad de datos procesados, el numero de procustos, el peridodo de analisis y si el funcionamiento de este.

Ingesta de Datos

Se procesaron exitosamente 13,870 registros de demanda histórica, correspondientes a 60 productos únicos. El período analizado abarca desde 2023-01-01 hasta 2024-12-31. Los datos fueron validados, limpiados y preparados para el análisis posterior.

Para el modulo 2, muestra lo correspondiente a la clasificacion ABC, el diagrama de pareto con su respectiva rotacion calculada internamente y diagramas que muetsran el valor según la clasificacion ABC.

Análisis ABC

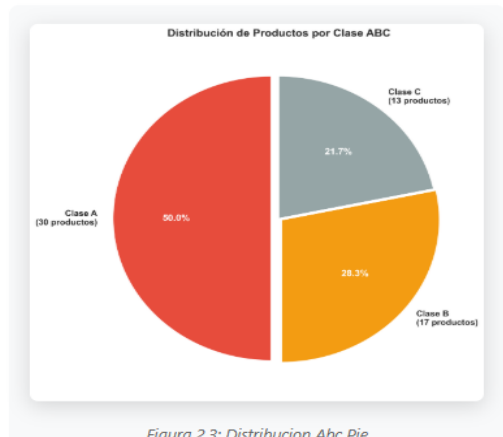
La clasificación ABC identificó 30 productos clase A (50.0% - alta rotación), 17 productos clase B (28.3% - rotación media) y 13 productos clase C (21.7% - baja rotación). Los productos clase A, aunque representan una minoría, generan aproximadamente el 80% del valor del inventario y requieren mayor atención en la gestión y control de existencias.



Figura 2.1: Analisis Abc Completo



Figura 2.2: Curva Pareto Abc



Fiaura 2.3: Distribucion Abc Pie

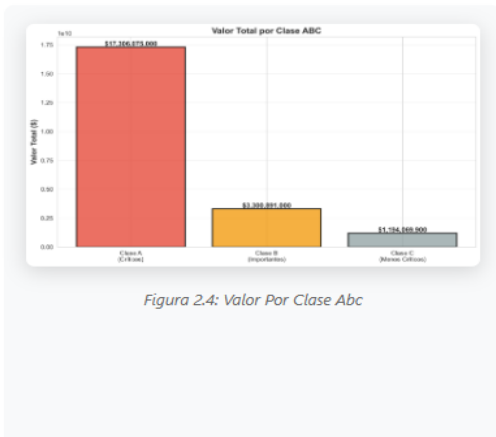


Figura 2.4: Valor Por Clase Abc

Para el módulo 3, el reporte muestra el modelo de predicción utilizada, seleccionada por el sistema internamente, en top de los productos, la gráfica de la distribución de errores y la gráfica de predicción de algunos productos.

Predicción de Demanda con IA

Se implementó el modelo de predicción LSTM para pronosticar la demanda de 0 productos con un horizonte de 30 días.

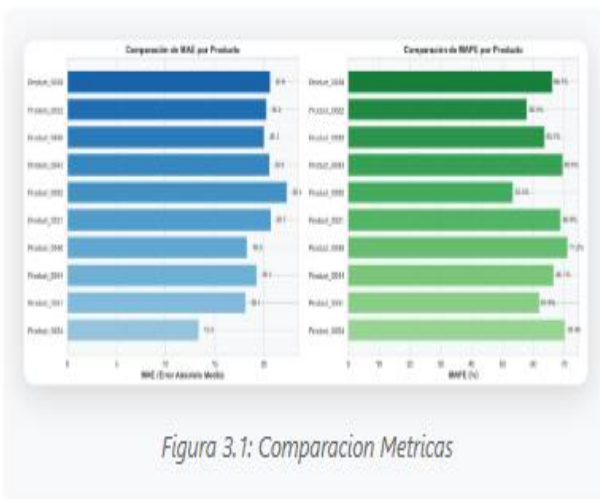


Figura 3.1: Comparacion Metricas



Figura 3.2: Distribucion Errores

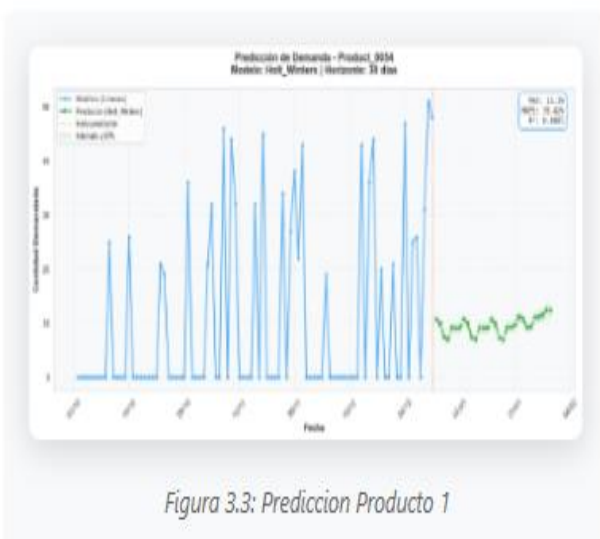


Figura 3.3: Prediccion Producto 1

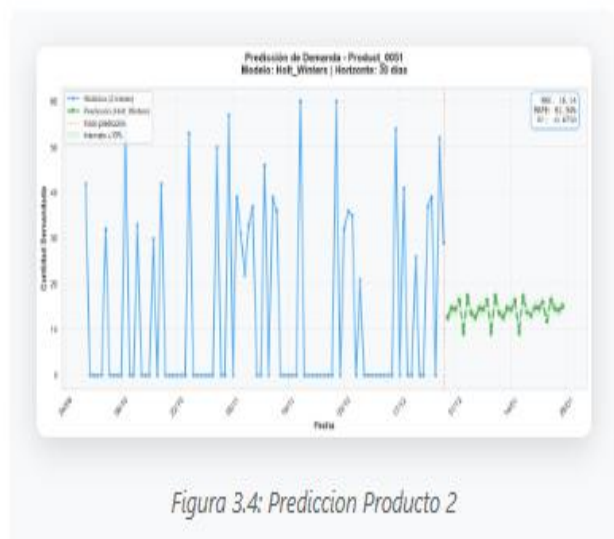


Figura 3.4: Prediccion Producto 2

Para el modulo 5, el reporte muestra las funciones de membresia utilizadas en el motor de inferencia difusa, la grafica de distribucion de productos según creiticidad, rotación, stock y variabilidad para dar a entender un poco el comportamiento de los productos.

🧠 Lógica Difusa - Priorización Inteligente

El sistema de lógica difusa evaluó 60 productos utilizando un motor de inferencia con reglas expertas. Se identificaron 0 productos con prioridad alta de reabastecimiento. El módulo integra múltiples variables (clasificación ABC, nivel de inventario, variabilidad, lead time) para generar recomendaciones inteligentes de compra.

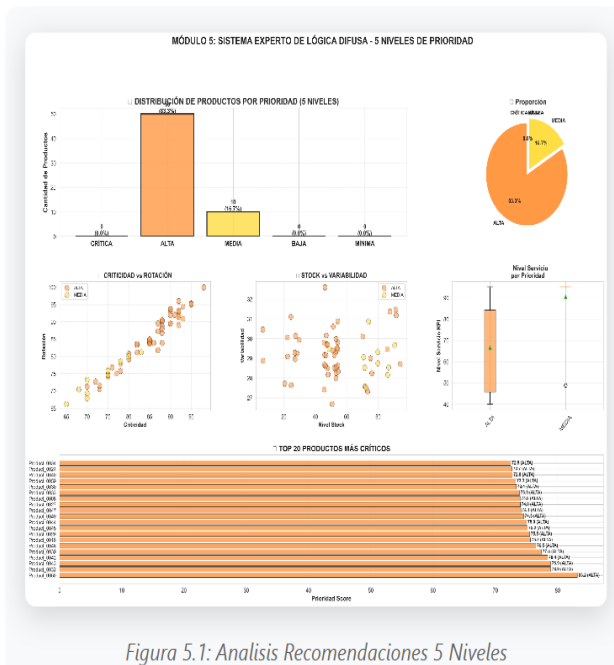


Figura 5.1: Analisis Recomendaciones 5 Niveles

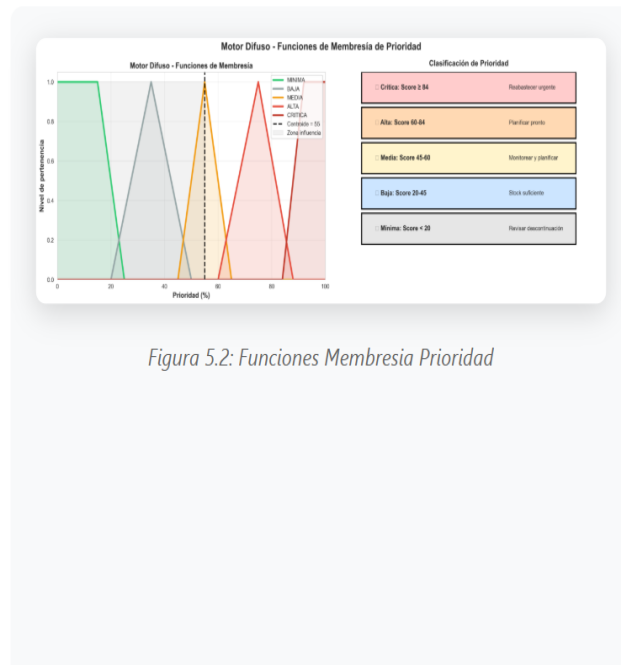
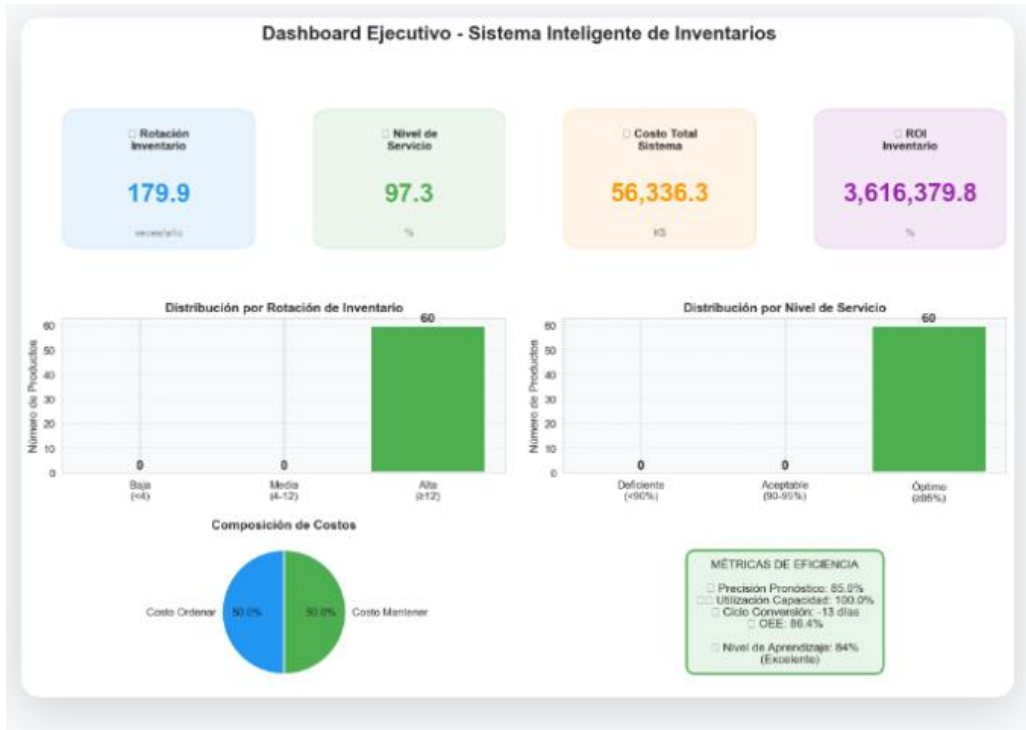
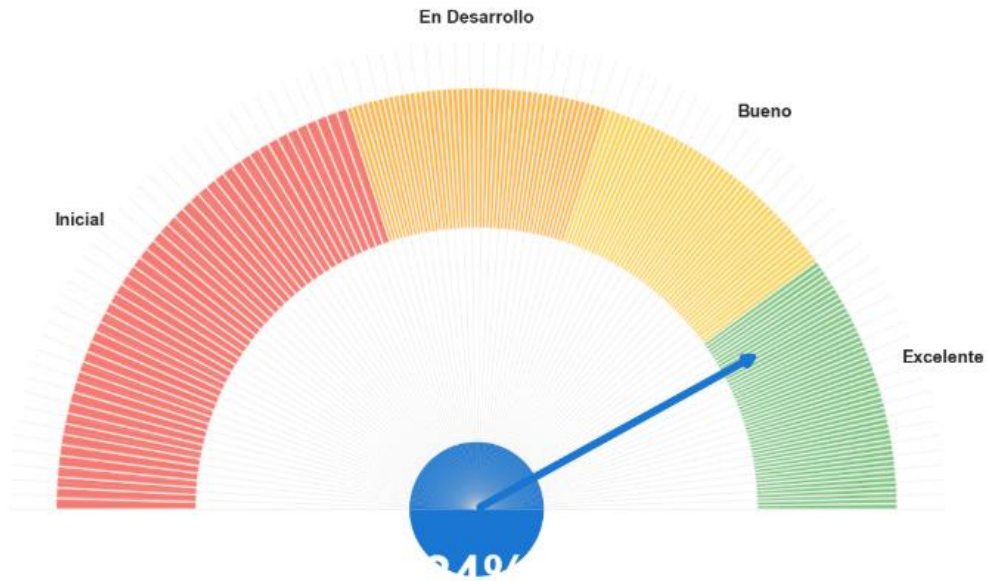


Figura 5.2: Funciones Membresia Prioridad

Para el modulo 7, el cual corresponde al calulo de cada uno de los KPIs, los datos que se incluyen en el reporten corresponde a la rotacion del inventario, nivel de servicio, costo total del sistema ademas de esto se muestra graficos de distribución de productos por rotación, por nivel de servicios y la composicion de costos del invenatrio. Ademas de todos estos calculos se mostrar el nivel de aprendizaje del sistema



Nivel de Aprendizaje del Sistema



Categoría: Excelente

