

# Instituto Tecnológico y de Estudios Superiores de Occidente

Reconocimiento de validez oficial de estudios de nivel superior según acuerdo secretarial 15018, publicado en el Diario Oficial de la Federación del 29 de noviembre de 1976.

Departamento de Matemáticas y Física  
**Maestría en Ciencia de Datos**



## **Pronóstico de Ventas en Negocio de Retail Ferretero en Zona Metropolitana de Guadalajara.**

---

**TRABAJO RECEPCIONAL** que para obtener el **GRADO** de  
**Maestro en Ciencia de Datos**

Presenta:  
**Guillermo Ibarra González**

Profesor:  
**Maestro Byron Michael Motta Bonilla.**

Tlaquepaque, Jalisco, 21 de mayo de 2026



# **Pronóstico de Ventas en Negocio de Retail Ferretero en Zona Metropolitana de Guadalajara**

**Guillermo Ibarra González**

## **Resumen**

El presente trabajo analiza el comportamiento de las ventas en un negocio de retail ferretero ubicado en la Zona Metropolitana de Guadalajara mediante técnicas de análisis de datos, estadística y modelado predictivo. A partir del estudio de variables comerciales, financieras, estacionales y operativas, se identificaron patrones relevantes que influyen directamente en la demanda y en el desempeño de ventas de la empresa Ferremate. Posteriormente, se evaluaron distintos modelos de pronóstico, incluyendo métodos estadísticos clásicos y algoritmos de aprendizaje automático, con el objetivo de generar predicciones más precisas que apoyen la toma de decisiones estratégicas. Los resultados obtenidos permitieron identificar tendencias de consumo, periodos de alta demanda y factores clave asociados al crecimiento comercial y financiero del negocio. Asimismo, se determinó que los modelos basados en aprendizaje automático presentaron un desempeño superior en términos de precisión y capacidad de adaptación frente a cambios en la dinámica de ventas. El estudio destaca la utilidad de la ciencia de datos como herramienta para optimizar inventarios, mejorar la planeación operativa, reducir riesgos financieros y fortalecer la competitividad en el sector retail ferretero.



# Tabla de Contenidos

|                                                                            | Página |
|----------------------------------------------------------------------------|--------|
| 1 Introducción . . . . .                                                   | 13     |
| 1.1. Contexto . . . . .                                                    | 13     |
| 1.1.1. El Sector Ferretero y el Modelo de Negocio . . . . .                | 13     |
| 1.1.2. Evolución Operativa y Tecnológica . . . . .                         | 13     |
| 1.1.3. El Proceso Actual de Toma de Decisiones . . . . .                   | 14     |
| 1.1.4. Desafíos Financieros y Toma de Decisiones . . . . .                 | 14     |
| 1.2. Justificación . . . . .                                               | 15     |
| 1.2.1. Impacto Económico y Optimización del Capital . . . . .              | 15     |
| 1.2.2. Impacto Operativo y Fortalecimiento B2B . . . . .                   | 15     |
| 1.2.3. Impacto Tecnológico y Adaptabilidad ante la Incertidumbre . . . . . | 15     |
| 1.3. Alcance del proyecto . . . . .                                        | 16     |
| 1.3.1. Alcance Temporal . . . . .                                          | 16     |
| 1.3.2. Alcance y Granularidad de los Datos . . . . .                       | 16     |
| 1.3.3. Alcance Técnico y Algorítmico . . . . .                             | 17     |
| 1.3.4. Alcance Funcional y Entregables . . . . .                           | 17     |
| 1.4. Planteamiento . . . . .                                               | 17     |
| 1.4.1. La Brecha: Rentabilidad vs. Liquidez . . . . .                      | 18     |
| 1.4.2. La Causa Raíz: Datos Subutilizados y Estrategia Empírica . . . . .  | 18     |
| 1.4.3. Pregunta de Investigación . . . . .                                 | 18     |
| 1.5. Objetivos . . . . .                                                   | 18     |
| 1.5.1. Objetivo general . . . . .                                          | 18     |
| 1.5.2. Objetivos específicos . . . . .                                     | 19     |
| 2 Metodología . . . . .                                                    | 21     |
| 2.1. Descripción del conjunto de datos . . . . .                           | 21     |
| 2.1.1. Tendencia . . . . .                                                 | 21     |
| 2.1.2. Estructura y depuración de datos . . . . .                          | 22     |
| 2.1.3. Agregación temporal . . . . .                                       | 22     |
| 2.1.4. Caracterización estadística preliminar . . . . .                    | 23     |
| 2.2. Análisis Exploratorio (EDA) . . . . .                                 | 23     |
| 2.2.1. Tendencia . . . . .                                                 | 23     |
| 2.2.2. Interpretación metodológica . . . . .                               | 24     |
| 2.2.3. Estacionalidad . . . . .                                            | 24     |

|        |                                                                             |    |
|--------|-----------------------------------------------------------------------------|----|
| 2.2.4. | Dependencia temporal (ACF y PACF) . . . . .                                 | 26 |
| 2.2.5. | Volatilidad . . . . .                                                       | 27 |
| 2.2.6. | Estacionariedad . . . . .                                                   | 28 |
| 2.3.   | Ingeniería de características . . . . .                                     | 28 |
| 2.3.1. | Variables de retardo (lags) . . . . .                                       | 29 |
| 2.3.2. | Variable de tendencia . . . . .                                             | 29 |
| 2.3.3. | Variable estacional . . . . .                                               | 29 |
| 2.3.4. | Transformación logarítmica . . . . .                                        | 30 |
| 2.3.5. | Consistencia temporal y eliminación de<br>observaciones iniciales . . . . . | 30 |
| 2.4.   | Descripción de los modelos . . . . .                                        | 30 |
| 2.4.1. | Holt – Winters . . . . .                                                    | 31 |
| 2.4.2. | SARIMA . . . . .                                                            | 32 |
| 2.4.3. | XGBoost . . . . .                                                           | 33 |
| 2.5.   | Métricas de evaluación . . . . .                                            | 36 |
| 2.5.1. | MAPE . . . . .                                                              | 36 |
| 2.5.2. | Resultados obtenidos . . . . .                                              | 36 |
| 2.6.   | Diseño de experimentos . . . . .                                            | 37 |
| 2.6.1. | División temporal de los datos . . . . .                                    | 37 |
| 2.6.2. | Consistencia metodológica entre modelos . .                                 | 37 |
| 2.6.3. | Tratamiento de la transformación logarítmica                                | 38 |
| 2.6.4. | Criterio de selección del modelo . . . . .                                  | 38 |
| 2.6.5. | Robustez y prevención de sobreajuste . . . .                                | 38 |
| 2.6.6. | Limitaciones del diseño experimental . . . .                                | 39 |
| 3      | Resultados . . . . .                                                        | 41 |
| 3.1.   | Comparación de modelos . . . . .                                            | 41 |
| 3.2.   | Selección del modelo final . . . . .                                        | 43 |
| 3.3.   | Pronóstico a 3 meses . . . . .                                              | 43 |
| 3.4.   | Impacto financiero . . . . .                                                | 44 |
| 4      | Discusión . . . . .                                                         | 45 |
| 4.1.   | Interpretación técnica . . . . .                                            | 45 |
| 4.2.   | Interpretación financiera . . . . .                                         | 46 |
| 4.3.   | Limitaciones . . . . .                                                      | 46 |
| 4.4.   | Trabajo futuro . . . . .                                                    | 47 |
| 5      | Conclusiones . . . . .                                                      | 49 |

# Índice de figuras

|                                                                                      | Página |
|--------------------------------------------------------------------------------------|--------|
| 1.1. Serie de tiempo de ventas totales de Ferremate (2021–2026).                     | 14     |
| 2.1. Serie de tiempo mensual de ventas totales. . . . .                              | 21     |
| 2.2. Serie de tiempo de la cantidad de tickets. . . . .                              | 21     |
| 2.3. Serie de tiempo con medias móviles. . . . .                                     | 23     |
| 2.4. Distribución de ventas mensuales por mes (evidencia de estacionalidad). . . . . | 24     |
| 2.5. Líneas comparativas. . . . .                                                    | 25     |
| 2.6. Análisis exploratorio de datos. . . . .                                         | 25     |
| 2.7. Dependencia temporal. . . . .                                                   | 26     |
| 2.8. Log dependencia temporal. . . . .                                               | 26     |
| 2.9. Distribución de ventas diarias por año. . . . .                                 | 27     |
| 2.10. Desviación estándar móvil de ventas (ventana de 6 meses).                      | 28     |
| 2.11. Pruebas Augmented Dickey-Fuller (ADF) y KPSS. . . . .                          | 28     |
| 3.1. Comparación de pronósticos. . . . .                                             | 42     |
| 3.2. Pronóstico de ventas a 3 meses con el modelo XGBoost.                           | 43     |



# Índice de tablas

|                                                                                                     | Página |
|-----------------------------------------------------------------------------------------------------|--------|
| 2.1. Tabla comparativa: MAPE y montos pronosticados<br>(horizonte de validación: 3 meses) . . . . . | 36     |
| 3.1. Tabla comparativa: MAPE y montos pronosticados<br>(horizonte de validación: 3 meses) . . . . . | 41     |



*Dedicado a... A mi familia, especialmente a mis padres y hermanas, por ser mi mayor apoyo y acompañarme en cada paso de este camino, su confianza, cariño y motivación me dieron la seguridad para seguir adelante. Al Mtro. Byron Michael Motta, por su guía, consejos y acompañamiento durante el desarrollo de este proyecto. Y al ITESO y a sus profesores, por las enseñanzas, experiencias y aprendizajes que marcaron esta etapa de mi vida.*



# 1 Introducción

La predicción de ventas se ha convertido en una herramienta clave para la toma de decisiones estratégicas en el sector comercial, ya que permite anticipar la demanda y optimizar la planificación de recursos. Este tipo de problemas puede abordarse mediante técnicas de análisis de series de tiempo, las cuales modelan el comportamiento de una variable a lo largo del tiempo a partir de sus valores históricos[1].

## 1.1 Contexto

### 1.1.1 El Sector Ferretero y el Modelo de Negocio

Ferremate es una empresa del sector retail y de suministros industriales que ha evolucionado más allá del concepto tradicional de ferretería. Aunque atiende al consumidor final (B2C), se ha posicionado estratégicamente como el departamento de compras externo para diversas empresas locales, brindando soporte técnico y logístico en proyectos de infraestructura y mantenimiento.

El modelo de negocio exige una gestión de inventarios ágil. Ferremate actúa como un aliado estratégico en la cadena de suministro de sus clientes corporativos, donde un *stockout* no solo representa una venta perdida o la pérdida de confianza, sino un posible paro técnico dentro de la cadena de valor de sus clientes.

### 1.1.2 Evolución Operativa y Tecnológica

Ferremate se constituyó en octubre de 2014. En sus inicios, la operación se gestionó mediante hojas de cálculo de Excel, donde se mantenía un modelo de datos y se realizaban consultas manuales. Este proceso implicaba una alta carga operativa y riesgos de integridad de datos, limitando la escalabilidad del negocio.

En 2021, la empresa alcanzó un punto de inflexión en el que la complejidad operativa superó las capacidades del manejo manual, motivando la migración hacia un sistema de Punto de Venta (POS) especializado denominado *Multicomercio*. Este cambio marcó el inicio de una etapa de datos estructurados, permitiendo un registro sistemático

de cada transacción y un control de inventarios más riguroso.

Este cambio permitió consolidar información histórica confiable, lo cual habilita el análisis cuantitativo del comportamiento de ventas en el tiempo. Como se muestra en la Figura 1.1, la serie presenta una tendencia creciente y variabilidad relevante en los últimos periodos.




Figura 1.1: Serie de tiempo de ventas totales de Ferremate (2021–2026).

1.1.3 El Proceso Actual de Toma de Decisiones

Actualmente, la reposición de inventario en Ferremate es de carácter reactivo. Se revisa periódicamente el reporte *Productos bajo stock*, el cual muestra los artículos que se encuentran por debajo del nivel mínimo previamente definido. Bajo este esquema, el encargado de compras adquiere la cantidad que, con base en su criterio, considera necesaria.

1.1.4 Desafíos Financieros y Toma de Decisiones

A pesar de contar con un sistema POS, la reposición de inventario continúa siendo de carácter reactivo y subjetivo, ya que la decisión final sobre qué y cuánto comprar recae en el criterio del encargado de compras, basándose en la percepción inmediata y no en una proyección estadística.

Esta falta de visibilidad a futuro ha generado un impacto financiero adverso. Históricamente, Ferremate ha enfrentado periodos de alta demanda sin contar con la liquidez suficiente, viéndose obligado a contratar deuda de corto plazo con tasas de interés elevadas. Este costo financiero merma el margen de utilidad del negocio.

El contexto actual exige una transición hacia una estrategia financiera preventiva, donde el pronóstico de demanda permita anticipar las necesidades de capital y gestionar instrumentos financieros más eficientes, como créditos revolventes con condiciones preferenciales, asegurando la continuidad operativa sin comprometer la rentabilidad.

## 1.2 Justificación

### 1.2.1 Impacto Económico y Optimización del Capital

La viabilidad financiera de Ferremate se ve directamente afectada por el costo de su capital de trabajo. Actualmente, la falta de un pronóstico preciso obliga a la organización a recurrir a instrumentos de financiamiento de alto costo (deuda de emergencia) para cubrir picos de demanda o adquisiciones de volumen fuera de la red habitual de proveedores.

Estos instrumentos no solo presentan tasas de interés significativamente superiores a las de un crédito revolvente, sino que imponen esquemas de pago de suma única que desequilibran el ciclo de flujo de efectivo del negocio, generando un círculo vicioso de falta de liquidez.

Al implementar un modelo con un MAPE del 8.69 %, la empresa puede transitar hacia una planeación financiera preventiva. Esto permite la contratación oportuna de líneas de crédito revolvente, donde el costo financiero es menor y se paga únicamente por el capital utilizado, alineando las salidas de efectivo con la recuperación de las ventas y liberando capital que actualmente se encuentra inmovilizado en inventario de baja rotación.

### 1.2.2 Impacto Operativo y Fortalecimiento B2B

Ferremate no opera únicamente bajo una lógica de retail tradicional; su rol como departamento de compras externo para empresas locales le exige un nivel de confiabilidad operativa crítico. La práctica actual de solicitar anticipos a clientes corporativos para financiar compras de gran volumen representa una carga administrativa y una fricción en la relación comercial que debilita la posición competitiva de la empresa. La precisión del modelo permite a Ferremate anticipar estos requerimientos de gran escala, asegurando el flujo necesario para realizar compras de contado sin comprometer la liquidez interna ni trasladar la carga operativa al cliente. Esto transforma a Ferremate de un simple proveedor a un socio estratégico capaz de acompañar el crecimiento y los proyectos de sus clientes sin contratiempos logísticos.

### 1.2.3 Impacto Tecnológico y Adaptabilidad ante la Incertidumbre

La complejidad de la demanda en el sector ferretero supera las capacidades de los métodos de análisis tradicionales o la intuición basada en la experiencia. Ferremate se encuentra expuesto a una volatilidad multidimensional:

- **Factores macroeconómicos:** la dependencia directa del crecimiento de sus clientes industriales, quienes a su vez reaccionan a la

incertidumbre geopolítica y a cambios en políticas de inversión (como se observó en el periodo de austeridad en dos de sus principales clientes durante 2025 ante la política exterior de Estados Unidos).

- **Factores estacionales:** el impacto del clima y los ciclos de construcción en la demanda de insumos.

El uso de algoritmos de *Machine Learning* (XGBoost) se justifica por su capacidad para modelar relaciones no lineales[2] y capturar patrones complejos dentro de la propia serie temporal. Aunque este tipo de algoritmos permite integrar variables exógenas como inflación, tipo de cambio o indicadores macroeconómicos, en el presente estudio se optó por un enfoque parsimonioso basado exclusivamente en información interna histórica (tendencia, estacionalidad y retardos), priorizando robustez estadística y claridad interpretativa en el análisis académico.

### 1.3 Alcance del proyecto

El presente proyecto se delimita a la creación de un sistema de pronóstico de demanda monetaria para la toma de decisiones financieras en Ferremate. Para asegurar la viabilidad y precisión del estudio, se han definido los siguientes límites y alcances:

#### 1.3.1 Alcance Temporal

El análisis utiliza un repositorio histórico de datos que comprende desde el 11 de febrero de 2021 (coincidiendo con la adopción del sistema POS Multicomercio) hasta el 31 de diciembre de 2025.

El horizonte de pronóstico se establece en una ventana de 3 meses, periodo alineado con los tiempos de respuesta requeridos por las instituciones bancarias para la gestión y contratación de líneas de crédito revolvente.

#### 1.3.2 Alcance y Granularidad de los Datos

El modelo se enfoca exclusivamente en la venta total mensual de la organización expresada en pesos mexicanos (MXN). El alcance de los datos contempla de forma integrada las operaciones de retail y B2B, dado que ambas fluyen a través del mismo ecosistema operativo y financiero de la empresa.

- **Nivel de agregación:** El análisis es de carácter global por unidad de negocio. Aunque el inventario está categorizado, el pronóstico por familias de productos queda fuera del alcance de este trabajo para priorizar la visión macro necesaria para la estrategia financiera.

- **Limpieza de datos:** Se consideran únicamente transacciones cerradas y efectivas. Los registros de devoluciones o cancelaciones han sido excluidos para evitar sesgos en la proyección de ingresos reales.

### 1.3.3 Alcance Técnico y Algorítmico

La investigación se centra en la evaluación y comparación de arquitecturas de series de tiempo de diversa complejidad:

- **Modelos incluidos:** métodos de suavizamiento exponencial (Holt-Winters), modelos autorregresivos (SARIMA) y algoritmos de aprendizaje automático supervisado (XGBoost).
- **Exclusiones:** debido al volumen de datos histórico disponible y la naturaleza de la serie, se excluyen arquitecturas de *Deep Learning* (redes neuronales). Asimismo, no se integran variables exógenas macroeconómicas como PIB o inflación, enfocándose en la señal interna de la serie y sus variables de retardo (*lags*).

### 1.3.4 Alcance Funcional y Entregables

El resultado final de este proyecto consiste en:

- **Código fuente:** un script en lenguaje Python que contiene el modelo entrenado, optimizado y regularizado. Este entregable está diseñado para ser ejecutado mensualmente, permitiendo la actualización del pronóstico con los nuevos datos generados por el sistema de gestión.

## 1.4 Planteamiento

El principal síntoma de la problemática en Ferremate es la dependencia de instrumentos de financiamiento de alto costo para solventar la operación diaria. Ante la ausencia de una previsión de demanda, la organización recurre a deuda de consumo no preferencial para cubrir picos de ventas o adquisiciones de volumen. Esta práctica genera un “efecto bola de nieve”: el pago de estas obligaciones en una sola exhibición compromete la liquidez del periodo siguiente, impidiendo la reposición óptima del inventario y obligando a la empresa a solicitar anticipos de clientes B2B en los grandes proyectos para operar.

Este esquema reactivo no solo erosiona el margen de utilidad a través del pago de intereses elevados, sino que genera una vulnerabilidad financiera donde la rentabilidad del negocio se pone en riesgo ante cualquier desviación en el flujo de efectivo esperado.

#### 1.4.1 *La Brecha: Rentabilidad vs. Liquidez*

Ferremate se define actualmente como una empresa rentable con problemas de liquidez. La brecha entre la intuición del encargado de compras y el comportamiento no lineal del mercado ha derivado en un error operativo recurrente: el quiebre de stock (*stockout*).

A pesar de tener una demanda latente y clientes corporativos cautivos, la incapacidad de anticipar los requerimientos monetarios impide que la empresa mantenga el nivel de servicio necesario. Esta falta de competitividad no se debe a la ausencia de mercado, sino a una gestión ineficiente del capital de trabajo, donde el dinero se encuentra “atrapado” en el ciclo de deuda o en inventario de baja rotación, en lugar de estar disponible para las ventanas de alta demanda.

#### 1.4.2 *La Causa Raíz: Datos Subutilizados y Estrategia Empírica*

El núcleo técnico del problema reside en que Ferremate posee un activo intangible que no ha sido explotado: un repositorio de datos históricos desde 2021 disponible y de fácil acceso dentro del sistema POS. Actualmente, no existe un mecanismo analítico que transforme los tickets de venta en una estrategia financiera proactiva.

La gestión actual ignora componentes vitales de las series de tiempo como la estacionalidad y los retardos (*lags*) de la demanda. Sin un modelo predictivo, la administración carece de los argumentos técnicos necesarios para negociar con instituciones bancarias líneas de crédito revolvente más económicas y eficientes, las cuales requieren de una planeación con al menos tres meses de antelación para ser otorgadas bajo condiciones preferenciales.

#### 1.4.3 *Pregunta de Investigación*

Ante este escenario, surge la siguiente interrogante que guía el presente trabajo:

¿Es posible desarrollar un modelo de pronóstico basado en *Machine Learning* que reduzca la incertidumbre de la demanda monetaria, permitiendo a Ferremate transitar de una gestión de deuda reactiva a una estrategia de financiamiento revolvente y preventiva?

### 1.5 *Objetivos*

#### 1.5.1 *Objetivo general*

Desarrollar un modelo de pronóstico de demanda monetaria basado en algoritmos de *Machine Learning* para optimizar la planeación financiera y la gestión de inventarios de Ferremate, permitiendo la

transición de un esquema de financiamiento reactivo de alto costo hacia una estrategia preventiva basada en líneas de crédito revolving.

### 1.5.2 *Objetivos específicos*

Para alcanzar el objetivo general, se proponen los siguientes hitos secuenciales:

1. Sistematizar y depurar el histórico de ventas (febrero 2021 – diciembre 2025) proveniente del sistema POS Multicomercio, asegurando la integridad de los datos.
2. Identificar y modelar los componentes de tendencia, estacionalidad y retardos (*lags*) de la serie de tiempo mediante un Análisis Exploratorio de Datos (EDA) profundo, para comprender la dinámica del negocio.
3. Evaluar y comparar la precisión de modelos de suavizamiento exponencial (Holt–Winters), modelos estadísticos autorregresivos (SARIMA) y modelos de aprendizaje supervisado (XGBoost), utilizando el Error Porcentual Absoluto Medio (MAPE) como métrica principal de desempeño.
4. Optimizar y regularizar el modelo seleccionado (XGBoost) para garantizar una alta capacidad de generalización, mitigando el riesgo de sobreajuste (*overfitting*) y asegurando la confiabilidad de las predicciones en entornos de incertidumbre macroeconómica.
5. Generar proyecciones financieras en una ventana de tres meses que permitan a la administración de Ferremate estimar las necesidades de flujo de efectivo y gestionar instrumentos de deuda con tasas preferenciales.



## 2 Metodología

### 2.1 Descripción del conjunto de datos

El presente estudio se fundamenta en el análisis del reporte nativo del sistema de Punto de Venta (POS) Multicomercio, denominado “reporte\_ventas\_ferremate”. Este archivo contiene el registro detallado de las transacciones realizadas por la empresa Ferremate desde la adopción formal del sistema en febrero de 2021.

#### 2.1.1 Tendencia




Figura 2.1: Serie de tiempo mensual de ventas totales.




Figura 2.2: Serie de tiempo de la cantidad de tickets.

### 2.1.2 Estructura y depuración de datos

El archivo original fue procesado mediante un procedimiento de limpieza orientado a identificar exclusivamente transacciones válidas. Para ello:

- Se identificaron los registros efectivos a través del marcador “+” presente en el reporte nativo del sistema.
- Se realizó la conversión de fechas en formato textual (español) a formato *datetime*.
- Se extrajo el total monetario de cada ticket.
- Se excluyeron registros nulos o inconsistentes.

Después del proceso de depuración, se obtuvieron:

- 50,253 tickets válidos.
- Periodo comprendido entre el 11 de febrero de 2021 y el 31 de enero de 2026.

Este volumen transaccional proporciona una base robusta para el análisis estadístico y el entrenamiento de modelos predictivos.

### 2.1.3 Agregación temporal

Dado que el objetivo del estudio es la planeación financiera y la estimación del flujo de efectivo, los datos fueron agregados a frecuencia mensual (MS, *Month Start*) mediante la suma total de ventas por mes.

La serie resultante presenta:

- 60 observaciones mensuales.
- 0 meses con ventas nulas, lo que confirma continuidad operativa.
- Promedio mensual: \$196,720 MXN.
- Desviación estándar mensual: \$71,293 MXN.
- Mínimo mensual: \$75,865 MXN.
- Máximo mensual: \$389,783 MXN.
- Coeficiente de variación: 0.36 (36 %).

#### 2.1.4 Caracterización estadística preliminar

El coeficiente de variación del 36 % indica una volatilidad moderada-alta en el comportamiento mensual de la demanda. Asimismo, la amplitud entre el valor mínimo y máximo mensual sugiere que la variabilidad crece proporcionalmente al nivel de ventas, lo que constituye un indicio preliminar de comportamiento multiplicativo en los componentes de la serie temporal.

Esta evidencia empírica justifica:

1. La aplicación de transformación logarítmica para estabilizar la varianza[3].
2. La utilización de un modelo de descomposición multiplicativo en el análisis exploratorio.
3. La consideración de modelos capaces de capturar relaciones no lineales[2].

## 2.2 Análisis Exploratorio (EDA)

### 2.2.1 Tendencia




Figura 2.3: Serie de tiempo con medias móviles.

La serie mensual de ventas evidencia una tendencia creciente clara a partir de 2023, con un cambio estructural significativo durante 2024.

Las medias móviles de 3 y 6 meses confirman:

- Un crecimiento sostenido en el nivel promedio de ventas.
- Una aceleración a partir del primer trimestre de 2024.
- Estabilización relativa hacia finales de 2025.

El suavizado reduce la variabilidad de corto plazo y permite observar que el incremento no es un fenómeno aislado, sino estructural.

### 2.2.2 Interpretación metodológica

La presencia de tendencia implica que la serie no es estrictamente estacionaria en nivel[1], lo que justifica:

- La aplicación de transformación logarítmica.
- La consideración de modelos con componente de tendencia (Holt-Winters, SARIMA).
- La inclusión de lags en modelos basados en ML.

### 2.2.3 Estacionalidad




Figura 2.4: Distribución de ventas mensuales por mes (evidencia de estacionalidad).

El boxplot mensual por mes del año muestra variabilidad diferenciada entre meses:

- Enero, abril y julio presentan alta dispersión.
- Febrero tiende a niveles relativamente bajos.
- Meses como noviembre y diciembre muestran incrementos consistentes.




Figura 2.5: Líneas comparativas.

La descomposición ETS multiplicativa evidencia un patrón estacional recurrente con amplitud proporcional al nivel de la serie.




Figura 2.6: Análisis exploratorio de datos.

La amplitud estacional crece cuando crece el nivel general de ventas, esto es evidencia clara de comportamiento multiplicativo[3] (no aditivo). Por tanto, la elección del modelo multiplicativo en la descomposición está empíricamente justificada.

- Autocorrelación positiva fuerte en los primeros rezagos.
- Decaimiento gradual hasta aproximadamente el rezago 18–20.
- Patrón típico de serie con persistencia temporal.

### 2.2.4 Dependencia temporal (ACF y PACF)




Figura 2.7: Dependencia temporal.




Figura 2.8: Log dependencia temporal.

Las gráficas ACF muestran:

- Autocorrelación positiva fuerte en los primeros rezagos.
- Decaimiento gradual hasta aproximadamente el rezago 18–20.
- Patrón típico de serie con persistencia temporal.

La PACF muestra:

- Rezago 1 altamente significativo.
- Rezagos 2 y 3 aún relevantes.
- Posteriormente los coeficientes caen dentro de los intervalos de confianza.

#### Interpretación:

La serie presenta:

- Dependencia autorregresiva de corto plazo[1].
- Memoria estructural en los primeros meses.
- Componente AR dominante en rezagos bajos.

Por lo tanto, se considera lo siguiente:

- Probar modelos ARIMA/SARIMA.
- Incorporar lags en el modelo XGBoost.
- No tratar la serie como ruido blanco[4].

### 2.2.5 Volatilidad




Figura 2.9: Distribución de ventas diarias por año.

La dispersión observada en los boxplots anuales y mensuales indica:

- Incremento en variabilidad conforme aumenta el nivel.
- Presencia de valores atípicos en 2024 y 2025.
- Distribución asimétrica en algunos meses.

El coeficiente de variación (36 %) confirma volatilidad moderada-alta.

La gráfica de desviación estándar móvil (ventana de 6 meses) evidencia un comportamiento no constante en la variabilidad de la demanda monetaria a lo largo del tiempo.




Figura 2.10: Desviación estándar móvil de ventas (ventana de 6 meses).

2.2.6 Estacionariedad

Se aplicaron las pruebas Augmented Dickey-Fuller[4] (ADF) y KPSS sobre la serie mensual en nivel y bajo transformación logarítmica. En ambos casos, la prueba ADF arrojó valores p superiores a 0.05, por lo que no se rechaza la hipótesis nula de presencia de raíz unitaria. Simultáneamente, la prueba KPSS arrojó valores p inferiores a 0.05, lo que implica el rechazo de la hipótesis de estacionariedad.

| Serie                    | ADF_stat     | ADF_pvalue  | ADF_lags | KPSS_stat   | KPSS_pvalue | KPSS_lags |
|--------------------------|--------------|-------------|----------|-------------|-------------|-----------|
| Ventas mensuales (nivel) | -1.44788487  | 0.55911663  | 2        | 1.1001693   | 0.01        | 4         |
| Ventas mensuales (log1p) | -1.302833248 | 0.627875104 | 2        | 1.138401795 | 0.01        | 4         |

Figura 2.11: Pruebas Augmented Dickey-Fuller (ADF) y KPSS.

La coincidencia entre ambas pruebas confirma que la serie mensual de ventas no es estacionaria. Este resultado es consistente con la evidencia gráfica previamente presentada (tendencia creciente y volatilidad no constante) y justifica la aplicación de diferenciación en modelos autorregresivos, así como el uso de transformaciones logarítmicas para estabilizar la varianza.

2.3 Ingeniería de características

Con base en los hallazgos obtenidos en el análisis exploratorio, se procedió a la construcción de variables explicativas orientadas a capturar de forma estructurada la dinámica temporal de la serie mensual de ventas. El objetivo de esta etapa fue transformar la serie original en un conjunto de variables que permitieran a los modelos predictivos representar adecuadamente los componentes de tendencia, estacionalidad y dependencia autorregresiva previamente identificados para estabilizar la varianza[3].

### 2.3.1 *Variables de retardo (lags)*

El análisis de autocorrelación parcial (PACF) evidenció significancia estadística en los primeros rezagos, particularmente en los periodos 1, 2 y 3. Esto indica la presencia de dependencia autorregresiva de corto plazo, es decir, que el comportamiento de la demanda en un mes determinado se encuentra influenciado por los valores observados en meses inmediatamente anteriores.

En consecuencia, se generaron las siguientes variables de retardo:

- Lag 1: ventas del mes anterior.
- Lag 2: ventas de hace dos meses.
- Lag 3: ventas de hace tres meses.

Adicionalmente, dado que el análisis estacional reveló un patrón anual recurrente, se incorporó:

- Lag 12: ventas del mismo mes del año anterior.

Este último retardo permite capturar la memoria estacional anual, facilitando que el modelo identifique recurrencias asociadas al ciclo calendario, particularmente relevantes en sectores sensibles a ciclos de construcción y dinámica industrial.

### 2.3.2 *Variable de tendencia*

El análisis de la serie evidenció un crecimiento estructural a partir de 2023, intensificándose durante 2024 y 2025. Con el fin de modelar este componente determinístico, se incorporó una variable índice temporal creciente (tendencia), definida como una secuencia numérica incremental desde el inicio del periodo de análisis.

Esta variable permite capturar el crecimiento estructural del negocio, diferenciándolo de fluctuaciones de corto plazo, y resulta especialmente útil en modelos basados en árboles de decisión que no modelan explícitamente términos de tendencia como lo hacen los modelos estadísticos clásicos.

### 2.3.3 *Variable estacional*

Se extrajo el mes calendario (valores de 1 a 12) a partir del índice temporal. Esta variable permite al modelo identificar patrones sistemáticos asociados al ciclo anual de ventas. Dado que el modelo XGBoost no requiere variables categóricas[2] codificadas mediante “dummies” para capturar relaciones no lineales, el mes fue incorporado como variable numérica ordinal, permitiendo que el algoritmo detecte particiones óptimas en función del comportamiento histórico.

#### 2.3.4 Transformación logarítmica

Considerando la evidencia de heterocedasticidad[3] observada en el análisis de volatilidad —donde la variabilidad aumenta proporcionalmente al nivel de ventas— se aplicó la transformación logarítmica  $\log_{1p}$  a la variable objetivo. Esta transformación contribuye a estabilizar la varianza y mejorar la robustez estadística del modelado, particularmente en escenarios de crecimiento estructural.

Aunque los modelos basados en árboles son menos sensibles a problemas de no normalidad, la transformación logarítmica facilita la comparación con modelos estadísticos tradicionales y reduce el impacto de valores extremos en el entrenamiento.

#### 2.3.5 Consistencia temporal y eliminación de observaciones iniciales

La creación de variables de retardo implica la pérdida de las primeras observaciones de la serie, debido a la imposibilidad de calcular rezagos en los periodos iniciales. En particular, la incorporación del retardo de 12 meses generó la eliminación de las primeras doce observaciones.

Tras depurar los valores nulos derivados de los retardos, el conjunto final de datos quedó conformado por 48 observaciones mensuales consistentes, garantizando que cada registro utilice exclusivamente información disponible hasta el periodo anterior.

Este procedimiento evita fuga de información[3] (data leakage) y asegura que el entrenamiento de los modelos se realice bajo un esquema temporalmente coherente.

La ingeniería de características realizada permite transformar una serie temporal univariada en un conjunto estructurado de variables que capturan:

- Dependencia autorregresiva de corto plazo.
- Memoria estacional anual.
- Tendencia estructural de crecimiento.
- Estabilización de varianza mediante transformación logarítmica.

Este conjunto de variables constituye la base del modelado predictivo desarrollado en las secciones siguientes.

### 2.4 Descripción de los modelos

Con el objetivo de evaluar distintas aproximaciones metodológicas para el pronóstico de ventas mensuales, se implementaron modelos pertenecientes a dos grandes enfoques: modelos estadísticos clásicos

de series de tiempo y modelos de aprendizaje automático basados en árboles de decisión. Esta comparación permite evaluar el desempeño predictivo bajo distintos supuestos estructurales y seleccionar la alternativa más adecuada en términos de precisión y aplicabilidad financiera.

#### 2.4.1 *Holt – Winters*

El primer enfoque evaluado fue el modelo Holt–Winters[3] (ETS: Error, Trend, Seasonality), un método clásico de pronóstico para series de tiempo que incorpora explícitamente tendencia y estacionalidad. Este modelo es especialmente útil como línea base (baseline) para comparar contra alternativas más complejas, ya que es interpretable y suele capturar patrones recurrentes con pocas suposiciones adicionales.

A partir del análisis exploratorio se observó que la serie mensual presenta:

- Tendencia creciente a lo largo del tiempo.
- Estacionalidad anual (periodicidad de 12 meses).
- Variabilidad que aumenta con el nivel de ventas, lo que sugiere un comportamiento multiplicativo.

Para hacer consistente el modelado con este comportamiento, el entrenamiento se realizó sobre la serie transformada  $\log_{1p}$ , lo cual ayuda a estabilizar la varianza; en esta escala, un patrón multiplicativo se modela de forma equivalente como aditivo.

#### **Configuración del modelo**

El modelo Holt–Winters se ajustó con:

- Trend = aditivo: para capturar el crecimiento estructural de la serie.
- Seasonal = aditivo (periodo 12): para representar la estacionalidad anual.
- Damped trend = True: con el fin de evitar proyecciones excesivamente agresivas y mantener un pronóstico más conservador y realista para fines de planeación.

#### **Validación y desempeño**

Para la evaluación se empleó una validación temporal, reservando los últimos 3 meses como conjunto de prueba. La métrica utilizada fue

el MAPE (Mean Absolute Percentage Error), adecuada para interpretar error relativo en términos porcentuales.

En esta validación, el modelo Holt–Winters obtuvo:

- MAPE Holt–Winters: 26.31 %

Este resultado indica que, aunque Holt–Winters logra capturar la estructura general de la serie (tendencia y estacionalidad), su precisión es limitada frente a modelos con mayor capacidad de adaptación a cambios recientes, por lo que se utiliza principalmente como referencia comparativa dentro del proyecto.

### Uso dentro del proyecto

Holt–Winters se mantuvo como baseline estadístico, permitiendo contrastar su desempeño contra los modelos SARIMA y XGBoost bajo el mismo horizonte de pronóstico (3 meses) y la misma estrategia de partición temporal. Esto ayuda a justificar de forma objetiva la selección del modelo final con base en métricas y evidencia empírica.

#### 2.4.2 SARIMA

El segundo enfoque evaluado fue el modelo SARIMA (Seasonal AutoRegressive Integrated Moving Average), una extensión del modelo ARIMA tradicional que permite incorporar explícitamente componentes autorregresivos, de media móvil y diferenciación tanto en la parte regular como en la parte estacional[4].

Del análisis exploratorio se identificaron dos características fundamentales de la serie:

- No estacionariedad en nivel, derivada de la tendencia creciente.
- Estacionalidad anual clara, con periodicidad de 12 meses.

Las pruebas de estacionariedad (ADF y KPSS) confirmaron que la serie en nivel no es estacionaria, lo que justifica aplicar diferenciación.

En consecuencia, el modelo se especificó como:

$$SARIMA(p, d, q)(P, D, Q)_s$$

$$SARIMA(1, 1, 1)(1, 1, 1)_{12}$$

donde:

- $d = 1 \rightarrow$  elimina la tendencia mediante diferenciación regular.
- $D = 1, s = 12 \rightarrow$  elimina la estacionalidad anual.
- $p = 1$  y  $q = 1 \rightarrow$  capturan dependencia de corto plazo.

- $P = 1$  y  $Q = 1 \rightarrow$  capturan dependencia estacional.

Esta configuración está basada en los patrones observados en las gráficas ACF y PACF, donde se detectaron rezagos significativos tanto en el componente regular como en el estacional. La selección de órdenes bajos responde a un criterio de parsimonia[4], priorizando un modelo estructuralmente simple pero capaz de capturar la dependencia regular y estacional observada en las funciones ACF y PACF. El modelo fue entrenado sobre la serie transformada mediante  $\log_{1p}$ , lo cual mejora estabilidad de varianza y consistencia con el comportamiento multiplicativo observado en el EDA.

### Validación y desempeño

Se utilizó la misma estrategia de validación temporal que en los demás modelos: los últimos 3 meses fueron reservados como conjunto de prueba.

El desempeño obtenido fue:

- MAPE SARIMA: 33.08 %

Este resultado indica que, aunque SARIMA logra modelar adecuadamente la estructura estadística de la serie (tendencia y estacionalidad), su capacidad predictiva fue inferior a la del modelo Holt–Winters y significativamente menor que la del modelo basado en aprendizaje automático (XGBoost).

Una posible explicación es que SARIMA asume relaciones lineales y estabilidad estructural en el tiempo, lo cual puede ser limitado cuando existen cambios recientes en dinámica de crecimiento o variaciones no lineales en el comportamiento de ventas.

#### 2.4.3 XGBoost

Basado en Machine Learning, específicamente XGBoost (Extreme Gradient Boosting), un algoritmo de ensamble basado en árboles de decisión optimizados mediante gradiente boosting.

A diferencia de los modelos clásicos (Holt–Winters y SARIMA), que modelan directamente la estructura estadística de la serie, XGBoost permite capturar relaciones no lineales[2], interacciones complejas y cambios estructurales recientes, lo cual resulta especialmente útil en contextos empresariales dinámicos.

El análisis exploratorio mostró:

- Tendencia creciente no lineal.
- Estacionalidad anual.

- Cambios estructurales recientes en el nivel de ventas (aceleración a partir de 2023–2024).
- Posible comportamiento no estrictamente lineal.

Los modelos clásicos suponen cierta estabilidad estructural y relaciones lineales en los rezagos. Sin embargo, en entornos reales de negocio, el comportamiento de ventas puede estar influenciado por factores como:

- Cambios en demanda.
- Efectos acumulativos.
- Interacciones entre rezagos.
- Ritmos de crecimiento variables.

Por ello, se incorporó un modelo de aprendizaje automático con mayor flexibilidad funcional.

#### **Ingeniería de características**

A diferencia de SARIMA, XGBoost requiere variables explicativas explícitas. Se construyó un conjunto de características basado en:

- Lag 1, 2 y 3 meses
- Lag 12 meses (estacionalidad anual)
- Mes del año (captura estacionalidad)
- Tendencia temporal (índice creciente)

La variable objetivo fue modelada en escala  $\log_{1p}$ , para mantener coherencia con el tratamiento aplicado en los modelos estadísticos y estabilizar varianza.

Esta estructura permite al modelo aprender:

- Dependencia temporal de corto plazo.
- Repetición estacional anual.
- Trayectoria de crecimiento estructural.
- Interacciones no lineales entre estas variables.

#### **Configuración del modelo**

Se utilizó un XGBRegressor con regularización para evitar sobreajuste:

- 400 árboles (n\_estimators)

- `learning_rate = 0.03`
- `max_depth = 3`
- `subsample = 0.9`
- `colsample_bytree = 0.9`
- `reg_lambda = 10`
- `min_child_weight = 3`

Estos hiperparámetros favorecen estabilidad y generalización en lugar de ajuste agresivo.

### **Validación y desempeño**

Se utilizó la misma estrategia de validación temporal que en los otros modelos: los últimos 3 meses fueron reservados como conjunto de prueba.

El desempeño obtenido fue:

- MAPE XGBoost: 8.69 %

Este resultado representa una mejora sustancial respecto a:

- Holt-Winters: 26.31 %
- SARIMA: 33.08 %

La reducción del error es significativa, lo que indica que XGBoost logra capturar patrones que los modelos lineales no pudieron modelar adecuadamente.

### **Interpretación del resultado**

El mejor desempeño puede atribuirse a:

- Capacidad para modelar relaciones no lineales.
- Flexibilidad ante cambios estructurales recientes.
- Uso explícito de múltiples rezagos como variables independientes.
- Regularización que evita sobreajuste en muestras pequeñas[2].

Mientras que los modelos clásicos extrapolan estructura estadística pasada, XGBoost aprende directamente patrones predictivos óptimos en función de los datos disponibles.

## 2.5 Métricas de evaluación

Para evaluar el desempeño predictivo de los modelos propuestos (Holt–Winters, SARIMA y XGBoost), se utilizó una estrategia de validación temporal, reservando los últimos 3 meses de la serie como conjunto de prueba. Esta metodología respeta la estructura cronológica de los datos y evita fuga de información (data leakage), lo cual es fundamental en problemas de series de tiempo[3].

### 2.5.1 MAPE

El MAPE (*Mean Absolute Percentage Error*) expresa el error en términos porcentuales, lo cual facilita la interpretación financiera del desempeño del modelo[5].

$$MAPE = \frac{1}{n} \sum \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100$$

Donde:

- $Y_t$ : Valor real observado.
- $\hat{Y}_t$ : Valor pronosticado.
- $n$ : Número de observaciones.

La elección del MAPE como métrica de evaluación se basa en que permite comparar modelos independientemente de la escala, además de ser intuitivo para la toma de decisiones, ya que expresa el error relativo.

### 2.5.2 Resultados obtenidos

| Modelo       | MAPE    | Pronóstico (2025-11) | Pronóstico (2025-12) | Pronóstico (2026-01) |
|--------------|---------|----------------------|----------------------|----------------------|
| Holt-Winters | 26.31 % | \$308,128            | \$304,566            | \$352,059            |
| SARIMA       | 33.08 % | \$345,720            | \$295,236            | \$374,601            |
| XGBoost      | 8.69 %  | \$299,868            | \$264,085            | \$266,778            |

Tabla 2.1: Tabla comparativa: MAPE y montos pronosticados (horizonte de validación: 3 meses)

Los resultados muestran diferencias claras en capacidad predictiva:

- SARIMA (33.08%) presentó el mayor error, lo que sugiere limitaciones para capturar cambios estructurales recientes o dinámicas no lineales.
- Holt–Winters (26.31%) mejoró respecto a SARIMA, logrando modelar adecuadamente tendencia y estacionalidad, aunque con limitaciones ante variaciones recientes.

- XGBoost (8.69 %) mostró un desempeño sustancialmente superior, reduciendo el error a menos de un tercio del error de los modelos estadísticos clásicos.

Un MAPE de 8.69 % implica que, en promedio, el error del modelo representa menos del 9 % del valor real observado, lo cual es considerado un nivel de precisión alto en contextos de pronóstico financiero.

## 2.6 *Diseño de experimentos*

El diseño experimental del presente trabajo se estructuró bajo un enfoque de validación temporal, respetando la naturaleza secuencial de los datos y evitando cualquier tipo de fuga de información (*data leakage*).

Dado que el objetivo del proyecto es generar pronósticos financieros aplicables en un entorno real, el esquema experimental se diseñó para simular el escenario operativo en el que la empresa se encontraría al momento de realizar una proyección.

### 2.6.1 *División temporal de los datos*

La serie mensual final estuvo conformada por 60 observaciones (febrero 2021 – enero 2026).

Para evaluar el desempeño predictivo, se implementó una partición tipo *train-test holdout* temporal, que es una práctica estándar en evaluación de modelos de series de tiempo[3], donde:

- **Conjunto de entrenamiento (Train):** Todas las observaciones excepto los últimos 3 meses.
- **Conjunto de prueba (Test):** Los últimos 3 meses de la serie.

Este esquema reproduce una situación real en la que el modelo se entrena únicamente con información histórica disponible hasta el periodo  $t$ , y posteriormente se evalúa su capacidad para anticipar los periodos  $t + 1$ ,  $t + 2$  y  $t + 3$ .

El horizonte de 3 meses fue seleccionado por su alineación con el tiempo requerido para la gestión y contratación de líneas de crédito revolving.

### 2.6.2 *Consistencia metodológica entre modelos*

Con el fin de garantizar una comparación objetiva, los tres modelos evaluados (Holt–Winters, SARIMA y XGBoost) fueron sometidos a condiciones idénticas:

- Mismo conjunto de entrenamiento.
- Mismo conjunto de prueba.
- Mismo horizonte de pronóstico (3 meses).
- Misma transformación logarítmica aplicada.
- Misma métrica de evaluación (MAPE).

Esto asegura que las diferencias en desempeño se atribuyan exclusivamente a la capacidad predictiva del modelo y no a variaciones en la configuración experimental.

### 2.6.3 *Tratamiento de la transformación logarítmica*

Todos los modelos fueron entrenados sobre la serie transformada mediante  $\log_{1p}$  con el objetivo de:

- Estabilizar la varianza.
- Reducir el impacto de valores extremos.
- Mantener coherencia con la evidencia de comportamiento multiplicativo.

Posteriormente, los pronósticos fueron transformados nuevamente a escala original ( $expm1$ ) para su evaluación y comparación en términos monetarios reales.

### 2.6.4 *Criterio de selección del modelo*

El modelo final fue seleccionado bajo el criterio de minimización del MAPE en el conjunto de prueba.

Este criterio se adoptó debido a que:

- Expresa el error en términos relativos.
- Es interpretable en contexto financiero.
- Permite comparar modelos de distinta naturaleza.

El modelo con menor MAPE fue considerado el más adecuado para producción.

### 2.6.5 *Robustez y prevención de sobreajuste*

Para mitigar el riesgo de sobreajuste:

- En los modelos estadísticos se priorizó la parsimonia estructural.

- En XGBoost se aplicaron técnicas de regularización (*reg\_lambda*, *min\_child\_weight*, *subsample*, *colsample\_bytree*).
- Se evitó el uso de variables exógenas adicionales que pudieran introducir ruido o complejidad innecesaria.

El uso de una ventana de prueba completamente fuera de la muestra permite evaluar la capacidad real de generalización del modelo.

#### 2.6.6 Limitaciones del diseño experimental

Aunque el esquema de validación temporal garantiza coherencia cronológica, presenta algunas limitaciones:

- El tamaño muestral es relativamente reducido (60 observaciones).
- La evaluación se basa en un único bloque de validación (*holdout*).
- No se implementó validación cruzada expandida (*rolling window*), lo cual podría explorarse en investigaciones futuras.

A pesar de estas limitaciones, el diseño es consistente con el objetivo aplicado del estudio y reproduce de manera realista el entorno operativo de la empresa.



## 3 Resultados

El presente capítulo expone los hallazgos derivados del proceso de modelado, validación y comparación de las arquitecturas evaluadas. Se presentan los resultados cuantitativos obtenidos, así como su interpretación técnica y financiera.

### 3.1 Comparación de modelos

Tras aplicar el diseño experimental descrito en la sección 2.6, se obtuvieron los siguientes resultados en el conjunto de prueba (últimos 3 meses):

| Modelo       | MAPE    | Pronóstico (2025-11) | Pronóstico (2025-12) | Pronóstico (2026-01) |
|--------------|---------|----------------------|----------------------|----------------------|
| Holt-Winters | 26.31 % | \$308,128            | \$304,566            | \$352,059            |
| SARIMA       | 33.08 % | \$345,720            | \$295,236            | \$374,601            |
| XGBoost      | 8.69 %  | \$299,868            | \$264,085            | \$266,778            |

Tabla 3.1: Tabla comparativa: MAPE y montos pronosticados (horizonte de validación: 3 meses)

La diferencia en desempeño es significativa. Mientras que los modelos estadísticos clásicos presentaron errores superiores al 25 %, el modelo basado en aprendizaje automático redujo el error a menos del 9 %.




Figura 3.1: Comparación de pronósticos.

La reducción del error no es marginal, sino estructural: XGBoost disminuye el error en aproximadamente 67 % respecto a Holt–Winters y en más del 70 % respecto a SARIMA.

### SARIMA (33.08 %)

A pesar de incorporar diferenciación regular y estacional, el modelo mostró limitaciones para capturar cambios estructurales recientes en la dinámica de crecimiento. Su naturaleza lineal restringe su capacidad de adaptación ante variaciones no lineales en la demanda[4].

### Holt–Winters (26.31 %)

El modelo capturó adecuadamente tendencia y estacionalidad, superando a SARIMA. Sin embargo, al depender de suavizamiento exponencial[3], su capacidad de ajuste ante aceleraciones recientes fue limitada.

### XGBoost (8.69 %)

El modelo presentó un desempeño sustancialmente superior, lo que sugiere que la demanda monetaria de Ferremate presenta patrones no lineales[2] e interacciones entre rezagos que los modelos lineales no lograron modelar adecuadamente.

### 3.2 Selección del modelo final

Dado que todos los modelos fueron evaluados bajo condiciones idénticas, la selección del modelo final se realizó bajo el criterio objetivo de menor MAPE en el conjunto de prueba.

El modelo seleccionado fue XGBoost (MAPE = 8.69 %).

Este nivel de precisión implica que, en promedio, el error del modelo representa menos del 9 % del valor real observado, lo cual es considerado un nivel de desempeño alto en contextos de pronóstico financiero[5].

La superioridad del modelo puede atribuirse a:

- Captura de relaciones no lineales[2].
- Uso explícito de múltiples rezagos.
- Incorporación estructurada de tendencia y estacionalidad.
- Regularización que previene sobreajuste[2].

### 3.3 Pronóstico a 3 meses

Una vez seleccionado el modelo XGBoost, se procedió a entrenarlo utilizando la totalidad de los datos históricos disponibles y se generó un pronóstico para los siguientes tres meses. Las proyecciones obtenidas fueron:




Figura 3.2: Pronóstico de ventas a 3 meses con el modelo XGBoost.

Los intervalos de predicción generados (50 %, 80 % y 95 %) muestran un rango plausible de variabilidad, permitiendo dimensionar escenarios conservadores y optimistas.

Desde una perspectiva financiera, estos valores representan la base cuantitativa para estimar necesidades de capital de trabajo con tres meses de anticipación.

### 3.4 *Impacto financiero*

La mejora en precisión no es únicamente un resultado estadístico; tiene implicaciones económicas directas.

Con un error promedio inferior al 9 %, la administración puede:

- Estimar requerimientos de liquidez con menor incertidumbre.
- Planificar compras de inventario sin recurrir a deuda de emergencia.
- Negociar líneas de crédito revolvante con condiciones preferenciales.
- Reducir el costo financiero asociado a financiamiento reactivo.

La diferencia entre un error del 30 % y uno inferior al 10 % puede representar decenas de miles de pesos en decisiones mal dimensionadas de inventario o financiamiento.

La implementación del modelo transforma la gestión financiera de Ferremate de un esquema reactivo basado en intuición hacia una estrategia preventiva basada en evidencia cuantitativa.

## 4 *Discusión*

El presente capítulo analiza los resultados obtenidos desde una perspectiva técnica y financiera, contextualizando su relevancia para la toma de decisiones estratégicas en Ferremate, así como las limitaciones y oportunidades de mejora del estudio.

### 4.1 *Interpretación técnica*

Los resultados obtenidos evidencian que la demanda monetaria de Ferremate no sigue una dinámica puramente lineal ni estrictamente estructural.

Aunque los modelos estadísticos clásicos (Holt–Winters y SARIMA) lograron capturar adecuadamente los componentes fundamentales de la serie —tendencia y estacionalidad—, su desempeño fue significativamente inferior al modelo basado en aprendizaje automático.

Este hallazgo sugiere que:

- Existen relaciones no lineales[2] en la evolución de la demanda.
- La interacción entre rezagos recientes y memoria estacional no puede representarse completamente mediante estructuras lineales[4].
- El crecimiento observado en 2023–2024 implicó un cambio estructural que los modelos tradicionales no lograron ajustar con suficiente flexibilidad.

El modelo XGBoost, al no imponer supuestos paramétricos estrictos[2], fue capaz de capturar estas dinámicas complejas mediante particiones óptimas en el espacio de variables explicativas.

Este resultado es consistente con la literatura reciente que demuestra que algoritmos de *boosting* suelen superar a modelos lineales cuando existen interacciones no triviales en los datos[2].

## 4.2 Interpretación financiera

Desde una perspectiva financiera, la mejora en precisión no es simplemente una ventaja estadística; representa una transformación operativa.

La reducción del MAPE de más del 30 % (SARIMA) a menos del 9 % (XGBoost) implica:

- Mayor certidumbre en la estimación de ingresos futuros.
- Menor riesgo de subestimar necesidades de inventario.
- Menor probabilidad de sobreestimar flujo disponible.

**En términos prácticos, esto permite:**

1. Planificar compras de inventario con anticipación.
2. Negociar líneas de crédito revolving con mejor perfil de riesgo.
3. Reducir la dependencia de financiamiento de emergencia.
4. Alinear salidas de efectivo con recuperación de ventas.

## 4.3 Limitaciones

A pesar de los resultados favorables, el estudio presenta limitaciones que deben considerarse:

### 1. Tamaño de muestra limitado

La serie cuenta con 60 observaciones mensuales, lo cual restringe la complejidad estructural que puede modelarse sin riesgo de sobreajuste.

### 2. Ausencia de variables exógenas

No se incorporaron indicadores macroeconómicos (inflación, tipo de cambio, PIB, inversión industrial). Si bien esto favorece parsimonia[4], podría limitar la capacidad explicativa ante shocks externos.

### 3. Sensibilidad ante cambios estructurales futuros

El modelo asume que la dinámica histórica contiene suficiente información para proyectar el corto plazo. Cambios abruptos en el entorno económico podrían afectar la precisión futura.

### 4. Naturaleza agregada del análisis

El estudio se realizó a nivel global mensual. No se evaluó comportamiento por familia de productos o segmento B2B/B2C, lo cual podría revelar patrones diferenciados.

#### 4.4 *Trabajo futuro*

El estudio abre diversas líneas de investigación y mejora:

1. Implementar validación cruzada temporal con ventana expandida[3].
2. Incorporar variables macroeconómicas externas.
3. Desarrollar modelos híbridos (SARIMA + XGBoost).
4. Evaluar modelos específicos por categoría de producto.
5. Explorar arquitecturas avanzadas como Prophet o modelos bayesianos estructurales.
6. Analizar impacto financiero cuantificado en ahorro de intereses.

Una extensión particularmente relevante sería medir el ahorro financiero real derivado del uso del modelo durante un año operativo completo.



## 5 Conclusiones

El presente trabajo tuvo como objetivo desarrollar y comparar modelos de series de tiempo para pronosticar las ventas mensuales de Ferremate, utilizando información proveniente del sistema POS Multicomercio.

A partir del análisis exploratorio se identificó que la serie presenta:

- Tendencia creciente en el mediano plazo.
- Estacionalidad anual con periodicidad de 12 meses.
- Variabilidad que aumenta con el nivel de ventas, evidenciado por una amplitud estacional proporcional al nivel de ventas.
- No estacionariedad en nivel, confirmada mediante las pruebas ADF y KPSS[4], cuyos resultados indican la presencia de raíz unitaria.

Estos hallazgos guiaron la especificación de tres enfoques de modelado:

- Holt–Winters con tendencia amortiguada.
- SARIMA  $(1, 1, 1)(1, 1, 1)_{12}$ .
- XGBoost con variables de ingeniería de características.

La evaluación se realizó mediante validación temporal utilizando los últimos tres meses como conjunto de prueba, empleando el MAPE como métrica principal de comparación[5].

Los resultados obtenidos fueron:

- Holt–Winters: 26.31 %.
- SARIMA: 33.08 %.
- XGBoost: 8.69 %.

El modelo XGBoost mostró una mejora sustancial en precisión respecto a los enfoques estadísticos tradicionales, lo cual sugiere la presencia de relaciones no lineales[2] y patrones complejos que no son completamente capturados por modelos lineales paramétricos.

Desde una perspectiva aplicada, esta mejora en precisión reduce significativamente la incertidumbre en la planeación financiera de corto plazo, permitiendo una mejor estimación de flujos de ingreso, gestión de inventarios y planificación de capital de trabajo.

El pronóstico generado a tres meses proporciona una herramienta práctica para la toma de decisiones estratégicas en la empresa, con intervalos de predicción que incorporan la incertidumbre inherente al proceso.

En síntesis, el estudio demuestra que:

1. El análisis exploratorio riguroso es fundamental para la correcta especificación de modelos.
2. Los modelos clásicos siguen siendo útiles como referencia estructural.
3. Los algoritmos de aprendizaje automático pueden superar a los enfoques tradicionales en presencia de dinámicas no lineales[2].
4. La modelación de series de tiempo aplicada a datos reales empresariales genera valor operativo tangible.

Este trabajo confirma que la integración de técnicas estadísticas y de *machine learning* constituye una estrategia robusta para la predicción de demanda en contextos comerciales reales.

## *Bibliografía*

- [1] J. Hamilton, "Time series analysis," 1994.
- [2] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," 2016.
- [3] R. J. Hyndman and G. Athanasopoulos, "Forecasting: Principles and Practice," 2018.
- [4] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, "Time Series Analysis: Forecasting and Control," 2015.
- [5] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "The M4 Competition: 100,000 Time Series and 61 Forecasting Methods," 2020.