

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



Implementación de modelos de predicción para la mejora de gestión de inventarios

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

Presenta:
Isaac Gabriel Gómez Flores

Director:
Dr. Jaime Emmanuel Alcalá Temores

Tlaquepaque, Jalisco, 7 de junio de 2024

Implementación de modelos de predicción para la mejora de gestión de inventarios

Isaac Gabriel Gómez Flores

Resumen

Este trabajo ofrece una introducción al desafío fundamental de mejorar la precisión en los pronósticos que se usan para la gestión de inventarios y sus efectos en la cadena de suministro. Los pronósticos inexactos pueden provocar desbalances en la gestión de inventarios, lo que implica costos de almacenamiento, posibles costos de desecho de productos sobrantes y gastos extra por tener que apresurar órdenes. Además, puede ocasionar problemas con los clientes y pérdida de ventas de productos.

El objetivo principal de este proyecto es proponer una alternativa para la generación de pronósticos de ventas de productos para dos unidades de negocios de la empresa donde el autor participa. Para lograr este objetivo, se realizarán las siguientes acciones: obtener, transformar y crear un conjunto de datos para el análisis, construir modelos de pronóstico estadísticos y de aprendizaje automático, seleccionar los mejores modelos por tipo de producto y comparar las predicciones obtenidas con las estimaciones internas compartidas.

Los resultados muestran que, para algunos productos, los modelos desarrollados presentaron una disminución significativa del error en comparación con el método utilizado actualmente. Sin embargo, para otros productos, los errores fueron mayores. En general, los modelos estadísticos tuvieron un mejor rendimiento que los modelos de aprendizaje automático. Finalmente fue posible sugerir una alternativa para la elaboración de pronósticos de ventas en las distintas unidades de negocio, planteando una forma de optimizar los inventarios mediante predicciones más precisas obteniendo para algunos productos una mejora en comparación con el método utilizado actualmente.

Tabla de Contenidos

	Página
1 Introducción	13
1.1. Contexto	13
1.2. Justificación	14
1.3. Problema	15
1.4. Objetivos	15
1.4.1. Objetivo general	15
1.4.2. Objetivos específicos	15
2 Metodología	17
2.1. Descripción de los datos	17
2.2. Análisis exploratorio	18
2.3. Descripción de los modelos	23
2.4. Descripción de las métricas	25
2.5. Descripción de los experimentos o simulaciones	26
3 Resultados y discusión.	29
3.1. Resultados	29
3.2. Discusión	36
4 Conclusiones y trabajo futuro.	39
4.1. Conclusiones	39
4.2. Trabajo futuro	40
Bibliografía	42

Índice de figuras

	Página
2.1. Comercialización de productos a través del tiempo de agosto 2022 - enero 2024.	18
2.2. Comercialización de los productos en las diversas regiones de agosto 2022 - enero 2024.	19
2.3. Comercialización de los productos en las dos unidades de negocio durante agosto 2022 - enero 2024.	19
2.4. Comercialización de los productos en la unidad de negocio 1 de agosto 2022 - enero 2024.	20
2.5. Top 10 de ventas acumuladas por producto del negocio 1 de agosto 2022 - enero 2024.	20
2.6. Promedio de ventas por clústeres de productos para el negocio 1.	21
2.7. Comercialización de los productos en la unidad de negocio 2 de agosto 2022 - enero 2024.	22
2.8. Top 10 de ventas acumuladas por producto del negocio 2 de agosto 2022 - enero 2024.	22
2.9. Promedio de ventas por clusteres de productos para el negocio 2.	23
2.10. Ejemplo de arquitectura MLP [1].	25
3.1. Resultados Producto 2090.	31
3.2. Comparación de modelos contra predicción interna producto 2090.	32
3.3. Resultados Producto 3901.	32
3.4. Comparación de modelos contra predicción interna producto 3901.	33
3.5. Resultados Producto 3842.	34
3.6. Comparación de modelos contra predicción interna producto 3842.	34
3.7. Resultados Producto288.	35
3.8. Comparación de modelos contra predicción interna producto 288.	35

3.9. Análisis Comparativo de Datos Históricos y Proyecciones
Futuras a 13 Semanas. 36

Índice de tablas

	Página
2.1. Descripción de modelos y estrategias.	27
3.1. Resumen de errores de pronóstico por Negocio.	29
3.2. Métricas de error de los modelos agrupadas por negocio.	30
3.3. Pronóstico de productos con mayor error por negocio.	30
3.4. Pronóstico de productos con menor error por negocio.	33

Dedico este logro a mi Mamá Martha y Mamá, quienes fueron mi pilar fundamental, brindándome el ánimo y apoyo necesarios para superarme académicamente. A Frida, que estuvo a mi lado en cada paso de mi aprendizaje y en cada éxito alcanzado. A mi Papá, cuya inspiración me llevó a ir siempre más allá. Agradezco a mi asesor y al cuerpo académico por su constante apoyo y motivación, y a mis compañeros de generación, quienes se han convertido en grandes amigos. Finalmente, extiendo mi sincero agradecimiento al ITESO por la beca y el crédito que me permitieron iniciar y culminar mis estudios, logrando así mi meta académica.

1 Introducción

En este capítulo se presenta el contexto del objeto de estudio, la justificación del objeto de estudio, la definición del problema y los objetivos generales y específicos.

1.1 Contexto

En el presente capítulo, se expondrán los antecedentes que contextualizan el proyecto y ofrecerá una justificación sólida para la necesidad de desarrollar una herramienta para el proceso actual de pronósticos de ventas, dado que enfrenta desafíos en la precisión, lo que repercute de manera directa en los costos operativos relacionados con el manejo del inventario, así como en los costos derivados de la falta de disponibilidad de productos. Finalmente se detallarán los objetivos generales y específicos que orientarán la propuesta de mejora destinada a abordar la problemática actual que afecta a la organización en la que el autor de este trabajo desempeña su labor.

Las empresas dedicadas a la comercialización de productos forman una compleja red de intermediarios entre las fábricas, los centros de distribución y los clientes. Para mejorar los tiempos de entrega y optimizar los costos de almacenamiento, estas empresas deben gestionar sus inventarios en diversas ubicaciones estratégicas. La base fundamental de esta gestión de inventarios reside en los pronósticos de ventas, que determinan cuántos productos deben adquirirse en función de los diferentes plazos de entrega [2].

La correcta gestión de los inventarios es un componente esencial en la cadena de suministro, tiene dos principales objetivos: garantizar el inventario disponible para la operatividad de la empresa y llegar a niveles óptimos que permitan minimizar el costo operativo [3]. Esto relacionado a las estimaciones de ventas de los productos nos puede llevar a aumentar los costos de pedido o incrementar los costos de mantenimiento de los productos [4].

En la empresa donde el autor labora, el proceso se inicia en el departamento de categoría, donde se generan los pronósticos de ventas para los productos en cada una de las regiones. Estos pronósticos se

comparten con el equipo de planificación, que tiene la responsabilidad de efectuar las compras de productos. La colocación de órdenes de compra debe llevarse a cabo con un mínimo de tres meses de antelación, considerando los tiempos de entrega de los productos.

No obstante, en la actualidad no se realiza un análisis exhaustivo del desempeño de cada producto ni se comparan las estimaciones con las ventas reales de tres meses atrás para evaluar su precisión. Esta falta de análisis detallado resulta en un constante desequilibrio en los niveles de inventario, dependiendo de la región. En las regiones de América, Europa y África, suele sobre estimarse la cantidad de productos necesarios, lo que conduce a un exceso de inventario en ciertas categorías. Mientras tanto, en la región de Asia-Pacífico, a menudo se subestiman las necesidades de productos, lo que provoca situaciones de escasez en el suministro a los clientes.

Este proceso de gestión de inventarios implica la colaboración de múltiples departamentos que trabajan en conjunto para mejorar las estimaciones de ventas, garantizar una gestión adecuada de los inventarios y promover la venta de productos que suelen permanecer en los almacenes durante períodos prolongados.

Sin embargo, la carencia de una herramienta alternativa para validar las estimaciones una vez generadas representa un punto crítico en el proceso, ya que dificulta la toma de decisiones al no contar con un método adecuado para comparar las ventas actuales con las predicciones y el estado actual del inventario de los diferentes productos. Una herramienta para la comparación de pronósticos entre categoría y cadena de suministro puede facilitar la comunicación para anticipar riesgos de sobre inventario o falta de producto en cadena de suministro.

1.2 *Justificación*

Los métodos de pronóstico actualmente empleados muestran un nivel de precisión insuficiente, lo que conlleva a un riesgo constante de exceso o falta de inventario. En los meses recientes, la precisión de los pronósticos apenas alcanzó el 42 %. Mejorar este grado de exactitud resultaría en la capacidad de mantener niveles de inventario óptimos y, en consecuencia, potenciar la eficiencia en la puntualidad de nuestras entregas a los clientes.

La optimización de nuestros niveles de inventario no solo contribuiría a reducir las pérdidas económicas derivadas de desequilibrios en el inventario, sino que también actuaría como un elemento crucial para prevenir la pérdida de clientes y para elevar la imagen de la empresa

1.3 *Problema*

Por lo tanto, el problema al que se enfrenta la empresa actual es que debido a la falta de precisión de los pronósticos se generan diversos costos operativos, siendo estos por el sobrecoste del almacenaje, por la expedición acelerada de ordenes de los proveedores a los distintos centros de distribución o multas de clientes. Así como costes no evidentes derivados de la falta de confianza de los clientes a la organización, lo cual puede provocar una pérdida de este.

1.4 *Objetivos*

1.4.1 *Objetivo general*

Desarrollar modelos estadísticos y de aprendizaje automático que generen pronósticos de ventas de los productos en dos unidades de negocio de la empresa en donde el autor colabora, con el propósito de mejorar la gestión del inventario.

1.4.2 *Objetivos específicos*

- Obtener, transformar y crear un conjunto de datos para el análisis y modelado de los mismos.
- Construir modelos de pronóstico estadísticos y de aprendizaje automático para obtener predicciones de ventas de las siguientes doce semanas del trimestre.
- Seleccionar para cada tipo de producto el modelo de predicción con el mejor ajuste de forma automática.
- Comparar los valores predichos con los pronósticos previamente generados por el equipo externo al departamento de cadena de suministro.

2 Metodología

En este capítulo se presenta el detalle del conjunto de datos, se incluye de donde se obtuvo, el preprocesamiento para el conjunto de datos inicial, cuáles son las variables utilizadas, el significado de cada una y el tratamiento de codificación de las variables para entender el contexto, pero no el valor exacto de la variable.

También se realiza un análisis exploratorio donde se muestran los diversos comportamientos de las ventas a través de las diferentes categorías como las unidades de negocios, regiones y productos. Para los productos se realiza una clusterización de los productos con el algoritmo de K-medias para ejemplificar la tendencia de ventas en cada negocio en los diferentes grupos.

2.1 Descripción de los datos

El conjunto de datos empleado en esta investigación abarca las órdenes de venta registradas desde agosto de 2022 hasta febrero de 2024. Es obtenida agrupada por trimestre del ERP de la empresa. La información se distribuye en siete archivos en formato CSV.

Una característica destacada de esta información es la presencia de órdenes repetidas, que se debe a la consolidación trimestral de los datos. Cualquier orden pendiente al final de un trimestre se registra en el archivo correspondiente al trimestre siguiente.

Antes de analizar los datos, se ejecuta un preprocesamiento con técnicas de concatenación, filtrado, renombrado de columnas y agrupación de datos. Esto culmina en un conjunto de datos final con cinco columnas y aproximadamente trescientos sesenta mil registros.

Para el desarrollo de esta investigación, se focalizará en el análisis de 4 variables de las cuales dos variables son: la unidad de negocio, y el ID del producto. Estas variables presentan un total de cuatro mil doscientos registros únicos, que constituyen el conjunto de variables a ser objeto de predicción en el presente trabajo.

Las variables de estudio se describen a continuación

- Unidad de negocio: categoría del negocio general para el estudio, contiene dos unidades de negocio únicas.

- ID de producto: identificador único para cada producto
- Fecha de venta: fecha en la que es ingresada la orden de venta
- Cantidad de venta: cantidad vendida

Sin embargo, por motivos de confidencialidad la información será anonimizada, por lo que se observará para todas las variables una etiqueta donde se detalle la variable y un número.

2.2 Análisis exploratorio

Para la exploración de datos se busca entender la información de lo general a lo particular es por lo que primero se hará una observación de las ventas a nivel general, por negocio y por región y una vez observada la información se ira buscando el detalle de la información para cada una de las categorías.

Las ventas generales a través del tiempo se pueden observar en la Figura 2.1 que las ventas del 2023 año con año tuvieron una mejora respecto al año anterior, de agosto a diciembre del 14 %. Se puede observar que en enero de 2024 hubo un incremento del 33 %, se deberá realizar la comparación a través del tiempo para evaluar una tendencia alcista para ese mismo año.

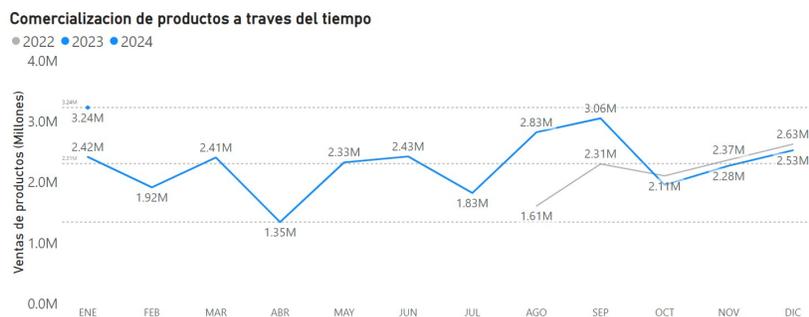


Figura 2.1: Comercialización de productos a través del tiempo de agosto 2022 - enero 2024.

La Figura 2.2 muestra el comportamiento de las regiones, en la cual sobresale la región 1 con ventas casi el doble que las otras dos y que llegó a su punto más alto en el último mes reportado. La región 2, por otro lado, tiene un desempeño volátil, con una etapa de estancamiento entre noviembre y marzo y una gran fluctuación en los meses posteriores. La región 3, por el contrario, muestra una tendencia descendente en sus ventas, aunque no tan variable como la región 2.

De forma general la comercialización se puede observar que tiene comportamientos definidos según las regiones sin embargo adicional a la región la comercialización para cada uno de los negocios se observa

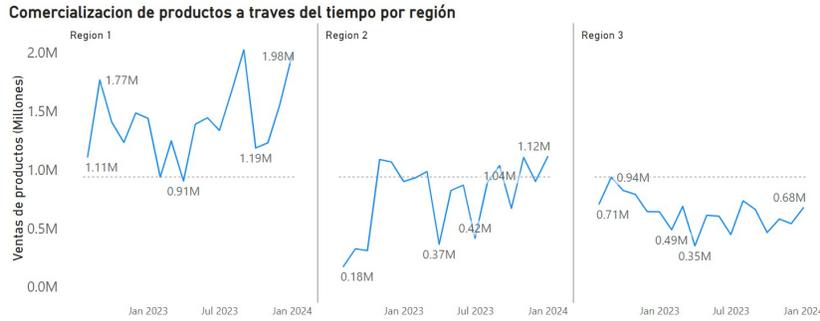


Figura 2.2: Comercialización de los productos en las diversas regiones de agosto 2022 - enero 2024.

en la Figura 2.3 donde ambas tendencias tienen un comportamiento similar en sus picos de crecimiento y de decrecimiento, sin embargo, entre los mismos negocios tenemos una relación de 3 a 4 veces a 1 lo que nos muestra cambios más abruptos para el negocio 1.

Algo a resaltar es como en los meses de agosto a diciembre de 2022 se tuvieron mayores valores de ventas, a partir de enero a agosto -septiembre se está repitiendo el mismo repunte de las ventas como en 2022.

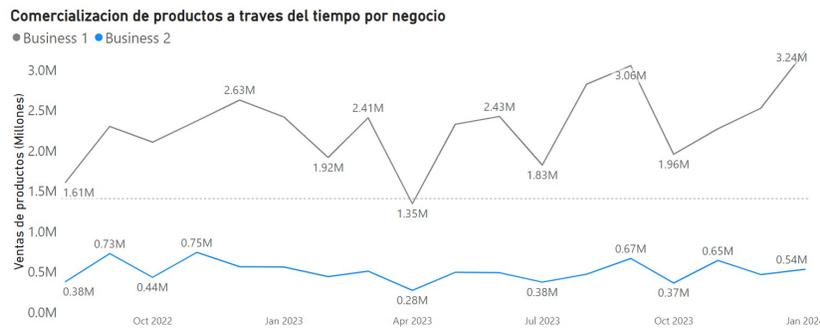


Figura 2.3: Comercialización de los productos en las dos unidades de negocio durante agosto 2022 - enero 2024.

Como se explicó anteriormente, el negocio 1 es el que influye más en el comportamiento de las ventas por regiones. La Figura 2.4 ilustra que el negocio 1 sigue una tendencia similar en las regiones 1 y 2, pero se diferencia en la región 3, donde se observa menor cantidad de ventas pero una menor variabilidad.

Esta unidad de negocio ha tenido ventas acumuladas por 42 millones de unidades divididas en 3,832 productos diferentes, sin embargo 486 productos diferentes presentan el 90% de las ventas acumuladas. Se muestra en la Figura 2.5 el top diez de ventas acumuladas por productos, donde solo estos diez productos representan el 14% de las ventas totales acumuladas.

La importancia de evaluar el volumen de ventas de cada producto será crucial en el proceso de elección de aquellos productos que podrán

Comercialización de productos a través del tiempo por región para el negocio 1

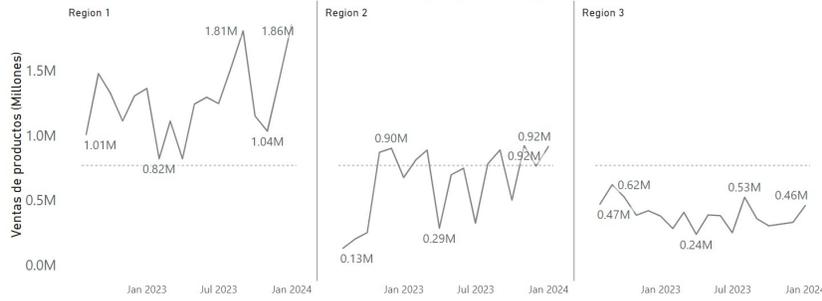


Figura 2.4: Comercialización de los productos en la unidad de negocio 1 de agosto 2022 - enero 2024.

Top 10 de ventas acumuladas por ID de producto

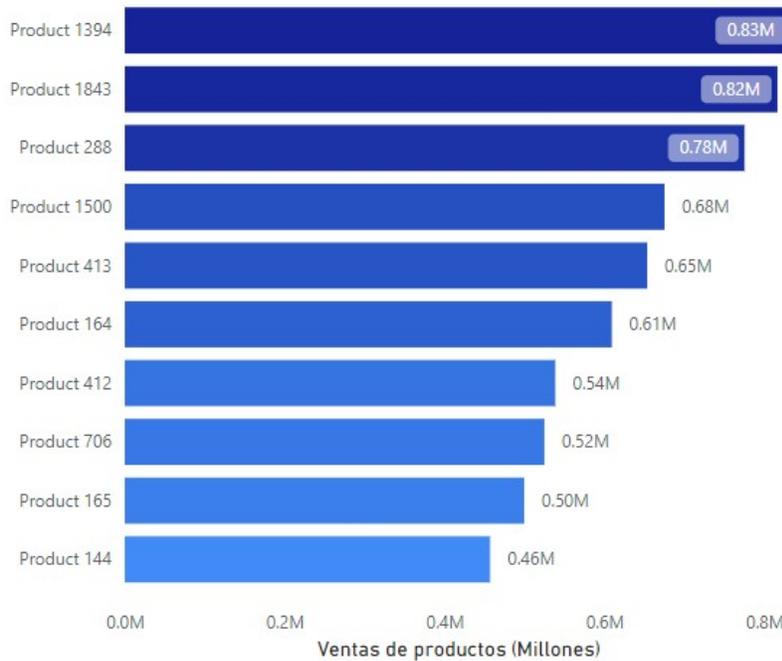


Figura 2.5: Top 10 de ventas acumuladas por producto del negocio 1 de agosto 2022 - enero 2024.

ser objeto de predicción en este estudio. Se excluyen de la predicción todos los productos que no cuenten con al menos 79 registros en el conjunto de datos, lo que indica que no han experimentado ventas durante el periodo estudiado.

Para aquellos productos que cumplen con el requisito mínimo de ventas, se empleó el algoritmo K-medias para clasificarlos de acuerdo con sus patrones de ventas. Se generó un conjunto de datos que incluyó los productos y las fechas organizadas semanalmente con este propósito, resultando en una matriz de dimensiones 477 filas por 79 columnas. La selección del número de grupos se basó en un análisis del codo [5] y se optó por utilizar 3 grupos.

La Figura 2.6 muestra el comportamiento de las ventas promedio para cada uno de los clústeres. El clúster 0 presenta el promedio de ventas más bajo de los tres siendo de 294, sin embargo, la cantidad de productos que contiene este grupo es de 429 (90%) de todos los productos.

El clúster 2 en comparación tiene un promedio de ventas de 1,971, siendo 6.7 veces más grande que el grupo anteriormente mencionado, en este se encuentran 40 productos (8%). El clúster 1 tiene un promedio de ventas de 6,500 y contiene solo 8 productos diferentes (1.6%). La magnitud de ventas entre productos puede tener implicaciones al momento de generar las predicciones.

Promedio de ventas por clústeres de productos para el negocio 1
Número de Cluster ● 0 ● 1 ● 2

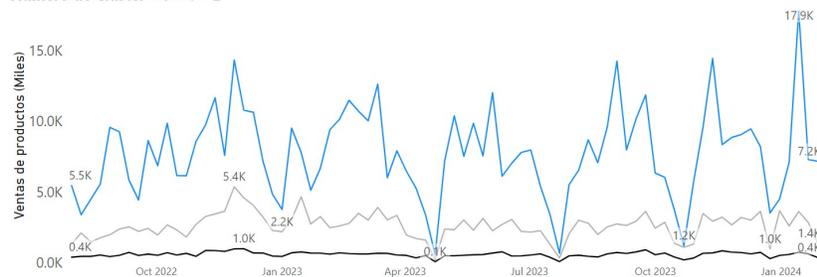


Figura 2.6: Promedio de ventas por clústeres de productos para el negocio 1.

En el caso del negocio 2 se observa en la Figura 2.7 un comportamiento muy diferente al observado en la Figura 2.4, en este caso la región 1 no es la que tiene el mayor volumen de ventas si no que aquí es la región 3 la cual predomina. Sin embargo, la proporción entre regiones si es similar, siendo del doble de ventas en la región en comparación a las demás. Las tendencias generales son similares, sobre todo para la región 2 donde tiene una meseta muy similar a la del negocio 1 observada en la Figura 2.4.

Las ventas acumuladas para este negocio son de 9.2 millones de unidades en 405 productos diferentes para este caso se requieren de 90

Comercialización de productos a través del tiempo por región para el negocio 2

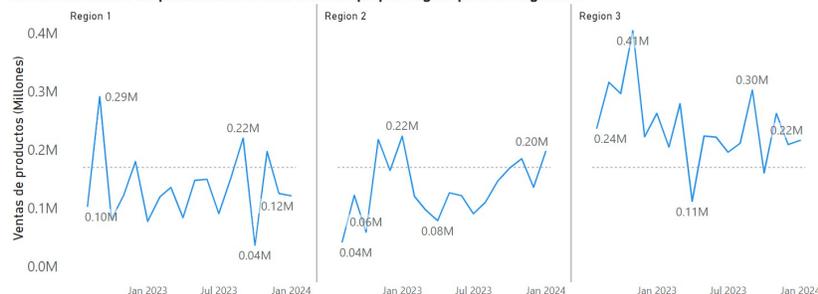


Figura 2.7: Comercialización de los productos en la unidad de negocio 2 de agosto 2022 - enero 2024.

productos para llegar al 90% de las ventas acumuladas. La Figura 8 nos muestra la relación de ventas por el top diez de ventas acumuladas, en este caso un solo producto representa el 10% de las ventas totales. El segundo producto tiene una proporción de la mitad del producto.

Top 10 de ventas acumuladas por ID de producto

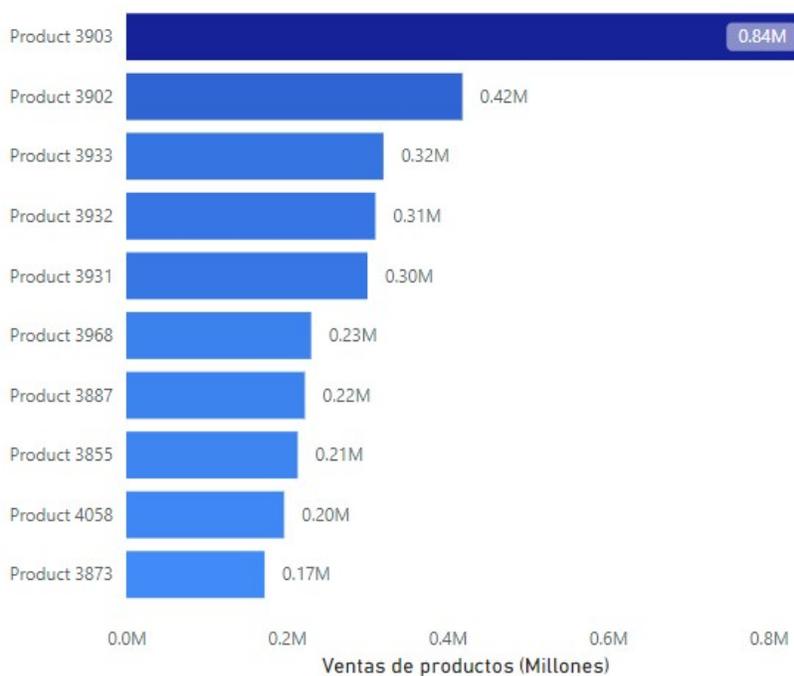


Figura 2.8: Top 10 de ventas acumuladas por producto del negocio 2 de agosto 2022 - enero 2024.

Para los productos de este negocio se siguió el mismo proceso de agrupación que para el negocio 1, se filtran los productos que contengan menos de 79 registros y luego se aplica el algoritmo de K-medias. Obteniéndose un total de 109 productos diferentes, que representa el 28% del total de productos por lo que las ventas que podrán ser pronosticadas será más del 90%.

La Figura 2.9 presenta el comportamiento de las series temporales para esta unidad de negocio, se observa como el grupo uno es la serie temporal que mayor número de ventas tiene, con un promedio de 12 mil unidades. Para el grupo 2 y 0 que son los de menor cantidad de ventas sus promedios rondan las 2,600 y 600 unidades, aun cuando son las que menor cantidad de ventas tienen son las que tienen más productos, similar al negocio 1.

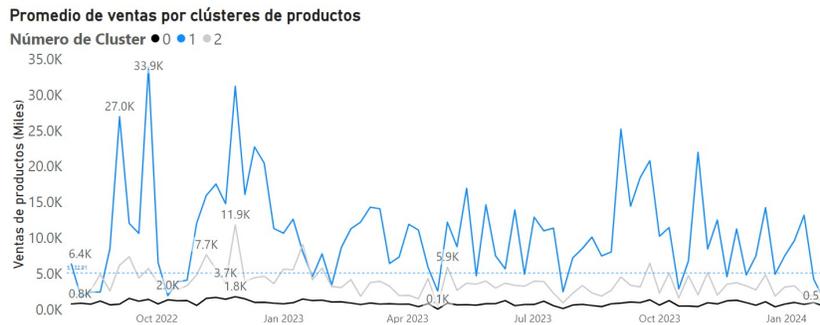


Figura 2.9: Promedio de ventas por clústeres de productos para el negocio 2.

Para los siguientes pasos, solo se harán pronósticos de series temporales para los productos que pasaron el criterio de filtrado de no tener valores faltantes en las ventas semanales.

2.3 Descripción de los modelos

Diversos estudios se han presentado a lo largo del tiempo como el de Makridakis [6] donde se hace una comparación de diversos modelos estadísticos (ME) de pronósticos contra modelos de aprendizaje automático y por lo general ME suelen tener un mejor desempeño. En el estudio donde fue utilizado el métrico de error porcentual absoluto simétrico (sMAPE) se compararon 18 modelos diferente entre modelos estadísticos y de aprendizaje automático. [6]

En el estudio comentado los ME presentaron un mejor desempeño siendo el modelo de suavizamiento exponencial (ETS) fue el que tuvo el menor error, 7.12 % en promedio. El modelo de referencia obtuvo un error del 8.58 %. En cambio, los modelos de aprendizaje automático (AM), se diferenciaron en un punto porcentual de los modelos clásicos, siendo la red neuronal bayesiana la que mostró el mejor desempeño con un error del 8.17 % [6]

En otro estudio del mismo autor se hizo una comparación de ensambles de ME y AM, los mismos si tuvieron una mejora de 0.2 % – 0.80 %. Una de las desventajas del ensamble de modelos y AM es que tuvieron un aumento en el costo computacional de los mismos, para el ensamble de ME apenas de 1 minuto respecto al modelo de menor

tiempo y el ensamble de AM de 6.5 minutos adicionales al de menor tiempo. [7]

Con base en lo anterior se decidió por utilizar los siguientes modelos considerando un modelo ase, dos modelos estadísticos, dos modelos de aprendizaje automático y dos ensambles de modelos estadísticos y AM, esto para seguir con la metodología propuesta por Makridakis. [7]

Modelo Naïve Estacional. El modelo Naïve estacional es un modelo que pronostica el valor utilizando el valor anterior futuro tomando como referencia el mismo valor observado en el ciclo pasado. Se define mediante la Ecuación 1 donde m es el periodo estacional y k es la cantidad de ciclos enteros que han sucedido previo al tiempo T . [8]

$$\hat{Y}_{T+h|T} = Y_{T+h-m(k+1)} \quad (2.1)$$

Modelo de Suavización Exponencial (ETS). El modelo ETS es un modelo utilizado cuando no se tienen patrones claros de estacionalidad o tendencia pero que los valores futuros son sensibles a los valores pasados y entre más lejanos sean menor será el impacto sobre ellos. Esto se define en la Ecuación 2 donde α es el parámetro de suavización, en las que los pesos disminuyen a medida que las observaciones son más antiguas. [8]

$$\hat{Y}_{T+1|T} = \alpha y_T + \alpha(1 - \alpha)y_{T-1} + \alpha(1 - \alpha)^2 y_{T-2} + \dots \quad (2.2)$$

Modelo Autorregresivo Integrado de Promedio Móvil (ARIMA). El modelo ARIMA es una combinación de los modelos autorregresivos y de promedio móvil, la letra I refiere al proceso de integración que es la inversa de la diferenciación. Para este caso el modelo se define mediante la Ecuación 3 donde se presentan cada una de las partes que expresan el modelo. La parte de AR tiene un parámetro ϕ que es la cantidad de diferenciaciones [8].

$$\frac{(\mathbf{1} - \phi_1 B - \dots - \phi_p B^p)}{AR(p)} \frac{(\mathbf{1} - B)^d y_t}{I(d)} = \frac{c + (\mathbf{1} + \theta_1 B + \dots + \theta_q B^q) \varepsilon_t}{MA(q)} \quad (2.3)$$

Modelo Regresión de Soporte Vectorial (SVR). Es un método de regresión lineal mediante una automático de soporte vectorial la cual busca encontrar el mejor hiperplano para disminuir el error. En estos modelos se añaden términos de regularización lo cual evita la inclusión de los valores atípicos mejorando la precisión del modelo. [4] La Ecuación 4 describe al modelo donde K es la función Kernel que convierte la información a un nuevo espacio de características para poder encontrar una separación lineal entre los mismos. [9]

$$Y_{T+1} = \sum_{i=1}^I (a_i + a_i^*) K(x_i, x) + b \quad (2.4)$$

Modelo de Perceptrón Multicapa (MLP). El modelo de perceptrón multicapa funciona mediante la conexión de varias capas perceptrón, estas se dividen en capa de entrada, oculta y de salida. La red MLP es un ejemplo de redes neuronales feedforward, refiriendo a que el flujo de la información es unidireccional se presenta una representación en la Figura 2.10 de cómo funciona el modelo [1].

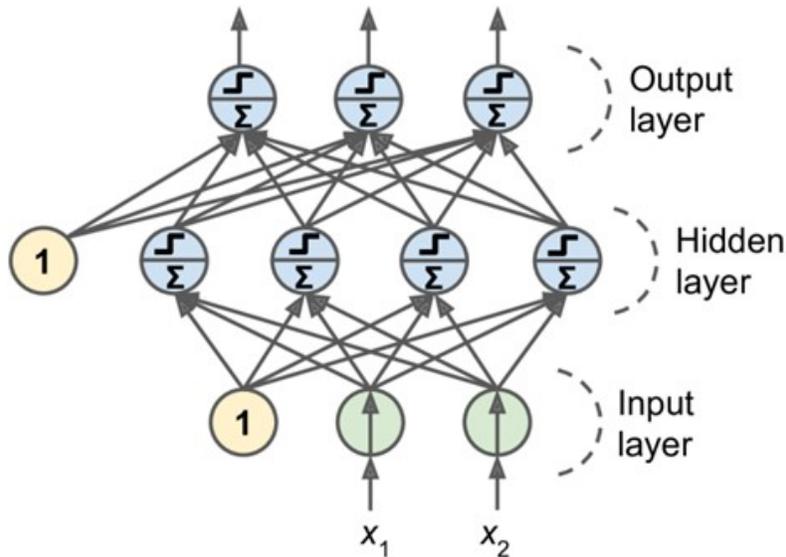


Figura 2.10: Ejemplo de arquitectura MLP [1].

Ensamble de modelos (Ensamble S & Ensamble ML). Para el ensamble de los modelos se consideran las medianas de los resultados de los modelos estadísticos y de aprendizaje automático como lo presentado en el estudio de Makridakis [7]

2.4 Descripción de las métricas

Los métricos que serán empleados para la medición de la precisión de los pronósticos serán utilizados los que dependen de las escalas como la raíz del error cuadrático medio (RMSE) y la raíz del error cuadrático mediano (RMdSE). Adicional a los métricos basado en las escalas serán considerados los errores basados en errores porcentuales como el error de porcentaje medio absoluto (MAPE) y el error de porcentaje mediano absoluto (MdAPE). Estos se basan en el estudio por Hyndman y colaboradores [10].

Error de porcentaje medio absoluto (MAPE). Se define como la división entre la diferencia absoluta entre el valor real y_i y el valor pronosticado \hat{y}_i , y el valor real. Este error se multiplica por 100 para expresarlo en términos porcentuales. Este error no depende de la escala

y penaliza mucho los errores cuando los valores reales son cercanos a cero. [10] Su fórmula está dada por (2.5)

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (2.5)$$

Error de porcentaje mediano absoluto (MdAPE). Esta métrica es parecida al MAPE, ya que no depende de la escala y castiga mucho los errores cuando son próximos a cero. Sin embargo, al usar la mediana en lugar de la media, es menos afectada por los valores atípicos. [11] Se define por la ecuación (2.6)

$$\text{MdAPE} = \text{Median} \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) * 100 \quad (2.6)$$

Raíz del error cuadrático medio (RMSE). El RMSE es una métrica distinta a los errores porcentuales que facilita la comparación de precisión en los pronósticos con diferentes escalas. Esto se debe a que el error usa la escala de los datos originales [10]. Y se determina por la ecuación (2.7).

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.7)$$

Raíz del error cuadrático mediano (RMdSE). Es una variante del RMSE. Mientras que el RMSE es la desviación estándar de los errores, el RMdSE utiliza la mediana de los errores al cuadrado y el error utiliza la escala de datos originales [12]. Se determina por la ecuación (2.8)

$$\text{RMdSE} = \sqrt{\text{Median}((y_i - \hat{y}_i)^2)} \quad (2.8)$$

2.5 Descripción de los experimentos o simulaciones

Como fue expresado en la sección 2.3 fueron entrenados cinco modelos diferentes y dos ensambles de modelos con 66 semanas para el set de entrenamiento y 13 semanas para los datos de prueba. Tras la elección del modelo se realizara la respectiva optimización de los hiperparámetros.

Para el caso del modelo ARIMA se optimizaron los valores de p, d, q y PDQ mediante rangos para que itere sobre los mismos. En el caso del modelo ETS se optimizaron los valores de β, ϕ , y de γ siguiendo la metodología empleada en el modelo ARIMA mediante el rango de los valores. Finalmente, con los mejores modelos obtenidos se realizó el modelo de ensamble estadístico mediante el promedio de las predicciones.

Con los modelos AM se hizo la optimización mediante grid search que es una técnica de optimización en la cual se crea una rejilla de

hiperparámetros y se entrenan los modelos basados en cada una de las posibles combinaciones [13]. Para el caso del modelo SVR se optimizan los parámetros de penalización C , el valor de gamma y el tipo de Kernel a emplear. Para el perceptrón multicapa se hace la optimización de la cantidad de neuronas, el número de épocas y la tasa de aprendizaje.

En la Tabla 2.1 se presenta el resumen de las estrategias e hiperparámetros a optimizar de los diferentes modelos, para la optimización se utilizó el métrico RMSE para la elección del mejor modelo.

Modelo	Estrategia	Hiperparámetros
Naïve	-	-
ARIMA	Iteración de hiper parámetros	pdq y PDQ
ETS	Iteración de hiper parámetros	β, ϕ, γ
EnsambleS	-	-
SVR	Grid Search	C , gamma y Kernel
MLP	Grid Search	Cantidad de neuronas, Epochs y Learn Rate
EnsambleML	-	-

Tabla 2.1: Descripción de modelos y estrategias.

3 Resultados y discusión

3.1 Resultados

Para los modelos realizados se presentan los métricos de error resumidos por unidad de negocio en la Tabla 3.1. Para la presentación de los datos se resumen utilizando el promedio, la mediana, el rango intercuartílico y los mínimos y máximos para cada uno de los errores y poder evaluar el impacto de los errores atípicos sobre los métricos de error.

Para el negocio 1, el resumen de los errores presentados en la Tabla 3.1 muestra un MAPE promedio del 292 %, con un valor máximo de 29,447 %. Utilizando el MdAPE el promedio de error es del 72 %, y la mediana de los errores esta por debajo del 59 %. Los errores RMSE y RMdSE obtenidos son de 528 y 394 unidades, respectivamente. El negocio 2 se encuentran impactos mayores a los métricos debido a los valores máximos obtenidos para los errores porcentuales, siendo de 25,258 % para el MAPE y 9,415 % para el MdAPE.

	Promedio	Mediana	IQR	Min	Max
Business 1					
MAPE	292 %	110 %	146 %	24 %	29,447 %
MdAPE	72 %	59 %	27 %	18 %	1,615 %
RMSE	1,030	528	1,093	4	11,225
RMdSE	783	394	769	5	11,225
Business 2					
MAPE	636 %	85 %	96 %	32 %	25,258 %
MdAPE	191 %	54 %	29 %	12 %	9,415 %
RMSE	2,245	1,410	2,559	43	14,700
RMdSE	1,832	1,135	1,921	88	18,447

Tabla 3.1: Resumen de errores de pronóstico por Negocio.

La Tabla 3.2 muestra los resultados de los métricos de error para cada modelo en las unidades de negocio 1 y 2. En la unidad de negocio 1, el ensamble de modelos combinados resultó ser el más eficaz en términos generales, con un MdAPE de 53 % y un RMdSE de 294 unidades. Por otro lado, aunque el modelo ARIMA presentó resultados

similares, su rango de error en el MdAPE fue ligeramente superior, con un incremento del 4 %

Modelo	MdAPE	IQR	RMdSE	IQR
Business 1				
S. Naive	72 %	26 %	337	766
ETS	59 %	28 %	311	566
ARIMA	53 %	30 %	296	532
S. Ensamble	53 %	26 %	294	569
MLP	64 %	36 %	553	1,119
SVR	55 %	22 %	501	1,044
Ensemble	60 %	21 %	311	1,068
Business 2				
S. Naive	72 %	47 %	1,262	1,847
ARIMA	47 %	20 %	888	1,182
ETS	53 %	23 %	997	925
S. Ensamble	49 %	20 %	826	1,238
MLP	64 %	26 %	1,528	2,025
SVR	49 %	18 %	1,281	2,502
ML. Ensamble	50 %	21 %	1,521	2,282

Tabla 3.2: Métricas de error de los modelos agrupadas por negocio.

Los resultados de la evaluación de los modelos se presentan en la Tabla 3.3, donde se muestran los 3 productos con el error más grande para cada unidad de negocio. En términos generales, se observó que la unidad de negocio 2 tuvo un desempeño inferior al de la unidad de negocio 1.

	S. Nai.	ARIMA	ETS	S. Ens	MLP	SVR	ML Ens
Business 1							
Prod. 2090							
MdAPE	1615 %	91 %	257 %	135 %	449 %	982 %	658 %
RMdSE	3,313	254	738	479	2,085	1,831	1,962
Prod. 1181							
MdAPE	99 %	393 %	112 %	342 %	294 %	108 %	225 %
RMdSE	766	610	395	538	1,073	1,204	1,244
Prod. 1991							
MdAPE	118 %	297 %	195 %	246 %	296 %	210 %	265 %
RMdSE	305	649	420	543	648	550	615
Business 2							
Prod. 3901							
MdAPE	689 %	3,500 %	2,864 %	35,00 %	2,220 %	1,624 %	1,896 %
RMdSE	2,436	3,849	3,849	3,807	2,047	1,538	1,824
Prod. 3887							
MdAPE	821 %	814 %	833 %	986 %	284 %	727 %	446 %
RMdSE	5,560	5,096	4,753	5,072	2,706	4,206	3,220
Prod. 3835							
MdAPE	9,415 %	211 %	782 %	560 %	1,045 %	3,196 %	1,972 %
RMdSE	8,238	297	1,283	797	2,960	3,125	3,024

Tabla 3.3: Pronóstico de productos con mayor error por negocio.

Para el caso de los errores del negocio 1 el producto 2090 tiene errores por encima del 100 % exceptuando el modelo ARIMA que tiene 91 %. La Figura 3.1 presenta los resultados de los modelos donde se puede observar la diferencia entre los valores reales y los pronosticados para el producto 2090, la tendencia del producto para antes de mayo 2023 eran valores por encima de las dos mil unidades, pasando esa fecha se presenta un ultimo pico de ventas y de agosto en adelante las ventas están debajo de las mil unidades.

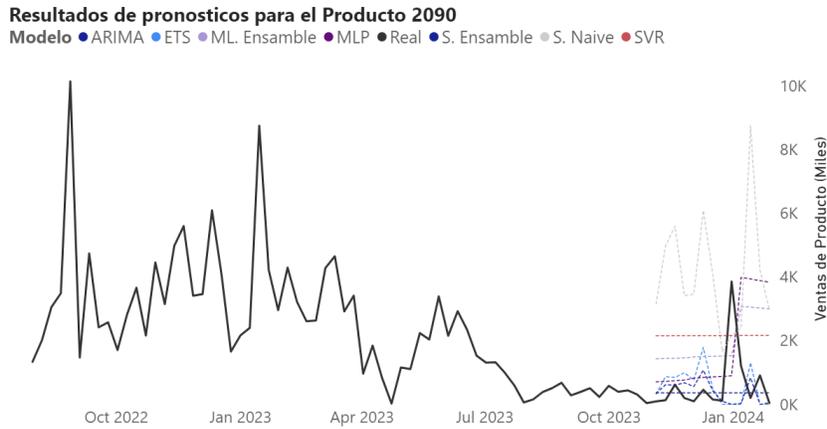


Figura 3.1: Resultados Producto 2090.

Finalmente, para el producto 2090, se realizó la comparación mensualizada, como se muestra en la Figura 3.2, de los valores pronosticados contra los reales para los datos de prueba. Se utilizó el pronóstico interno para comparar el mejor modelo contra los valores estimados previamente. En esta comparativa, el MdAPE del modelo ARIMA fue del 40 %, significativamente más bajo que el 98 % obtenido con el método interno. Aunque el 98 % puede considerarse elevado, representa una mejora respecto a las estimaciones anteriores. Sin embargo, es importante destacar que una predicción excesiva, como en este caso, puede resultar en sobre inventario, lo cual tiene implicaciones directas en la gestión de la cadena de suministro.

En la unidad de negocio 2, el análisis del producto 3901 reveló en la Tabla 3.3 que los modelos estadísticos presentaron errores porcentuales excepcionalmente altos, superando el 2,800 %. Por su parte, el modelo S. Naive, que replica los resultados del ciclo anterior, registró un error significativamente menor del 689 %. La Figura 3.3 ilustra claramente la discrepancia entre los valores pronosticados y los reales, con una sobreestimación promedio de 2,000 unidades. Sin embargo, es notable que el modelo base logró una precisión perfecta en cuatro ocasiones.

Para el producto 3901, la Figura 3.4 muestra que el pronóstico interno resultó en un MdAPE del 100 %, en contraste con el 440 % del siguiente mejor modelo. Este caso ilustra que, a pesar de anticipar una

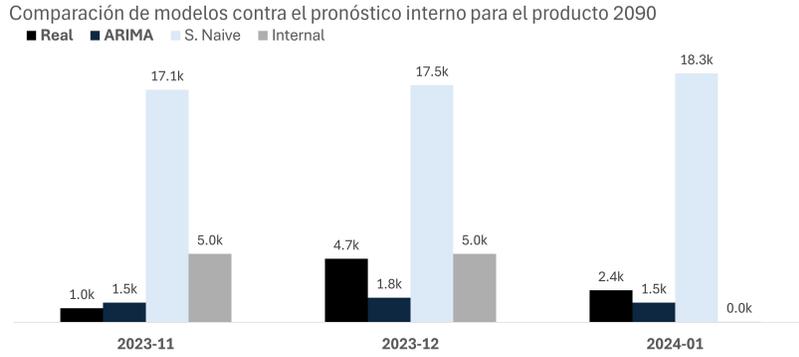


Figura 3.2: Comparación de modelos contra predicción interna producto 2090.



Figura 3.3: Resultados Producto 3901.

caída en las ventas, los modelos no ofrecieron una alternativa confiable para predecir las ventas.

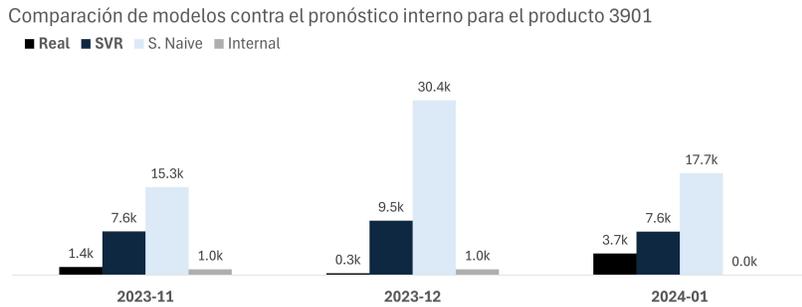


Figura 3.4: Comparación de modelos contra predicción interna producto 3901.

Al igual que se destacaron los productos con los mayores errores, en la Tabla 3.4 se presentan aquellos productos cuyo error fue el menor según las métricas utilizadas. Se observa que los valores de error promedian alrededor del 30 %, con algunos modelos mostrando errores hasta 10 puntos porcentuales por debajo de lo esperado, lo que indica un margen de mejora en las predicciones.

	S. Nai.	ARIMA	ETS	S. Ens	MLP	SVR	ML Ens
Business 1							
Prod. 1294							
MdAPE	55 %	30 %	38 %	31 %	20 %	26 %	25 %
RMdSE	966	537	511	288	909	554	828
Prod. 288							
MdAPE	18 %	30 %	29 %	25 %	81 %	30 %	53 %
RMdSE	2,401	3,918	2,775	2,700	11,225	5,538	8,120
Prod. 451							
MdAPE	29 %	31 %	23 %	22 %	60 %	27 %	44 %
RMdSE	1,046	1,108	730	989	2,264	1,349	1,896
Business 2							
Prod. 3842							
MdAPE	28 %	20 %	34 %	19 %	30 %	39 %	33 %
RMdSE	164	166	212	119	601	332	452
Prod. 3843							
MdAPE	49 %	30 %	34 %	43 %	62 %	35 %	33 %
RMdSE	1,478	1,086	1,238	1,052	2,702	2,515	2,469
Prod. 3934							
MdAPE	12 %	22 %	41 %	28 %	66 %	61 %	44 %
RMdSE	308	830	1,078	1,030	2,433	1,310	1,847

Tabla 3.4: Pronóstico de productos con menor error por negocio.

El producto 3842 de la unidad de negocio 2, ilustrado en la Figura 3.5, fue evaluado para determinar el desempeño de distintos modelos de pronóstico frente a los valores reales de venta. A pesar de la alta variabilidad observada en las ventas históricas, se mantuvo una estabilidad sin comportamientos anómalos en el conjunto de prueba. El modelo S. Ensamble demostró ser el más efectivo, con un error del 19 %. Este nivel de error se atribuye principalmente a dos eventos en enero,

donde las predicciones del modelo excedieron considerablemente las ventas reales, con 1,000 unidades pronosticadas frente a 100 reales y 500 unidades frente a 200 reales.



Figura 3.5: Resultados Producto 3842.

En la comparación mensualizada contra el modelo base y el pronóstico interno, se observó que el modelo base tuvo un MdAPE del 21 %, mientras que el pronóstico interno registró un 58 %. Este resultado indica una mayor precisión del modelo base en la estimación de las ventas. Además, la Figura 3.6 revela que el modelo S. Naive logró un ajuste más cercano a los valores reales, con un MdAPE del 12 % en la predicción mensualizada.

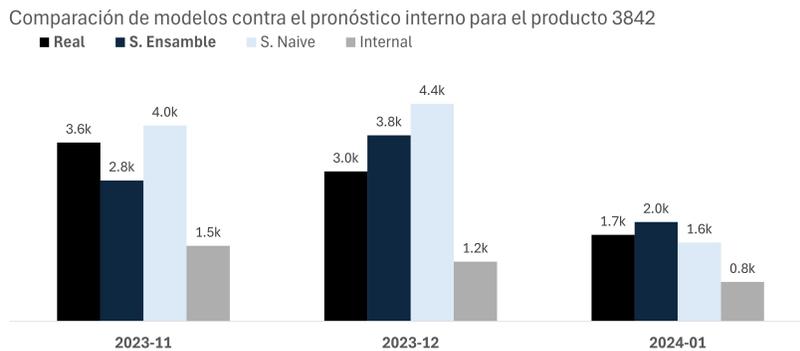


Figura 3.6: Comparación de modelos contra predicción interna producto 3842.

Para el producto 288, el modelo S. Naive tuvo el error más bajo con un MdAPE del 18 %, en comparación con el ensamble de modelos estadísticos que tuvo un MdAPE del 25 %. La Figura 3.7 muestra cómo el modelo S. Naive predice correctamente la tendencia general de los datos de prueba.

En la Figura 3.8 se observa el comportamiento de los valores mensualizados de los pronósticos, el modelo interno presenta un



Figura 3.7: Resultados Producto 288.

MdAPE del 19% sin embargo la variabilidad de los resultados va de un error del 6% para el mes de noviembre contra un 30% para el mes de enero, teniendo un comportamiento similar para el error del S. Naive. El modelo de ensamble tuvo un error del 26% manteniéndose constante con sus errores y disminuyendo para el mes de enero. Por lo que también funcionó para las generar las predicciones del siguiente cuarto.

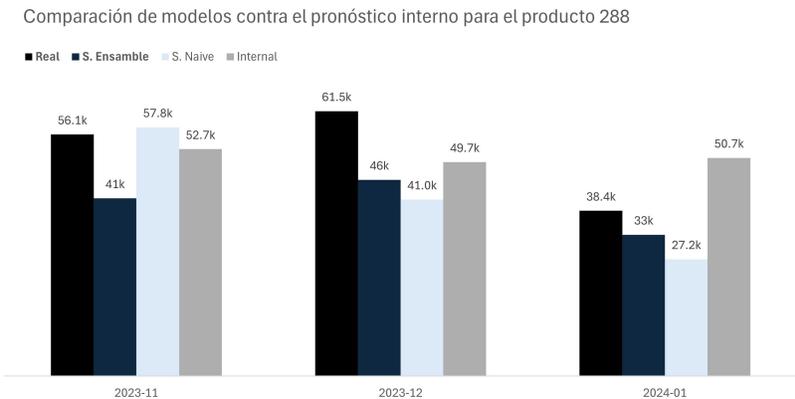


Figura 3.8: Comparación de modelos contra predicción interna producto 288.

Finalmente se presenta un ejemplo para el mejor modelo obtenido del producto 288 en la Figura 3.9 donde se re-entrena con todos los datos y se generan las predicciones del siguiente cuarto dando un promedio de venta mensual de 45 mil unidades por mes. Parte de los siguientes pasos será la comparación mensual de cada mes de ventas y la generación del siguiente pronóstico para las siguientes 13 semanas.



Figura 3.9: Análisis Comparativo de Datos Históricos y Proyecciones Futuras a 13 Semanas.

3.2 Discusión

La selección del mejor modelo para pronosticar la demanda representa un desafío, tanto por la naturaleza de los modelos como por la variabilidad de los errores de pronóstico reflejados en los valores de MAPE, lo cual puede afectar la confiabilidad de estos para el desarrollo de estrategias. El MdAPE ofrece una medida más robusta del error típico, menos influenciada por valores extremos, como ya había sugerido Fildes [11]. De manera similar, al comparar los valores de RMSE y RMdSE con las cantidades de ventas de cada producto, se obtiene una perspectiva más precisa del desempeño de los modelos.

La Tabla 3.1 presenta una discrepancia pues el negocio 2 tiene productos con menor error que el negocio 1, pero también al tener una menor proporción de productos los valores atípicos tuvieron un mayor impacto, lo que pudo generar una mayor variabilidad al hacer los pronósticos en comparación con el negocio 1.

Los resultados de los modelos por negocios de la Tabla 3.2 son bastante variables, especialmente en el MdAPE más elevado del modelo ARIMA en comparación con el ensamble, lo que indica que la elección del modelo puede ser clave según el contexto particular de cada unidad de negocio. La tabla resume los métricos de error por modelo, pero un análisis en profundidad para cada producto sería conveniente. Siguiendo las recomendaciones de Hyndman y colaboradores [10], se deberían priorizar los métricos de error porcentuales para mejorar la exactitud en la evaluación de los modelos.

El negocio 2 muestra una ventaja de los métodos estadísticos sobre los demás, siendo el modelo ARIMA el que tiene el error más bajo. Le siguen el modelo S. Ensamble y el modelo SVR, que tienen resultados parecidos. Por el contrario, el modelo base supera a todos los modelos propuestos, lo que sugiere una mayor complejidad para predecir el

comportamiento de este negocio.

La Figura 3.1 muestra que los modelos de aprendizaje automático no consiguen ajustarse a la nueva escala de ventas y sus predicciones sobrepasan las dos mil unidades. Los modelos estadísticos sí lograron adaptarse a esa nueva escala, pero a finales de 2023 el producto experimenta un incremento en las ventas que los modelos estadísticos no pudieron anticipar.

Según lo presentado en la Tabla 3.3, la notable diferencia en los errores porcentuales entre los modelos estadísticos y el modelo S. Naive resalta la importancia de considerar la naturaleza de los datos y el contexto al seleccionar un modelo de pronóstico. Aunque el modelo S. Naive mostró un error porcentual menor, su enfoque podría no ser adecuado para todas las situaciones. Por otro lado, la precisión puntual del modelo base sugiere que, bajo ciertas condiciones, este puede ser el más acertado para predecir las ventas.

Además, en el caso específico del producto 3901, conforme a lo observado en Figura 3.3 es crucial obtener la experiencia del equipo de planeación para evaluar las razones detrás de la significativa caída en ventas. Se presume que el equipo posee detalles más concretos que pueden enriquecer la comparación con el pronóstico interno.

En la Figura 3.5 se muestra al modelo S. Ensamble muestra un alto rendimiento, a pesar de tener un error del 19 %, lo que indica su capacidad para afrontar las variabilidades en las ventas, aunque necesita ser calibrado o ajustado para aumentar la precisión en períodos de cambios bruscos. La evaluación minuciosa de los errores por incidente específico, como las diferencias en enero, ayuda a detectar dónde el modelo puede estar sobreestimando las ventas.

Para el producto 288 el modelo S. Naive, fue efectivo porque replicó la tendencia pasada, sin embargo tiene limitaciones para predecir futuras debido a su simplicidad. En cambio, el ensamble de modelos estadísticos, que mejor aproxima la tendencia general, es por ello que fue seleccionado como el modelo para la comparación de los pronósticos mensualizados.

Los resultados obtenidos no tienen forma de ser comparados con otros estudios debido a que los métricos empleados no fueron los mismos que en el estudio de Makridakis [7] ni los datos tuvieron la misma granularidad ni magnitudes. Sin embargo, como fue indicado por Makridakis [6] los modelos estadísticos tienen mejor desempeño que los modelos de aprendizaje automático, debe de hacerse una consideración para cada uno de los casos ya que los productos con alta variabilidad pudieron ser explicados mejor por los modelos de aprendizaje automático.

4 Conclusiones y trabajo futuro

4.1 Conclusiones

A través del presente trabajo, se ha propuesto una alternativa para la elaboración de pronósticos de ventas en las distintas unidades de negocio, contribuyendo a la optimización de los inventarios mediante predicciones más precisas para algunos productos en comparación con el método utilizado actualmente. Se logró obtener un conjunto de datos preparado para el posterior análisis y modelamiento asegurando la calidad y fiabilidad.

Se desarrollaron modelos de pronóstico tanto como estadísticos como de aprendizaje automático, mismos que facilitaron la generación de predicciones de ventas para las siguientes trece semanas del trimestre. Los modelos, a través de sus algoritmos proporcionaron estimaciones y un proceso de selección automática del modelo mas adecuado basándose en el menor error de predicción registrado. Adicional, se genero un conjunto de datos en un archivo .csv integrado por los valores históricos, las predicciones y los pronósticos de las trece semanas subsecuentes, buscando potenciar la capacidad de análisis y toma de desiciones para el equipo de planeación de la empresa.

Finalmente, la comparación de los pronósticos generados por los modelos desarrollados frente a los métodos existentes presentó una reducción significativa del error para ciertos productos. Es por ello que junto con la experiencia del equipo de planeación de la empresa se puede identificar aquellos productos para los cuales la implementación de los modelos podría optimizar la gestión de inventarios de manera más efectiva, mediante la reducción o aumento de ordenes de compra para satisfacer los requerimientos de los clientes. Por lo tanto, el estudio ofrece una alternativa al proceso de pronóstico actual, aportando información adicional y aumentando las herramientas para la toma de decisiones en la gestión de los inventarios.

4.2 *Trabajo futuro*

El presente trabajo abre las oportunidades para evaluar la mejor forma de acercar nuevas herramientas para los diversos equipos para la toma de decisiones y mejora de los flujos actuales, será importante dar seguimiento para gestionar la incorporación de los modelos a los sistemas de reporte o herramientas que actualmente se utilizan para lo relacionado a la gestión de los inventarios.

En el caso de aquellos productos cuyos errores disminuyen la eficacia de los modelos se deberán buscar variables adicionales o información adicional que pueda alimentar a los modelos para mejorar el poder predictivo y disminuir el error. Aún cuando el estudio solo eligió 4 modelos adicionales al benchmark de modelos se puede evaluar la utilización de mas modelos que puedan mejorar los ensambles de modelos o mejorar la forma de ensamblar los modelos ya que se observo que la combinación de los modelos si es una alternativa viable para la disminución de los errores.

Bibliografía

- [1] T. Peris, “Modelos de predicción en series temporales: Un estudio comparativo entre métodos estadísticos y machine learning,” Master’s thesis, UAJI, Castellon, 2022. Thesis (B.S.).
- [2] V. Bahamon and A. Palacio, “Desarrollo de un modelo de pronósticos e inventarios para ítems clase a en una empresa comercial de la ciudad de cali,” Master’s thesis, Universidad ICESI, 2014. Thesis (Master’s).
- [3] M. Ehrhardt and E. Brigham, *Finanzas Corporativas*. Mexico: Cenage Learning Editores, 2007.
- [4] Y. Durán, “Administración del inventario: elemento clave para la optimización de las utilidades en las empresas,” *Visión Gerencial*, vol. 1, pp. 55–78, 2012.
- [5] D. Saputra, D. Saputra, and L. Oswari, “Effect of distance metrics in determining k-value in kmeans clustering using elbow and silhouette method,” *Advances in Intelligent Systems Research*, vol. 172, 2019.
- [6] S. Makridakis, E. Spiliotis, and V. Assimakopulos, “Statistical and machine learning forecasting,” *Plos One*, 2018.
- [7] S. Makridakis, E. Spilotis, V. Assimakopoulos, A.-A. Semenoglou, G. Mulder, and K. Nikolopoulos, “Statistical, machine learning and deep learning forecasting methods: Comparisons and ways forward,” *Journal of the Operational Research Society*, vol. 74, pp. 840–859, 2023.
- [8] R. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*. Melbourne: OTexts, 2021.
- [9] G. Valenzuela, “Aprendizaje supervisado: Métodos, propiedades y aplicaciones,” Master’s thesis, RiUMA, Malaga, 2022. B.S. Thesis.
- [10] R. Hyndman and A. B. Koehler, “Another look at measures of forecast accuracy,” *International Journal of Forecasting*, vol. 22, pp. 679–688, 2006.

- [11] R. Fildes, "The evaluation of extrapolative forecasting methods," *International Journal of Forecasting*, vol. 8, no. 1, pp. 81–98, 1992.
- [12] C. Arenas and F. Mestres, "Rmdse: An extension to related metric scaling," *Advances and Applications in Statistics*, vol. 7, no. 1, pp. 97–113, 2007.
- [13] R. Hossain and D. Timmer, "Machine learning model optimization with hyper parameter tuning," *Global Journal of Computer Science and Technology: D Neural & Artificial Intelligence*, vol. 21, no. 2, 2021.