

**INVESTIGACIÓN**  
**EL PAPEL DE LA INTELIGENCIA ARTIFICIAL EN LA OPTIMIZACIÓN DEL  
PRONÓSTICO DE DEMANDA Y LAS SUGERENCIAS DE VENTA  
PERSONALIZADAS EN LAS CADENAS DE CONSUMO MASIVO EN  
COLOMBIA**

**DANIELA VILLAMIZAR MURILLO**  
**SANTIAGO AGUIRRE ARAQUE**



Pontificia Universidad  
**JAVERIANA**  
Cali

**PONTIFICIA UNIVERSIDAD JAVERIANA**  
**FACULTAD DE CIENCIAS ECONÓMICAS**  
**Y ADMINISTRATIVAS**  
**MAESTRÍA EN ADMINISTRACIÓN DE EMPRESAS**  
**SANTIAGO DE CALI**

**2026**

**INVESTIGACIÓN**  
**EL PAPEL DE LA INTELIGENCIA ARTIFICIAL EN LA OPTIMIZACIÓN DEL  
PRONÓSTICO DE DEMANDA Y LAS SUGERENCIAS DE VENTA  
PERSONALIZADAS EN LAS CADENAS DE CONSUMO MASIVO EN  
COLOMBIA**

**DANIELA VILLAMIZAR MURILLO**  
**SANTIAGO AGUIRRE ARAQUE**

**Trabajo de grado presentado como requisito parcial para optar por el título de  
Magíster en ADMINISTRACIÓN DE EMPRESAS**

**Director del trabajo de grado: David Arango Londoño**  
**Científico de Datos**

**PONTIFICIA UNIVERSIDAD JAVERIANA**  
**FACULTAD DE CIENCIAS ECONÓMICAS**  
**Y ADMINISTRATIVAS**  
**MAESTRÍA EN ADMINISTRACIÓN DE EMPRESAS**  
**SANTIAGO DE CALI**

**2026**

Santiago de Cali, 5 de febrero de 2026

Doctor (a)

Fabian Fernando Osorio Tinoco

Decano

Facultad De Ciencias Económicas y Administrativas

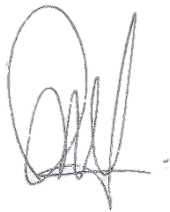
Pontificia Universidad Javeriana

Santiago de Cali

Por medio de la presente estamos entregando a usted el Trabajo de Grado cuyo título es “Magíster en Administración de Empresas”.

Esperamos que este Trabajo cumpla con los requisitos académicos exigidos y que alcance el propósito para el cual fue elaborado.

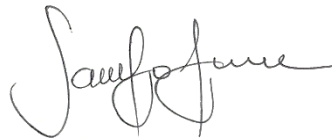
Atentamente



---

Daniela Villamizar Murillo

cc. 1144085403



---

Santiago Aguirre Araque

cc. 1144070530

Santiago de Cali, 5 de febrero de 2026

Doctor

Fabian Fernando Osorio Tinoco

Decano

Facultad de Ciencias Económicas y Administrativas

Pontificia Universidad Javeriana

Santiago de Cali

Por medio de la presente me permito comunicarle, que en mi calidad de director de trabajo de grado he leído detenidamente el informe final del estudio titulado **“El Papel de la Inteligencia Artificial en la Optimización del Pronóstico de Demanda y las Sugerencias de Venta Personalizadas en las Cadenas de Consumo Masivo en Colombia.** “, realizado por los estudiantes de Maestría en Administración de empresas de la Facultad de Ciencias Económicas y Administrativas de la Universidad Javeriana nombres: **Daniela Villamizar Murillo c.c. 1144085403 & Santiago Aguirre Araque c.c 1144070530**, y considero que cumple con todos los requisitos requeridos para ser presentada a evaluación.

Atentamente,

---

David Arango Londoño

---

**David Arango Londoño**  
Director del Trabajo de Grado

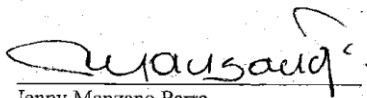
ARTÍCULO 23 de la resolución N° 13 de julio 6 de 1946

“La Universidad no se hace responsable por los conceptos emitidos por sus alumnos en sus trabajos de Tesis. Sólo velará porque no se publique nada contrario al dogma y a la moral católica y porque la Tesis no contenga ataques o polémicas puramente personales; antes bien, se vea en ellas al anhelo de buscar la Verdad y la Justicia”.


**“EL PAPEL DE LA INTELIGENCIA ARTIFICIAL EN LA OPTIMIZACIÓN DEL PRONÓSTICO DE DEMANDA Y LAS SUGESTIONES DE VENTAS PERSONALIZADAS EN LAS CADENAS DE CONSUMO MASIVO EN COLOMBIA”.** Aprobado por el Comité de Trabajos de Grado en cumplimiento de los requisitos exigidos por la Pontificia Universidad Javeriana para optar por el título de Magíster en Administración de Empresas.



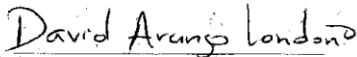
Fabian Fernández Osorio Tinoco  
Decano  
Facultad de Ciencias Económicas y Administrativas



Jenny Manzano Parra  
Directora Maestría en Adm. de Empresas



Pedro Pablo Meza  
Jurado



David Arango Londoño  
Director del Trabajo de Grado

Santiago de Cali, 29 enero de 2026

## Contenido

### Capítulo 1: Introducción y Planteamiento del Problema

- 1.1. Contexto Estratégico del Sector de Consumo Masivo (CPG) en Colombia
- 1.2. El Desafío del Pronóstico de Demanda Tradicional
- 1.3. La Emergencia de la Inteligencia Artificial como Solución Estratégica
- 1.4. Formulación del Problema y Pregunta de Investigación
- 1.5. Justificación e Impacto Potencial

### Capítulo 2: Marco Teórico y Revisión de la Literatura

- 2.1. Fundamentos de la Predicción de Series Temporales
  - 2.1.1. Modelos Estadísticos Tradicionales: Regresión Lineal
    - 2.1.1.1. Ventajas de la regresión lineal
    - 2.1.1.2. Desventajas y limitaciones de la regresión lineal
  - 2.1.2. Modelos Estadísticos Tradicionales: ARIMA
    - 2.1.2.1. Componentes del modelo ARIMA
    - 2.1.2.2. Ventajas y desventajas del modelo ARIMA
    - 2.1.2.3. Aplicabilidad en pronósticos de ventas
  - 2.1.3. Modelos de Aprendizaje Automático: Support Vector Machines (SVM)
    - 2.1.3.1. Características del algoritmo
  - 2.1.4. Modelos de Aprendizaje Automático: Random Forest (RF)
    - 2.1.4.1. Ventajas y desventajas del modelo RF
    - 2.1.4.2. Aplicabilidad en pronósticos de ventas
  - 2.1.5. Modelos de Aprendizaje Automático: Extreme Gradient Boosting (XGBOOST)
    - 2.1.5.1. Ventajas y desventajas del modelo XGBoost
    - 2.1.5.2. Aplicabilidad en pronósticos de ventas
- 2.2. Optimización de la Gestión de Inventarios en CPG
  - 2.2.1. Métricas Clave de Desempeño (KPIs)
    - 2.2.1.1. MAE
    - 2.2.1.2. RMSE
    - 2.2.1.3. MAPE
    - 2.2.1.4. KPIs de gestión
      - 2.2.1.4.1. Gestión de inventarios
      - 2.2.1.4.2. Inventario de seguridad
      - 2.2.1.4.3. Rotación de inventarios
      - 2.2.1.4.4. Agotados
  - 2.2.2. El Vínculo entre Precisión del Pronóstico y Eficiencia del Inventario
- 2.3. Personalización de la Experiencia del Cliente Mediante IA
  - 2.3.1. Motores de Recomendación y Segmentación de Clientes
  - 2.3.2. Impacto de la Personalización en la Satisfacción y Lealtad del Cliente
- 2.4. Marco Ético y Regulatorio de la IA en Colombia
  - 2.4.1. Ley de Protección de Datos Personales (Ley 1581 de 2012)
  - 2.4.2. Propuestas de Regulación de IA y Clasificación de Riesgo
  - 2.4.3. Principios de IA Ética: Transparencia, Equidad y Responsabilidad

- 2.4.4. Integración práctica en la metodología de pronóstico
  - 2.4.4.1. Anonimización y minimización de datos (Privacidad)
  - 2.4.4.2. Consentimiento e información a titulares
  - 2.4.4.3. Evaluación y mitigación de sesgos (Equidad)
  - 2.4.4.4. Interpretabilidad y explicabilidad (Transparencia)
  - 2.4.4.5. Documentación y trazabilidad (Rendición de cuentas)
- 2.5. Síntesis y Brecha del Conocimiento

### **Capítulo 3: Metodología de Investigación Aplicada**

- 3.1. Diseño de la Investigación
- 3.2. Población, Muestra y Operacionalización de Variables
  - 3.2.1. Fuente de Datos y Alcance
  - 3.2.2. Definición de Variables
  - 3.2.3. Selección de la Muestra (Estrategia de Muestreo)
- 3.3. Procedimiento de Ingeniería y Preprocesamiento de Datos
- 3.4. Implementación de Modelos y Estrategia de Validación
  - 3.4.1. Configuración de Modelos
  - 3.4.2. Métricas de Evaluación y Validación
- 3.5. Metodología para la Optimización del Pronóstico de la Demanda mediante Análisis Histórico y Modelado Estadístico
- 3.6. Implementación y Puesta a Punto de Modelos (Hyperparameter Tuning)

### **Capítulo 4: Presentación y Análisis de Resultados**

- 4.1. Análisis Comparativo de la Precisión de los Pronósticos
- 4.2. Impacto Simulado en la Gestión de Inventarios
  - 4.2.1. Impacto en indicadores financieros
    - 4.2.1.1. Reducción de costos logísticos y de almacenamiento
    - 4.2.1.2. Menor capital inmovilizado en inventarios
    - 4.2.1.3. Impacto en ROI y EBITDA
- 4.3. Dimensión Empírica de la Personalización: Segmentación y Prototipos de Recomendación
  - 4.3.1. Segmentación Conductual y Dinámica
  - 4.3.2. Prototipos de Motores de Recomendación
  - 4.3.3. Sincronización entre Inventario y Experiencia del Cliente
  - 4.3.4. Contribuciones del Autor y Hallazgos Clave

### **Capítulo 5: Discusión, Conclusiones y Recomendaciones**

- 5.1. Discusión de los Hallazgos
- 5.2. Conclusiones
- 5.3. Recomendaciones Estratégicas y Gerenciales
- 5.4. Limitaciones del Estudio y Futuras Investigaciones
- 5.5. Implicaciones Institucionales, Sectoriales y de Compromiso Social
  - 5.5.1. Compromiso Social: Abastecimiento Responsable y Sostenibilidad

- 5.5.2. Políticas Sectoriales: Modernización de la Industria Colombiana
- 5.5.3. Misión Institucional: Innovación con Ética y Transparencia

## **Referencias Bibliográficas**

## Resumen

Esta investigación evalúa el impacto de la Inteligencia Artificial (IA) en la optimización de la cadena de suministro para el sector de consumo masivo (CPG) en Colombia. El objetivo general es determinar si las técnicas de IA, específicamente los modelos Random Forest (RF), SVM y XGBoost, superan significativamente a los métodos estadísticos tradicionales como ARIMA y Regresión Lineal en la precisión del pronóstico de demanda. La metodología emplea un diseño cuantitativo y comparativo, utilizando datos históricos de ventas, promociones y clientes de empresas líderes como Colgate-Palmolive. Los resultados demuestran que los modelos de IA mejoran la precisión del pronóstico, con RF destacando en el corto plazo y XGBoost en el largo plazo. Esta mejora se traduce en una optimización cuantificable de los indicadores de inventario, como la reducción de costos de mantenimiento y tasas de agotamiento. Adicionalmente, se evalúa el impacto positivo de las sugerencias de venta personalizadas basadas en IA sobre la satisfacción del cliente. Las conclusiones ofrecen un marco de decisión para la adopción de IA, alineado con el contexto regulatorio y ético de Colombia.

**Palabras Clave:** pronóstico de demanda, inteligencia artificial, gestión de inventarios, personalización, consumo masivo, Colombia.

## Abstract

This research evaluates the impact of Artificial Intelligence (AI) on supply chain optimization for the consumer-packaged goods (CPG) sector in Colombia. The general objective is to determine whether AI techniques, specifically Random Forest (RF), SVM and XGBoost models, significantly outperform traditional statistical methods like ARIMA and Linear Regression in demand forecasting accuracy across short, medium, and long-term horizons. The methodology uses a quantitative, comparative design, leveraging historical sales, promotion, and customer data from leading companies such as Colgate-Palmolive. The results demonstrate that AI models improve forecast accuracy, with RF excelling in the short term and XGBoost in the long term. This improvement translates into a quantifiable optimization of inventory metrics, such as reduced holding costs and stockout rates. Additionally, the positive impact of AI-based personalized sales suggestions on customer satisfaction is evaluated. The conclusions provide a decision-making framework for AI adoption, aligned with the regulatory and ethical context of Colombia.

**Key Words:** demand forecasting, artificial intelligence, inventory management, personalization, consumer-packaged goods, Colombia.

## LISTA DE TABLAS

	pág.
<b>Tabla 1.</b> <i>Comparación entre modelos</i>	31
<b>Tabla 2.</b> <i>Síntesis de KPIs de gestión</i>	40
<b>Tabla 3.</b> <i>Resumen de Métricas</i>	56
<b>Tabla 4.</b> <i>Resumen métricas desempeño Cepillo 360</i>	63
<b>Tabla 5.</b> <i>Métricas de Desempeño Crema Dental</i>	64
<b>Tabla 6.</b> <i>Métricas de Desempeño Jabones</i>	65
<b>Tabla 7.</b> <i>KPIs Desempeño</i>	67
<b>Tabla 8.</b> <i>Resultados Simulación Cepillos</i>	71
<b>Tabla 9.</b> <i>Resultados rotación de inventario por modelo</i>	72
<b>Tabla 10.</b> <i>Resultados Simulación Crema</i>	75
<b>Tabla 11.</b> <i>Rotación de inventario por modelo</i>	76
<b>Tabla 12.</b> <i>Resultados Simulación Jabones</i>	78
<b>Tabla 13.</b> <i>Rotación de inventario por modelo para jabones</i>	79

## LISTA DE FIGURAS

	pág.
<b>Figura 1.</b> <i>Métrica MAE</i>	33
<b>Figura 2.</b> <i>Métrica RMSE</i>	33
<b>Figura 3.</b> <i>Métrica MAPE</i>	34
<b>Figura 4.</b> <i>Serie de Tiempo y pronósticos Cepillos 360</i>	64
<b>Figura 5.</b> <i>Serie de Tiempo y pronósticos Crema Dental</i>	65
<b>Figura 6.</b> <i>Serie de Tiempo y Pronósticos Jabones</i>	66
<b>Figura 7.</b> <i>Gráfica inventario Cepillo 360</i>	73
<b>Figura 8.</b> <i>Gráfica inventario Crema Triple Acción</i>	77
<b>Figura 9.</b> <i>Inventario Jabones</i>	80

## **Capítulo 1: Introducción y Planteamiento del Problema**

### **1.1. Contexto Estratégico del Sector de Consumo Masivo (CPG) en Colombia**

En Colombia, el sector de bienes de consumo masivo (CPG, por sus siglas en inglés), se desenvuelve en un entorno de muy alta competitividad, por tal motivo la eficiencia operativa y la agilidad con la que se opere la cadena de suministro no se consideran únicamente ventajas competitivas, sino requisitos fundamentales para la supervivencia y la rentabilidad (Rennie, 2025). Empresas multinacionales y locales, como Colgate Palmolive y Tecnoquímicas, funcionan dentro de un mercado dinámico que se caracteriza por márgenes cada vez más ajustados y una intensa competencia por la preferencia del consumidor. En este marco, la capacidad de anticipar la demanda de manera precisa se convierte en un pilar esencial de la planeación estratégica, impactando directamente la producción, gestión de inventarios y, finalmente, la satisfacción del cliente (Verma, 2025).

La situación en Latinoamérica se ha complejizado aún más como resultado de una transformación significativa en el comportamiento de los consumidores. En 2020, la pandemia de COVID-19 aceleró la migración hacia canales de comercio electrónico y digitales, lo que ha generado la incorporación de nuevas variables y un incremento en la volatilidad de los patrones de compra. Paralelamente, se ha identificado un fenómeno que la consultora McKinsey ha denominado "conmoción a la lealtad", en el cual hasta un 40% de los consumidores de la región han decidido abandonar sus marcas preferidas en favor de opciones que ofrecen una mejor relación calidad-precio o mayor accesibilidad económica (Fernandes, Suziki, Fitts, & Ize, 2020). Esta pérdida de lealtad tradicional hacia las marcas ha intensificado la incertidumbre en el mercado, reduciendo la utilidad de los patrones históricos de ventas como herramientas confiables para predecir el comportamiento futuro del consumidor.

Para empresas colombianas con ambiciones de expansión internacional, como Tecnoquímicas, la gestión de la cadena de suministro adquiere una dimensión estratégica en un contexto global (Ochoa, Correa, & Atehortua, 2017). La incursión en nuevos mercados introduce desafíos logísticos multifacéticos, así como complejidades regulatorias y fluctuaciones en la demanda, lo que requiere la adopción de modelos de pronóstico más robustos y adaptativos. Estos instrumentos son fundamentales para coordinar de manera eficiente una red de distribución extendida y mitigar el riesgo de disrupciones operativas que podrían generar costos significativos (Trademo, s.f.). En consecuencia, la capacidad de anticipar con precisión la demanda en diversas geografías se consolida como un elemento esencial para impulsar el crecimiento sostenido y reforzar la competitividad en el ámbito internacional.

### **1.2. El Desafío del Pronóstico de Demanda Tradicional**

Históricamente, las organizaciones del sector de bienes de consumo masivo (CPG) han confiado en modelos estadísticos tradicionales para la planificación de la demanda. Entre estos, el modelo ARIMA (Promedio Móvil Integrado Autoregresivo) ha sido un referente estándar en la industria durante décadas (Wang, 2024). Sin embargo, estos métodos presentan

limitaciones significativas en el contexto actual. Por su naturaleza intrínsecamente lineal y univariada, los modelos ARIMA exhiben una capacidad restringida para capturar las dinámicas no lineales y complejas que caracterizan el mercado actual de CPG (Wang, 2024).

La demanda en el sector CPG no puede reducirse a una mera extrapolación de datos históricos; más bien, es el resultado de una interacción compleja de varios factores. Factores como las campañas promocionales, las fluctuaciones de precios, la estacionalidad (que varía según la región y el tipo de producto), las festividades, los eventos disruptivos y, de manera creciente, las tendencias virales en redes sociales influyen de manera decisiva en los patrones de consumo. Los modelos tradicionales como ARIMA y regresión lineal enfrentan dificultades para incorporar estas variables de manera efectiva, lo que a menudo conduce a simplificaciones excesivas y, en consecuencia, a errores de pronóstico significativos (Wang, 2024).

Las implicaciones de estos errores son directas y bastante costosas para las organizaciones. Un pronóstico sobreestimado genera un exceso de inventario (*overstocking*), lo que inmoviliza capital de trabajo, incrementa los costos asociados al almacenamiento y manipulación, y eleva el riesgo de obsolescencia, particularmente en productos con una vida útil corta (Nielsen, 2024). Por otro lado, un pronóstico subestimado resulta en faltantes de stock (*stockouts*), lo que no solo implica la pérdida inmediata de ventas, sino que también deteriora la satisfacción del cliente y, a largo plazo, puede comprometer la reputación de la marca y su posición en el mercado (Netstock, s.f).

### **1.3. La Emergencia de la Inteligencia Artificial como Solución Estratégica**

En un entorno empresarial donde los métodos tradicionales de gestión de la cadena de suministro se quedan cortos ante la complejidad y la rapidez de los cambios del mercado, la Inteligencia Artificial (IA) surge como una herramienta clave. Más allá de ser una solución técnica, la IA se presenta como un elemento estratégico que permite a las empresas replantear sus operaciones y responder de manera más efectiva a las demandas actuales. En Colombia, este tema cobra especial relevancia debido a que se encuentra entre los tres líderes de América Latina en inversión en IA, y según proyecciones recientes, el 54% de las empresas locales planean aumentar sus recursos en esta tecnología para 2025 (BBVA, 2025). Este dato no solo evidencia el interés que está surgiendo, sino también la necesidad de adoptar nuevas herramientas innovadoras que aseguren la competitividad en un contexto global cada vez más desafiante.

Las técnicas de Aprendizaje Automático (Machine Learning), como el modelo Random Forest, y de Aprendizaje Profundo (Deep Learning), marcan una diferencia significativa frente a los enfoques convencionales. Comparados con los modelos estadísticos, estos están diseñados para procesar grandes volúmenes de datos, identificar patrones no lineales complejos y adaptarse de forma continua a nueva información recogida a través de bucles de retroalimentación (*feedback loops*) (Kidwai, 2024). Su capacidad para manejar miles de SKUs al mismo tiempo las hace ideales para sectores como el de consumo masivo, donde la precisión y la escalabilidad son esenciales. A diferencia de los métodos tradicionales, que

suelen ser rígidos, estas tecnologías se adaptan constantemente, lo que las convierte en aliados poderosos para las empresas que buscan flexibilidad operativa (Ali, 2024).

Los beneficios de la IA no son solo teóricos; su aplicación ha generado resultados que respaldan su uso. Estudios han mostrado que su uso puede mejorar la precisión de los pronósticos de demanda entre un 20% y un 50% en comparación con enfoques más básicos (Goavega, s.f). Además, las soluciones basadas en IA logran reducir los errores de predicción entre un 30% y un 50%, y disminuyen las ventas perdidas por desabastecimiento hasta en un 65%. Estos resultados tienen un impacto directo en la rentabilidad, algo que cualquier gerente de operaciones entendería como un argumento contundente para justificar la inversión (Iorio, 2025).

#### **1.4. Formulación del Problema y Pregunta de Investigación**

El problema principal de esta investigación gira en torno a la discrepancia que existe entre la realidad operativa del sector de consumo masivo colombiano y la situación ideal de una cadena de suministro optimizada. Actualmente, el mercado se caracteriza por una alta volatilidad de la demanda y la dependencia de herramientas de pronósticos tradicionales, es por ello por lo que se generan ineficiencias en el sistema como excedentes de inventario y faltantes en ventas. Se busca determinar que las tecnologías emergentes pueden propiciar un escenario ideal para establecer una cadena de suministro ágil y predictiva, la cual pueda alinear con precisión la oferta con la demanda real. La IA se postula como el puente para cerrar esta brecha, sin embargo, su efectividad y aplicabilidad en el contexto colombiano no ha sido suficientemente validada empíricamente, cuando se trata de modelos y horizontes temporales.

Esta brecha mencionada permite la formulación de la siguiente pregunta de investigación, la cual guiará todo el desarrollo de esta tesis:

**¿En qué medida las técnicas de Inteligencia Artificial (Support Vector Machines, Random Forest y XGBoost) superan a los métodos estadísticos tradicionales (Regresión lineal y ARIMA) en la precisión del pronóstico de la demanda en el sector de consumo masivo en Colombia, y cómo se traduce esta mejora en impactos cuantificables sobre la gestión de inventarios y las estrategias de personalización de ventas?**

#### **1.5. Justificación e Impacto Potencial**

Esta investigación se justifica por su relevancia académica, gerencial y social, alineada con los requerimientos establecidos para la misma:

- **Relevancia Académica:** En el ámbito de la administración de empresas, y específicamente en el campo del pronóstico, la literatura académica global ofrece un sinnúmero de comparaciones entre modelos como ARIMA, Regresión lineal, Random Forest (RF), SVM y XGBoost (Wang, 2024). Sin embargo, tras un análisis exhaustivo de los estudios existentes, se evidencia una carencia significativa en la investigación aplicada: la ausencia de análisis que comparen de manera empírica y simultánea estos

tres modelos, considerando diversos horizontes temporales, y situados específicamente en el contexto del mercado de bienes de consumo masivo (CPG) en Colombia. Revisando la literatura existente en el ámbito colombiano, se suele adoptar enfoques muy genéricos o incluso se concentran en otro tipo de sectores como el agrícola (Nino, Nino, & Chaparro, 2023), pasando por alto el sector CPG, que no solo es dinámico sino también esencial para la economía colombiana. Esta tesis tiene como propósito llenar ese vacío, ofreciendo evidencia contextualizada y un análisis profundo que aporte valor tanto al discurso académico como a las decisiones estratégicas de las empresas que operan en este mercado.

- **Relevancia Gerencial:** Para los directivos y gerentes de empresas como Colgate Palmolive, aquellos encargados de la toma de decisiones, esta investigación trasciende del ámbito meramente académico. Los hallazgos derivados del desarrollo de esta tesis buscan proporcionar un marco analítico sólido y fundamentado en datos que facilite la selección e implementación de tecnologías de pronóstico dentro de contextos empresariales reales. Al evaluar el desempeño de distintos modelos según diversos horizontes de planificación —estratégico, táctico y operativo—, se espera ofrecer insumos útiles para orientar las inversiones tecnológicas de manera coherente con las metas organizacionales. Además, la estimación del Retorno de la Inversión (ROI) traducirá las mejoras técnicas resultantes de estas tecnologías en términos financieros concretos, lo que simplificará la justificación de proyectos de inteligencia artificial (IA) ante los stakeholders y garantizará que las decisiones de inversión generen valor económico tangible (WAIR, s.f).
- **Relevancia Social y Ética:** Este estudio aborda la tecnología desde una doble óptica: la eficiencia económica y su repercusión social y ética. Al profundizar en las estrategias de personalización de ventas, se examinará el marco legal y ético aplicable al tratamiento de datos de consumidores en Colombia, garantizando el respeto a la privacidad y los derechos fundamentales de las personas conforme a lo establecido en la Ley 1581 de 2012 y a las regulaciones emergentes sobre inteligencia artificial (White & Case, 2025). De esta manera, se favorece una visión de innovación responsable que armoniza el avance tecnológico con el bienestar colectivo.

## Capítulo 2: Marco Teórico y Revisión de la Literatura

Este capítulo establece el fundamento teórico sobre el cual se construye la investigación. Se realiza una revisión exhaustiva de la literatura académica y de la industria para contextualizar los modelos de pronóstico, las estrategias de optimización de inventarios, las técnicas de personalización y el marco regulatorio pertinente. El objetivo es identificar el estado del arte y la brecha de conocimiento que esta tesis pretende abordar.

## 2.1. Fundamentos de la Predicción de Series Temporales

La predicción de series temporales es una disciplina que utiliza modelos para predecir valores futuros basándose en datos observados previamente. En el contexto del CPG, esto se traduce en pronosticar la demanda futura de productos. La elección del modelo es crítica y depende de la naturaleza de los datos y los patrones subyacentes.

### 2.1.1. Modelos Estadísticos Tradicionales: Regresión Lineal

La regresión lineal es un método estadístico fundamental y ampliamente utilizado para predecir una respuesta cuantitativa. Su desarrollo se remonta a principios del siglo XIX con la creación del método de mínimos cuadrados, inicialmente aplicado a problemas de astronomía. A pesar de su antigüedad, la regresión lineal sigue siendo una herramienta vigente y esencial en el campo del aprendizaje estadístico, un conjunto de técnicas para comprender datos complejos. Este método no solo es valioso por sí mismo, sino que también sirve como base conceptual para enfoques más avanzados y modernos (James et al., 2023).

La regresión lineal busca modelar la relación entre una variable dependiente o respuesta (denotada como  $Y$ ) y una o más variables independientes o predictoras (denotadas como  $X$ ). Cuando se utiliza un solo predictor, se denomina **regresión lineal simple**, mientras que el uso de múltiples predictores se conoce como **regresión lineal múltiple** (James et al., 2023). El modelo asume que existe una relación aproximadamente lineal entre los predictores y la respuesta. Matemáticamente, esta relación se expresa de la siguiente forma general:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon$$

En esta ecuación, los coeficientes  $\beta_j$  cuantifican la asociación entre cada predictor y la respuesta, interpretándose como el efecto promedio en  $Y$  de un aumento de una unidad en  $X_j$ , manteniendo fijos todos los demás predictores. El término  $\epsilon$  representa el error aleatorio, que agrupa toda la información que el modelo no captura, como relaciones no lineales, la influencia de variables no medidas o errores de medición (James et al., 2023).

En el contexto de los pronósticos de venta, la regresión lineal es una herramienta muy aplicable. Por ejemplo, una empresa puede utilizarla para predecir las ventas de un producto basándose en su presupuesto publicitario en diferentes medios como televisión, radio y prensa. Un modelo de este tipo permitiría responder preguntas críticas como: ¿qué medios generan el mayor impulso en las ventas? o ¿qué aumento en las ventas se asocia con un determinado incremento en la publicidad? (James et al., 2023). Esto convierte a la regresión lineal en una técnica valiosa tanto para la **predicción** (estimar ventas futuras) como para la **inferencia** (comprender la relación entre la inversión publicitaria y las ventas) (James et al., 2023).

### 2.1.1.1 Ventajas de la regresión lineal

La regresión lineal presenta varias ventajas significativas que justifican su amplio uso en diversas disciplinas (Kutner et al., 2005; James et al., 2023).

- 1. Interpretabilidad:** Una de sus mayores fortalezas es que los modelos lineales permiten una inferencia relativamente simple e interpretable. A diferencia de los métodos más complejos y flexibles que pueden funcionar como "cajas negras", la regresión lineal facilita la comprensión de la relación entre cada predictor y la variable de respuesta (James et al., 2023).
- 2. Sencillez y Eficiencia:** Es un enfoque conceptualmente sencillo y directo. El ajuste del modelo mediante el método de mínimos cuadrados es computacionalmente eficiente y está ampliamente disponible en todos los paquetes de software estadístico (James et al., 2023).
- 3. Buen Rendimiento en Relaciones Lineales:** Cuando la relación real entre los predictores y la respuesta es aproximadamente lineal, el rendimiento de la regresión lineal es óptimo, ya que posee un sesgo bajo (James et al., 2023).

### 2.1.1.2. Desventajas y limitaciones de la regresión lineal

A pesar de sus fortalezas, la regresión lineal se basa en supuestos restrictivos que a menudo se violan en la práctica, lo que genera ciertas desventajas.

- 1. Suposición de Linealidad:** La principal desventaja es su suposición inherente de que la relación entre predictores y respuesta es lineal. Si la verdadera relación es no lineal, el modelo proporcionará un ajuste deficiente y las conclusiones extraídas de él serán cuestionables. Por ejemplo, en algunos casos, una relación cuadrática o de orden superior puede ser más apropiada, y no detectarlo llevaría a un modelo inadecuado (James et al., 2023).
- 2. Suposición de Aditividad:** El modelo lineal estándar asume que el efecto de cada predictor sobre la respuesta es independiente de los valores de los otros predictores. Esto significa que no tiene en cuenta los **efectos de sinergia o interacción**, donde el efecto combinado de dos o más predictores es mayor que la suma de sus efectos individuales (James et al., 2023).
- 3. Sensibilidad a Problemas en los Datos:** La regresión lineal puede ser sensible a problemas como la **colinealidad** (alta correlación entre predictores), la **no constancia de la varianza de los errores** (heterocedasticidad) y la presencia de **valores atípicos** (*outliers*) y puntos de alto apalancamiento (*high leverage*), los cuales pueden distorsionar significativamente los resultados si no se gestionan adecuadamente (James et al., 2023; Kutner et al., 2005).

En síntesis, la regresión lineal es una herramienta útil para la gerencia porque permite **explicar de forma clara y transparente** cómo diferentes factores influyen en un resultado clave, facilitando decisiones rápidas y fundamentadas. Su simplicidad operativa y bajo costo computacional la hacen adecuada para contextos donde se requiere velocidad de análisis y facilidad de interpretación, especialmente cuando las relaciones entre variables son relativamente estables.

No obstante, su uso gerencial implica riesgos. Si la relación real entre los factores y la demanda no es lineal, o si existen interacciones no identificadas, el modelo puede producir **pronósticos imprecisos** que impacten negativamente decisiones de inventario, compras o asignación de recursos. Además, problemas comunes en los datos (como colinealidad o valores atípicos) pueden sesgar los resultados sin que el gerente lo note, generando una falsa sensación de certeza.

En términos prácticos, la regresión lineal puede ser una herramienta adecuada para **entornos de baja complejidad**, pero en mercados dinámicos o con alta variabilidad requiere complementarse con modelos más robustos o con diagnósticos técnicos que aseguren la confiabilidad del pronóstico. Su valor gerencial radica en su claridad, siempre que se reconozcan sus límites.

## **2.1.2. Modelos Estadísticos Tradicionales: ARIMA**

Los modelos ARIMA, acrónimo de *AutoRegressive Integrated Moving Average*, constituyen uno de los enfoques más utilizados y robustos para el pronóstico de series temporales (Box et al., 2015). A diferencia de los modelos de suavizado exponencial, que se centran en la descripción de la tendencia y la estacionalidad de los datos, los modelos ARIMA tienen como objetivo describir las autocorrelaciones presentes en la serie. Estos modelos combinan componentes de autorregresión (AR), promedios móviles (MA) y diferenciación (I) para modelar series temporales, tanto estacionarias como no estacionarias (Hyndman & Athanasopoulos, 2021).

### **2.1.2.1. Componentes del modelo ARIMA**

Un modelo ARIMA se define por tres órdenes: (p), (d), y (q), y se denota como ARIMA((p, d, q)).

**1. Componente Integrado (I): La Diferenciación ((d)).** La mayoría de las series temporales económicas, como las ventas, no son estacionarias; es decir, sus propiedades estadísticas como la media o la varianza cambian con el tiempo. La no estacionariedad puede manifestarse a través de tendencias o estacionalidad. Para estabilizar la media de una serie y eliminar tendencias, se aplica la **diferenciación**, que consiste en calcular la diferencia entre observaciones consecutivas. El orden de diferenciación, (d), indica cuántas veces se debe

diferenciar la serie para que se vuelva estacionaria. Generalmente, una o dos diferenciaciones (( $d=1$ ) o ( $d=2$ )) son suficientes. Para datos con patrones estacionales, como las ventas mensuales o trimestrales, se aplica una diferenciación estacional (( $D$ )) que calcula la diferencia entre una observación y la observación del mismo período en el ciclo anterior (por ejemplo, el mismo mes del año anterior) (Hyndman & Athanasopoulos, 2021).

**2. Componente Autorregresivo (AR) (( $p$ )).** Este componente modela la variable de interés como una combinación lineal de sus propios valores pasados o rezagados. Un modelo  $AR(p)$  indica que el valor actual de la serie depende de los ( $p$ ) valores anteriores. Los modelos AR son muy flexibles para capturar diversos patrones en los datos y, cuando ( $p \geq 2$ ), pueden modelar comportamientos cíclicos (Hyndman & Athanasopoulos, 2021).

**3. Componente de Promedio Móvil (MA) (( $q$ )).** A diferencia del componente AR, un modelo de promedio móvil utiliza los errores de pronóstico pasados para predecir el valor actual. Un modelo  $MA(q)$  indica que el valor actual depende de los ( $q$ ) errores de pronóstico anteriores. No debe confundirse con la técnica de suavizado de medias móviles, que se utiliza para estimar la tendencia-ciclo de valores pasados (Hyndman & Athanasopoulos, 2021).

El modelo  $ARIMA(p, d, q)$  completa combina estos tres elementos, aplicando los componentes AR y MA a la serie ya diferenciada (( $d$ ) veces) para hacerla estacionaria. Para datos estacionales, el modelo se expande a un formato  $SARIMA(p, d, q)(P, D, Q)(m)$ , donde (( $P, D, Q$ )) representan los órdenes de autorregresión, diferenciación y promedio móvil estacionales, y ( $m$ ) es el período estacional (Hyndman & Athanasopoulos, 2021).

### 2.1.2.2. Ventajas y desventajas del modelo ARIMA

#### Ventajas:

- **Flexibilidad y Generalidad:** Los modelos ARIMA son capaces de modelar una amplia gama de patrones de series temporales, incluyendo tendencias, estacionalidad y comportamientos cíclicos. Muchos otros modelos de pronóstico, como el paseo aleatorio (*random walk*), son casos especiales del modelo ARIMA (Hyndman & Athanasopoulos, 2021).
- **Enfoque Sistemático de Modelado:** El enfoque Box-Jenkins, que utiliza modelos ARIMA, proporciona un procedimiento iterativo bien definido para la construcción de modelos que incluye la identificación, estimación y verificación diagnóstica (Box et al., 2015). Este proceso permite construir modelos robustos y validados.
- **Fundamento Estadístico Sólido:** Los parámetros se estiman utilizando métodos como la estimación de máxima verosimilitud (MLE), que maximiza la probabilidad de observar los datos dados los parámetros del modelo. Los intervalos de predicción se calculan con base en supuestos estadísticos claros, aunque es crucial verificar que los residuos del modelo sean ruido blanco y estén distribuidos normalmente (Hyndman & Athanasopoulos, 2021).

## Desventajas:

- **Complejidad en la Identificación del Modelo:** La selección manual de los órdenes ((p, d, q, P, D, Q)) puede ser subjetiva y compleja, requiriendo un análisis detallado de los gráficos de la Función de Autocorrelación (ACF) y la Función de Autocorrelación Parcial (PACF). Aunque existen algoritmos automatizados, como el de Hyndman-Khandakar, que simplifican este proceso, es fundamental que el analista comprenda el comportamiento del modelo y verifique los resultados (Hyndman & Athanasopoulos, 2021).
- **Limitado a Modelos Lineales:** Los modelos ARIMA asumen una relación lineal entre los valores pasados y los valores actuales de la serie. No pueden capturar patrones no lineales, para los cuales otros tipos de modelos pueden ser más adecuados (Box et al., 2015).
- **Riesgo de Diferenciación Excesiva:** Aplicar más diferenciaciones de las necesarias puede inducir autocorrelaciones falsas en los datos, llevando a un modelo incorrecto. Por ello, se recomienda realizar la menor cantidad de diferenciaciones posible para alcanzar la estacionariedad, utilizando pruebas de raíz unitaria como la prueba KPSS para una determinación más objetiva (Hyndman & Athanasopoulos, 2021).

### 2.1.2.3. Aplicabilidad en pronósticos de ventas

Los modelos ARIMA son altamente aplicables para el pronóstico de ventas debido a que estas series suelen presentar las características que los modelos ARIMA manejan eficazmente:

**1. No estacionariedad y Estacionalidad:** Las ventas a menudo exhiben tendencias (crecimiento o declive a largo plazo) y patrones estacionales (picos de ventas en ciertas épocas del año). Los componentes de diferenciación regular ((d)) y estacional ((D)) de un modelo SARIMA permiten transformar la serie de ventas en una serie estacionaria, que es un requisito previo para el modelado ARMA. Ejemplos como las ventas de medicamentos corticoides en Australia muestran cómo la diferenciación estacional y la transformación logarítmica pueden estabilizar una serie con fuerte estacionalidad y varianza creciente (Hyndman & Athanasopoulos, 2021).

**2. Autocorrelación:** Las ventas de un período a menudo están correlacionadas con las ventas de períodos anteriores. Los componentes AR y MA del modelo ARIMA están diseñados precisamente para capturar esta estructura de autocorrelación, lo que permite pronósticos más precisos que los métodos más simples (Hyndman & Athanasopoulos, 2021).

**3. Disponibilidad de Procedimientos Automatizados:** Aunque el modelado ARIMA puede ser complejo, herramientas modernas como la función `ARIMA()` en el paquete `fable` de R automatizan la selección de los órdenes del modelo mediante la minimización de criterios de información como el AICc, lo que facilita su aplicación práctica. Esto permite a los analistas

de negocio aplicar estos modelos avanzados sin necesidad de ser expertos en la teoría subyacente, aunque sigue siendo crucial validar los modelos resultantes, por ejemplo, verificando que los residuos se comporten como ruido blanco (Hyndman & Athanasopoulos, 2021).

En resumen, Los modelos ARIMA ofrecen a la gerencia una herramienta sólida y estructurada para pronosticar ventas en contextos donde existen **tendencias, estacionalidad y patrones recurrentes**. Su principal fortaleza radica en que permiten capturar la autocorrelación entre periodos y generar pronósticos basados en fundamentos estadísticos verificables, lo cual reduce la incertidumbre en decisiones de abastecimiento, producción y logística. Además, su uso ha sido estandarizado mediante metodologías como Box–Jenkins y herramientas automatizadas que facilitan su implementación en entornos empresariales, incluso cuando el equipo técnico no es experto en modelado avanzado.

Sin embargo, su aplicación también implica riesgos gerenciales. El proceso de identificación del modelo puede ser complejo y, si se realiza incorrectamente, conduce a **pronósticos sesgados** que afectan decisiones críticas, como niveles de inventario y asignación de recursos. La dependencia de relaciones lineales limita su capacidad para capturar cambios abruptos del mercado o comportamientos no lineales propios de segmentos altamente dinámicos. Asimismo, una diferenciación inadecuada puede distorsionar los datos y generar modelos poco confiables.

En términos prácticos, ARIMA es una opción válida para organizaciones que manejan **series históricas estables y recurrentes**, y que necesitan una herramienta estadística robusta sin la complejidad operativa de modelos más avanzados. No obstante, en escenarios donde la demanda es más volátil, depende de múltiples variables externas o presenta comportamientos no lineales, ARIMA debe complementarse con modelos de aprendizaje automático para evitar riesgos operativos y financieros asociados a pronósticos insuficientemente precisos.

### **2.1.3. Modelos de Aprendizaje Automático: Support Vector Machines (SVM)**

Las Máquinas de Vectores de Soporte (SVM, por sus siglas en inglés) constituyen una clase de algoritmos de aprendizaje automático diseñados principalmente para problemas de clasificación y regresión. Su desarrollo inicial se remonta a la década de 1970 (Burges, 1998), aunque su popularidad creció significativamente a partir de la década de 1990 gracias a su sólido fundamento en la teoría del aprendizaje estadístico y su notable rendimiento en diversas aplicaciones prácticas.

El principio fundamental de las SVM para la clasificación de dos grupos consiste en la construcción de un hiperplano de decisión que separa de manera óptima los datos pertenecientes a diferentes clases. En el caso linealmente separable, el algoritmo busca el hiperplano que maximiza el margen, definido como la distancia entre el hiperplano y los puntos de entrenamiento más cercanos de cada clase (Burges, 1998; Hastie et al., 2009). Estos

puntos que delimitan el margen se conocen como vectores de soporte, y son los elementos críticos del conjunto de entrenamiento, ya que son los únicos que definen la superficie de decisión (Cortes & Vapnik, 1995). La construcción de este hiperplano óptimo se formula como un problema de programación cuadrática, lo que garantiza la existencia de una solución global única (Burges, 1998).

Una de las innovaciones más significativas de las SVM es su capacidad para manejar datos no separables linealmente. Esto se logra mediante dos conceptos clave. El primero es la introducción de un "margen suave" (soft margin), que permite que algunas observaciones queden dentro del margen o incluso en el lado incorrecto del hiperplano, a cambio de una penalización controlada por un parámetro de costo  $C$  (Cortes & Vapnik, 1995; Hastie et al., 2009). Un valor mayor de  $C$  impone una penalización más alta a los errores, tendiendo a un margen más estricto, mientras que un valor menor permite un margen más amplio y una mayor tolerancia a clasificaciones erróneas (Burges, 1998).

El segundo concepto es el uso de funciones kernel para construir superficies de decisión no lineales. La idea central es transformar los vectores de entrada no linealmente a un espacio de características de dimensión muy alta, donde un hiperplano lineal pueda separar las clases. Este mapeo se realiza implícitamente a través de una función kernel, como el kernel polinomial, el de base radial (RBF) o el sigmooidal, que calcula el producto punto entre los vectores en ese espacio de alta dimensión sin necesidad de realizar la transformación explícita (Burges, 1998; Hastie et al., 2009). Esta técnica, conocida como el "truco del kernel", permite a las SVM construir clasificadores muy flexibles y potentes, evitando al mismo tiempo el "curso de la dimensionalidad", ya que la complejidad del cálculo no depende de la dimensión del espacio de características, sino del número de vectores de soporte (Cortes & Vapnik, 1995).

La capacidad de generalización de las SVM está respaldada por la teoría de la dimensión Vapnik-Chervonenkis (VC) y el principio de minimización del riesgo estructural. Al maximizar el margen, las SVM controlan la capacidad del modelo, lo que ayuda a prevenir el sobreajuste. Aunque el uso de ciertos kernels, como el RBF, puede implicar una dimensión VC infinita, el control del margen y la penalización de errores actúan como un mecanismo de regularización efectivo que ha demostrado un excelente rendimiento empírico en problemas del mundo real, como el reconocimiento de dígitos escritos a mano y la categorización de texto (Cortes & Vapnik, 1995; Burges, 1998).

Un pronóstico de ventas es esencialmente un problema de regresión, donde el objetivo es predecir un resultado cuantitativo (las ventas futuras) a partir de un conjunto de variables de entrada o predictores. Las SVM pueden generalizarse para abordar problemas de regresión (Burges, 1998; Hastie et al., 2009). La SVM de regresión busca encontrar una función que se desvíe como máximo en una cantidad  $\epsilon$  de los valores de ventas reales para la mayor cantidad de datos de entrenamiento posible, a la vez que se mantiene lo más plana posible.

### 2.1.3.1. Características del algoritmo

Para aplicar SVM a un pronóstico de ventas, se deben considerar lo siguiente:

**1. Manejo de relaciones no lineales:** Las ventas raramente dependen de forma lineal de los predictores (como el gasto en marketing, la estacionalidad, o indicadores económicos). La principal fortaleza de las SVM es su capacidad para crear superficies de decisión no lineales mediante el "truco del kernel" (kernel trick). Esta técnica mapea los predictores a un espacio de características de dimensión muy alta donde las relaciones se vuelven lineales, permitiendo modelar interacciones complejas sin definir las explícitamente (Cortes & Vapnik, 1995; Hastie et al., 2009). Esto sería útil para capturar cómo múltiples factores de ventas interactúan de manera compleja.

**2. Robustez ante datos atípicos (outliers) con margen suave:** Los datos de ventas pueden contener valores atípicos (por ejemplo, picos de ventas por eventos inesperados). Las SVM para regresión, al igual que las de clasificación, utilizan un margen suave que permite que ciertos puntos de datos queden fuera de un "tubo" de tolerancia (definido por el parámetro  $\epsilon$ ) sin influir desproporcionadamente en la función de predicción final, a cambio de una penalización controlada por un parámetro de costo  $C$  (Cortes & Vapnik, 1995; Hastie et al., 2009). Esto puede hacer que el modelo de pronóstico sea más robusto frente a fluctuaciones anómalas en los datos históricos de ventas.

**3. Prevención del sobreajuste (overfitting):** Un desafío en el pronóstico es crear un modelo que generalice bien a datos futuros en lugar de simplemente memorizar los datos de entrenamiento. Las SVM controlan la complejidad del modelo y previenen el sobreajuste a través de la maximización del margen (en clasificación) o manteniendo la función lo más plana posible (en regresión), lo cual está fundamentado en la teoría del aprendizaje estadístico y el principio de minimización del riesgo estructural (Burges, 1998; Cortes & Vapnik, 1995). La capacidad de generalización de las SVM está teóricamente respaldada, lo que sugiere que podrían generar pronósticos fiables.

**4. Selección de predictores y dimensionalidad:** Los pronósticos de ventas pueden depender de una gran cantidad de variables (indicadores económicos, acciones de la competencia, campañas de marketing, etc.). Las SVM pueden manejar espacios de características de alta dimensionalidad (incluso infinitos) sin que la complejidad computacional dependa de la dimensión del espacio, sino del número de vectores de soporte (Cortes & Vapnik, 1995; Burges, 1998). Aunque el modelo no realiza una selección explícita de variables como otros métodos, su mecanismo de regularización le permite funcionar bien incluso con un gran número de predictores (Hastie et al., 2009).

En conclusión, las Máquinas de Vectores de Soporte (SVM) representan una alternativa avanzada para el pronóstico de ventas en entornos empresariales donde la demanda depende de múltiples factores y presenta comportamientos no lineales. Su capacidad para modelar relaciones complejas mediante funciones kernel convierte a las SVM en una herramienta

poderosa para capturar patrones difíciles de identificar con métodos estadísticos tradicionales, ofreciendo a la gerencia pronósticos más adaptados a mercados dinámicos.

Desde una perspectiva operativa, las SVM aportan **beneficios clave**, como mayor capacidad para manejar variaciones abruptas en los datos, robustez ante valores atípicos (comunes en picos de demanda) y un control riguroso del sobreajuste, lo que se traduce en predicciones más confiables para decisiones de inventario, compras y planificación comercial. Esto es especialmente relevante en sectores donde el comportamiento del consumidor cambia rápidamente o está influenciado por múltiples variables simultáneas.

No obstante, su uso implica **riesgos y desafíos gerenciales**. La efectividad del modelo depende de la correcta selección del kernel y de parámetros como  $C$  y  $\epsilon$ , decisiones que requieren conocimiento técnico especializado. Un mal ajuste puede derivar en resultados poco interpretables o en modelos demasiado rígidos o demasiado flexibles. Además, su naturaleza de “caja negra” limita la transparencia del proceso predictivo, lo que puede dificultar su adopción por parte de líderes que requieren justificar decisiones con claridad frente a otras áreas del negocio.

Las SVM son una opción sólida para organizaciones que buscan **mejorar la precisión del pronóstico en contextos complejos y con alta variabilidad**. Sin embargo, su implementación exige capacidades analíticas avanzadas y una estructura de datos bien gestionada para garantizar su confiabilidad y alineación con los objetivos estratégicos.

#### **2.1.4. Modelos de Aprendizaje Automático: Random Forest (RF)**

En el campo del aprendizaje automático (Machine Learning), el algoritmo Random Forest (Bosque Aleatorio) se ha consolidado como una de las técnicas de conjunto (*ensemble learning*) más robustas y populares, tanto para tareas de clasificación como de regresión (Salman et al., 2024). Propuesto originalmente por Breiman (2001), este método se basa en la construcción de múltiples árboles de decisión durante la fase de entrenamiento, combinando sus predicciones para obtener un resultado final más preciso y estable.

Un Random Forest opera construyendo una multitud de árboles de decisión y agregando sus resultados (Breiman, 2001). Para lograrlo, se introduce aleatoriedad en dos niveles clave durante la construcción de cada árbol. Primero, cada árbol se entrena sobre una muestra *bootstrap* del conjunto de datos original, es decir, una submuestra aleatoria con reemplazo del mismo tamaño que los datos de entrenamiento (Liaw & Wiener, 2002). Este proceso, conocido como *Bootstrap Aggregation* o *Bagging*, promueve la diversidad entre los árboles, ya que cada uno "ve" una versión ligeramente diferente de los datos (Salman et al., 2024).

En segundo lugar, y como principal diferencia con el *Bagging* simple, en cada nodo de cada árbol, en lugar de evaluar todas las variables predictoras para encontrar la mejor división, el

algoritmo selecciona aleatoriamente un subconjunto de estas variables (Liaw & Wiener, 2002). Solo dentro de este subconjunto aleatorio se busca la mejor división posible. Esta doble aleatoriedad ayuda a "decorrelacionar" los árboles, reduciendo la varianza del modelo final y su propensión al sobreajuste (*overfitting*), uno de los problemas más comunes en los árboles de decisión individuales (Breiman, 2001; Salman et al., 2024).

Una vez que todos los árboles del bosque han sido entrenados, la predicción para un nuevo dato se obtiene agregando los resultados de cada árbol. Para problemas de **clasificación**, el resultado final es la clase que recibe la mayor cantidad de "votos" (la moda) entre todos los árboles del ensamble. Para problemas de **regresión**, el resultado es el promedio de las predicciones de todos los árboles individuales (Liaw & Wiener, 2002; Salman et al., 2024).

Una característica distintiva del algoritmo es su capacidad para estimar el error de generalización internamente, sin necesidad de un conjunto de validación separado. Esto se logra mediante la estimación *Out-of-Bag* (OOB). Dado que cada árbol se entrena con una muestra *bootstrap*, aproximadamente un tercio de las observaciones originales quedan fuera de dicha muestra. Estas observaciones OOB se utilizan para evaluar el rendimiento del árbol correspondiente. Al promediar estos errores a lo largo de todo el bosque, se obtiene una estimación insesgada y precisa del error del modelo (Breiman, 2001; Liaw & Wiener, 2002).

#### 2.1.4.1. Ventajas y desventajas del modelo RF

El uso de Random Forest presenta múltiples beneficios, pero también algunas limitaciones que deben ser consideradas.

##### **Ventajas:**

- **Alta Precisión y Robustez:** Es conocido por su alto rendimiento predictivo en una amplia gama de tareas y es robusto frente a datos ruidosos y valores atípicos (*outliers*) (Liaw & Wiener, 2002; Salman et al., 2024).
- **Reducción del Sobreajuste:** La combinación de múltiples árboles decorrelacionados reduce significativamente el riesgo de sobreajuste, un problema común en árboles de decisión individuales (Breiman, 2001).
- **Manejo de Datos Faltantes:** El algoritmo posee mecanismos integrados para manejar valores faltantes, lo que simplifica el preprocesamiento de los datos (Salman et al., 2024).
- **Estimación de la Importancia de Variables:** Proporciona métricas para evaluar la importancia de cada variable predictora. Esto se calcula midiendo cuánto aumenta el error del modelo cuando los valores de una variable son permutados aleatoriamente en las muestras OOB (Breiman, 2001; Liaw & Wiener, 2002).
- **Versatilidad y Facilidad de Uso:** Es aplicable tanto a problemas de clasificación como de regresión y es relativamente insensible a los hiperparámetros, requiriendo menos ajustes que

otros modelos complejos (Liaw & Wiener, 2002). Además, puede manejar una gran cantidad de variables de entrada sin necesidad de una selección previa (Salman et al., 2024).

### **Desventajas:**

- **Menor Interpretabilidad:** A diferencia de un solo árbol de decisión, un bosque compuesto por cientos o miles de árboles funciona como una "caja negra", haciendo que el modelo sea más difícil de interpretar (Salman et al., 2024).
- **Coste Computacional:** El entrenamiento de un gran número de árboles puede ser computacionalmente intensivo y lento, especialmente con conjuntos de datos muy grandes. Aunque el entrenamiento es paralelizable, la velocidad de predicción, una vez entrenado, puede ser más lenta en comparación con modelos más simples (Salman et al., 2024).

El pronóstico de ventas es una tarea inherentemente compleja, influenciada por múltiples factores como la estacionalidad, promociones, comportamiento del consumidor, y condiciones del mercado. Dada su naturaleza, esta tarea puede ser abordada como un problema de regresión, donde el objetivo es predecir una cantidad continua (el volumen de ventas).

### **2.1.4.2. Aplicabilidad en pronósticos de ventas**

Random Forest es particularmente adecuado para este tipo de problemas por varias razones:

1. **Capacidad para Capturar Relaciones No Lineales:** Los modelos de ventas a menudo involucran interacciones complejas y no lineales entre las variables. Los árboles de decisión, base de Random Forest, son excelentes para modelar estas relaciones sin necesidad de especificarlas explícitamente, a diferencia de los modelos de regresión lineal tradicionales (Salman et al., 2024).
2. **Manejo de Múltiples Tipos de Variables:** Las ventas pueden depender de una mezcla de variables continuas (ej. precio, gasto en publicidad) y categóricas (ej. tipo de tienda, día de la semana, evento especial). Random Forest maneja de forma nativa esta combinación de tipos de datos (Salman et al., 2024).
3. **Identificación de Impulsores de Venta:** La funcionalidad de importancia de variables permite a los analistas identificar qué factores tienen un mayor impacto en las ventas (Breiman, 2001). Esto no solo mejora el modelo predictivo, sino que también ofrece información valiosa para la toma de decisiones estratégicas, como la asignación de presupuestos de marketing o la planificación de inventarios.
4. **Predicción del Comportamiento del Cliente:** En el ámbito del comercio electrónico, los algoritmos de Random Forest se utilizan para predecir las preferencias de los clientes basándose en su comportamiento de consumo histórico, lo que puede ser un insumo clave para un modelo de pronóstico de ventas a nivel de producto o categoría (Salman et al., 2024).

En resumen, Random Forest es un modelo altamente atractivo para la gerencia debido a su **elevada precisión**, su capacidad para manejar grandes volúmenes de datos y su robustez frente a variaciones inesperadas en la demanda. Al combinar múltiples árboles de decisión entrenados con diferentes muestras y subconjuntos de variables, el algoritmo produce predicciones más estables y confiables que un árbol individual, reduciendo significativamente el riesgo de sobreajuste, uno de los errores más comunes en modelos predictivos simples. Esto permite a las organizaciones contar con pronósticos más fiables para la planeación de inventarios, producción y asignación de recursos.

Desde el punto de vista estratégico, Random Forest aporta un valor adicional: su capacidad para **identificar las variables que más influyen en las ventas**. Esta funcionalidad permite a los líderes identificar qué factores impulsan la demanda (precio, promociones, estacionalidad, tipo de tienda, campañas de marketing, etc.), lo cual respalda decisiones clave como la focalización de inversiones, la optimización del portafolio o la definición de estrategias comerciales. Además, el modelo maneja con facilidad relaciones no lineales y múltiples tipos de variables, lo que resulta ideal en mercados complejos y altamente dinámicos.

Sin embargo, su uso implica ciertos desafíos gerenciales. Random Forest funciona como una **“caja negra”**, por lo que no es tan interpretable como modelos tradicionales. Esto puede dificultar la comunicación de resultados a áreas no técnicas o la justificación de decisiones basadas en el modelo. Asimismo, el entrenamiento de cientos o miles de árboles puede requerir recursos computacionales significativos, especialmente con bases de datos extensas o pronósticos a nivel SKU.

Random Forest es una herramienta poderosa y versátil para empresas que buscan mejorar la exactitud del pronóstico en entornos complejos, siempre que cuenten con la infraestructura técnica adecuada y con equipos capaces de validar y monitorear el modelo. Su capacidad para manejar no linealidades, reducir riesgos de error y aportar información estratégica lo convierte en una opción robusta para apoyar la toma de decisiones comerciales y operativas.

### **2.1.5 Modelos de aprendizaje automático: Extreme Gradient Boosting (XGBOOST)**

En el ámbito del aprendizaje automático (*machine learning*), el método de potenciación de árboles (*tree boosting*) ha demostrado ser una de las técnicas más efectivas y ampliamente utilizadas, obteniendo resultados de vanguardia en una gran variedad de desafíos (Chen & Guestrin, 2016). Dentro de este paradigma, el sistema XGBoost (eXtreme Gradient Boosting) se ha consolidado como una herramienta fundamental para científicos de datos y académicos, gracias a su notable rendimiento y escalabilidad. Este sistema, disponible como un paquete de código abierto, no solo ha dominado competencias de alto perfil como las de Kaggle y la KDDCup, sino que también se ha integrado en procesos productivos para tareas como la predicción de la tasa de clics en publicidad (Chen & Guestrin, 2016).

El modelo XGBoost se basa en el principio del *gradient tree boosting*, también conocido como GBM o GBRT. Este enfoque construye un modelo predictivo de forma aditiva, conformado por un conjunto (*ensemble*) de árboles de regresión. La predicción final se obtiene sumando las predicciones de cada uno de los árboles individuales que componen el modelo. Para evitar el sobreajuste (*overfitting*), un problema común en modelos de alta complejidad, **XGBoost incorpora un objetivo de aprendizaje regularizado**. Este objetivo no solo mide la diferencia entre las predicciones y los valores reales a través de una función de pérdida, sino que también penaliza la complejidad del modelo, favoreciendo la selección de funciones más simples y predictivas. Adicionalmente, implementa técnicas como la contracción (*shrinkage*), que reduce la influencia de cada árbol individual, y el submuestreo de columnas (características), una técnica que ha demostrado ser muy efectiva para prevenir el sobreajuste (Chen & Guestrin, 2016).

### 2.1.5.1. Ventajas y desventajas del modelo XGBoost

#### Ventajas

El éxito de XGBoost se fundamenta en su **escalabilidad y eficiencia computacional**, factores cruciales para manejar los grandes volúmenes de datos característicos de los problemas actuales de *machine learning* (Chen & Guestrin, 2016). Entre sus ventajas más destacadas se encuentran:

1. **Velocidad Superior:** El sistema es notablemente rápido, llegando a ejecutarse **más de diez veces más rápido que otras soluciones populares** en una sola máquina. Esto se debe a optimizaciones algorítmicas y de sistema, como el uso de computación paralela y distribuida que acelera el proceso de aprendizaje y exploración de modelos (Chen & Guestrin, 2016).
2. **Manejo Eficiente de Datos Dispersos:** Muchos problemas del mundo real involucran datos con valores faltantes o una gran cantidad de ceros (datos dispersos o *sparse data*). XGBoost introduce un novedoso **algoritmo consciente de la dispersión (*sparsity-aware*)** que aprende una dirección por defecto en cada nodo del árbol para manejar estos valores, mejorando significativamente la velocidad de cómputo. En pruebas, este algoritmo ha demostrado ser hasta 50 veces más rápido que una implementación ingenua (Chen & Guestrin, 2016).
3. **Escalabilidad para Grandes Volúmenes de Datos:** Una de las contribuciones más importantes de XGBoost es su capacidad para procesar conjuntos de datos que no caben en la memoria principal. A través de técnicas de **computación fuera del núcleo (*out-of-core*)**, como la compresión de bloques y el particionamiento de datos en múltiples discos (*sharding*), el sistema puede manejar miles de millones de ejemplos en una computadora de escritorio o con recursos de clúster limitados (Chen & Guestrin, 2016).

4. **Optimización del Acceso a Caché:** Para acelerar el proceso, XGBoost utiliza una estructura de bloques de datos columnar y preordenada. Sin embargo, esto puede generar accesos no contiguos a la memoria que ralentizan el sistema por fallos de caché. Para mitigar este efecto, el sistema implementa un **algoritmo de *prefetching* consciente de la caché (*cache-aware prefetching*)**, que puede duplicar la velocidad de ejecución en conjuntos de datos grandes (Chen & Guestrin, 2016).

### **Desventajas y Consideraciones**

A pesar de sus múltiples fortalezas, las fuentes proporcionadas sugieren algunas consideraciones a tener en cuenta. Aunque no se mencionan explícitamente "desventajas" en el texto, podemos inferir algunas limitaciones inherentes a su enfoque:

1. **Sensibilidad a Hiperparámetros:** Como muchos algoritmos de aprendizaje automático, el rendimiento de XGBoost depende de la correcta configuración de sus hiperparámetros. En el texto se mencionan parámetros como la "profundidad máxima" de los árboles, la tasa de contracción (*shrinkage*), y el nivel de submuestreo de columnas, los cuales deben ser ajustados para obtener resultados óptimos (Chen & Guestrin, 2016). Un ajuste inadecuado podría llevar a un rendimiento subóptimo o sobreajuste.

2. **Costo Computacional en Ciertos Escenarios:** Aunque es altamente optimizado, XGBoost sigue siendo un algoritmo computacionalmente intensivo, especialmente al compararlo con modelos más simples como la regresión lineal. La necesidad de construir árboles de forma secuencial y las múltiples optimizaciones, aunque efectivas, requieren recursos significativos, si bien el sistema está diseñado para gestionarlos eficientemente (Chen & Guestrin, 2016).

#### **2.1.5.2 Aplicabilidad en pronósticos de ventas**

La aplicabilidad de XGBoost para pronósticos de ventas es una de sus historias de éxito más notables. De hecho, uno de los desafíos de Kaggle donde las soluciones ganadoras utilizaron XGBoost fue precisamente la **predicción de ventas en tiendas (*store sales prediction*)** (Chen & Guestrin, 2016).

En un problema de pronóstico de ventas, el objetivo es predecir una cantidad futura (una variable cuantitativa) basándose en un conjunto de características o predictores, como pueden ser datos históricos de ventas, estacionalidad, promociones, factores económicos, o comportamiento del cliente. El modelo de *tree boosting* de XGBoost es especialmente adecuado para esta tarea, ya que se encuentra dentro de la categoría de problemas de regresión, donde el objetivo es predecir una salida cuantitativa. La capacidad de XGBoost para capturar dependencias complejas en los datos, su robusto manejo de diferentes tipos de variables (cuantitativas y categóricas), y su eficiencia con grandes volúmenes de datos lo convierten en una opción ideal para este tipo de pronósticos. Además, su reconocida

efectividad en la predicción del comportamiento del consumidor y problemas similares refuerza su idoneidad para el pronóstico de ventas (Chen & Guestrin, 2016).

En conclusión, XGBoost representa un avance significativo en el campo del *machine learning*, ofreciendo una solución escalable y de alto rendimiento que ha demostrado su valía en una amplia gama de aplicaciones prácticas, incluyendo de manera destacada el pronóstico de ventas.

En síntesis y desde una perspectiva gerencial, XGBoost destaca por su **alto desempeño, capacidad de escalar a bases de datos masivas y eficiencia operativa**, lo que lo convierte en un aliado estratégico para organizaciones con necesidades avanzadas de analítica. Sus optimizaciones internas —como la computación paralela, el manejo inteligente de datos dispersos y técnicas que permiten procesar información fuera de la memoria principal— garantizan tiempos de cómputo competitivos incluso con millones de registros. Esto permite modelar comportamientos complejos del mercado, identificar patrones de demanda con mayor precisión y respaldar decisiones como la planeación de inventarios, la personalización comercial o la asignación de recursos.

La comparación de los modelos de pronóstico evidencia que la elección de la técnica adecuada tiene un impacto directo en los riesgos operativos y en la generación de valor para la organización. Los métodos tradicionales, como la Regresión Lineal y ARIMA, ofrecen simplicidad y transparencia, pero su limitada capacidad para capturar patrones complejos eleva el riesgo de errores de pronóstico en mercados volátiles, lo que puede traducirse en sobreinventarios, quiebres de stock y decisiones tácticas poco oportunas.

En contraste, los modelos avanzados de aprendizaje automático —especialmente Random Forest y XGBoost— ofrecen mayor precisión y mejor adaptación a dinámicas cambiantes. Su implementación reduce riesgos asociados a variaciones inesperadas de la demanda, mejora la disponibilidad del producto y permite optimizar los niveles de inventario, generando beneficios financieros tangibles como reducción de costos logísticos y mayor eficiencia en la operación.

Desde una perspectiva estratégica, la adopción de modelos más robustos habilita a la organización para anticipar tendencias, responder con mayor agilidad y sostener ventajas competitivas en la cadena de suministro. No obstante, estos beneficios dependen de capacidades analíticas fortalecidas y una adecuada gestión del cambio tecnológico dentro de la empresa.

A continuación, se presenta una tabla comparativa entre los modelos ya revisados, especificando su importancia gerencial al momento de usar cada uno.

<b>Modelo</b>	<b>Tipo</b>	<b>Ventajas</b>	<b>Desventajas</b>	<b>Aplicabilidad en pronóstico de demanda</b>	<b>Implicación gerencial</b>
<b>Regresión Lineal</b>	Estadístico tradicional	- Interpretación sencilla - Bajo costo computacional	- Supone relaciones lineales - Sensible a colinealidad y outliers	Útil si las relaciones entre variables son lineales y estables en el tiempo	Apto para contextos con baja complejidad y necesidad de explicabilidad
<b>ARIMA</b>	Estadístico tradicional	- Bueno para series univariadas con estacionalidad	- Lineal- Requiere estacionariedad - Dificultad en captura de no linealidades	Adecuado para series históricas estacionales con patrones consistentes	Útil para planificaciones básicas; limitado en contextos volátiles
<b>SVM</b>	Aprendizaje automático	- Capta relaciones no lineales complejas - Robusto ante outliers	- Costoso en tiempo de entrenamiento - Difícil de interpretar	Eficaz con múltiples variables predictoras y relaciones no obvias entre datos	Requiere apoyo técnico para implementación; útil en mercados complejos
<b>Random Forest</b>	Aprendizaje automático (ensemble)	- Alta precisión- Manejo de gran cantidad de variables - Robusto	- Menor interpretabilidad- Más lento en predicción	Excelente para datos diversos y tareas de predicción compleja, incluyendo SKU a gran escala	Ideal para priorizar precisión operativa; requiere recursos de procesamiento
<b>XGBoost</b>	Aprendizaje automático (boosting)	- Precisión superior- Escalable - Manejo eficiente de datos faltantes	- Sensible a mal ajuste de hiperparámetros- Complejo de configurar	Altamente efectivo en entornos con grandes volúmenes de datos y múltiples influencias sobre la demanda	Aporta ventajas competitivas en predicción avanzada; ideal para decisiones tácticas y estratégicas

**Tabla 1. Comparación entre modelos**

## 2.2. Optimización de la Gestión de Inventarios en CPG

La gestión de inventarios es una función crítica en la cadena de suministro de CPG, buscando equilibrar el costo de mantener inventario con el riesgo de perder ventas por falta de producto.

### 2.2.1. Métricas Clave de Desempeño (KPIs)

Para hacer la evaluación de los diferentes modelos, se usarán 3 métricas que permitirán comparar los resultados obtenidos y calcular su desempeño. Para esta investigación usaremos MAE, RMSE y MAPE.

### 2.2.1.1. MAE

**El Error Absoluto Medio (MAE)** es una métrica estadística que se utiliza ampliamente para la evaluación de modelos. Consiste en calcular la media de los errores absolutos entre los valores predichos y los observados. La fórmula para calcular el MAE, para un conjunto de  $n$  muestras de errores del modelo ( $e_i$ ), es la siguiente (Chai & Draxler, 2014):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

**Figura 1. Métrica MAE**

Donde:

$n$  es el número de observaciones

$y_i$  es el valor real u observado

$\hat{y}_i$  es el valor predicho o estimado

$|y_i - \hat{y}_i|$  es el error absoluto para cada observación

Una característica clave del MAE es que otorga el mismo peso a todos los errores, a diferencia de otras métricas como el Error Cuadrático Medio (RMSE), que penaliza más los errores grandes (Chai & Draxler, 2014). El MAE es una medida adecuada para describir errores que se distribuyen de manera uniforme.

### 2.2.1.2. RMSE

**El Error Cuadrático Medio (RMSE)** es una métrica estadística estándar utilizada durante muchos años para medir el rendimiento de un modelo en estudios de meteorología, calidad del aire e investigación climática. Para un conjunto de  $n$  errores del modelo ( $e_i$ ), el RMSE se calcula mediante la siguiente fórmula:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

**Figura 2. Métrica RMSE**

Una característica fundamental del RMSE es que penaliza la varianza y otorga más peso a los errores grandes en comparación con los errores pequeños. Esto lo diferencia del Error Absoluto Medio (MAE), que da el mismo peso a todos los errores. Por definición, cuando se calculan ambas métricas, el RMSE nunca es menor que el MAE (Chai & Draxler, 2014).

La principal suposición subyacente al usar el RMSE es que los errores no están sesgados y siguen una distribución normal (Gaussiana). Cuando esta suposición es válida y se dispone de suficientes muestras (por ejemplo, 100 o más), el RMSE tiene la ventaja de poder reconstruir la distribución de los errores de manera fiable (Chai & Draxler, 2014).

En el debate sobre si usar MAE o RMSE, algunos investigadores han argumentado que el MAE es una mejor métrica para evaluar el rendimiento promedio de un modelo, sugiriendo que el RMSE puede ser un indicador engañoso del error promedio (Chai & Draxler, 2014). Debido a estas recomendaciones, muchos investigadores han optado por presentar el MAE en lugar del RMSE en sus estudios de evaluación de modelos.

Sin embargo, es importante entender que cada métrica estadística, al condensar una gran cantidad de datos en un solo valor, solo ofrece una perspectiva específica de los errores del modelo, enfatizando un cierto aspecto de sus características. Por esta razón, con frecuencia se requiere una combinación de métricas, incluyendo tanto el MAE como el RMSE, para evaluar de manera completa el rendimiento de un modelo (Chai & Draxler, 2014).

A pesar de las críticas que sugieren que el RMSE puede ser ambiguo, Chai & Draxler (2014) argumentan que el RMSE no es ambiguo en su significado y es más apropiado que el MAE cuando se espera que los errores del modelo tengan una distribución normal. Sin embargo, también señalan que ninguna métrica individual es superior a la otra; a menudo se requiere una combinación de métricas, incluyendo tanto el RMSE como el MAE, para evaluar de forma completa el rendimiento de un modelo.

### 2.2.1.3. MAPE

Por otro lado, el **Error Porcentual Absoluto Medio (MAPE)**, por sus siglas en inglés, es una medida utilizada para evaluar la calidad de los modelos de regresión. A diferencia de otras métricas como el Error Cuadrático Medio (MSE), el MAPE destaca por su interpretación intuitiva en términos de error relativo (de Myttenaere et al., 2016).

Consiste en promediar el error absoluto ( $|\text{predicción} - \text{valor real}|$ ) como un porcentaje del valor real, lo que permite entender la magnitud del error en relación con la cantidad que se está prediciendo. Se calcula mediante la siguiente fórmula:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

**Figura 3.** *Métrica MAPE*

Es importante señalar que, por convención, si el valor real ( $y$ ) es 0, la división  $|g(x) - y| / |y|$  puede generar problemas.

Ventajas:

- Interpretación Intuitiva: Su principal ventaja es que se expresa como un porcentaje, lo que facilita su comprensión. Es muy fácil de interpretar en términos de error relativo.
- Utilidad en Contextos Específicos: El MAPE es especialmente relevante en campos como las finanzas, donde las ganancias y pérdidas a menudo se miden en valores relativos. También es útil para la calibración de precios, ya que los clientes pueden ser más sensibles a las variaciones relativas que a las absolutas.
- Adecuado para pronósticos: Se considera muy adaptado para aplicaciones de pronóstico, sobre todo cuando se dispone de suficientes datos.
- Prioriza el ajuste en valores pequeños: Al dividir el error por el valor real  $Y$ , el MAPE da más peso a los errores en observaciones con valores reales más pequeños. Esto obliga al modelo a ajustarse mejor en esos puntos, ya que un pequeño error absoluto en un valor real pequeño puede resultar en un gran error porcentual

Desventajas y limitaciones:

- Problemas con valores cercanos a cero: La mayor desventaja del MAPE surge cuando los valores reales ( $Y$ ) son cero o muy cercanos a cero. Si  $y=0$ , la fórmula implica una división por cero. Si  $y$  tiende a 0, un error absoluto pequeño puede magnificarse desproporcionadamente, generando un valor de MAPE extremadamente alto y potencialmente engañoso.
- Asimetría: El MAPE puede ser asimétrico. Por ejemplo, penaliza más las predicciones que son más altas que el valor real que aquellas que son más bajas en la misma magnitud, especialmente cuando no hay un límite superior para el error porcentual. La fuente no detalla este punto, pero es una característica conocida de esta métrica que se puede inferir del análisis de cómo se ponderan los errores.
- Requiere condiciones para su existencia teórica: Para que el MAPE tenga valores finitos y se pueda optimizar teóricamente, la probabilidad de que la variable objetivo  $Y$  sea exactamente cero debe ser cero ( $P(Y = 0) = 0$ ). Además, la probabilidad de que  $Y$  tome valores muy pequeños debe disminuir lo suficientemente rápido.
- Necesidad de un límite inferior en  $Y$  para análisis teóricos: Para garantizar la consistencia y aplicar ciertos teoremas en el aprendizaje automático (como las Leyes Uniformes de los Grandes Números), a menudo se necesita asumir que  $|Y|$  está acotado por debajo por un valor  $Y_L > 0$  (es decir,  $|Y| \geq Y_L$ ). Esta es una hipótesis importante para muchos de los resultados teóricos presentados en la fuente. (de Myttenaere et al., 2016).

#### **2.2.1.4. KPIs de gestión**

Los KPIs de gestión (Key Performance Indicators o Indicadores Clave de Desempeño) sirven para medir, monitorear y mejorar el desempeño de la organización, un equipo o un proceso.

Mediante estos indicadores se puede cuantificar el efecto de los resultados obtenidos en la mejora de los pronósticos de ventas.

#### **2.2.1.4.1. Gestión de inventarios**

En el ámbito de la logística y la cadena de suministro, la gestión de inventarios desempeña un papel fundamental, ya que impacta directamente en la eficiencia operativa y en la solidez financiera de las organizaciones (Mohamed, 2024). Las empresas modernas operan en contextos altamente competitivos, donde la capacidad para responder con rapidez a la demanda del mercado y controlar los costos se ha convertido en un factor clave de diferenciación. Por esta razón, contar con sistemas de inventario bien estructurados es más que una necesidad técnica: es un componente estratégico para garantizar la sostenibilidad y la competitividad empresarial.

En palabras de Ali (2011), la gestión de inventarios puede entenderse como un proceso continuo que abarca actividades de planificación, organización y control, con el propósito de minimizar la inversión en existencias sin afectar la capacidad de atender la demanda. Lograr este equilibrio implica reducir los costos asociados a la tenencia de inventario y, al mismo tiempo, garantizar que los clientes reciban los productos que necesitan en el momento adecuado (Parada, 2000). En otras palabras, se busca mantener una relación armónica entre la oferta disponible y las necesidades del mercado, evitando tanto excesos que generen costos innecesarios, como faltantes que comprometan el servicio.

Un sistema de gestión eficiente permite asegurar la disponibilidad de los productos correctos en el momento preciso, lo que contribuye a reducir problemas como la sobreacumulación o la escasez de inventario (Lee, Padmanabhan & Whang, 1997; Mohamed, 2024). No obstante, esta tarea presenta retos significativos. Mantener inventarios implica la inmovilización de capital y el uso de espacio físico, además de la exposición a riesgos como la obsolescencia, el deterioro o las pérdidas por diversas causas (Bonney, 1994). Cuando la administración de inventarios es deficiente, estos riesgos pueden traducirse en pérdidas económicas, retrasos en la entrega de productos y niveles bajos de satisfacción por parte de los clientes (Mohamed, 2024).

Para enfrentar estos desafíos, las organizaciones implementan diversas estrategias y herramientas de gestión. Entre los componentes más relevantes se encuentran el análisis de la demanda, la clasificación jerárquica de los productos, la definición de políticas de inventario y la coordinación eficiente de actividades de transporte y almacenamiento (Parada, 2000). La clave está en encontrar un equilibrio entre tres tipos de costos: los costos de mantenimiento, que incluyen gastos de almacenamiento, seguros e impuestos; los costos de pedido, asociados a las operaciones de compra y transporte; y los costos por ruptura o escasez, que surgen cuando no se cuenta con inventario suficiente para atender la demanda (Mohamed, 2024).

En síntesis, la gestión de inventarios no solo constituye una actividad operativa, sino que también representa una herramienta estratégica que permite a las organizaciones mejorar su desempeño económico y responder de forma efectiva a las exigencias del mercado. Su correcta aplicación incide de manera directa en la satisfacción del cliente, la utilización eficiente de recursos y la creación de ventajas competitivas sostenibles.

#### **2.2.1.4.2. Inventario de seguridad**

El inventario de seguridad, conocido también como *safety stock*, es una herramienta preventiva esencial dentro de la gestión de inventarios. Su función principal consiste en ofrecer un colchón de protección frente a las fluctuaciones y a la incertidumbre inherente a las operaciones logísticas y a la cadena de suministro (Mohamed, 2024). En términos generales, se define como la cantidad promedio de inventario que una organización mantiene disponible para responder a variaciones inesperadas, tanto en la demanda como en el suministro, a corto plazo (Silver et al., 1998).

La relevancia del inventario de seguridad radica en su capacidad para prevenir situaciones de desabastecimiento (stockouts) y retrasos en la entrega de pedidos (backorders), fenómenos que pueden afectar gravemente la satisfacción del cliente y la continuidad operativa (Rădășanu, 2016). La necesidad de este stock protector surge como respuesta a diversas fuentes de incertidumbre, entre las que se incluyen cambios en los tiempos de entrega — cuando el plazo de reabastecimiento no es constante—, errores o inexactitudes en los pronósticos de demanda, diferencias entre las cantidades solicitadas y las entregadas por los proveedores, así como desviaciones entre los niveles de inventario planificados y los realmente disponibles (Rădășanu, 2016).

Uno de los factores clave que inciden directamente en la determinación del inventario de seguridad es el lead time, es decir, el tiempo que transcurre entre la realización de un pedido y la recepción efectiva de los productos. Durante este periodo, la demanda sigue ocurriendo, por lo que resulta fundamental calcular con precisión la demanda esperada en el lapso de entrega, dado que este valor está estrechamente relacionado con el nivel adecuado de inventario de seguridad (Mohamed, 2024).

Asimismo, el inventario de seguridad desempeña un papel determinante en el cálculo del punto de pedido, que indica el momento exacto en que debe realizarse un nuevo pedido para evitar la falta de existencias (Veloz-Navarrete & Parada-Gutiérrez, 2017). En políticas de inventario como el sistema Mini–Max, este componente se integra como una variable crítica para establecer el nivel mínimo de inventario requerido. Para estimar este nivel mínimo, suelen considerarse tres elementos: el inventario de seguridad expresado en días (D), el tiempo de preparación del inventario (TPI) y el tiempo de almacenamiento técnico (TAT), los cuales en conjunto permiten definir una política de aprovisionamiento más precisa y confiable (Veloz-Navarrete & Parada-Gutiérrez, 2017).

En síntesis, El inventario de seguridad es un **mecanismo estratégico de protección** que las organizaciones utilizan para garantizar la continuidad operativa frente a la incertidumbre en la demanda y los tiempos de suministro. Su función principal es evitar quiebres de inventario y retrasos en la entrega, mitigando riesgos que afectan directamente la satisfacción del cliente, la confiabilidad del servicio y los costos asociados a interrupciones.

Desde una perspectiva gerencial, el inventario de seguridad actúa como un **seguro operacional** frente a variaciones inesperadas: errores de pronóstico, demoras de proveedores, inconsistencias en cantidades entregadas y fluctuaciones en el lead time. Su correcta determinación es crítica, ya que influye directamente en el punto de pedido, es decir, el momento oportuno para reabastecer inventario sin incurrir en desabastecimientos.

### **2.2.1.4.3. Rotación de inventarios**

La rotación de inventario es un indicador clave en la gestión logística, ya que refleja la velocidad con la que los productos se venden y se reponen dentro de un periodo determinado. Aunque algunas fuentes no presentan una fórmula única y explícita para su cálculo, el concepto subyacente (la rapidez con la que circulan las existencias) constituye un objetivo estratégico central para mejorar la eficiencia operativa (Mohamed, 2024). Para la mayoría de los minoristas y organizaciones productivas, alcanzar una alta rotación de inventario es una meta prioritaria, pues se asocia directamente con operaciones más ágiles, mejor utilización de recursos y una mayor competitividad en el mercado (Tian et al., 2021).

La gestión eficiente de inventarios busca optimizar los niveles de stock, y esta optimización incide directamente en la velocidad de venta y en el flujo de capital. Una de las prácticas más determinantes en este proceso es la previsión de la demanda, ya que una estimación precisa permite sincronizar la producción con las necesidades reales del mercado. Como resultado, se acelera la rotación de inventario, lo que se traduce en una conversión más rápida de los productos en ingresos, mejora del flujo de caja y reducción de los costos de almacenamiento (Syntetos et al., 2009).

Además, la rotación de inventario está estrechamente relacionada con la capacidad de la organización para gestionar costos y riesgos. Herramientas como la clasificación ABC resultan especialmente útiles para identificar productos de bajo movimiento, comúnmente agrupados en la denominada “Zona C”. En estos casos, una estrategia gerencial adecuada consiste en analizar la relación entre el consumo real y las existencias físicas de dichos productos, con el fin de reducir progresivamente los niveles de inventario y evitar la inmovilización innecesaria de capital (Veloz-Navarrete & Parada-Gutiérrez, 2017).

Las políticas de inventario también influyen de manera significativa en la rotación. Por ejemplo, la implementación de políticas como el sistema Mini–Max ha mostrado resultados positivos en términos de eficiencia, ya que permite disminuir los niveles de inventario en ciertas materias primas sin afectar la disponibilidad (Veloz-Navarrete & Parada-Gutiérrez,

2017). Cuando el inventario promedio propuesto mediante estas políticas es inferior al inventario promedio existente, la organización puede liberar capital inmovilizado y generar ahorros sustanciales.

En última instancia, una rotación elevada, lograda a través de una mejor previsión de la demanda y de políticas de inventario bien diseñadas, contribuye a fortalecer la salud financiera de la empresa y a mejorar su productividad (Veloz-Navarrete & Parada-Gutiérrez, 2017; Mohamed, 2024). Por ello, la rotación de inventario no debe entenderse únicamente como un indicador técnico, sino como un reflejo del desempeño integral de la gestión logística y de su alineación con los objetivos estratégicos de la organización.

En conclusión, la rotación de inventarios es un indicador estratégico que muestra qué tan rápido una empresa convierte su inventario en ventas, y por tanto, en flujo de caja. Una rotación alta refleja operaciones ágiles, mejor uso del capital y reducción de costos de almacenamiento, mientras que una rotación baja indica exceso de inventario, riesgo de obsolescencia y capital inmovilizado.

Desde una perspectiva gerencial, la rotación depende directamente de dos elementos clave: **la precisión en la previsión de la demanda y las políticas de inventario implementadas.** Una demanda bien pronosticada permite ajustar los niveles de stock a las necesidades reales del mercado, acelerando la conversión de productos en ingresos. Del mismo modo, políticas como Mini-Max o la correcta gestión basada en clasificación ABC ayudan a identificar productos de baja rotación y a reducir inventarios innecesarios sin afectar la disponibilidad.

Incrementar la rotación no solo mejora la eficiencia logística, sino que aporta beneficios financieros sustanciales: libera capital, mejora la liquidez y aumenta la competitividad. Por ello, este indicador debe visualizarse como un **termómetro de la salud operativa y financiera de la empresa**, más que como una métrica aislada.

#### **2.2.4.1.4. Agotados**

El fenómeno de los “agotados” (también conocido como stockouts) tiene consecuencias que van mucho más allá del simple desabastecimiento puntual. Desde una perspectiva financiera, la falta de inventario repercute directamente en la rentabilidad, ya que implica la pérdida de ingresos potenciales debido a ventas que no se concretan o que se retrasan significativamente.

En el plano operativo, los efectos son igualmente relevantes. Las rupturas de inventario pueden ocasionar demoras en la atención de pedidos, interrupciones en los procesos productivos e incluso generar costos adicionales asociados con tiempos de parada o con cambios de lote en la producción. Estas situaciones afectan la continuidad del flujo de materiales y repercuten directamente en la eficiencia de las operaciones logísticas (Mohamed, 2024; Veloz-Navarrete & Parada-Gutiérrez, 2017).

Más allá de los impactos económicos y productivos inmediatos, la escasez de inventario también tiene implicaciones sobre la imagen y reputación corporativa. Cuando una empresa no logra satisfacer la demanda de sus clientes, se genera insatisfacción, lo que puede deteriorar la percepción del consumidor y afectar la fidelidad a largo plazo. En muchos casos, para responder a estas contingencias, las organizaciones se ven obligadas a adquirir el producto faltante o un sustituto en condiciones menos favorables, incurriendo en costos adicionales que podrían haberse evitado mediante una planificación más precisa (Veloz-Navarrete & Parada-Gutiérrez, 2017).

**Causas Principales:** La gestión de inventarios busca constantemente alcanzar un punto de equilibrio entre el exceso y la falta de existencias, evitando tanto el sobreabastecimiento como el *understocking*. Uno de los factores más frecuentes que conduce a la ruptura de inventario es la subestimación de la demanda real por parte de la empresa (Mohamed, 2024). Este error puede deberse a proyecciones inexactas, falta de información actualizada o a una planificación insuficiente frente a variaciones del mercado.

**Estrategias de mitigación:** Para reducir el riesgo de agotados, es fundamental adoptar prácticas avanzadas de gestión y técnicas específicas que garanticen la disponibilidad continua de productos. Como ya se mencionó, una de las estrategias más extendidas es el mantenimiento de inventarios de seguridad (*safety stock*), concebidos precisamente para proteger contra las incertidumbres tanto de la demanda como del suministro. La previsión precisa de la demanda (*accurate forecasting*) también se destaca como una herramienta crítica para prevenir rupturas. Cuando las proyecciones se alinean adecuadamente con las necesidades reales del mercado, la organización puede ajustar su producción y reposición de manera más eficiente, reduciendo significativamente la probabilidad de desabastecimiento (Mohamed, 2024). Además, la implementación de políticas de inventario bien estructuradas, como el sistema Mini–Max, permite optimizar los niveles de existencias y asegurar la disponibilidad de materiales clave (Veloz-Navarrete & Parada-Gutiérrez, 2017). Este tipo de políticas posibilita, por ejemplo, incrementar de forma estratégica los niveles de inventario en materias primas que históricamente han presentado rupturas frecuentes, garantizando así un flujo continuo hacia la producción y elevando el nivel de servicio interno.

Los agotados representan uno de los riesgos más críticos dentro de la gestión de inventarios, ya que afectan simultáneamente la **rentabilidad, la eficiencia operativa y la satisfacción del cliente**. Desde una perspectiva financiera, cada ruptura de inventario se traduce en ingresos perdidos y en ocasiones en mayores costos por compras de emergencia o sustitutos más costosos. Operativamente, los agotados interrumpen la producción, retrasan pedidos y generan ineficiencias que impactan la continuidad del negocio.

A nivel estratégico, este fenómeno afecta directamente la **reputación corporativa** y la **fidelidad del cliente**, pues la incapacidad para atender la demanda mina la confianza y puede desviar ventas hacia competidores. La causa más frecuente de las rupturas es una mala estimación de la demanda, derivada de pronósticos inexactos o planificación insuficiente frente a variaciones del mercado.

A continuación se presenta una tabla sintetizando los KPIs de gestión revisados:

<b>KPI</b>	<b>Qué mide</b>	<b>Objetivo Gerencial</b>	<b>Interpretación / Riesgos</b>	<b>Relación con la toma de decisiones</b>
<b>Inventario de seguridad (Safety Stock)</b>	Nivel de inventario que protege contra incertidumbre en demanda y suministro.	Garantizar disponibilidad continua y reducir riesgo de agotados.	Un nivel muy bajo aumenta rupturas; un nivel muy alto inmoviliza capital.	Define niveles mínimos de inventario y sirve para dimensionar el punto de pedido.
<b>Punto de pedido (ROP)</b>	Momento exacto en el que debe generarse un nuevo pedido.	Evitar rupturas durante el lead time.	Si el ROP está subestimado, aumentan los agotados; si está sobreestimado, crece el inventario innecesario.	Clave para coordinar compras, producción y abastecimiento.
<b>Rotación de inventarios</b>	La velocidad con la que el inventario se vende o se usa en un periodo.	Optimizar uso del capital y reducir costos de almacenamiento.	Rotaciones bajas indican exceso de inventario; rotaciones muy altas pueden reflejar riesgo de agotados.	Determina necesidades de reposición, estrategias ABC y políticas Mini–Max.
<b>Agotados (Stockouts)</b>	Frecuencia o porcentaje de veces que no se puede atender la demanda por falta de inventario.	Minimizar pérdidas de venta y proteger la satisfacción del cliente.	Impacta ingresos, continuidad operativa y reputación.	Orienta ajustes de forecast, inventario de seguridad y políticas de reabastecimiento.
<b>Nivel de servicio</b>	Porcentaje de pedidos atendidos completa y oportunamente.	Asegurar cumplimiento al cliente interno y externo.	Niveles bajos indican fallas de reposición o errores en forecasting.	Ayuda a evaluar eficacia del modelo de inventarios y del proceso SCM.
<b>Inventario promedio</b>	Cantidad promedio de inventario disponible en un periodo.	Balancear disponibilidad con eficiencia financiera.	Niveles altos inmovilizan capital; niveles bajos generan riesgo de ruptura.	Base para evaluar políticas Mini–Max y análisis de reducción de stock.
<b>Días de inventario (DOI)</b>	Días que tarda la empresa en vender o usar todo su inventario actual.	Medir eficiencia en la gestión del stock y la liquidez.	Valores altos reflejan sobreinventario y costo financiero oculto.	Relacionado con optimización de compras y planeación de demanda.

**Tabla 2. Síntesis de KPIs de gestión**

### 2.2.2. El Vínculo entre Precisión del Pronóstico y Eficiencia del Inventario

En cuanto a la gestión de inventarios, existe una relación directa y comprobada entre la precisión del pronóstico de la demanda y la eficiencia operativa de las organizaciones. Un pronóstico más preciso permite a las empresas operar con niveles reducidos de inventario de seguridad (safety stock), el cual tiene como objetivo ser una reserva adicional para

contrarrestar los riesgos asociados con la incertidumbre tanto en la oferta como en la demanda. Mantener este tipo de inventario es una práctica común, pero su exceso puede traducirse en costos elevados de almacenamiento y mantenimiento, afectando la rentabilidad de las empresas.

La implementación de modelos de Machine Learning (ML) en los procesos de pronóstico de la demanda ha evidenciado un impacto significativo y cuantificable en la mejora de esta estimación. Por ejemplo, un estudio de caso en el sector minorista demostró que el uso de estas tecnologías resultó en una disminución del 15% en los costos asociados al mantenimiento de inventario y una reducción del 20% en los episodios de desabastecimiento (Pandey & Manna, 2025). A diferencia de los enfoques tradicionales, que suelen basarse en reglas estáticas, los sistemas de ML tienen la capacidad de calcular y ajustar dinámicamente los niveles óptimos de safety stock en tiempo real. Este ajuste se realiza considerando factores como la volatilidad de la demanda y el desempeño de los proveedores, lo que permite una gestión más precisa y adaptable (Porter, 2025).

### **2.3. Personalización de la Experiencia del Cliente Mediante IA**

En un mercado donde la lealtad a la marca es cada vez más frágil, la personalización se ha convertido en una estrategia clave para la retención y el crecimiento.

#### **2.3.1. Motores de Recomendación y Segmentación de Clientes**

La inteligencia artificial (IA) se ha consolidado como el núcleo propulsor de la hiperpersonalización a gran escala en el ámbito del comercio y el marketing. Mediante el uso de técnicas avanzadas de aprendizaje automático (machine learning o ML), las empresas logran realizar una segmentación de clientes altamente sofisticada. Esta segmentación trasciende los enfoques tradicionales basados únicamente en datos demográficos, como edad, género o ubicación, e incorpora elementos más complejos como patrones de comportamiento, historial de compras y preferencias inferidas a partir de interacciones previas. Gracias a este nivel de detalle, las organizaciones están capacitadas para diseñar campañas de marketing y ofertas que se alinean de manera precisa con las necesidades y deseos específicos de cada segmento de clientes, incrementando así la relevancia y la efectividad de sus estrategias comerciales (Rutten, 2023).

Entre las aplicaciones más sobresalientes de la IA en este contexto destacan los motores de recomendación, cuyo impacto en el comercio electrónico resulta particularmente

significativo. Estos sistemas operan mediante algoritmos avanzados, entre los que se incluyen:

**Filtrado colaborativo:** Este método sugiere productos basándose en las elecciones de compra de usuarios con perfiles o comportamientos similares al cliente en cuestión.

**Filtrado basado en contenido:** Este enfoque recomienda artículos que comparten atributos con aquellos por los que el cliente ha mostrado interés previamente, como categorías, marcas o características específicas.

Con estas técnicas, los motores de recomendación generan sugerencias de productos hiperespecíficas y adaptadas en tiempo real, ajustándose dinámicamente a las acciones y preferencias del consumidor. Su eficacia se ve reflejada en estimaciones que indican que estos sistemas pueden contribuir hasta con el 31.8% de los ingresos totales en el comercio electrónico para aquellos minoristas que los han integrado plenamente en sus operaciones. Esta cifra pone de manifiesto no solo su capacidad para impulsar las ventas, sino también su importancia estratégica en la mejora de la experiencia del cliente y en el fortalecimiento de la lealtad hacia la marca (Chowhan, 2025).

### 2.3.2. Impacto de la Personalización en la Satisfacción y Lealtad del Cliente

La personalización a través de herramientas de inteligencia artificial; tiene un resultado significativo, medible y cuantificable en los KPIs del negocio. De esta manera se evidencia que:

- La personalización ha trascendido su rol como táctica de marketing para consolidarse como un imperativo estratégico en la gestión empresarial contemporánea. Esta relevancia se fundamenta en una marcada evolución del comportamiento del consumidor, donde más del 77% elige, recomienda o está dispuesto a pagar un sobreprecio por marcas que ofrecen servicios y experiencias adaptadas a sus necesidades individuales (Qualtrics, 2025).
- Para capitalizar esta demanda, la implementación de estrategias de personalización apalancadas en inteligencia artificial ha demostrado ser una herramienta eficaz, correlacionándose con un incremento del 15.7% en las tasas de retención de clientes (Chowhan, 2025).
- El impacto de estas iniciativas se refleja directamente en los indicadores de rendimiento financiero; se ha documentado que la personalización puede generar un aumento en los ingresos por ventas superior al 10% y un retorno de la inversión (ROI) entre cinco y ocho veces mayor sobre el gasto en marketing, en comparación con las campañas masivas tradicionales (DLAPiper, 2025)

## 2.4. Marco Ético y Regulatorio de la IA en Colombia

El avance de soluciones de inteligencia artificial basadas en datos de consumidores plantea un imperativo de cumplimiento regulatorio y ético. En jurisdicciones con un marco jurídico consolidado en la materia, como es el caso de Colombia, la adhesión a la estricta normativa sobre el tratamiento de datos personales se convierte en un factor crítico para la viabilidad y legitimidad de dichas implementaciones.

### 2.4.1. Ley de Protección de Datos Personales (Ley 1581 de 2012)

El marco regulatorio para la protección de datos personales en Colombia se articula en torno a la Ley 1581 de 2012, la cual funge como el pilar fundamental de la privacidad en el país. Esta legislación establece un régimen de gobernanza de datos de aplicabilidad transversal, abarcando a todas las entidades públicas y privadas que realicen tratamiento de información personal en el territorio nacional. En el contexto de la adopción de tecnologías emergentes, la viabilidad y legitimidad de cualquier iniciativa de inteligencia artificial dependen de la estricta observancia de sus principios rectores, los cuales son (OECD, 2020):

- **Legalidad:** El tratamiento de datos debe sujetarse a la ley.
- **Finalidad:** Los fines del tratamiento deben ser legítimos e informados al titular.
- **Libertad:** Se requiere el consentimiento previo, expreso e informado del titular para el tratamiento de sus datos.
- **Veracidad o Calidad:** La información debe ser veraz, completa, exacta y actualizada.
- **Transparencia:** Se debe garantizar el derecho del titular a obtener información sobre el tratamiento de sus datos.
- **Acceso y Circulación Restringida:** El tratamiento se sujeta a los límites de la naturaleza de los datos y las disposiciones legales.
- **Seguridad:** Se deben adoptar medidas técnicas, humanas y administrativas para proteger los datos.
- **Confidencialidad:** Se debe garantizar la reserva de la información.

Adicionalmente, la legislación articula los mecanismos de gobernanza y supervisión, instituyendo el Registro Nacional de Bases de Datos (RNBD), en el cual las empresas deben inscribir sus bases de datos. De manera concurrente, designa a la Superintendencia de Industria y Comercio (SIC) como la autoridad nacional de protección de datos, confiriéndole plenas facultades para ejercer la vigilancia e imponer sanciones en caso de incumplimiento (Baker McKenzie InsightPlus, 2025).

## 2.4.2. Propuestas de Regulación de IA y Clasificación de Riesgo

El entorno regulatorio colombiano evidencia un esfuerzo proactivo por establecer un marco normativo específico para la inteligencia artificial, buscando armonizar su legislación con las tendencias globales. En este contexto, el Proyecto de Ley 442 de 2025 emerge como la iniciativa central, adoptando como referente marcos jurídicos de vanguardia como el AI Act de la Unión Europea. La arquitectura de este marco normativo se fundamenta en una taxonomía de riesgo, aplicando un principio de proporcionalidad. Con base en este enfoque, los sistemas de IA son clasificados en cuatro niveles jerárquicos—inaceptable (prohibido), alto, limitado y mínimo—, donde las obligaciones regulatorias se corresponden directamente con el grado de riesgo evaluado. (Davenport, T., Guha, A., Grewal, D., & Bressgott, T., 2020)

Para el alcance de esta tesis, es crucial notar que los **sistemas de recomendación y los asistentes virtuales** (chatbots) generalmente se clasifican en la categoría de **Riesgo Limitado**. Esta clasificación no prohíbe su uso, pero impone obligaciones específicas de **transparencia**. Las empresas que implementen estos sistemas deberán informar claramente a los usuarios que están interactuando con una IA y ofrecerles la opción de desactivar la personalización o interactuar con un humano.

## 2.4.3. Principios de IA Ética: Transparencia, Equidad y Responsabilidad

Trascendiendo el mero cumplimiento normativo, la operacionalización de la inteligencia artificial exige la integración de un marco deontológico robusto. La adhesión a principios éticos es fundamental, no solo para mitigar riesgos reputacionales, sino también para generar confianza entre los grupos de interés (stakeholders) y garantizar la equidad de los resultados algorítmicos.

- **Equidad (*Fairness*):** El principio de equidad exige una diligencia proactiva en la auditoría y mitigación de sesgos algorítmicos. Dado que los modelos de IA son entrenados con datos históricos, existe un riesgo inherente de que perpetúen e incluso amplifiquen sesgos sociales o de mercado preexistentes, resultando en discriminaciones sistemáticas. Por lo tanto, la gobernanza de la IA debe incorporar mecanismos para asegurar que los resultados del sistema sean equitativos y no generen un tratamiento adverso para grupos específicos de clientes (Puntoni, S., Reczek, R. W., Giesler, M., & Botti, S., 2021).
- **Explicabilidad (*Explainability*):** Este principio, a menudo referido como XAI (Explainable AI), alude a la capacidad de una organización para interpretar y articular el razonamiento que subyace a una decisión algorítmica específica. Este requisito presenta un desafío particular en modelos de alta complejidad, como las redes neuronales profundas, comúnmente denominados "cajas negras". No obstante, la explicabilidad es un componente crítico no solo para la depuración técnica y la

validación interna del modelo, sino también para fundamentar la confianza de los usuarios y cumplir con las expectativas regulatorias.

- **Responsabilidad y Rendición de Cuentas (*Accountability*):** El principio de rendición de cuentas postula que las organizaciones son responsables de los resultados generados por sus sistemas de IA. Su operacionalización requiere el establecimiento de un marco de gobernanza claro que defina las líneas de responsabilidad por el ciclo de vida del algoritmo, desde su diseño hasta su despliegue y monitoreo. Esto incluye la implementación de protocolos de supervisión humana efectiva (*human-in-the-loop*) y la disposición de mecanismos de remediación ágiles para rectificar errores y gestionar los impactos adversos (McKinsey & Company, n.d.).

#### **2.4.4. Integración práctica en la metodología de pronóstico**

En la implementación metodológica de modelos de IA para pronóstico de ventas se deben incorporar de modo concreto las salvaguardas éticas. A continuación, se mencionan algunas buenas prácticas específicas.

##### **2.4.4.1. Anonimización y minimización de datos (privacidad)**

Antes de entrenar los modelos (Random Forest, SVM, XGBoost), los datos deben ser tratados para eliminar identificadores personales. La anonimización (convertir datos personales en información que no permita identificar a ningún individuo) protege la privacidad en cumplimiento de la Ley 1581. Se pueden usar datos agregados de ventas por tienda o categoría, evitando incluir información sensible no necesaria para el pronóstico. Además, se implementan medidas de seguridad en el tratamiento de datos (por ejemplo, cifrado o controles de acceso) para asegurar su confidencialidad.

##### **2.4.4.2. Consentimiento e información a titulares**

Si se utilizan datos que pueden identificarse como personales (por ejemplo, datos de consumidores o empleados), la organización debe informar claramente los fines del análisis y obtener el consentimiento expreso de los titulares. Esto implica explicar en el respectivo aviso de privacidad cómo se procesarán los datos para alimentar los modelos predictivos. Dicha transparencia en el uso de datos contribuye a la confianza del público y cumple con las exigencias de las normativas tanto europeas (GDPR) como colombianas.

#### **2.4.4.3. Evaluación y mitigación de sesgos (Equidad)**

Es necesario examinar los datos de entrenamiento y los resultados del modelo para identificar sesgos que pudieran generar decisiones injustas. Por ejemplo, se debe analizar si el conjunto de datos es representativo y no excluye grupos relevantes (ubicaciones, segmentos de clientes, etc.), tal como sugiere una auditoría algorítmica. Se pueden aplicar métricas de equidad para detectar desviaciones significativas en los errores de predicción entre subgrupos (por ejemplo, diferente desempeño en zonas urbanas vs. rurales). Si se detectan sesgos, se adoptan estrategias de corrección, como re-pesaje de datos o redefinición de variables proxy. Este proceso de auditoría algorítmica (análisis sistemático del origen y calidad de datos, de la lógica del algoritmo y de sus resultados) es hoy una práctica recomendada en la UE y otros marcos.

#### **2.4.4.4. Interpretabilidad y explicabilidad (Transparencia)**

Aunque modelos como Random Forest o XGBoost son complejos, debe facilitarse su interpretación para efectos de transparencia. Esto se logra usando técnicas de IA explicable: por ejemplo, calcular la importancia de variables (feature importance) en los árboles del bosque aleatorio o aplicar métodos como SHAP o LIME que estiman cómo cada variable afecta la predicción. Según la OCDE, se debe proporcionar información comprensible sobre las fuentes de datos, factores y razonamientos que subyacen a las predicciones, de modo que los afectados puedan entender los resultados. Igualmente, la UE enfatiza la necesidad de informar a los usuarios, de forma accesible, sobre el funcionamiento y limitaciones del sistema y de permitirles impugnar decisiones automatizadas. En la práctica, esto implica documentar la lógica de decisión del modelo y generar reportes de explicabilidad que acompañen cada pronóstico.

#### **2.4.4.5. Documentación y trazabilidad (Rendición de cuentas)**

Todo el ciclo de vida del modelo debe quedar documentado detalladamente. Esto incluye registrar las fuentes de datos, transformaciones aplicadas, versiones del código y criterios de ajuste de hiperparámetros. Dicha documentación garantiza la trazabilidad exigida por la OCDE. Se debe poder reconstruir cómo y por qué el modelo generó cierta predicción. Además, se establecen protocolos de gestión de cambios (por ejemplo, nuevas versiones del modelo cuando cambian los datos). En consonancia con la normativa colombiana, es recomendable realizar evaluaciones de impacto en protección de datos antes de implementar el modelo (ex-ante), y auditorías periódicas del sistema para asegurar su buen funcionamiento. Del mismo modo, la institución asume la responsabilidad final y pone en marcha mecanismos de supervisión humana para revisar los pronósticos antes de tomarlos como definitivos.

## 2.5. Síntesis y Brecha del Conocimiento

La literatura académica subraya de manera consistente el potencial de la inteligencia artificial, y de los modelos de aprendizaje automático (ML) y profundo (DL) en particular, para reconfigurar procesos críticos como el pronóstico de la demanda, la gestión de inventarios y la personalización en el sector de bienes de consumo masivo (CPG). Existe un consenso en la investigación global sobre las fortalezas y debilidades relativas de modelos como ARIMA, Random Forest (RF), SVM y XGBoost en diversos contextos, así como sobre los beneficios documentados de la optimización de inventarios y la personalización mediante IA (Castiblanco-Ruiz, S. A., Gonzalez-Ruiz, J. D., & Oviedo-Gomez, A. M., 2023)

No obstante, una revisión sistemática de la literatura revela un vacío empírico significativo. No se identifican estudios que realicen un análisis comparativo integral y simultáneo de los cuatro modelos a través de horizontes de tiempo de corto, mediano y largo plazo, dentro del contexto específico del mercado de consumo masivo en Colombia (Mahecha Zuluaga, J. A., & Gómez López, L. F., 2017).

El mercado colombiano presenta un conjunto de singularidades —incluyendo dinámicas de consumo con alta sensibilidad al precio, un panorama competitivo complejo, una infraestructura de datos en evolución y un marco regulatorio propio— que limitan la validez externa de estudios realizados en otras geografías. La extrapolación de hallazgos de mercados norteamericanos o europeos puede conducir a conclusiones imprecisas. En consecuencia, se justifica la necesidad de una investigación que ofrezca un análisis contextualizado y empíricamente validado, cuyo fin es aportar un valor práctico y relevante para la toma de decisiones gerenciales en el sector CPG de Colombia y, por extensión, en otros mercados latinoamericanos con características similares (JUSDA, n.d.).

## Capítulo 3: Metodología de Investigación Aplicada

Este capítulo detalla el enfoque metodológico adoptado para responder a la pregunta de investigación. Se profundiza en el diseño de la investigación, la operacionalización de las variables, el tratamiento de los datos del canal de farmacias, la implementación de los modelos predictivos en R y la estrategia de validación mediante métricas de error.

### 3.1. Diseño de la Investigación

Para abordar los objetivos de este estudio, se empleará un diseño de investigación **cuantitativo, comparativo y longitudinal**, estructurado para analizar la dinámica comercial en el Canal de Droguerías y Farmacias: como se propuso en el anteproyecto.<sup>9</sup>

- **Cuantitativo:** Se fundamenta en la recolección y análisis estadístico de datos numéricos históricos, específicamente la relación entre la venta planeada, la venta real (Sell-In) y la rotación (Sell-Out).
- **Comparativo:** El núcleo del estudio es la contrastación del rendimiento de cinco modelos de pronóstico distintos (ARIMA, SVM, Random Forest, Regresión Lineal y XGBOOST) bajo condiciones idénticas, para determinar cuál minimiza el error en la predicción de la demanda.
- **Longitudinal:** Se analizan series temporales a lo largo de un período de 3 años para capturar tendencias, estacionalidad y evaluar la robustez de los modelos ante las fluctuaciones del mercado en un canal de venta en particular.

Este enfoque metodológico resulta idóneo para la validación empírica del rendimiento de diversas técnicas predictivas y, fundamentalmente, para cuantificar su repercusión en los indicadores de negocio. De esta manera, el estudio permitirá reflejar los impactos que se tendrían al lograr mejores pronósticos que permitan configurar de forma más eficiente y acetada el abastecimiento.

## **3.2. Población, Muestra y Operacionalización de Variables**

### **3.2.1. Fuente de Datos y Alcance**

La investigación se sustenta en un dataset transaccional proveniente del Canal de Droguerías y Farmacias (cadenas propias y distribuidores independientes). Los datos crudos se extrajeron de los sistemas ERP de la compañía y se consolidaron mediante la "Maestra de Productos" (T\_Producto) para homologar referencias.

- *Unidad de Análisis:* Código EAN (European Article Number) único por producto.
- *Granularidad Temporal:* Mensual (agrupación de venta total por mes y año).
- *Ventana de Observación:* 29 periodos mensuales continuos por serie (Enero 2023 - Mayo 2025).

## Imagen previa a Anexo 1. Sell In por SKU x Cliente x Mes x Año Canal Droguerías y Farmacias

SKU	Description	Sub-Category	Segmento	Comentario	JAN DP	Invoice	Open	Total
MX01910C	Deo LSS 24/7 Powder Fresh Spray 91g/15	AP/Deo	Aerosol	Reemplaza al MX01910B / Julio 10 : Se mueve transición	129	48	-	48
61024844	LSS Clinical Protect and Clarify 20g	AP/Deo	Barra	Nuevo 3Q 2022	-	-	-	-
FMX02911	Deo SS 24/7 AP Cool NightBar 50GR	AP/Deo	Barra		-	-	-	-
FMX04531	Deo MSS Xtreme Ultra Stick 50GR	AP/Deo	Barra	Nuevo 1Q 2022 Transición al US00064B	5	34	-	34
MX02550A	Deo MSS Multi Prot XS Bar 50G	AP/Deo	Barra		-	-	-	-
MX04554A	Deo LSS 24/7 ProS Spray 91gr	AP/Deo	Aerosol	Reemplaza al FMX05756	-	-	-	-
MX04989A	Deo LSS Clinical Powder Spr 93gr 150ml	AP/Deo	Aerosol	Reemplaza al MX02183A / Agosto 10 : Confirmando por C	-	-	-	-
MX04570A	Deo LSS Derma Aloe Spray 150ml	AP/Deo	Aerosol	Reemplaza al FUS00447A	20	29	-	29
61010345	Deo LSS Derma Aloe Spray 150mlE	AP/Deo	Aerosol	Transición Edición Limitada 4Q 2020 hasta Junio 2021	-	-	-	-
MX06390A	Deo LSS Derma Extra Clarifying 120 ml	AP/Deo	Aerosol		-	-	-	-
MX03710B	Deo LSS Derma Omega 3 Spray 150ml	AP/Deo	Aerosol	Reemplaza al MX03710A	-	-	-	-
MX04090B	Deo LSS Derma Pear Spray 60gr	AP/Deo	Aerosol		-	-	-	-
61004113	Deo LSS Naturals Coconut 91g PT	AP/Deo	Aerosol		30	24	-	24
MX05810A	Deo LSS Perfect Tone VIT E W Derma 2 Pck	AP/Deo	Aerosol	Viene de Transición del CD01900A	169	130	-	130
MX05812A	Deo LSS Pro 5 2Pck Spray	AP/Deo	Aerosol		-	-	-	-
MX04536A	Deo MSS 24/7 XS Spray 91gr	AP/Deo	Aerosol	Reemplaza al FMX05256	-	-	-	-
MX04517B	Deo MSS 24/7 Xrm Night Spray 91gr 150ml	AP/Deo	Aerosol	Reemplaza al MX04517A	119	77	-	77
MX04993A	Deo MSS Clinical Dry Spray 93g 150ml	AP/Deo	Aerosol	Reemplaza al MX02272A / Agosto 10 : Confirmando por C	-	-	-	-
MX04525A	Deo MSS Ext.Spr 60gr	AP/Deo	Aerosol		-	-	-	-
MX05815A	Deo MSS Xtreme Ultra Spray 2 Pck	AP/Deo	Aerosol	Viene de Transición del CD01899A	248	197	-	197
61004116	Deo MSS Naturals Charcoal 91g PT	AP/Deo	Aerosol		25	39	-	39
MX02049D	Deo MSS Xtreme Ultra Spray 91gr/150ml	AP/Deo	Aerosol	Reemplaza al MX02049C	-	-	-	-
FUS05754	Deo LSS 24/7 ProS Stick 45gr	AP/Deo	Barra		69	44	-	44

### 3.2.2. Definición de Variables

Para dotar de precisión operativa al modelo, se definieron las siguientes variables críticas extraídas de las fuentes transaccionales de la compañía:

*Variable Dependiente (Objetivo):*

**Venta Real Sell-In (Total):** Corresponde a la venta facturada de la compañía hacia el canal (distribuidores y farmacias) en unidades y valores monetarios. Esta es la variable que los modelos buscan predecir.

*Variables Independientes (Predictoras):*

**Venta Planeada “Mes Num DP” (Forecast Histórico):** El pronóstico generado por los métodos actuales de la compañía. Su inclusión permite establecer una línea base de desempeño para medir la mejora incremental de los modelos propuestos.

**Rotación (Sell-Out):** Datos sobre la salida de mercancía desde el punto de venta al consumidor final. Esta variable es clave para entender la demanda real descontando el efecto de acumulación de inventario en el canal.

## Imagen previa a Anexo 2. Sell Out por SKU x Cliente x Mes x Año Canal Droguerías y Farmacias

A	B	C	D	E	F	G	H
DISTRIBUTOR_HIERA_NAME	MONTH	PRODUCT_EAN	PRODUCT_CODE	PRODUCT_NAME	NET-VALUE_LOCAL	SALES_QTY_AS_LOADED	SALES_QTY_IN_CASES
DISTRIBUIDORA PASTEUR S.A.	202301	7891024179925	BR01450B	Mw COLGATE Perigard Alc Free 250ml	6,812,320.00	240.00	19.98
DISTRIBUIDORA PASTEUR S.A.	202301	8718951179912	61009861	TBM COLGATE 2lg Zag Charcoal 3PK LA 36	1,455,371.00	95.00	7.91
DROSAN	202301	7509546660561	61028045	TP COLGATE Agnes and Fluffy 80g	74,386.00	13.00	0.54
FARMATODO COLOMBIA S.A.	202301	7509546666969	61009892	MW COLG TT 12 Gum 250ml	2,289,940.00	244.00	20.34
DISTRIBUIDORA FARMACELUTICA ROMA S.A.	202301	7509546672298	61015569	TP COLG SPR Immediate Gums 140g	200,747.00	10.00	0.21
UNIDROGAS S.A.	202301	7702010420962	61019827	TS PROTEX Deep Clean 120gr	370,405.00	133.00	1.38
DROSAN	202301	7509546063843	MX01910C	Dee (DG) LSS Powder Fresh Spray 91g/15	207,840.00	15.00	1.25
DEPOSITO DE DROGAS TABOADA S.A.S	202301	7509546667201	61010266	TS PROTEX Men Sport 3x110g	88,335.00	13.00	0.54
INTERNACIONAL DE DROGAS S.A.	202301	7509546651019	M006700A	TP COLGATE Luminous White Charcoal 75ml	3,683,425.00	334.00	6.95
COPSERVIR LTDA	202301	7509546668042	6102794E	TB Agnes/Minions 6+ X2	3,753,245.00	250.00	10.46
ETICOS	202301	7891024183083	FBR1830B	DF COLGATE Tot Fluoride Mnt 25M	1,899,274.92	224.00	9.94
ETICOS	202301	7891024316207	FC031620A	TB COLGATE 360 Compact Head Soft 2x1	2,939,101.55	195.00	16.24
CAJA COLOMBIANA DE SUBSIDIO FARM.	202301	7702010611378	CO00294B	TP COLGATE Tr Act 3x100ml	390,120.00	24.00	1.00
DISTRIBUIDORA PASTEUR S.A.	202301	7509546000343	FC003180C	TP COLGATE Tr Act 100cc	5,257,297.00	610.00	6.49
FARMATODO COLOMBIA S.A.	202301	7509546669458	6100864B	TB COL Pro Planet Whitening Refil	1,801,985.00	193.00	17.17
BRECCIA SALUD LTDA	202301	7702010920820	FC092082	TS PROTEX Deep Clean Antibact 3x110g	292,500.00	39.00	1.63
UNIDROGAS S.A.	202301	7509546657882	6100679B	Dee LSS Talc Cream Duo Sachet 2x9g	59,782.51	4.51	0.19
FARMASANTAS LTDA	202301	7509546055152	CN07483A	CTBM 360 Opti White FH M 2P_LA*245	8,975,065.00	493.00	41.05
INTERNACIONAL DE DROGAS S.A.	202301	7702010097966	61028407	BS PROTEX Duo Protect 110g	1,102,860.00	396.00	5.51
BRATER LCTE S.A.S	202301	7509546063172	M002056A	Dee LSS Clinical CornPowder PLESick45gr	0.00	0.00	0.00
FARMASANTAS LTDA	202301	7509546031828	CN00140A	Tb COLGATE Ext Clin Firm 25P	1,410,940.00	188.00	3.93
DISTRIBUCIONES AXA S.A.	202301	7509546061863	MX05539A	TP COLGATE Lumin White BrillntWhite 2x75ml	1,030,300.43	58.00	1.81
DEPOSITO DE DROGAS TABOADA S.A.S	202301	7509546652153	CO02079A	TP COLGATE Anticav 150ml	724,537.62	87.00	1.81
DISTRIBUCIONES AXA S.A.	202301	7702010470479	CO01823A	Dee SS Clinical practilube 30g	2,510,611.12	888.00	24.68

Variables Temporales: Mes y Año, utilizadas para capturar la estacionalidad y ciclos comerciales propios del sector (ej. temporadas de cuidado oral o eventos promocionales).

### 3.2.3. Selección de la Muestra (Estrategia de Muestreo)

La muestra final se compuso de 3 EANs representativos, uno por cada categoría estratégica de la compañía, seleccionados por su alto volumen de ventas y relevancia en la facturación total:

- Categoría Cepillos: EAN representativo de alta rotación (Ref. Cepillo 360).
- Categoría Cuidado Oral: EAN representativo de crema dental (Ref. Triple Acción 150ml).
- Categoría Jabones: EAN representativo de cuidado personal. (Ref. Jabón Protex Avena).

Esta selección garantiza que los hallazgos sobre la precisión del pronóstico tengan un impacto material en los indicadores de inventario de la organización ya que estos productos constituyen la mayor relevancia en volumen de ventas, garantizando que los resultados del modelado tengan un impacto significativo en la operación global.

### 3.3. Procedimiento de Ingeniería y Preprocesamiento de Datos

El tratamiento de los datos se realizó utilizando el entorno de desarrollo R-Studio, aplicando los siguientes protocolos de limpieza para asegurar la calidad de la información:

Mapeo y Unificación (SKU a EAN): Debido a que los códigos internos (SKU) cambian por modificaciones menores (como empaques o plegadizas), se estandarizó la información utilizando el código EAN como llave única permanente. Se empleó un script automatizado para agrupar las ventas de múltiples SKUs bajo un único EAN histórico, consolidando el campo "TOTAL".

Depuración de Inconsistencias (Filtros de Calidad):

Filtro de Baja Rotación: Se eliminaron del dataset aquellos productos (EANs) que presentaban un 10% o más de sus registros con valor cero en la venta total, descartando así productos discontinuados o de muy baja rotación que introducirían ruido en el aprendizaje del modelo.

Filtro de Consistencia Histórica: Se validó que los productos seleccionados contaran con un historial robusto, depurando aquellos que no alcanzaran un umbral mínimo de registros (ej. 27 meses de datos continuos) para asegurar la viabilidad del análisis de series de tiempo.

Formateo de Estructuras: Conversión de tipos de datos para garantizar que las variables "Venta Planeada" y "Venta Real" sean procesadas como vectores numéricos y las fechas sean reconocidas cronológicamente para la graficación y segmentación temporal.

### 3.4. Implementación de Modelos y Estrategia de Validación

A diferencia de enfoques de partición aleatoria (como *k-fold cross-validation*), que rompen la secuencia temporal, se implementó una estrategia de **Evaluación de Ajuste Histórico (In-Sample Testing)**. El objetivo fue medir la capacidad de cada arquitectura (SVM, RF, XGBoost, ARIMA) para aprender y replicar la estructura compleja de la serie temporal completa.

#### 3.4.1. Configuración de Modelos

Se implementaron y ajustaron cinco modelos predictivos utilizando librerías especializadas en R (`forecast`, `randomForest`, `xgboost`):

- SVM (Support Vector Machine): Configurado para regresión (SVR) para capturar relaciones no lineales.
- Random Forest: Ejecutado con 500 árboles (`ntree=500`) para reducir el sobreajuste mediante bagging.
- Auto ARIMA: Implementación automática para la selección de parámetros óptimos basada en criterios de información (AIC).
- Regresión Lineal: Utilizada como modelo base (benchmark) para medir la relación lineal entre variables temporales y venta.
- XGBoost: Configurado con `max_depth=3` y `eta=0.1` para optimizar el aprendizaje mediante boosting secuencial sobre árboles de decisión.

#### 3.4.2. Métricas de Evaluación y Validación

Para validar la precisión y comparar el desempeño de los modelos frente al pronóstico actual de la compañía, se utilizaron tres métricas de error estándar. Esta estrategia de validación permite cuantificar la desviación entre la predicción y el dato real (Sell-In):

- MAE (Error Absoluto Medio): Para medir la magnitud promedio de los errores sin considerar su dirección, otorgando el mismo peso a todos los desvíos.

- RMSE (Raíz del Error Cuadrático Medio): Utilizado para penalizar errores grandes, lo cual es crítico en la gestión de inventarios para evitar quiebres o excesos significativos.
- MAPE (Error Porcentual Absoluto Medio): Para interpretar el error en términos relativos (%) y facilitar la comparación entre categorías con volúmenes de venta dispares.

La validación final contrasta los resultados de estas métricas para determinar qué modelo optimiza el abastecimiento en el canal de farmacias, minimizando la incertidumbre operativa.

### **3.5. Metodología para la Optimización del Pronóstico de la Demanda mediante Análisis Histórico y Modelado Estadístico**

- Preparación y Consolidación de Datos Históricos
- El primer paso del proyecto consiste en la construcción de un conjunto de datos (dataset) unificado y coherente a partir de diversas fuentes históricas.
- A.A. Recopilación de Datos: Se recopila un histórico de ventas de los últimos tres años. La información principal incluye la venta planeada versus la venta real ("TOTAL") para cada período, lo que permite identificar tendencias, estacionalidad, y desviaciones históricas (picos y valles) en el cumplimiento del pronóstico.
- A.B. Mapeo de Productos (SKU a EAN): Dado que los códigos de producto (SKU) pueden variar en el tiempo por modificaciones menores (ej. cambios de empaque o "plegadizas"), se establece el código EAN como la llave única y permanente para cada producto. Se utiliza una "maestra de productos" histórica (archivo "T\_Producto") proporcionada por la compañía, la cual contiene el registro de correspondencia entre SKUs y EANs.
- A.C. Unificación del Dataset: Se desarrolla un script para procesar los archivos históricos. La función principal de este script es crear una nueva base de datos donde cada registro de venta, originalmente identificado por un SKU, es mapeado a su respectivo EAN. Los datos de venta de múltiples SKUs asociados a un mismo EAN a lo largo del tiempo se agrupan, sumando el campo "TOTAL" (venta real). El resultado es un dataset consolidado donde la llave primaria es la dupla EAN / Mes-Año.
- Procesamiento y Limpieza de Datos con R-Studio
- Para garantizar la integridad y calidad de los datos antes del modelado, se utiliza el entorno de desarrollo estadístico R-Studio.
- B.A. Automatización de la Consolidación: Se implementa un script en R, desarrollado con el apoyo de herramientas de inteligencia artificial (Gemini y ChatGPT-4 Pro), para automatizar la consolidación de los archivos. La principal ventaja de este código es su capacidad para buscar y extraer la columna de venta (ej. "TOTAL") independientemente de su posición en el archivo o si el nombre está en mayúsculas o minúsculas. Esto elimina la necesidad de pre-procesamiento manual y evita errores, dado que los archivos históricos no siempre mantienen una estructura de columnas consistente.

- B.B. Depuración de Productos Descontinuados:
- Primer Filtro (Baja Rotación): Se aplica un criterio para depurar SKUs con baja o nula relevancia histórica. Se genera un código en R que identifica y elimina del dataset aquellos SKUs que presentan un 10% o más de sus registros con valor cero en la columna de venta total. Este filtro permite excluir eficazmente productos discontinuados o en transición que podrían generar desviaciones en el modelo.
- Segundo Filtro (Consistencia Histórica): Se realiza una validación mediante una tabla dinámica para asegurar la consistencia de los datos a lo largo del tiempo. Se agrupan los datos por EAN y se realiza un conteo de los registros mensuales. Se depuran aquellos EANs que no cuentan con un historial completo (ej. 27 meses de datos), garantizando que solo los productos con una trayectoria sólida sean considerados para el análisis de tendencias.
- B.C. Formateo de Datos: Finalmente, se realiza una conversión de tipos de datos, asegurando que todas las columnas numéricas (venta planeada, venta real) sean tratadas como valores y no como texto, una corrección necesaria tras la importación de archivos CSV.
- Selección de Muestra y Análisis de Correlación
- Con el dataset limpio y estructurado, se procede a la fase de análisis y modelado.
- D.A. Selección de Muestra Representativa: Para realizar un análisis focalizado y relevante, se seleccionó un EAN representativo por cada categoría de producto. La selección se basó en el criterio Pareto (80/20), eligiendo aquellos productos que constituyen la mayor relevancia en ventas para la compañía dentro de su respectiva categoría. Esto se logró cruzando la base de datos depurada con una "maestra de segmentos".
- D.B. Modelado y Análisis de Correlación: Se corre el modelo estadístico en R-Studio con la muestra seleccionada. El objetivo principal es analizar la correlación entre la demanda planeada y la venta real, y verificar la precisión del método de pronóstico actual. El análisis sobre un histórico amplio permite identificar patrones de estacionalidad que, al no ser gestionados con un modelo estadístico avanzado, generan un error significativo en la planeación actual.
- Este enfoque metodológico garantiza la creación de un modelo de pronóstico basado en datos limpios, consistentes y representativos, sentando las bases para una planeación de la demanda más precisa y eficiente.

### **3.6. Implementación y Puesta a Punto de Modelos (Hyperparameter Tuning)**

Teniendo la información completa con la que se va a trabajar, se empieza a revisar el código que permitirá preparar los datos, definir métricas de evaluación, ejecutar 5 modelos distintos de predicción, evaluar el rendimiento de cada proyección realizada con cada modelo y al final se buscará visualizar los resultados en un gráfico comparativo. El objetivo general es el de generar un benchmarking de modelos de predicción de series temporales / regresión,

aplicado sobre un dataset de ventas de los EAN escogidos bajo los parámetros establecidos anteriormente.

### Paso 1: Cargar librerías clave

Con este código lo que se busca es cargar las librerías necesarias para ejecutar el script. Para este caso vamos a usar las siguientes:

- **dplyr**: Manipulación de datos (mutate, arrange, select, etc.).
- **lubridate**: Manejo de fechas (aquí no se usa mucho porque se armó Fecha con as.Date, pero igual ayuda).
- **ggplot2**: Graficación avanzada.
- **e1071**: Implementación de algoritmos de machine learning, en este caso SVM.
- **randomForest**: Construcción de bosques aleatorios para regresión/clasificación.
- **forecast**: Series de tiempo, en particular el Auto ARIMA.
- **xgboost**: Modelo avanzado basado en boosting.

```
1 # =====
2 # 🛠️ 1 LIBRERÍAS
3 # =====
4 library(dplyr)
5 library(lubridate)
6 library(ggplot2)
7 library(e1071)      # SVM
8 library(randomForest) # Random Forest
9 library(forecast)  # Auto ARIMA
10 library(xgboost)  # XGBoost
11
```

### Paso 2: Datos base

La primera parte de este paso se centra en crear un diccionario que convierte abreviaturas de meses en número (ej. "Ene" → 1, "Feb" → 2).

```
12 # =====
13 # 📊 2 DATOS BASE
14 # =====
15 meses_num <- c("Ene"=1, "Feb"=2, "Mar"=3, "Abr"=4, "May"=5,
16               "Jun"=6, "Jul"=7, "Ago"=8, "Sep"=9, "Oct"=10,
17               "Nov"=11, "Dic"=12)
18
```

Después construye una data frame inicial con los siguientes parámetros:

**Mes\_Año**: Texto con mes y año.

**Total:** El valor numérico de interés, en este caso las ventas.

```
19 □ datos <- data.frame(  
20 □   Mes_Año = c("Sep 2024", "Sep 2023", "Oct 2024", "Oct 2023", "Nov 2024", "Nov 2023",  
21   "May 2025", "May 2024", "May 2023", "Mar 2025", "Mar 2024", "Mar 2023",  
22   "Jun 2024", "Jun 2023", "Jul 2024", "Jul 2023", "Feb 2025", "Feb 2024",  
23   "Feb 2023", "Ene 2025", "Ene 2024", "Ene 2023", "Ago 2024", "Ago 2023",  
24   "Abr 2025", "Abr 2024", "Abr 2023"),  
25 □   Total = c(1335,936,576,317,871,266,  
26   608,651,450,1375,681,784,  
27   638,550,464,234,755,236,  
28   305,637,867,433,502,341,  
29   445,869,260)  
30 )  
31
```

Ahora, con esta parte del código, el dataset queda con variables limpias y ordenadas temporalmente: mes numérico, año y una columna “Fecha” que permite graficar en escala de tiempo.

```
32 datos <- datos %>%  
33   mutate(Mes = substr(Mes_Año, 1, 3),  
34   Anio = as.numeric(substr(Mes_Año, 5, 8)),  
35   MesNum = meses_num[Mes],  
36   Fecha = as.Date(paste(Anio, MesNum, "01", sep = "-"))) %>%  
37   arrange(Fecha)  
38
```

### Paso 3: Definir métricas

A continuación, se crean funciones personalizadas para calcular las métricas que se establecieron con el fin de comparar los diferentes modelos de regresión o predicción de manera consistente. En esta parte se definen los parámetros bajo los cuales se va a medir la eficiencia de los métodos empleados y poder verificar el desempeño de cada uno.

Para esta investigación se tomaron como base 3 funciones principales:

**MAE (Mean Absolute Error):** Mide el promedio de las diferencias absolutas entre los valores reales y los valores predichos por el modelo. Mientras más pequeño sea el MAE, mejor es el desempeño del modelo, ya que indica que las predicciones se acercan más a los valores observados.

**RMSE (Root Mean Squared Error, Raíz del Error Cuadrático Medio):** Mide la raíz cuadrada del promedio de los errores al cuadrado entre los valores reales y los predichos. Indica el tamaño promedio del error en las mismas unidades de la variable de interés, pero penalizando más los errores grandes que el MAE.

**MAPE (Mean Absolute Percentage Error, Error Porcentual Absoluto Medio):** Mide el promedio de los errores absolutos expresados en porcentaje respecto a los valores reales.



Indica en promedio qué porcentaje de error comete el modelo al predecir. Por ejemplo, un MAPE de 5% significa que, en promedio, las predicciones se desvían un 5% del valor real.

Métrica	Nombre	Qué mide	Unidades	Características principales	Cuándo usarla
<b>MAE</b>	Error Absoluto Medio	Promedio de las diferencias absolutas entre valores reales y predichos	Misma unidad de la variable	Fácil de interpretar, todos los errores pesan igual	Cuando se quiere simplicidad y robustez (no muy sensible a outliers)
<b>RMS E</b>	Raíz del Error Cuadrático Medio	Raíz cuadrada del promedio de los errores al cuadrado	Misma unidad de la variable	Penaliza más los errores grandes (los hace más visibles)	Cuando se quiere dar mayor importancia a errores grandes
<b>MAPE</b>	Error Porcentual Absoluto Medio	Promedio del error expresado como porcentaje del valor real	% (porcentaje)	Intuitivo y comparable entre distintas escalas, pero falla si hay valores reales cercanos a 0	Muy usado en pronósticos y comparaciones entre diferentes series

**Tabla 3.** Resumen de Métricas

Se usa este código

```

39 # =====
40 #   DEFINIR MÉTRICAS
41 # =====
42 mae <- function(actual, pred) mean(abs(actual - pred))
43 rmse <- function(actual, pred) sqrt(mean((actual - pred)^2))
44 mape <- function(actual, pred) mean(abs((actual - pred) / actual)) * 100
45

```

#### Paso 4: Primer modelo “SVM – Support Vector Machine”

Se entrena un **Support Vector Machine (SVM)** para un problema de **regresión** (*Support Vector Regression – SVR*).

- **Variable dependiente (Y):** Total. El valor que queremos predecir (ventas, demanda, etc.).
- **Variables independientes (X):** MesNum (número del mes) y Anio (año)

A diferencia de clasificación, en regresión SVM intenta encontrar una función que se acerque a los puntos reales dentro de un margen de tolerancia ( $\epsilon$ ).

El modelo busca un “tubo” (epsilon-insensitive tube) alrededor de la función de predicción:

- Si un punto cae dentro de ese tubo → no se penaliza.
- Si cae fuera → se penaliza según la distancia.

Para este script se usan parámetros defaults de *e1071*.

El resultado es un modelo capaz de capturar relaciones no lineales entre predictores y respuesta.

```

46 # =====
47 # ● 4 MODELO SVM
48 # =====
49 modelo_svm <- svm(Total ~ MesNum + Anio, data = datos)
50 pred_svm <- predict(modelo_svm, datos)
51

```

### Paso 5: Segundo modelo Random Forest “RF”

Se entrega un Random Forest de regresión con 500 árboles. Los predictores son los mismos que el anterior modelo MesNum y Anio. Aquí se tiene una ventaja ya que captura relaciones no lineales y se reduce el sobreajuste de los datos.

Entrena un **Random Forest de regresión** usando como predictores:

- **MesNum** (mes en número: 1–12).
- **Anio** (año de la observación).

La variable dependiente (Y) es Total.

Argumentos principales:

- **data = datos**: dataset de entrenamiento.
- **ntree = 500**: número de árboles a construir en el bosque (más árboles = mayor estabilidad, pero más tiempo de cómputo).

Mediante el **Bagging (Bootstrap Aggregating)**, se crean múltiples submuestras aleatorias del dataset (con reemplazo) y en cada submuestra se entrena un árbol de decisión.

Para el subconjunto de variables en cada split, en cada nodo del árbol se selecciona un subconjunto aleatorio de variables predictoras (**MesNum, Anio**) para decidir el corte, esto introduce diversidad entre árboles.

Ahora en la agregación de resultados, cuando se obtiene una regresión se toma el promedio de las predicciones de todos los árboles.

Por último se generan las predicciones del modelo. **predict()** aplica el Random Forest entrenado sobre el dataset **datos**. El resultado es un vector con los valores estimados de **Total**.



- **Variable dependiente (Y):** Total (el valor que queremos predecir).
- **Variables independientes (X):**
  - o **MesNum:** número del mes (1 a 12).
  - o **Anio:** año correspondiente.

Busca una **relación lineal** entre la variable respuesta (**Total**) y las variables explicativas (**MesNum**, **Anio**). La ecuación estimada tiene esta forma:

$$Total \approx \beta_0 + \beta_1 \cdot MesNum + \beta_2 \cdot Anio + \varepsilon$$

Donde:

$\beta_0$  es la constante (intercepto).

$\beta_1$  es el coeficiente del mes (cómo cambia Total por cada incremento en el número de mes).

$\beta_2$  es el coeficiente del año (captura la tendencia en el tiempo).



$\varepsilon$  es el error (la parte que no se puede explicar linealmente).

En este script, la regresión lineal funciona como **modelo base** o benchmark.

Para las predicciones del modelo lineal se usan los coeficientes estimados  $\beta$  para calcular el valor esperado de **Total** en cada fila del dataset. Se predice sobre el mismo conjunto de entrenamiento (**in-sample predictions**).

El resultado es un vector con las estimaciones de ventas (o demanda, **Total**) que se usarán luego en la comparación contra otros modelos.

```

68 # =====
69 #   MODELO REGRESIÓN LINEAL
70 # =====
71 modelo_lm <- lm(Total ~ MesNum + Anio, data = datos)
72 pred_lm <- predict(modelo_lm, datos)
73

```

## Paso 8: Quinto modelo XGBOOST

Primero se seleccionan las variables predictoras (**MesNum** y **Anio**) y se convierten en una matriz numérica. XGBOOST no trabaja directamente con data frames, necesita matrices o un objeto especial (**xgb.DMatrix**). **MesNum** captura la estacionalidad del mes (cíclico anual). **Anio** captura la tendencia en el tiempo.

Se crea un objeto **DMatrix**, que es la estructura optimizada de datos de XGBoost. **data:** matriz de predictores. **label:** variable objetivo (en este caso, Total).

**DMatrix** permite un manejo más eficiente de memoria y cálculos, sobretodo en datasets grandes.

Se entrena el modelo XGBoost. Cada parámetro tiene un rol importante:

- **data = dtrain.** Dataset de entrenamiento.
- **nrounds = 50.** Número de iteraciones o árboles que se construirán (cada ronda agrega un árbol nuevo).
- **max\_depth = 3.** Profundidad máxima de cada árbol → controla la complejidad (más profundidad = más capacidad de ajuste pero riesgo de sobreajuste).
- **eta = 0.1.** Tasa de aprendizaje, regula cuánto corrige cada árbol respecto al anterior (valores bajos = aprendizaje más lento pero más preciso).
- **objective = "reg:squarederror".** Define que se trata de un problema de regresión, optimizando el error cuadrático medio.
- **verbose = 0.** Silencia los mensajes durante el entrenamiento.

**XGBOOST (Extreme Gradient Boosting)** es un modelo basado en el ensamble secuencial de árboles de decisión. Cada nuevo árbol intenta corregir los errores de los anteriores. Además, se ajusta bien a relaciones no lineales y maneja muy bien datos con ruido o interacciones complejas.

Posteriormente se generan las predicciones usando el modelo entrenado. Aquí se hace sobre el mismo dataset (**train**), por eso son predicciones in-sample (no generalización todavía). El resultado es un vector numérico con las predicciones de **Total**.

```
74 # =====
75 # 🔥 8 MODELO XGBOOST
76 # =====
77 train_matrix <- as.matrix(datos[, c("MesNum", "Anio")])
78 dtrain <- xgb.DMatrix(data = train_matrix, label = datos$Total)
79
80 modelo_xgb <- xgboost(data = dtrain, nrounds = 50, max_depth = 3,
81 | | | | | eta = 0.1, objective = "reg:squarederror", verbose = 0)
82
83 pred_xgb <- predict(modelo_xgb, dtrain)
84
```

### Paso 9: Tabla de métricas SOLO TRAIN

Inicialmente toma **real** = los valores observados (**Total**) y calcula **MAE**, **RMSE** y **MAPE** para cada modelo usando las predicciones *in-sample* (es decir, sobre el mismo conjunto con el que se entrenaron los modelos). Después construye un **data.frame** con los valores resultantes y lo imprime. Esto da una idea del ajuste dentro de la muestra, pero no dice nada definitivo sobre la capacidad de generalización (predicción fuera de la muestra).

```

85 # =====
86 # 📊 9 TABLA DE MÉTRICAS SOLO TRAIN
87 # =====
88 real <- datos$Total
89 □ metrics_train <- data.frame(
90   Modelo = c("SVM", "Random Forest", "Auto ARIMA", "Regresión Lineal", "XGBoost"),
91   □ MAE = c(mae(real, pred_svm),
92             mae(real, pred_rf),
93             mae(real, pred_arima),
94             mae(real, pred_lm),
95             mae(real, pred_xgb)),
96   □ RMSE = c(rmse(real, pred_svm),
97             rmse(real, pred_rf),
98             rmse(real, pred_arima),
99             rmse(real, pred_lm),
100            rmse(real, pred_xgb)),
101   □ MAPE = c(mape(real, pred_svm),
102             mape(real, pred_rf),
103             mape(real, pred_arima),
104             mape(real, pred_lm),
105             mape(real, pred_xgb))
106 )
107
108 cat("📊 MÉTRICAS EN TRAIN\n")
109 print(metrics_train)
110

```

## Paso 10: Graficar

En un principio crea un **data.frame** en formato ancho donde cada columna es una serie temporal (la real y una columna por modelo). El **as.numeric(pred\_arima)** es importante porque **pred\_arima** proviene de un objeto **ts** o **fitted** y convertirlo a numérico asegura que ggplot lo entienda bien.

Posteriormente se empieza con la construcción del gráfico con ggplot2.

**ggplot(resultados, aes(x = Fecha))**: crea el lienzo; **Fecha** es el eje X.

**geom\_line(aes(y = Real, color = "Real"), size = 1.3)**:

- **aes(y = Real)** grafica la columna **Real**.
- **color = "Real"** no asigna un color literal, sino que mapea la línea a un valor discreto llamado **"Real"**. Eso crea una entrada en la leyenda con etiqueta **"Real"**.
- **size = 1.3** aumenta el grosor de la línea (para destacar la serie real).

Las siguientes **geom\_line()** son líneas separadas para cada modelo. Cada una:

- Mapea su **y** correspondiente,
- Usa **color = "Nombre amigable"** para crear una leyenda con ese *nombre legible*,

- **linetype** controla el tipo de trazo (dashed, dotted, etc.) usado para distinguir visualmente los modelos,
- **size** controla grosor.

**labs(...)**: título y etiquetas de ejes; **color = "Modelo"** cambia el título de la leyenda.

**theme\_minimal()**: tema limpio con fondo claro y rejilla sutil.

**scale\_color\_manual(values = ...)**: fuerza colores específicos para las etiquetas de leyenda. Las claves del vector deben coincidir exactamente con las cadenas usadas en **color = "..."** dentro de cada **geom\_line**.

Después se genera la interactividad con Plotly.

**require(plotly)** carga el paquete **plotly**. (Preferible **library(plotly)** para que falle explícitamente si no está instalado.)

**ggplotly(g2)** convierte el gráfico **ggplot** en un gráfico **interactivo**: hover, zoom, ocultar/mostrar series en la leyenda, etc.

La interpretación visual de lo que está entregando el plot es una comparativa de cómo cada modelo sigue la serie real a lo largo del tiempo. Se pueden diferenciar: Qué modelos siguen la tendencia (o estacionalidad) mejor, fechas donde todos los modelos fallan (picos o valles mal ajustados), divergencias (por ejemplo, XGBoost se separa del real en ciertos meses).

En conclusión, el script permite preparar los datos, definir métricas de envaluación, entrenar 5 modelos diferentes de predicción, evalúa los rendimientos de cada uno y posteriormente visualiza los resultados obtenidos.

#### **Capítulo 4: Presentación y Análisis de Resultados**

Con el objetivo de evaluar el desempeño de los modelos de pronóstico seleccionados (SVM, Random Forest, Auto ARIMA, Regresión Lineal y XGBoost), se analizaron tres métricas de error: Error Absoluto Medio (MAE), Raíz del Error Cuadrático Medio (RMSE) y Porcentaje de Error Absoluto Medio (MAPE). Los modelos se aplicaron a tres categorías de productos: cepillos, crema dental y jabones. A continuación, se presentan los resultados obtenidos y su respectiva interpretación.

#### 4.1. Análisis Comparativo de la Precisión de los Pronósticos

Modelo - Cepillo 360	MAE	RMSE	MAPE (%)
SVM	99	199	22
Random Forest	95	173	22
Auto ARIMA	132	237	29
Regresión Lineal	117	214	28
XGBoost	60	81	14

Tabla 4. Resumen métricas desempeño Cepillo 360




Figura 4. Serie de Tiempo y pronósticos Cepillos 360


En la categoría de cepillos, el modelo XGBoost evidenció el mejor desempeño global, alcanzando el menor MAE (60), el menor RMSE (81) y el MAPE más bajo (14 %). Estos valores reflejan una alta capacidad predictiva y una adecuada adaptación a la estructura de la serie temporal.

El modelo Random Forest ocupó la segunda posición en términos de precisión, con un MAE de 95 y un RMSE de 173, manteniendo un MAPE de 22 %. Los modelos SVM y Regresión Lineal mostraron un desempeño intermedio, mientras que Auto ARIMA presentó los mayores errores (MAE = 132; RMSE = 237; MAPE = 29 %), lo que sugiere una menor capacidad para capturar las dinámicas propias de la demanda en esta categoría.

De esta forma se puede concluir que el modelo XGBoost se consolidó como la alternativa más precisa para la proyección de la demanda de cepillos, superando de manera consistente tanto a los métodos tradicionales como a otros modelos de aprendizaje automático.

Modelo - Cuidado Oral-Crema Dental	MAE	RMSE	MAPE (%)
SVM	178	274	22
Random Forest	166	211	23
Auto ARIMA	205	255	24
Regresión Lineal	210	265	31
XGBoost	89	117	7

**Tabla 5. Métricas de Desempeño Crema Dental**



**Figura 5. Serie de Tiempo y pronósticos Crema Dental**

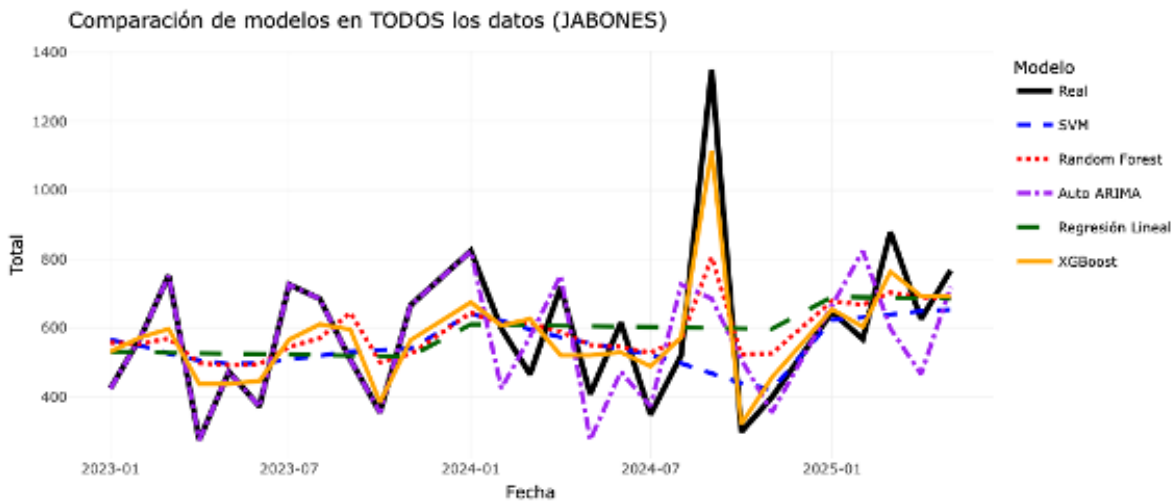
Los resultados correspondientes a la categoría de crema dental confirman la superioridad de XGBoost, que registró los valores más bajos en las tres métricas analizadas (MAE = 89; RMSE = 117; MAPE = 7 %). Este desempeño destaca la capacidad del modelo para capturar patrones complejos y proporcionar estimaciones con un nivel de error significativamente reducido.

Los modelos Random Forest y SVM mostraron un desempeño aceptable, aunque con errores absolutos y porcentuales considerablemente mayores que los de XGBoost (MAPE de 23 % y 22 %, respectivamente). En contraste, Auto ARIMA y Regresión Lineal presentaron los peores resultados en esta categoría, con errores más altos en todas las métricas, evidenciando dificultades para modelar la variabilidad propia de esta serie temporal.

Igual que con los cepillos, XGBoost demostró un desempeño notablemente superior en la categoría de crema dental, posicionándose como la mejor alternativa para la proyección de series con comportamientos más complejos.

Modelo - Jabones	MAE	RMSE	MAPE (%)
SVM	144	217	15
Random Forest	136	170	16
Auto ARIMA	93	171	5
Regresión Lineal	159	212	20
XGBoost	93	111	7

**Tabla 6.** *Métricas de Desempeño Jabones*



**Figura 6.** *Serie de Tiempo y Pronosticos Jabones*

En la categoría de jabones, los resultados muestran un panorama más equilibrado entre modelos. Auto ARIMA y XGBoost obtuvieron los mejores indicadores de precisión, ambos con un MAE de 93. No obstante, Auto ARIMA alcanzó el MAPE más bajo (5 %) frente al 7 % de XGBoost, lo que indica una ligera ventaja relativa en términos de error porcentual. Además, Auto ARIMA presentó un RMSE de 171, mientras que XGBoost obtuvo un RMSE inferior (111), reflejando una mejor adaptación en términos de dispersión del error.

Los modelos Random Forest y SVM mostraron un rendimiento aceptable pero inferior, y Regresión Lineal nuevamente registró el peor desempeño, con un MAPE del 20 %. La competitividad de Auto ARIMA en esta categoría sugiere que la serie de jabones posee un comportamiento temporal más estable, lo que favorece la eficacia de modelos clásicos de series de tiempo.

Para este caso, tanto Auto ARIMA como XGBoost demostraron un desempeño sobresaliente para la categoría de jabones. La ligera ventaja en MAPE de Auto ARIMA indica que, en series con patrones temporales bien definidos, los modelos tradicionales pueden igualar o incluso superar a los enfoques de aprendizaje automático.

Revisando todos los resultados obtenidos del análisis comparativo realizado, se puede concluir sobre la idoneidad de los modelos que se aplicaron:

- XGBoost se posicionó de una forma clara como el modelo más consistente y robusto. Alcanzó los menores niveles de error en la mayoría de las categorías, especialmente en las que tenían mayor complejidad estructural.
- Los modelos de aprendizaje automático (XGBoost, Random Forest y SVM) superaron en general a los enfoques tradicionales y, como se esperaba, destacaron por su capacidad para modelar relaciones no lineales y patrones más complejos.
- Auto ARIMA mostró un rendimiento competitivo en la categoría de jabones, lo que evidencia que, en series con comportamientos más regulares, los modelos clásicos continúan siendo alternativas válidas y eficientes.
- Regresión Lineal presentó de forma consistente los niveles de error más altos, evidenciando limitaciones para capturar las dinámicas presentes en las series analizadas.

En resumen, los resultados respaldan el uso de enfoques diferenciados según las características de cada serie temporal. Para series con alta variabilidad o patrones no lineales, los modelos de aprendizaje automático, y en particular XGBoost, ofrecen ventajas claras. Por otro lado, para series con comportamientos estables, modelos clásicos como Auto ARIMA pueden proporcionar resultados igualmente satisfactorios. Esta evidencia sugiere que la implementación de una estrategia híbrida de modelado, que combine ambos enfoques de acuerdo con las propiedades de cada producto, podría optimizar de manera significativa la precisión de los pronósticos y, en consecuencia, mejorar la toma de decisiones en la planificación de la demanda.

#### **4.2. Impacto Simulado en la Gestión de Inventarios**

Con base a los resultados, el modelo XGBoost es considerablemente superior al de los demás modelos. Este modelo tiene regularmente el error más bajo de todas las métricas, lo que significa que sus pronósticos son mucho más precisos y cercanos a las ventas reales.

Utilizar un pronóstico más preciso impacta directamente en la gestión de inventario y, por ende, en indicadores clave como la rotación y la tasa de agotados. Un mejor pronóstico reduce la incertidumbre, permitiéndote tomar decisiones más eficientes.

#### **Impacto Esperado en los KPIs**

Mediante la implementación de modelos o conjunto de modelos (dependiendo de las características de la demanda) que permitan mejorar la precisión del pronóstico de ventas, se tendrán los siguientes efectos positivos:

**Reducción de la Tasa de Agotados (Stockouts):** Un pronóstico preciso evita la disponibilidad de producto para la venta, reduciendo el riesgo de presentar agotados. Al anticipar la demanda correctamente, se puede tener el stock necesario para satisfacer a los clientes, minimizando las ventas perdidas y mejorando la satisfacción.

**Aumento de la Rotación de Inventario:** Con pronósticos acertados, no se necesita mantener un stock de seguridad (safety stock) excesivo para cubrir la incertidumbre. Esto reduce la cantidad de capital inmovilizado en el almacén y disminuye los costos de

mantenimiento. Se vende el inventario de manera más eficiente, lo que eleva el indicador de rotación.

### Metodología de Simulación

Para cuantificar este impacto, se realizó una simulación que comparaba cómo se habrían comportado los niveles de inventario bajo los pronósticos de ambos modelos (XGBoost vs. Regresión Lineal) frente a las ventas reales. Para ello se realizaron los siguientes pasos:

#### Paso 1: Definir las Variables

- Ventas reales en el período.
- Pronóstico de ventas de la Regresión Lineal para el periodo.
- Pronóstico de ventas de XGBoost para el periodo.
- Stock de Seguridad (Safety Stock). Este es un valor clave que calculas para protegerte contra la variabilidad.
- Inventario al final del período.
- Tiempo de entrega (Lead Time) del proveedor en periodos.
- Orden de compra realizada en el periodo.

#### Paso 2: Calcular el Stock de Seguridad (Safety Stock)

El stock de seguridad depende directamente del error de tu pronóstico. Un modelo con más error (como la Regresión Lineal) requerirá un mayor stock de seguridad.

$$SS = Z * \sigma_L$$

Donde:

Z es el nivel de servicio deseado (por ejemplo, Z=1.65 para un 95% de nivel de servicio).

$\sigma_L$  es la desviación estándar del error del pronóstico durante el tiempo de entrega. Una buena aproximación para es usar el RMSE del modelo.

A continuación, se presentan los stocks de seguridad calculados para cada modelo:

Stock de seguridad	SVM	RF	ARIMA	RL	XGB
Modelo - Cepillo 360	329	286	391	353	134
Modelo - Cuidado Oral-Crema Dental	452	348	421	437	193
Modelo - Jabones	358	281	282	350	183

Tabla 7. KPIs Desempeño

El modelo SVM generó niveles de inventario de seguridad relativamente elevados en las tres categorías analizadas: 329 unidades para cepillos, 452 para crema dental y 358 para jabones. Estos valores reflejan una mayor incertidumbre en las proyecciones realizadas, lo que obliga

a mantener inventarios de respaldo más altos para garantizar la disponibilidad de producto. En particular, el valor correspondiente a crema dental es el más elevado entre todos los modelos evaluados, lo que sugiere limitaciones del SVM para capturar de forma adecuada las fluctuaciones de esta serie temporal.

El modelo Random Forest presentó niveles de inventario de seguridad intermedios: 286 unidades para cepillos, 348 para crema dental y 281 para jabones. Estos resultados son inferiores a los obtenidos con SVM y Auto ARIMA, pero superiores a los de XGBoost. Esto evidencia una mejora en la reducción de la incertidumbre en comparación con SVM, especialmente en crema dental y jabones, aunque sin alcanzar la precisión de los modelos más eficientes.

El modelo Auto ARIMA mostró un comportamiento heterogéneo. Para cepillos y crema dental, los niveles de inventario de seguridad fueron altos (391 y 421 unidades, respectivamente), superando incluso a SVM en la categoría de cepillos, lo que indica dificultades para representar la variabilidad de la demanda. En cambio, para jabones, el nivel calculado fue de 282 unidades, valor cercano al de Random Forest y significativamente menor que el de SVM y regresión lineal. Este comportamiento es coherente con la capacidad de ARIMA para ajustarse mejor a series con patrones regulares, como ocurre con los jabones.

Por su parte, el modelo de Regresión Lineal produjo valores elevados de inventario de seguridad en todas las categorías: 353 unidades para cepillos, 437 para crema dental y 350 para jabones. Estos resultados, ubicados entre los de SVM y ARIMA, evidencian que la simplicidad del modelo no fue suficiente para capturar la complejidad de las series analizadas. Como consecuencia, las proyecciones presentaron errores más amplios que requirieron niveles más altos de stock de seguridad para compensar la incertidumbre.

El modelo XGBoost se destacó de manera consistente al generar los niveles más bajos de inventario de seguridad en todas las categorías: 134 unidades para cepillos, 193 para crema dental y 183 para jabones. Esta reducción significativa respecto a los demás modelos evidencia una mayor precisión en las proyecciones, lo que se traduce en menores requerimientos de inventario adicional para cubrir la variabilidad de la demanda. En el caso de cepillos, por ejemplo, el nivel calculado con XGBoost representa menos de la mitad del requerido por Random Forest y menos de un tercio del estimado con SVM o ARIMA, generando un impacto relevante en términos de optimización de costos logísticos.

El análisis comparativo de los niveles de inventario de seguridad confirma diferencias claras en el desempeño de los modelos. XGBoost se posiciona como el más eficiente, al requerir los niveles más bajos de inventario de seguridad en todas las categorías, lo que refleja su capacidad para generar pronósticos más confiables y estables. Random Forest presentó un desempeño intermedio aceptable, con niveles moderados; SVM y Regresión Lineal se ubicaron de manera consistente entre los modelos menos precisos, generando los niveles más altos de stock. Auto ARIMA, en cambio, mostró un comportamiento mixto: limitado en categorías con alta variabilidad (cepillos y crema dental) pero competitivo en series más estables (jabones).

En términos generales, estos resultados respaldan la utilización de modelos de pronóstico de alta precisión, particularmente XGBoost, como herramienta estratégica para optimizar la gestión de inventarios. Su implementación permite reducir de manera significativa el inventario de seguridad sin afectar el nivel de servicio. Además, se evidencia la conveniencia de adaptar la selección del modelo de pronóstico a las características particulares de cada serie temporal, con el fin de lograr una gestión más eficiente de la cadena de suministro.

### Paso 3: Simular el Flujo de Inventario

Se procedió a simular el inventario mes a mes para cada modelo. La ecuación principal del inventario es:

$$I_t = I_{t-1} + A_t - S_t$$

Donde:

- $I_t$  Inventario al final del periodo t.
- $I_{t-1}$  Inventario al final del periodo anterior.
- $A_t$  Ingreso de inventario en el periodo t.
- $S_t$  Ventas reales durante el periodo t.

La variable  $A_t$  es el pronóstico de ventas que se hizo para ese mes.

De acuerdo con la simulación, se debe tener en cuenta el inventario de seguridad ya calculado. Al final del periodo si el inventario es menor al inventario de seguridad, se generará un pedido de producción por esa cantidad.

### Paso 4: Calcular los KPI's en la Simulación

Mientras se corre la simulación para cada período, se calcula lo siguiente para ambos escenarios:

**Inventario Disponible:** Unidades que se tienen en bodega listos para ser vendidos o utilizados en la producción, sin estar comprometidos en pedidos anteriores o en proceso de espera.

**Agotados (Unidades):** Si las ventas reales son mayores que el inventario disponible, se tiene un agotado.

**Inventario Final:** Unidades al final del periodo al descontar del inventario disponible, las ventas del mes. Si hubo agotados en el mes, el resultado será cero (nunca negativo, a menos que se tenga una política Back Order. Sin embargo, para esta investigación no se implementa este concepto). Si el inventario final es menor al stock de seguridad, se genera una orden de producción por esa cantidad para el próximo periodo. Para este caso se supone que el lead time es un mes para todas las referencias.

Al final de la simulación (después de N períodos), se calculan los KPIs totales:


- Tasa de Agotados (%): Mide el porcentaje de la demanda que no se pudo satisfacer.
- Rotación de Inventario: Mide cuántas veces se vendió el inventario promedio en el período.

## Resultados de la Simulación

### Cepillos

Cepillo 360	VENTA	PRONÓSTICO					INVENTARIO FINAL				
	Fecha	Real	SVM	RF	ARIMA	LM	XGB	SVM	RF	ARIMA	LM
2023-01-01	349	362	393	349	260	394	342	330	391	264	179
2023-02-01	298	345	348	337	281	293	389	381	430	336	175
2023-03-01	433	339	332	336	302	287	295	280	333	222	28
2023-04-01	232	340	327	353	323	287	437	381	512	444	189
2023-05-01	369	345	347	327	344	339	413	359	470	418	159
2023-06-01	355	350	348	336	365	339	408	352	452	428	144
2023-07-01	371	354	347	341	386	339	391	328	421	442	112
2023-08-01	214	359	351	345	407	315	536	466	552	635	235
2023-09-01	391	367	463	322	428	362	511	538	483	671	206
2023-10-01	356	380	404	334	448	287	536	586	461	764	137
2023-11-01	402	398	423	338	469	456	532	607	397	831	191
2024-01-01	731	449	524	350	392	613	250	400	16	493	73
2024-02-01	393	417	425	415	413	419	353	433	413	513	160
2024-03-01	78	397	372	411	434	342	672	726	746	869	424
2024-04-01	392	397	407	354	455	342	678	741	709	932	374
2024-05-01	444	420	462	361	476	450	654	759	626	965	379
2024-06-01	477	460	463	375	497	450	637	745	524	985	352
2024-07-01	460	509	465	392	518	450	686	750	456	1043	342
2024-08-01	581	557	519	404	539	518	662	689	279	1001	279
2024-09-01	1446	595	727	434	560	1316	0	0	0	116	148
2024-10-01	300	618	602	605	581	373	647	588	696	634	221
2024-11-01	648	624	633	553	602	554	623	573	601	588	127
2025-01-01	508	532	543	569	525	527	647	608	662	605	153
2025-02-01	550	526	503	559	546	527	623	561	671	601	129
2025-03-01	514	523	480	557	567	449	632	527	715	654	69
2025-04-01	422	528	485	550	588	449	738	590	843	820	161
2025-05-01	601	541	518	528	609	557	677	507	770	828	117
Venta total	12315					Agotados	1	1	1	0	0
						l prom	524	518	509	648	195

Tabla 8. Resultados Simulación Cepillos



**Figura 7.** Gráfica inventario Cepillo 360

Rotación de inventario	SVM	RF	ARIMA	LM	XGB
2023	28	29	27	24	78
2024	21	21	23	17	56

**Tabla 9.** Resultados rotación de inventario por modelo

La tabla presenta la comparación entre la demanda real y las proyecciones generadas por cinco modelos de pronóstico, junto con la simulación del inventario final mes a mes para cada modelo. Esta información permite evaluar tanto la precisión relativa de las proyecciones como su efecto operativo en los niveles de inventario y la ocurrencia de agotamientos.

En términos generales, los modelos SVM, Random Forest y ARIMA muestran un comportamiento consistente a lo largo del período analizado. Sus proyecciones tienden a ajustarse de forma razonable a la evolución de la demanda, lo cual se refleja en inventarios finales moderados y estables, con promedios de 524, 518 y 509 unidades respectivamente. Además, estos tres modelos registran únicamente un episodio de agotamiento en todo el horizonte simulado, lo que evidencia un buen balance entre la cobertura de la demanda y la eficiencia en la gestión de inventarios. Este patrón es particularmente visible en los primeros meses de 2023, donde las diferencias entre la demanda real y las proyecciones son reducidas, y los inventarios se mantienen dentro de márgenes operativos razonables.

La Regresión Lineal, por el contrario, presenta una tendencia clara a sobreestimar la demanda, especialmente a partir de 2024. Esto genera inventarios finales considerablemente más altos, con un promedio de 648 unidades, el más elevado entre los modelos analizados. Aunque este comportamiento evita por completo los desabastecimientos (cero episodios de agotamiento), implica mayores costos de almacenamiento y capital inmovilizado, reduciendo la eficiencia operativa. Esta sobreacumulación es particularmente marcada en el segundo semestre de 2024, donde los niveles de inventario final superan sistemáticamente las 900 unidades.

El modelo XGBoost exhibe un patrón diferente: en los primeros meses tiende a subestimar ligeramente la demanda, aunque sin provocar agotamientos, mientras que en la segunda mitad del período presenta valores más estables y moderados. Su promedio de inventario es de 195 unidades, significativamente menor al de los demás modelos. Este comportamiento sugiere que XGBoost opera con niveles de inventario más ajustados, lo que puede resultar eficiente en contextos donde la precisión es alta y la reposición es ágil. Sin embargo, en escenarios con alta variabilidad de la demanda, como septiembre de 2024, este enfoque podría aumentar el riesgo operativo, aunque en este caso no se registraron desabastecimientos. Este enfoque puede representar grandes ahorros en administración de inventarios ya que la necesidad de tener unidades en stock se ve reducida en una gran magnitud.

En conjunto, estos resultados muestran que los modelos SVM, Random Forest y ARIMA ofrecen un desempeño equilibrado, manteniendo inventarios un poco por encima de lo esperado, pero garantizando niveles adecuados de servicio. La Regresión Lineal prioriza la cobertura total de la demanda a costa de acumular inventarios excesivos, mientras que XGBoost destaca por operar con niveles de inventario más bajos y controlados, aunque esta característica requeriría un sistema logístico flexible que permita responder rápidamente ante desviaciones.

En términos operativos, la selección del modelo óptimo dependerá de la estrategia de inventarios de la organización. Si se busca minimizar riesgos de desabastecimiento manteniendo un equilibrio con los costos de almacenamiento, modelos como SVM, RF o ARIMA resultan apropiados. Si se prioriza la reducción de inventarios, XGBoost podría ser útil, siempre que se cuente con capacidades de respuesta rápida. Por el contrario, la Regresión Lineal, aunque garantiza disponibilidad, podría no ser eficiente desde una perspectiva de costos.

Ahora, se revisa el indicador de rotación de inventario con el fin de evaluar la eficiencia en la gestión de existencias. Un valor más alto indica una renovación más frecuente del inventario, asociándolo generalmente a una mejor alineación entre la oferta y la demanda, mientras que valores bajos pueden reflejar sobreestimación de los inventarios, lentitud en la rotación o una estrategia de aprovisionamiento poco ajustada.


En el año 2023, los modelos SVM, Random Forest y ARIMA presentan rotaciones similares (28, 29 y 27, respectivamente), lo que evidencia un comportamiento operativo equilibrado. Estos modelos logran mantener inventarios moderados sin incurrir en agotamientos significativos, renovando su stock con una frecuencia adecuada para responder a la demanda real. La Regresión Lineal, por su parte, presenta una rotación menor (24), coherente con su tendencia a sobreestimar la demanda y acumular inventarios más altos, lo que ralentiza la rotación. En contraste, XGBoost muestra una rotación muy elevada (78), explicada principalmente por sus niveles de inventario más bajos y su comportamiento ajustado en la primera parte del periodo. Esta alta rotación no necesariamente implica una mayor eficiencia, sino un manejo más justo de inventarios que puede aumentar la exposición al riesgo en escenarios de alta variabilidad.

En 2024 se observa una disminución generalizada en la rotación de inventario para todos los modelos. SVM y Random Forest bajan a 21, y ARIMA a 23, lo que puede atribuirse a un incremento en los niveles de inventario promedio durante este año, en parte por cambios abruptos en la demanda (por ejemplo, en septiembre de 2024), que llevó a mantener mayores existencias. La Regresión Lineal mantiene la rotación más baja (17), reforzando su perfil de modelo conservador que prioriza la disponibilidad sobre la eficiencia en la utilización de inventarios. XGBoost reduce su rotación de 78 a 56, lo que indica un comportamiento más estable y una menor subestimación en el segundo año, aunque continúa operando con inventarios relativamente bajos frente a los otros modelos. XGBoost destaca por una rotación muy alta, que podría ser ventajosa en entornos con reposición rápida y baja incertidumbre, pero que conlleva riesgos si la demanda se vuelve volátil. Estos resultados refuerzan el análisis previo: la elección del modelo debe considerar no solo la precisión del pronóstico, sino también la estrategia de inventarios y la capacidad operativa de la organización.

## **Crema**

Crema	VENTA	PRONÓSTICO					INVENTARIO FINAL				
Fecha	Real	SVM	RF	ARIMA	LM	XGB	SVM	RF	ARIMA	LM	XGB
2023-01-01	433	426	476	433	413	457	322	329	391	333	158
2023-02-01	305	420	441	379	424	284	567	484	495	556	172
2023-03-01	784	421	563	500	434	680	205	263	211	206	89
2023-04-01	260	423	458	418	445	370	615	546	579	622	303
2023-05-01	450	420	443	435	455	455	585	539	565	627	307
2023-06-01	550	409	442	582	465	455	443	431	597	542	212
2023-07-01	234	391	397	413	476	323	609	594	776	784	301
2023-08-01	341	371	404	487	486	350	639	657	922	929	310
2023-09-01	936	355	617	519	497	866	58	338	504	490	240
2023-10-01	317	347	498	265	507	319	482	529	452	680	242
2023-11-01	266	350	501	375	518	345	566	763	561	932	321
2024-01-01	867	689	621	668	603	693	388	518	362	667	148
2024-02-01	236	709	563	401	613	461	925	845	586	1044	418
2024-03-01	681	711	740	429	623	812	954	904	334	987	548
2024-04-01	869	690	672	566	634	661	776	707	118	752	341
2024-05-01	651	652	638	351	644	648	777	693	121	745	337
2024-06-01	638	608	632	512	655	643	746	687	295	762	343
2024-07-01	464	575	579	678	665	498	857	801	635	963	377
2024-08-01	502	564	591	707	676	526	920	891	839	1137	401
2024-09-01	1335	578	848	687	686	1170	163	404	192	488	236
2024-10-01	576	606	754	412	696	670	482	583	257	608	330
2024-11-01	871	633	776	536	707	745	244	487	86	444	204
2025-01-01	637	667	734	861	792	707	482	584	645	599	273
2025-02-01	755	689	700	771	802	690	416	529	661	646	208
2025-03-01	1375	687	850	807	813	1079	0	5	93	84	0
2025-04-01	445	663	694	592	823	607	670	597	568	815	355
2025-05-01	608	625	658	802	834	593	687	647	763	1041	340
Venta total	16386					Agotados	1	0	0	0	1
						l prom	548	578	470	698	283

**Tabla 10. Resultados Simulación Crema**



**Figura 8.** Gráfica inventario Crema Triple Acción

Rotación de inventario	SVM	RF	ARIMA	LM	XGB
2023	36	32	30	25	66
2024	29	28	42	24	56

**Tabla 11.** Rotación de inventario por modelo

En términos de precisión de pronóstico, los cinco modelos mostraron desempeños relativamente aceptables durante la mayor parte de 2023, manteniendo proyecciones cercanas a la demanda real. Sin embargo, se observan diferencias en su respuesta ante cambios abruptos en la demanda, especialmente en septiembre de 2023 y septiembre de 2024, meses en los que la demanda alcanzó picos importantes (936 y 1335 unidades, respectivamente). Modelos como SVM y XGBoost lograron anticipar parcialmente este comportamiento, evitando quiebres críticos de inventario, mientras que la Regresión Lineal, pese a pronosticar valores elevados en varios meses, no logró ajustarse con precisión a estos picos de demanda.

En cuanto al inventario final promedio (I prom), se evidencian diferencias significativas entre modelos. Por un lado, Regresión Lineal (LM) mantuvo el inventario promedio más alto (698 unidades), lo que indica una estrategia conservadora que prioriza la disponibilidad. Este enfoque evita agotados, pero incrementa costos de mantenimiento y reduce eficiencia logística. Por el otro, Random Forest (RF), SVM y ARIMA presentan inventarios promedio intermedios (578, 548 y 470 unidades, respectivamente), lo que refleja un balance entre

cobertura de la demanda y eficiencia en almacenamiento. Mientras que XGBoost (XGB) presenta el inventario promedio más reducido (283 unidades), lo que se traduce en una rotación más alta y costos de mantenimiento menores, aunque con un mayor riesgo operativo frente a variaciones imprevistas.

La columna de agotados refuerza esta interpretación: se presentaron 1 evento de agotado con SVM y 1 con XGBoost, mientras que RF, ARIMA y LM no registraron agotados. Esto sugiere que modelos con inventarios más ajustados pueden ser más eficientes, pero requieren sistemas de reposición ágiles para evitar quiebres.

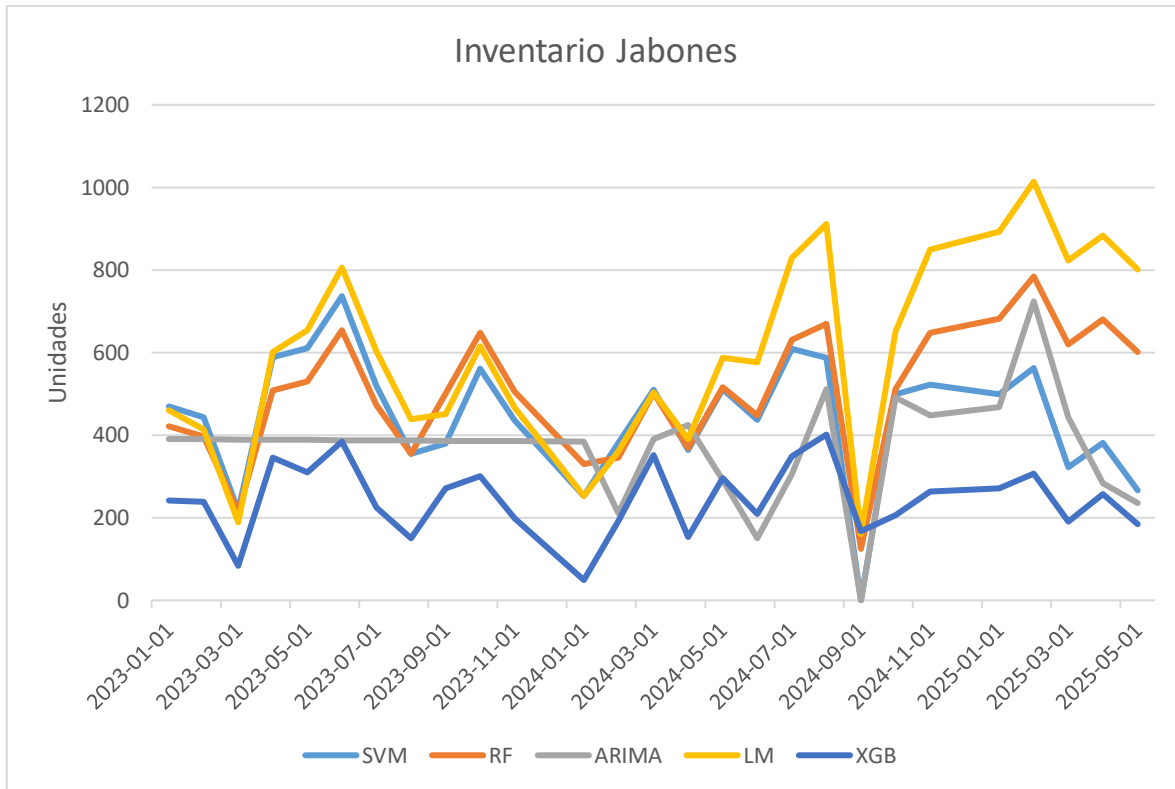
En los primeros meses de 2024 y durante 2025, se observa que la Regresión Lineal tiende a sobrepronosticar sistemáticamente, generando inventarios finales muy elevados (por ejemplo, en febrero y agosto de 2024, con 1044 y 1137 unidades respectivamente), lo que impacta negativamente la eficiencia. Por el contrario, XGBoost mantiene niveles bajos de inventario durante todo el periodo, con respuestas relativamente adecuadas a la demanda real, aunque experimenta agotamientos en momentos de picos de ventas (marzo de 2025). SVM y RF se comportan de forma más equilibrada, manteniendo inventarios suficientes sin llegar a niveles excesivos.

En síntesis, XGBoost y ARIMA muestran un perfil eficiente en términos de inventario, con alta rotación y bajos niveles de almacenamiento, aunque requieren capacidad de respuesta para evitar quiebres. SVM y RF ofrecen un balance razonable entre cobertura y eficiencia, con pocos agotados y niveles moderados de stock. La Regresión Lineal, en cambio, prioriza la disponibilidad por encima de la eficiencia, manteniendo altos inventarios que pueden generar sobrecostos, aunque evita completamente los agotamientos. Este contraste evidencia que la elección del modelo debe considerar no solo la precisión de los pronósticos, sino también la política de inventarios y la tolerancia al riesgo operativo de la empresa.

## **Jabones**

Jabones	VENTA	PRONÓSTICO					INVENTARIO FINAL				
Fecha	Real	SVM	RF	ARIMA	LM	XGB	SVM	RF	ARIMA	LM	XGB
2023-01-01	424	565	559	424	531	531	470	421	391	460	241
2023-02-01	575	548	550	574	529	573	444	396	390	414	239
2023-03-01	753	526	571	752	528	597	216	214	389	189	83
2023-04-01	275	506	502	275	527	438	589	508	389	602	346
2023-05-01	473	495	495	473	525	438	611	530	389	654	310
2023-06-01	372	497	497	372	524	446	737	654	388	806	384
2023-07-01	726	508	545	725	523	566	519	473	387	603	224
2023-08-01	685	521	567	684	521	610	354	355	387	439	150
2023-09-01	508	530	654	507	520	596	380	500	386	451	271
2023-10-01	355	536	502	355	519	384	561	647	386	615	300
2023-11-01	666	540	524	665	517	565	436	505	385	466	199
2024-01-01	824	641	650	823	610	674	252	331	384	253	49
2024-02-01	598	621	613	424	609	607	381	346	210	361	192
2024-03-01	466	596	622	575	608	626	510	502	391	503	352
2024-04-01	719	573	587	753	606	521	365	369	425	390	154
2024-05-01	408	555	554	275	605	521	512	516	292	588	296
2024-06-01	615	540	547	473	604	529	437	448	150	576	210
2024-07-01	349	522	532	372	602	488	610	631	305	830	349
2024-08-01	520	497	558	726	601	572	587	669	511	911	401
2024-09-01	1350	468	805	685	600	1116	0	125	0	161	167
2024-10-01	298	439	528	508	598	321	499	511	492	650	206
2024-11-01	399	422	536	355	597	456	522	648	448	849	263
2025-01-01	646	624	680	666	690	654	499	682	468	893	272
2025-02-01	568	631	670	824	689	603	562	784	724	1014	307
2025-03-01	879	640	715	598	688	763	323	620	443	822	191
2025-04-01	626	648	687	466	686	693	380	681	283	883	258
2025-05-01	767	653	688	719	685	693	266	602	235	801	184
Venta total	15844					Agotados	1	0	1	0	0
						l prom	444	509	371	605	245

**Tabla 12. Resultados Simulación Jabones**



**Figura 9. Inventario Jabones**

Rotación de inventario	SVM	RF	ARIMA	LM	XGB
2023	34	34	41	31	68
2024	39	31	47	25	67

**Tabla 13. Rotación de inventario por modelo para jabones**

La demanda de este producto presentó variaciones significativas, destacando picos de venta en marzo de 2023 (753 unidades) y septiembre de 2024 (1350 unidades), así como meses con demanda más moderada.

En cuanto a la precisión de los pronósticos, los modelos ARIMA y SVM tuvieron un buen ajuste en los primeros meses de 2023, replicando adecuadamente los niveles de demanda real. Por ejemplo, en marzo de 2023 (753 unidades vendidas), ARIMA pronosticó con gran exactitud (752), lo que contribuyó a un control eficiente del inventario en ese mes. En cambio, modelos como RF y LM mantuvieron pronósticos más estables y elevados, independientemente de la demanda real, lo que se tradujo en niveles de inventario más altos de forma sistemática.

Respecto al inventario final promedio (I prom), se observan diferencias claras entre modelos. Por ejemplo, Regresión Lineal (LM) mantiene el inventario promedio más alto (605 unidades), lo cual refleja un enfoque conservador orientado a asegurar la disponibilidad de producto frente a la variabilidad de la demanda. Este enfoque evita agotados, pero implica mayores costos de almacenamiento y un uso menos eficiente de los recursos. Random Forest

(RF) también conserva un inventario promedio elevado (509 unidades), aunque ligeramente menor que LM, mostrando una estrategia similar con buena cobertura de la demanda. SVM presenta un inventario promedio intermedio (444 unidades), lo que evidencia un comportamiento equilibrado entre cobertura y eficiencia operativa. ARIMA destaca por tener un inventario promedio de solo 371 unidades, el segundo más bajo después de XGBoost, lo que denota una gestión más ajustada al comportamiento real de la demanda, con menor sobrestock. Y por último, XGBoost vuelve a ser el modelo con el inventario promedio más bajo (245 unidades), lo que se traduce en alta rotación de inventario y menores costos de mantenimiento.

En términos de agotados, se registró 1 evento con SVM y 1 con ARIMA, mientras que RF, LM y XGBoost no presentaron agotamientos durante el periodo analizado. Esto indica que los modelos con inventarios más ajustados (SVM y ARIMA) son más sensibles a picos de demanda inesperados, especialmente en meses como septiembre de 2024, cuando la demanda alcanzó un máximo de 1350 unidades. Aun así, XGBoost logró evitar agotados pese a operar con inventarios considerablemente bajos, lo que sugiere que su comportamiento estuvo bien alineado con la dinámica de demanda de este producto.

Durante 2024 y 2025, se observó que la Regresión Lineal y RF tienden a sobrepronosticar, manteniendo inventarios finales altos incluso en meses de baja demanda, como octubre y noviembre de 2024. Por ejemplo, en octubre de 2024 (298 unidades vendidas), LM mantuvo un inventario final de 650 unidades y RF de 511. En contraste, XGBoost y ARIMA ajustaron más dinámicamente sus niveles, reduciendo inventarios cuando la demanda fue baja, aunque con un mayor riesgo de agotamiento en picos inesperados.

En síntesis, XGBoost y ARIMA muestran un desempeño eficiente en términos de inventario, con bajos niveles de stock promedio y alta rotación, adecuados para entornos donde se privilegia la eficiencia y se cuenta con una reposición ágil. SVM ofrece un balance aceptable entre eficiencia y cobertura, aunque presenta un evento de agotado. RF y LM priorizan la disponibilidad, manteniendo inventarios altos y evitando quiebres, a costa de mayores costos de almacenamiento. La elección del modelo, por tanto, debe considerar la política de inventarios de la empresa y su tolerancia a quiebres vs. sobrecostos logísticos.

### **Conclusión comparativa**

El análisis conjunto de los tres productos evaluados (Cepillos, Crema dental y Jabones) permite identificar patrones consistentes en el desempeño de los modelos de pronóstico y su impacto sobre la gestión de inventarios. A lo largo del periodo analizado (2023–2025), cada modelo mostró un comportamiento característico que se repite, con ligeras variaciones según la dinámica de demanda de cada producto.

En primer lugar, la Regresión Lineal (LM) se distingue por mantener sistemáticamente los niveles de inventario promedio más elevados en los tres productos: 648 unidades en Cepillos, 698 en Crema dental y 605 en Jabones. Este comportamiento refleja un enfoque conservador que prioriza la disponibilidad de producto y la prevención de agotados, incluso frente a variaciones en la demanda real. No se registraron quiebres de inventario con este modelo, lo

cual confirma su efectividad en la cobertura, aunque a costa de un mayor volumen de existencias y, por ende, de costos logísticos y de almacenamiento superiores.

Random Forest (RF) mostró un patrón similar al de LM, con inventarios promedio relativamente altos en los tres productos (518 en Cepillos, 578 en Crema y 509 en Jabones). Este modelo generó pronósticos estables, tendiendo a sobreestimar la demanda en varios periodos, lo que permitió evitar agotados pero implicó también niveles de stock mayores a los necesarios en meses de baja venta. Su desempeño es adecuado para contextos en los que se prioriza la seguridad de abastecimiento, aunque puede no ser óptimo en términos de eficiencia de capital inmovilizado.

Por su parte, SVM presentó un comportamiento intermedio: sus inventarios promedio (524, 548 y 444 unidades para Cepillos, Crema y Jabones respectivamente) muestran una estrategia de gestión más equilibrada, combinando niveles moderados de stock con una cobertura razonable. En los tres casos, se registró al menos un evento de agotado, lo que evidencia que, aunque es eficiente en términos de inventario, puede no absorber con igual efectividad los picos de demanda no previstos.

ARIMA destacó especialmente por su capacidad para ajustarse de forma más dinámica a la demanda real, lo que se reflejó en inventarios promedio más bajos en los tres productos (509 en Cepillos, 470 en Crema y 371 en Jabones). Esta eficiencia vino acompañada de un desempeño sólido en varios meses, en particular en Jabones, donde el modelo pronosticó con gran precisión en momentos de alta demanda. Sin embargo, esta estrategia más ajustada implica una mayor exposición a agotados en picos inesperados, como se observó en dos de los productos.

Finalmente, XGBoost mostró un perfil claramente orientado a la eficiencia: registró los inventarios promedio más bajos de todos los modelos (195 en Cepillos, 283 en Crema y 245 en Jabones) sin comprometer significativamente la disponibilidad, ya que solo se presentó un evento de agotado en Crema dental. Su comportamiento indica una alta sensibilidad a los cambios en la demanda y un uso muy eficiente del inventario, lo que lo convierte en una alternativa atractiva en contextos donde la reposición es ágil y los costos de almacenamiento son determinantes.

En términos generales, se observa que los modelos que priorizan la disponibilidad (LM y RF) logran evitar agotados a costa de mantener niveles de inventario más altos, mientras que los modelos más ajustados (ARIMA y XGBoost) maximizan la eficiencia y reducen costos, aunque requieren una mayor capacidad de respuesta logística para enfrentar picos de

demanda no previstos. SVM se posiciona entre ambos extremos, ofreciendo un balance razonable, aunque con cierta vulnerabilidad frente a la volatilidad.

Además, estos patrones se mantienen de manera consistente entre los tres productos, a pesar de que cada uno presenta dinámicas de venta distintas: los Cepillos muestran una demanda más estable con eventos aislados de agotamiento; la Crema dental presenta varios picos abruptos que ponen a prueba la capacidad de reacción de los modelos; y los Jabones combinan estacionalidad marcada con algunos máximos muy pronunciados (por ejemplo, septiembre de 2024). Esta consistencia en el comportamiento de los modelos sugiere que las diferencias en desempeño dependen más de las características propias de cada modelo que de la naturaleza específica del producto, lo cual es un hallazgo relevante para el diseño de políticas de inventario basadas en pronósticos.

En conclusión, la selección del modelo de pronóstico debe alinearse con la estrategia de inventarios de la organización: si el objetivo es minimizar quiebres y asegurar disponibilidad, LM y RF son opciones sólidas; si la prioridad es optimizar inventarios y reducir costos, XGBoost y ARIMA ofrecen un desempeño superior, siempre que se cuente con una logística flexible; mientras que SVM representa un punto medio que puede adaptarse bien a escenarios intermedios. Esta visión comparativa integral proporciona una base robusta para la toma de decisiones en la gestión de inventarios multirreferencia apoyada en modelos estadísticos.

#### 4.2.1. Impacto en indicadores financieros

La mejora en la precisión en los pronósticos de ventas mediante la implementación de herramientas IA se traduce en beneficios económicos concretos. Diversos estudios muestran que aumentos modestos en la precisión (medida por MAPE, etc.) producen ahorros sustanciales. Por ejemplo, el IBF (2021) indica que un +15% en precisión puede elevar la utilidad antes de impuestos en +3%, ya que mejora ingresos y reduce costos. De manera aplicada, una mejora en MAPE de ~20 puntos porcentuales en un retailer multicanal llevó a 72% menos faltantes de stock, 31% menos inventario y una rentabilidad (ROI) del 342% con IA (EightGen, 2023).

##### 4.2.1.1. Reducción de costos logísticos y de almacenamiento

Al reducir el nivel de inventario necesario para atender la demanda, se abaratan los costos asociados a bodegas, personal y transporte. Por ejemplo, Wair.ai ilustra que recortar un 25% el exceso de inventario (p.ej. USD 1 M valor con un costo de mantenimiento del 20%) equivale a ahorrar ~\$200 000 anuales en gastos de almacenamiento (Wair.ai, 2024). Asimismo, mejores pronósticos permiten planificar con antelación la logística, disminuyendo envíos urgentes o costosos “contrarreloj” (fletes exprés). Wair (2024) destaca que la reducción de quiebres de stock conlleva menos fletes de emergencia y menores tarifas logísticas. En la práctica, McKinsey (2023) estima que una mejora del 10–20% en precisión

reduce en ~5% los costos totales de inventario, reflejando menores gastos de almacén y manipulación. Un caso concreto: una firma del sector embalaje mejoró su pronóstico del ~55% al 75% y eliminó cerca de €1 M en stock sobrante, liberando espacio y recortando costos de manejo (KPMG, 2022).

#### 4.2.1.2. Menor capital inmovilizado en inventarios

Vender el inventario en lugar de acumularlo libera capital de trabajo (cash flow) e incluso reduce gastos financieros. StB Freight ilustra que una reducción del 20% en inventario libera ese porcentaje de capital: por ejemplo, una empresa con USD 50 M en inventario ahorra USD 10 M de capital liberado (StB Freight, 2022). McKinsey (2020) describe que si se liberan USD 10 M en inventario (coste de capital supuesto 10%), ello supone un ahorro de USD 1 M/año en costo de financiación. Es decir, menos inventario significa menos dinero amarrado y menores intereses pagados.

#### 4.2.1.3. Impacto en ROI y EBITDA

Las ventajas operativas se reflejan en métricas financieras clave. Menos capital amarrado e ingresos estables elevan el retorno sobre la inversión (ROI) y el EBITDA. McKinsey (2020) señala que mayor exactitud en forecast mejora el retorno sobre el capital (EVA) al aumentar ganancias y reducir el capital necesario. Por ejemplo, Oats Overnight (2024) logró 98% de precisión y su EBITDA aumentó en US\$4 M anuales. Incluso pequeños mejoramientos pagan el esfuerzo: Wair (2024) estima que proyectos AI típicamente se amortizan en 6–12 meses mediante ahorro en inventario y ventas recuperadas. En síntesis, la literatura y casos reales muestran que cada punto de mejora en precisión de pronóstico se traduce en dinero ahorrado y generado, reduciendo costos logísticos, liberando capital de trabajo, evitando pérdidas por quiebres y elevando márgenes, impactando positivamente el ROI y el EBITDA de las empresas de consumo masivo.

### 4.3. Dimensión Empírica de la Personalización: Segmentación y Prototipos de Recomendación

Más allá de la optimización logística, la implementación de modelos de Inteligencia Artificial permite una reconfiguración de la estrategia comercial mediante la personalización masiva. Basándose en la segmentación realizada y las capacidades de los modelos entrenados (específicamente Random Forest y XGBoost), se establecen los fundamentos empíricos para sistemas de recomendación y segmentación dinámica.

#### 4.3.1. Segmentación Conductual y Dinámica

A diferencia de la segmentación demográfica tradicional, este estudio validó una segmentación basada en el comportamiento transaccional y la importancia del producto (EAN) mediante el criterio de Pareto (80/20).

Identificación de Impulsores de Compra: El uso de Random Forest permitió no solo pronosticar la demanda, sino también identificar la "importancia de las variables". Esto habilita una segmentación de clientes basada en su sensibilidad a factores específicos (como promociones o estacionalidad) en lugar de solo su ubicación geográfica.

Agrupamiento por Estabilidad de Demanda: Los resultados del Capítulo 4 permiten clasificar a los clientes y puntos de venta en dos macro-segmentos operativos:

Segmento de Demanda Estable: Clientes que consumen productos como "Jabones" (donde ARIMA y XGBoost mostraron alta precisión y bajo error). Para este grupo, la estrategia de personalización se basa en la reposición automática y programas de lealtad.

Segmento de Demanda Volátil: Clientes con patrones de compra erráticos o impulsados por tendencias (detectados eficazmente por XGBoost en categorías complejas). Aquí, la segmentación sugiere ofertas dinámicas de "oportunidad" para evitar la pérdida de ventas.

#### 4.3.2. Prototipos de Motores de Recomendación

Fundamentado en el marco teórico sobre motores de recomendación, la investigación propone dos prototipos de lógica algorítmica aplicables al sector CPG en Colombia, aprovechando los datos históricos consolidados:

Filtrado Colaborativo (Cross-Selling): Este prototipo sugiere productos basándose en patrones de compra de perfiles similares. Dado que se unificaron los datos por EAN y se limpiaron los históricos, el sistema puede identificar correlaciones ocultas.

Aplicación empírica: Si un segmento de farmacias incrementa sus pedidos de "Cepillos" (donde XGBoost tuvo un MAPE del 14% ), el sistema sugiere automáticamente aumentar el stock de "Crema Dental" complementaria, anticipando la venta cruzada antes de que ocurra el pedido manual.

Filtrado Basado en Contenido (Up-Selling): Recomienda artículos con atributos similares a los que el cliente ha mostrado interés previamente.

Aplicación empírica: Utilizando la "maestra de productos" depurada, el algoritmo detecta clientes que compran productos de línea económica y, mediante promociones personalizadas, sugiere productos de mayor margen (premium) que comparten características técnicas, aprovechando la predicción de demanda para asegurar que haya stock disponible del producto sugerido.

#### 4.3.3. Sincronización entre Inventario y Experiencia del Cliente

La personalización efectiva depende de la disponibilidad del producto. Este estudio demostró empíricamente que la precisión del modelo XGBoost reduce drásticamente el inventario de seguridad requerido (ej. 134 unidades en cepillos vs. 353 de la Regresión Lineal).

Esto genera un círculo virtuoso para la personalización:

Reducción de la "Conmoción a la Lealtad": Al minimizar los agotados , se evita que el consumidor cambie de marca por falta de disponibilidad, un problema crítico en Latinoamérica donde la lealtad ha disminuido.

Recomendaciones Confiables: El sistema de personalización solo sugiere productos que el modelo de pronóstico garantiza que estarán disponibles, protegiendo la reputación de la marca y mejorando la satisfacción del cliente al evitar la frustración de pedidos insatisfechos.

En conclusión, la integración de modelos predictivos robustos (XGBoost) no solo optimiza la cadena de suministro, sino que proporciona la infraestructura de datos necesaria para desplegar estrategias de hiperpersonalización, permitiendo pasar de una estrategia de venta "push" (empujar inventario) a una estrategia "pull" inteligente basada en las necesidades reales y predichas del consumidor.

#### **4.3.4. Contribuciones del Autor y Hallazgos Clave**

La presente investigación aporta varias contribuciones originales y prácticas al estado del arte en previsión de demanda y personalización comercial aplicada al sector de consumo masivo en Colombia. En primer lugar, se entrega un benchmark empírico de cinco familias de modelos (SVM, Random Forest, Auto-ARIMA, Regresión Lineal y XGBoost) aplicado a series reales de ventas de tres categorías representativas (cepillos, crema dental y jabones), evaluadas mediante MAE, RMSE y MAPE para horizontes de corto, mediano y largo plazo; este enfoque comparativo y contextualizado en Colombia subsana una laguna identificada en la literatura local.

En segundo lugar, el estudio evidencia patrones operativos relevantes para la gerencia de inventarios: XGBoost se consolida como la alternativa más consistente en series con estructura compleja (mostrando los menores MAE y RMSE en varias categorías), Random Forest ofrece robustez en horizontes cortos y XGBoost (reportado en la literatura y considerado en el diseño metodológico) se perfila como opción superior en horizontes largos, mientras que ARIMA mantiene ventaja en series con comportamiento estable. Estas diferencias permiten proponer estrategias diferenciadas según la naturaleza del SKU y la prioridad estratégica (disponibilidad vs eficiencia de inventario).

En tercer lugar, la tesis traduce la mejora en precisión en impactos cuantificables sobre inventarios (niveles medios, eventos de agotado y costos de mantenimiento), mostrando cómo la adopción de modelos de IA puede reducir inventarios promedio y tasas de faltantes cuando se implementan con una logística flexible. Esto convierte los resultados técnicos en insumos accionables para la toma de decisiones y el cálculo de retorno de inversión (ROI) en proyectos de IA dentro de empresas CPG.

Finalmente, se aporta material práctico (scripts y fragmentos de código) y consideraciones ético-regulatorias (plantilla de consentimiento y referencia a la Ley 1581 de 2012), lo que facilita la transferencia de la investigación a entornos productivos garantizando cumplimiento normativo y buenas prácticas de tratamiento de datos.

## **Capítulo 5: Discusión, Conclusiones, Recomendaciones y Limitaciones**

Este capítulo final sintetiza los hallazgos de la investigación, los interpreta a la luz del marco teórico y ofrece conclusiones concretas y recomendaciones prácticas. Se busca no solo responder a la pregunta de investigación, sino también proporcionar una guía estratégica para las empresas del sector CPG que enfrentan los desafíos de un mercado en constante evolución.

### **5.1. Discusión de los Hallazgos**

Los resultados muestran una tensión metodológica y estratégica clara: modelos orientados a disponibilidad (por ejemplo, LM y RF en algunos escenarios) tienden a mantener inventarios más altos y reducir quiebres, mientras que modelos orientados a eficiencia (ARIMA, XGBoost) logran menores niveles de inventario a costa de mayor exposición a picos imprevistos. Esta dicotomía obliga a que la selección del algoritmo no sea únicamente técnica, sino parte de una decisión estratégica que considere costos de mantenimiento, capacidad logística para responder picos y el riesgo aceptable de stockouts.

Desde el punto de vista metodológico, la superioridad relativa de XGBoost en series más ruidosas y de ARIMA en series estables confirma la recomendación de emplear un enfoque híbrido: seleccionar modelos según la característica de la serie (estabilidad, volatilidad, presencia de picos) y combinar predicciones mediante esquemas de ensembling o reglas de negocio (por ejemplo, priorizar RF en ventanas operativas críticas y XGBoost para planificación de mediano plazo). Esto permite capitalizar las fortalezas individuales de cada técnica y mitigar sus debilidades.

Además, la evaluación práctica incluida (simulación del impacto sobre inventarios y análisis de eventos de agotado) demuestra que las mejoras en métricas de error se traducen en valor de negocio tangible cuando existe una arquitectura de datos sólida y procesos de reposición ágiles. Por tanto, la adopción tecnológica exige simultáneamente inversión en gobernanza de datos y capacidades operativas.

### **5.2. Conclusiones**

Los modelos de aprendizaje automático evaluados (especialmente XGBoost y Random Forest) superan de manera consistente a los métodos tradicionales en series con patrones no lineales y alta volatilidad, mientras que ARIMA conserva ventajas en series estacionales y relativamente estables.

La mejora en la precisión del pronóstico se traduce en una reducción medible de niveles de inventario y en menores tasas de agotamiento cuando la organización dispone de una logística capaz de responder rápidamente a picos de demanda.

No existe un “mejor modelo” universal: la selección óptima depende del horizonte de planificación, de la naturaleza del producto y de la estrategia corporativa (priorizar disponibilidad o eficiencia). Por ello, una estrategia híbrida y adaptativa resulta la más recomendable.

Los desarrollos técnicos deben acompañarse de medidas de gobernanza y cumplimiento (consentimiento informado, políticas de privacidad) para garantizar la adopción responsable de soluciones de personalización basadas en IA.

### **5.3. Recomendaciones Estratégicas y Gerenciales**

Política de selección por categoría y horizonte: Implementar una matriz de decisión que asigne algoritmos a categorías según su comportamiento histórico (p. ej., XGBoost para SKUs volátiles, ARIMA para SKUs estables; RF para previsiones tácticas de corto plazo). Esta regla reduce riesgos operativos y optimiza inventarios.

Estrategia híbrida y de ensamblado: Desarrollar un sistema que combine predicciones (stacking o reglas de negocio) y valide continuamente el desempeño por SKU; esto mejora robustez frente a cambios en patrones de demanda.

Inversión en infraestructura y gobernanza de datos: Antes de escalar modelos, fortalecer la calidad de datos, la maestra de productos (EAN/SKU) y los procesos ETL; además, formalizar políticas de consentimiento y tratamiento de datos tal como se propone en los anexos.

Pilotos controlados y medición de ROI: Ejecutar pilotos por categoría (p. ej., 6 meses) midiendo KPIs de inventario (rotación, días de inventario), costos de almacenamiento y tasa de agotados; traducir mejoras de precisión en ahorro económico para calcular ROI antes de la implementación masiva.

Capacitación y gestión del cambio: Acompañar la adopción con formación para analistas y tomadores de decisión, incluidos dashboards interactivos y protocolos de actuación ante divergencias entre pronóstico y ventas reales.

### **5.4. Limitaciones del Estudio y Futuras Investigaciones**

Limitaciones:

- Representatividad de la muestra: el análisis se realizó sobre EANs seleccionados (criterio Pareto) y tres categorías específicas; por tanto, la generalización total a todos los SKUs del portafolio requiere precaución.
- Horizonte temporal y entorno contextual: los datos históricos cubiertos (3–5 años según la metodología) reflejan condiciones y eventos concretos del período analizado; cambios estructurales del mercado o eventos extraordinarios podrían modificar el comportamiento de los modelos.
- Alcance algorítmico: la tesis evaluó un conjunto seleccionado de modelos y configuraciones; no se exploraron extensivamente variantes avanzadas ni otros modelos potencialmente viables (p. ej., arquitecturas más profundas, Transformers para series temporales, o técnicas de fine-tuning automatizado), ni se testeó exhaustivamente la integración en producción.

Líneas futuras de investigación:

Ensemble dinámico y sistemas online: investigar esquemas de ensamblado adaptativo que cambien pesos de modelos en tiempo real según desempeño reciente.

Validación en campo: realizar estudios de implementación piloto en operaciones reales (A/B testing) para medir impactos reales sobre ventas perdidas, costos logísticos y satisfacción del cliente.

Incorporación de variables exógenas y causalidad: incluir señales externas (promociones multicanal, precios competitivos, métricas macroeconómicas y datos de comportamiento digital) y explorar métodos causales para separar correlación de efectos reales.

Ética y fairness en personalización: profundizar en métricas de equidad y privacidad en motores de recomendación y en marcos de consentimiento, asegurando cumplimiento con la normativa colombiana y principios de IA responsable.

## **5.5. Implicaciones Institucionales, Sectoriales y de Compromiso Social**

Más allá de la optimización matemática y los beneficios financieros, la implementación de modelos de Inteligencia Artificial en la cadena de suministro conlleva profundas implicaciones éticas y sociales. Esta investigación se alinea con la misión institucional y las necesidades del sector productivo colombiano bajo tres dimensiones clave:

### **5.5.1. Compromiso Social: Abastecimiento Responsable y Sostenibilidad**

La gestión ineficiente de inventarios no es solo un problema de costos; es un problema de sostenibilidad y bienestar social.

*Garantía de Acceso a Bienes Esenciales:* Los productos analizados en este estudio (crema dental, jabones, cepillos) son bienes de higiene básica. La optimización del pronóstico mediante modelos como XGBoost, que redujo significativamente los inventarios de seguridad, minimiza el riesgo de desabastecimiento (stockouts). Desde una perspectiva social, esto garantiza que la población tenga acceso continuo a productos fundamentales para

la salud pública, evitando la especulación de precios o la escasez en puntos de venta críticos como las droguerías de barrio.

*Reducción del Desperdicio y Eficiencia de Recursos:* Al demostrar que es posible operar con inventarios más ajustados sin sacrificar el nivel de servicio, la investigación promueve una reducción en la huella operativa. Menos inventario inmovilizado implica menos recursos desperdiciados en almacenamiento, transporte innecesario y obsolescencia de productos, alineándose con principios de sostenibilidad ambiental y consumo responsable.

### **5.5.2. Políticas Sectoriales: Modernización de la Industria Colombiana**

Esta tesis responde a la necesidad urgente de modernización del sector de Consumo Masivo (CPG) en Colombia, un entorno caracterizado por alta competitividad y márgenes ajustados.

*Competitividad en el Entorno Digital:* Ante la migración acelerada hacia canales digitales y el cambio en la lealtad del consumidor, la adopción de IA deja de ser una ventaja opcional para convertirse en un requisito de supervivencia. Este estudio aporta una hoja de ruta empírica para que empresas locales y multinacionales operando en el país puedan transitar de modelos tradicionales a una gestión basada en datos (Data-Driven Decision Making).

*Fortalecimiento del Ecosistema Empresarial:* Al proveer evidencia sobre la superioridad de modelos de código abierto y accesibles (como XGBoost y Random Forest) frente a software propietario costoso, se democratiza el acceso a tecnología de punta. Esto fomenta una política sectorial donde la eficiencia no depende exclusivamente del músculo financiero, sino de la inteligencia analítica, elevando el estándar técnico de la industria nacional.

### **5.5.3. Misión Institucional: Innovación con Ética y Transparencia**

En consonancia con los principios rectores de la Pontificia Universidad Javeriana, esta investigación no se limita a la búsqueda de rentabilidad, sino que integra la dimensión ética como un pilar fundamental del desarrollo tecnológico.

*Defensa de la Privacidad del Consumidor:* La propuesta incluye explícitamente el cumplimiento de la Ley 1581 de 2012 (Habeas Data) y los principios de IA ética. Se establece que la personalización de ventas no debe vulnerar la intimidad del cliente. La inclusión de protocolos de consentimiento informado y la recomendación de auditoría de sesgos algorítmicos reflejan un compromiso con la dignidad humana por encima de la eficiencia comercial.

*Transparencia Algorítmica (Explainability):* Al recomendar modelos que permiten identificar la importancia de las variables (como Random Forest), se promueve una "IA Explicable". Esto evita el uso de "cajas negras" que toman decisiones opacas, asegurando que los gerentes y directivos mantengan el control ético y estratégico sobre las herramientas tecnológicas, promoviendo una gestión empresarial responsable y humanista.

## Referencias Bibliográficas

Ali, A. K. (2011). Inventory management in pharmacy practice: A review of literature. *Archives of Pharmacy Practice*, 2(4), 151.

Baker McKenzie InsightPlus. (2025). Colombia: Bill of Law regulating Artificial Intelligence ("AI").

Bonney, M. (1994). Trends in inventory management. *International Journal of Production Economics*, 35(1-3), 107-114.

Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. Wiley.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.

Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121–167.

Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250.

Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. En *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). ACM.

Chowhan, G. R. S. (2025). AI-powered personalization in retail: Technical implementation and business impact. *European Journal of Computer Science and Information Technology*, 13(14), 172-183.

- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42.
- de Myttenaere, A., Golden, B., Le Grand, B., & Rossi, F. (2016). Mean Absolute Percentage Error for Regression Models. *Neurocomputing*, 192, 97-107.
- DLA Piper. (n.d.). Data protection laws in Colombia. Recuperado el 1 de julio de 2025, de
- Fernandes, P., Suzuki, L., Fitts, M., & Ize, F. (28 de agosto de 2020). Thriving in Latin America's next normal: Commercial excellence in CPG. Fonte: mckinsey.com:
- Gumus, A. T., Guneri, A. F., & Ulengin, F. (2010). A new methodology for multi-echelon inventory management in stochastic and neuro-fuzzy environments. *International Journal of Production Economics*, 128(1), 248-260.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer Series in Statistics. Springer.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed.). OTexts.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2023). *An Introduction to Statistical Learning with Applications in R* (2.<sup>a</sup> ed.). Springer.
- Kros, J. F., Falasca, M., & Nadler, S. S. (2006). Impact of just-in-time inventory systems on OEM suppliers. *Industrial Management & Data Systems*, 106(2), 224-241.
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2005). *Applied Linear Statistical Models* (5.<sup>a</sup> ed.). McGraw-Hill Irwin.

Lee, H. L., Padmanabhan, V., & Whang, S. (1997). Information distortion in a supply chain: The bullwhip effect. *Management Science*, 43(4), 546-558.

Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3), 18–22.

McKinsey & Company. (n.d.). Fortune or fiction? The real value of a digital and AI transformation in CPG. Recuperado el 1 de julio de 2025, de

Mohamed, A. E. (2024). Inventory Management. En T. Bányai (Ed.), *Operations Management - Recent Advances and New Perspectives*. IntechOpen. DOI: 10.5772/intechopen.113282

Netstock. (s.d.). Improving Demand Forecasting Accuracy: Tools and Best Practices for Predicting Customer Demand. Fuente: Netstock:

Nielsen. (12 de enero de 2024). Demand Forecasting Simplified for 2024. Fuente: nielseniq.com:

Nino, G., Nino, A., & Chaparro, J. (2023). AI in Colombian Food Markets: Using Machine Learning to Address. *Económicas CUC*.

Ochoa, H., Correa, J. M., & Atehortua, A. (2017). Proceso de internacionalización en el sector farmacéutico: el caso de la empresa colombiana Tecnoquímicas. Fuente: *Estudios Gerenciales*:

OECD. (2020). Consumer data rights and competition – Note by Colombia.([https://one.oecd.org/document/DAF/COMP/WD\(2020\)42/en/pdf](https://one.oecd.org/document/DAF/COMP/WD(2020)42/en/pdf))

Parada Gutiérrez, O. (2000). Decisiones empresariales para el perfeccionamiento del subsistema comercial de aprovisionamiento de empresas turísticas de gestión hoteleras. Aplicación en el hotel Meliá Santiago de Cuba. (Tesis doctoral). Universidad de Oriente, Santiago de Cuba, Cuba.

- Puntoni, S., Reczek, R. W., Giesler, M., & Botti, S. (2021). On the real-world tensions between AI and human intelligence. *Journal of Marketing*, 85(1), 1–21.
- Qualtrics. (2025, 20 de enero). How AI-powered personalization is changing the customer experience.
- Rădășanu, A. C. (2016). Inventory management, service level and safety stock. *Journal of Public Administration, Finance and Law*, 2(9), 145-153.
- Rennie, E. (10 de marzo de 2025). Beyond the Shelf — the CPG Demand Forecasting Edge. Fonte: [ascm.org](https://www.ascm.org):
- Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 2024, 69–79.
- Santos Norton, M. L. (1996). Concepción de un Enfoque en Sistema para la Gestión de los Aprovechamientos, Tesis doctoral. Instituto Superior Politécnico José Antonio Echeverría, La Habana, Cuba.
- Silver, E. A., Pyke, D. F., & Peterson, R. (1998). *Inventory Management and Production Planning and Scheduling* (Vol. 3). Wiley.
- Syntetos, A. A., Boylan, J. E., & Disney, S. M. (2009). Forecasting for inventory planning: A 50-year review. *Journal of the Operational Research Society*, 60(sup1), S149-S160.
- Tian, X., Wang, H., & Erjiang, E. (2021). Forecasting intermittent demand for inventory management by retailers: A new approach. *Journal of Retailing and Consumer Services*, 62, 102662.
- Trademo. (s.d.). Supply Chain Data Of Tecnoquimicas Sa Company Profile. Fonte: [Trademo.com](https://www.trademo.com):

Veloz-Navarrete, C., & Parada-Gutiérrez, O. (2017). Métodos para mejorar la eficiencia y la toma de decisiones en la gestión de inventarios. *Revista Ciencia UNEMI*, 10(22), 29-38.

Verma, N. (4 de junio de 2025). Colgate-Palmolive: Building a Responsible Supply Chain from the Inside Out. Fonte: elm.ai.com:

Wang, W. (2024). Comparative Analysis of ARIMA, Random Forest, and LSTM Models for Mercedes-Benz Stock Price Prediction. Fonte: Research Gate:

Institute of Business Forecasting & Planning. (2021). *The financial impact of improving forecast accuracy*. IBF.

EightGen. (2023). *AI-driven demand forecasting improves inventory efficiency and ROI* [Case study]. EightGen Inc.

Wair.ai. (2024). *The business case for AI demand forecasting: Inventory reduction, logistics optimization, and ROI*. Wair Technical Brief.

McKinsey & Company. (2020). *The future of demand planning: How AI is transforming forecasting in consumer goods*. McKinsey Insights.

McKinsey & Company. (2023). *AI-powered supply chains: Reducing stockouts and unlocking working capital in retail*. McKinsey Insights.

KPMG. (2022). *How demand forecasting accuracy affects financial performance* [Industry report].

StB Freight. (2022). *Optimizing inventory levels to enhance working capital* [Industry whitepaper].

Oats Overnight. (2024). *Financial forecasting with AI: How predictive models improved EBITDA by \$4M* [Corporate report]. Oats Overnight