



FACULTAD DE INGENIERÍA

Maestría en Ciencia de Datos

Integrante(s):

James Osorio Prada

Fernando Rodas Suazo

Tutor: Diego Fernando Agudelo Burbano

Mayo, 2023

Tabla de Contenido

| | |
|---|----|
| Resumen | 4 |
| 1 Título del Trabajo de Grado | 5 |
| 2 Contexto, Antecedentes y Justificación..... | 5 |
| 3 Planteamiento del Problema | 8 |
| 4 Objetivos del Proyecto | 9 |
| 4.1 Objetivo General..... | 9 |
| 4.2 Objetivos Específicos | 10 |
| 5 Marco Teórico..... | 10 |
| 5.1 Dominio del Problema | 10 |
| 5.1.1 Pronóstico..... | 10 |
| 5.1.2 Demanda | 11 |
| 5.1.4 WAPA (Weighted Absolute Percent Accuracy) | 11 |
| 5.1.5 Planeación de la demanda..... | 12 |
| 5.2 Dominio de la Solución | 13 |
| 5.2.1 Machine Learning..... | 13 |
| 5.2.2 Análisis Exploratorio de Datos | 14 |
| 5.2.3 Series de Tiempo | 14 |
| 5.2.4 Modelos ARIMA..... | 15 |
| 5.2.5 Modelo Prophet | 15 |
| 5.2.6 Optimización Bayesiana | 16 |
| 6 Estado del Arte | 16 |
| 7 Metodología..... | 20 |
| 8 Propuesta | 22 |
| 8.1 Comprensión del negocio | 23 |
| 8.2 Comprensión de los datos | 27 |
| 8.3 Descripción de los Datos | 28 |
| 8.4 Exploración de los Datos | 29 |
| 8.5 Preparación de los datos | 37 |
| 8.6 Modelado..... | 40 |
| 9 Evaluación | 47 |
| 9.2 Resultados utilizando mejores técnicas | 47 |
| 9.3 Pronósticos para el año 2022 según el mejor modelo..... | 48 |
| 10 Despliegue | 51 |
| Conclusiones | 52 |
| Bibliografía..... | 53 |

Índice de Tablas

| | |
|--|----|
| Tabla 1: Numero de productos ofrecidos, Fuente: Empresa | 5 |
| Tabla 2: Adecuación propia del libro para el cálculo del MAPE..... | 12 |
| Tabla 3: Cuadro comparativo del Estado del arte vs proyecto de grado | 19 |
| Tabla 4: Productos por commodities, Fuente: Empresa..... | 27 |
| Tabla 5: Productos seleccionados para estudio, Fuente: Propia..... | 28 |
| Tabla 6: Métricas para el protocolo de evaluación, Fuente: Propia | 41 |
| Tabla 7: Parámetros usados para el mejor modelo - Producto 1 y 3..... | 43 |
| Tabla 8: Parámetros usados para el mejor modelo en el Producto 2 | 44 |
| Tabla 9: Parámetros usados para el mejor modelo en los Productos 4 y 5..... | 44 |
| Tabla 10: Resumen de resultados para las métricas del protocolo de evaluación..... | 48 |

Índice de Gráficas

| | |
|---|----|
| Gráfico 1: Procesos del área de Supply Planning, Fuente: La empresa..... | 6 |
| Gráfico 2: Comportamiento del indicador WAPA de la empresa, Fuente: La empresa..... | 7 |
| Gráfico 3: Comportamiento del indicador MAPE de la empresa, Fuente: Propia..... | 7 |
| Gráfico 4: Análisis de Demanda, pronóstico e inventario en dólares, Fuente: Propia..... | 8 |
| Gráfico 5: Causa raíz de excesos de inventario a Sep-22, Fuente: Empresa..... | 9 |
| Gráfico 7: Ciclo de vida de minería de datos Fuente: IBM | 20 |
| Gráfico 8: Demanda producto 1 y su componente estacional | 30 |
| Gráfico 9: Demanda producto 2 y su componente estacional | 31 |
| Gráfico 10: Demanda producto 3 y su componente estacional | 32 |
| Gráfico 11: Demanda producto 4 y su componente estacional | 32 |
| Gráfico 12: Demanda producto 5 y su componente estacional | 33 |
| Gráfico 13: Demanda vs Pronóstico Empresa – Producto 1, Fuente: Propia | 34 |
| Gráfico 14: Demanda vs Pronóstico Empresa – Producto 2, Fuente: Propia | 34 |
| Gráfico 15: Demanda vs Pronóstico Empresa – Producto 3, Fuente: Propia | 35 |
| Gráfico 16: Demanda vs Pronóstico Empresa – Producto 4, Fuente: Propia | 36 |
| Gráfico 17: Demanda vs Pronóstico Empresa – Producto 5, Fuente: Propia | 36 |
| Gráfico 18: Ventana Móvil para 36 meses de entrenamiento | 39 |
| Gráfico 19: Ventana Móvil para 48 meses de entrenamiento | 39 |
| Gráfico 20: Ventana Móvil para 60 meses de entrenamiento | 40 |
| Gráfico 21: Resultados por Modelo para todos los productos | 45 |
| Gráfico 22: Resultado de Métricas de evaluación por producto en cada modelo | 46 |
| Gráfico 23: Comparación del promedio final del MAPE por modelo | 47 |
| Gráfico 24: Resultados de los Mejores Modelos por Producto según MAPE | 48 |
| Gráfico 25: Pronóstico generado por modelo Prophet para el Producto 1 | 49 |
| Gráfico 26: Pronóstico generado por modelo Holt-Winter para el Producto 2 | 49 |
| Gráfico 27: Pronóstico generado por modelo Prophet para el Producto 3..... | 50 |
| Gráfico 28: Pronóstico generado por modelo ARIMA para el Producto 4..... | 50 |
| Gráfico 29: Pronóstico generado por modelo ARIMA para el Producto 5..... | 50 |

Resumen

En este trabajo se formuló una propuesta para abordar los altos niveles de inventario en una empresa de cintas y adhesivos, donde se manifiesta que dichos niveles han sido producto de una baja efectividad de los modelos tradicionales de pronóstico de ventas, generando un sobrestimado de pronóstico en comparación con la demanda real, donde posteriormente se ha utilizado este pronóstico para calcular el reaprovisionamiento de inventario con anticipación según su tiempo de producción, pero al no cumplirse dicho estimado se generaron excesos de inventario y costos adicionales para su almacenamiento.

Para desarrollarlo se propuso la metodología CRISP-DM, que considera iniciar con una comprensión del negocio y preparación de los datos, definir un protocolo de evaluación que permita estimar el desempeño de los modelos seleccionados, evaluación de modelos, generar resultados, identificar los modelos que pueden ser utilizados para pronosticar la demanda de las ventas en periodos mensuales y realizar la validación de los modelos.

Se propone la evaluación de cuatro modelos de pronóstico: Promedio móvil, suavización exponencial triple (Holt-Winters), ARIMA y Prophet. Los cuales han sido seleccionados debido a su efectividad en la predicción de series de tiempo. A través de esta evaluación, se espera identificar el modelo que mejor se adapte a las características de la demanda de productos, lo que permitirá una mejor planificación de la cadena de suministro y de forma indirecta una reducción en los niveles de inventarios.

Finalmente, después de todo el trabajo desarrollado y de la validación realizada se puede afirmar que el enfoque de solución propuesto y la metodología empleada para obtenerla resultan apropiados.

1 Título del Trabajo de Grado.

Evaluación de modelos de pronósticos de ventas para estimar la demanda mensual en una empresa de Cintas y Adhesivos en Colombia.

2 Contexto, Antecedentes y Justificación.

En el presente trabajo no se mencionara la empresa en la que se desarrollará el trabajo debido a situaciones de confidencialidad, por esa razón la llamaremos de ahora en adelante “La Empresa”, la cual cuenta con 4 grandes grupos de negocio como Safety & Industrial, Consumo, Health care y Transportation, adicionalmente tiene presencia en más de 100 países, con más de 55.000 productos y 25 plantas de producción donde su mayor concentración se encuentra en USA, para efectos de este trabajo analizaremos la operación del negocio de Safety & industrial para la división de Cintas y Adhesivos Industriales en Colombia para un portafolio de 144 productos que se comercializan bajo inventario.

Tabla 1: Numero de productos ofrecidos, Fuente: Empresa

| País | MTS – Make to Stock | MTO – Make to Order | Total |
|--------------------|---------------------|---------------------|--------------|
| Colombia | 144 | 156 | 300 |
| Peru | 87 | 186 | 273 |
| Ecuador | 55 | 118 | 173 |
| Paraguay | 26 | 105 | 131 |
| Bolivia | 21 | 107 | 128 |
| Grand Total | 333 | 672 | 1.005 |

El área de Demand Planning de la empresa utiliza un software llamado “i2 Demand Manager” para generar modelos de pronóstico como Suavizamiento exponencial simple, doble, triple y medias móviles, obteniendo las predicciones de venta que son analizadas y

ajustadas en colaboración con el equipo comercial, aplicando reglas de negocio para cada producto como incrementos o reducciones del mismo, estableciendo así el pronóstico final ajustado que utilizara el área de Supply Chain para la planeación de la cadena de suministro en los siguientes 12 meses y satisfacer las necesidades de los clientes.



Gráfico 1: Procesos del área de Supply Planning, Fuente: La empresa

Para medir el desempeño de los resultados obtenidos de estos modelos la empresa utiliza un indicador WAPA (Weighted Absolute Percent Accuracy), el cual mide el desempeño de efectividad entre los valores reales de demanda y los valores predichos, para este caso la empresa realiza la medición para el pronóstico estadístico como para el pronóstico final ajustado, donde el objetivo es alcanzar un valor mayor al 65%.




Gráfico 2: Comportamiento del indicador WAPA de la empresa, Fuente: La empresa

Estos resultados del WAPA generan dos impactos en los inventarios, el primero es un sobrestimado del pronóstico que resulta en altos niveles de inventario. Por otro lado, si se subestima el pronóstico se puede producir un desabastecimiento de inventario, lo cual afectaría el nivel de servicio esperado por los clientes.




Gráfico 3: Comportamiento del indicador MAPE de la empresa, Fuente: Propia

Con esto podemos concluir que, en promedio, el error del pronóstico estadístico (MAPE¹) para los productos durante el año 2022 fue del 47% y un (WAPA²) del 53%, lo cual será un dato para nuestro “Base Line” o línea base de partida del indicador a mejorar al momento de evaluar los resultados de los diferentes modelos de pronóstico que se desarrollarán.

3 Planteamiento del Problema

La empresa presenta altos niveles de inventario, debido a una “Disminución de demanda”, esto significa que dicha acumulación de inventario ha sido producto de una baja efectividad de los modelos tradicionales aplicados por el área de Demand Planning, generado un sobrestimado de pronóstico en comparación con la demanda real que tuvieron los clientes, donde a su vez el área Supply Chain ha utilizado este pronóstico para realizar su reaprovisionamiento de inventario con anticipación, pero al no cumplirse dicho estimado trae como resultado excesos de inventario y costos adicionales en almacenamiento.




Gráfico 4: Análisis de Demanda, pronóstico e inventario en dólares, Fuente: Propia

¹ **MAPE:** El Error Porcentual Absoluto Medio es una medida comúnmente utilizada para evaluar la precisión de los pronósticos. Se calcula tomando el valor absoluto de la diferencia porcentual entre los valores pronosticados y los valores reales, y luego promediando estos errores porcentuales para todas las observaciones, el objetivo de la empresa es tener un resultado menor al 35%.
² **WAPA:** (Weighted Absolute Percent Accuracy), Métrica definida por la empresa para medir el desempeño del pronóstico estadístico contra los valores reales de la demanda, el objetivo de la empresa es tener un resultado mayor al 65%.

En el gráfico 3 observamos cómo entre los meses de diciembre de 2021 y Julio de 2022 la demanda estuvo por debajo del pronóstico y a su vez se evidencia como los inventarios empezaron a incrementarse llegando al punto más alto en agosto de 2022. Adicionalmente la empresa ha identificado la causa raíz de dicha acumulación de inventario donde al cierre de cada mes clasifica cada producto según su causa, las cuales se detallan en el siguiente Gráfico 4 donde agrupa cada causa según su valor de inventario en dólares.




Gráfico 5: Causa raíz de excesos de inventario a Sep-22, Fuente: Empresa

Se observa que la causa principal es “**Demand Decrease**” con un 64% y un total de \$113.860 USD, seguido por “**Other**” que representan un 12% con un valor de \$21.973 USD y finalmente “**Large MOQ**” con un 9%, esto significa que deberíamos enfocarnos en atacar la primera causa y así lograr un mayor impacto sobre la reducción de los inventarios.

4 Objetivos del Proyecto

4.1 Objetivo General

- Seleccionar y evaluar modelos de series de tiempo que permitan generar pronósticos de ventas mensuales para el negocio de cintas y adhesivos industriales en Colombia.

4.2 Objetivos Específicos

- Organizar y anonimizar los datos disponibles para pronosticar la demanda Mensual.
- Identificar los modelos de series de tiempo que podrían ser utilizados para pronosticar la demanda de las ventas en periodos mensuales.
- Definir un protocolo de evaluación que permita estimar el desempeño de los modelos seleccionados.
- Evaluar y seleccionar el mejor modelo de series de tiempo para cada producto que permitan pronosticar la demanda de las ventas de forma mensual.

5 Marco Teórico

En esta parte se considerarán los conceptos para el contexto de planeación de la demanda y de los suministros que se deben conocer para entender el problema y las soluciones planteadas. Donde se presentarán los conceptos claves en el dominio del problema y los conceptos clave en el dominio de la solución en el campo de la ciencia de datos.

5.1 Dominio del Problema

5.1.1 Pronóstico

El proceso de elaboración del pronóstico o Forecasting consiste en la estimación y análisis de la demanda futura mediante algoritmos que utilizan datos pasados, presentes, análisis de patrones y tendencia que implican las siguientes tareas (Alonso, 2021):

1. Entender el problema e identificar la variable a pronosticar.
2. Crear una base de datos con la información histórica.

3. Determinar las características más relevantes del comportamiento histórico.
4. Escoger el “mejor” modelo, entre las diferentes posibles aproximaciones, para explicar el comportamiento de la variable a pronosticar en la muestra de evaluación.
5. Realizar un monitoreo continuo del comportamiento de los pronósticos.

Los pronósticos también implican realizar unos supuestos. El principal es que el comportamiento futuro de la variable de interés será igual al comportamiento pasado. Así mismo, los modelos estadísticos que se emplean para la construcción de los pronósticos también implican unos supuestos y por tanto para tener buenos pronósticos tendremos que estar seguros de que los supuestos de los modelos estadísticos se cumplen.

5.1.2 Demanda

El objetivo de la demanda histórica es conocer el comportamiento del consumo en el tiempo pasado, es decir, la demanda del producto o servicio que hubo en años anteriores, como lo indica (Romero, 2020). Por lo tanto, al analizar los datos históricos, es importante aclarar que debemos trabajar con la cantidad realmente solicitada por los clientes a la empresa incluso si no se pudieron vender al cliente, en lugar de basarnos únicamente en las cantidades vendidas y que pudo despachar la empresa.

5.1.4 WAPA (Weighted Absolute Percent Accuracy)

Esta métrica WAPA definida al interior de la compañía traduce “Precisión porcentual absoluta ponderada” y se utiliza para medir el resultado del pronóstico contra la demanda real para cada mes ejecutado, este indicador es una adaptación de la empresa basado en

el MAPE (Mean Absolute Percent Error - Error Porcentual absoluto medio) que según (Vandeput, 2015). en su libro indicador se calcula de la siguiente forma:

Tabla 2: Adecuación propia del libro para el cálculo del MAPE

| Mes | Real | Pronóstico | Absolute Error (Real-Pronos) | Absolute % Error (Real-Pronos) / Real | WMAPE (Error*Real) |
|--------------------------------|------------|------------|---------------------------------|---|-----------------------|
| 1 | 112 | 120 | 8 | 7,1% | 8,0 |
| 2 | 11 | 10 | 1 | 9,1% | 1,0 |
| 3 | 149 | 117 | 32 | 21,5% | 32,0 |
| 4 | 117 | 79 | 38 | 32,5% | 38,0 |
| Total | 389 | | 79 | 70,2% | 79,0 |
| Mad (promedio abs err.) | | | <----- 19,75 | | |
| Mape (promedio abs % err.) | | | <----- | 17,5% | |
| Wmape (Suma Wmape / suma Real) | | | <----- | | 20,3% |

1. Restamos el dato pronosticado y el real para cada mes.
2. Calculamos el valor absoluto de la resta de la anterior resta.
3. Sumamos todos los resultados anteriores.
4. Dividimos el resultado sobre la suma total de los valores reales.
5. Hasta aquí tendríamos el resultado del MAPE que se refiere al error final, pero para efectos de la compañía en cuestión esta mide el desempeño como:
 $(WAPA) = 1 - \text{Error (MAPE = 20.3\%)} = 79.7\%$

5.1.5 Planeación de la demanda

El área de demanda realiza su proceso de construcción de pronóstico basados en la demanda histórica de los últimos 36 meses móviles y un mismo modelo para todos los productos, para esto utilizan una software el cual les proporciona diferentes modelos de estadística tradicional, dicho modelo es procesado en una plataforma web donde recibe el input por parte del negocio donde se ajustan los valores obtenidos por producto ya sea incrementando o reduciendo dicho valor según los planes de negocio que se tengan a futuro y otras variables adicionales como cambios de precio, lanzamientos de nuevos productos. A continuación, en la Gráfica 2 se presenta un diagrama sobre el proceso de demanda.

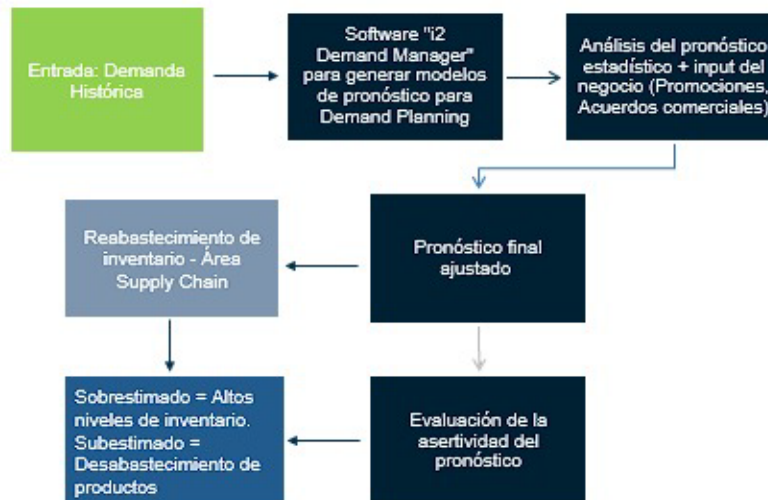


Gráfico 6: Diagrama del proceso de planeación de la demanda

Tener en cuenta que al evaluar el resultado del desempeño del pronóstico este puede tener como primer resultado un sobrestimado del pronóstico, que se produce cuando el pronóstico fue mayor que la demanda real o un segundo resultado que sería tener un subestimado del pronóstico que se genera cuando el valor de la demanda real fue mayor que lo pronosticado y se le conoce en la empresa como Backorder que traduce pedido pendiente, generando desabastecimientos de los productos.

5.2 Dominio de la Solución

Aquí detallaremos los diferentes conceptos que se utilizarán para dar respuesta a la solución del problema.

5.2.1 Machine Learning

Es un método del análisis de datos que automatiza la creación y uso de modelos estadísticos, que da a una computadora la habilidad de aprender de los datos, se basa en

la idea de que los sistemas pueden aprender de los datos, identificar patrones y tomar decisiones con mínima intervención humana. (Romero, 2020)

5.2.2 Análisis Exploratorio de Datos

Los científicos de datos utilizan el análisis exploratorio de datos (EDA) para analizar e investigar conjuntos de datos y resumir sus características principales, a menudo empleando métodos de visualización de datos. También facilita el descubrimiento de patrones, detectar anomalías, probar hipótesis o verificar suposiciones. (IBM, 2015)

Adicionalmente para ver qué pueden revelar los datos más allá del modelado formal o tarea de prueba de hipótesis y proporciona una mejor comprensión de las variables del conjunto de datos y las relaciones entre ellas. También puede ayudar a determinar si las técnicas estadísticas que está considerando para el análisis de datos son apropiadas.

5.2.3 Series de Tiempo

Las series de tiempo son datos secuenciales cuyos registros tienen un tiempo asociado (hora, fecha, año, entre otros). Una serie de tiempo es un tipo de dato secuencial en la que sus registros consisten en datos numéricos medidos sobre el tiempo y se pueden comportar de diferentes maneras a través del tiempo: puede que se presente una tendencia, estacionalidad o simplemente no presenten una forma definida. (Alegre Ibáñez & Lozano Aparicio, 2022)

La predicción de series de tiempo significa que se extienden los valores históricos de la serie al futuro, donde aún no se han hecho mediciones. Para llevar a cabo el pronóstico se

definen dos variables: cantidad de períodos y horizonte de predicción. La cantidad de períodos representa el nivel de agregación de los datos. Usualmente los datos se encuentran por meses, semanas o días. Todo pronóstico tiene asociado un alcance, pudiendo ser de corto, mediano o largo plazo. (Management, 2016)

5.2.4 Modelos ARIMA

Los modelos ARIMA son utilizados para analizar series de tiempo y se expresan de la siguiente manera (p,d,q) , ya que $AR(p)$ hace referencia a los procesos autorregresivos, $I(d)$ que es el orden y $MA(q)$ que son procesos de medias móviles. (Martín & Píneros, 2020)

También permiten analizar la serie temporal con métodos de descomposición tradicionales que las clasifican en componentes como tendencia, factor cíclico, estacionalidad y componente irregular. (Jiménez Guerrero, 2006)

5.2.5 Modelo Prophet

Prophet es un procedimiento para pronosticar datos de series temporales basado en un modelo aditivo en el que las tendencias no lineales se ajustan a la estacionalidad anual, semanal y diaria, además de los efectos de las vacaciones. Funciona mejor con series temporales que tienen fuertes efectos estacionales y varias temporadas de datos históricos. Prophet es resistente a los datos faltantes y los cambios en la tendencia, y por lo general maneja bien los valores atípicos. (Duong, 2023)

5.2.6 Optimización Bayesiana

Para (Koehrsen, 2018), la optimización consiste en encontrar el conjunto de valores de entrada en una función objetivo que produce el valor de salida más bajo, denominado "pérdida". La función objetivo $f(x) = x^2$ tiene una sola entrada y es un problema de optimización 1-D. Por lo general, en el aprendizaje automático, nuestra función objetivo es multidimensional porque toma un conjunto de hiperparámetros del modelo, los cuales al ser evaluados aquellos que parecen más prometedores a partir de resultados anteriores, los métodos bayesianos pueden encontrar mejores configuraciones de modelo que la búsqueda aleatoria en menos iteraciones.

6 Estado del Arte

En esta sección se describe el estado del arte actual relacionado con el uso de la ciencia de datos para la evaluación de pronósticos de series de tiempo en productos del sector industrial o de consumo masivo. A continuación, se presentan en orden cronológico los trabajos que mejor se ajustaron a los criterios de búsqueda.

6.1 Pronóstico de la demanda internacional del banano orgánico de Perú usando algoritmos de Machine Learning (Almeyda, 2022).

Este trabajo tiene como objetivo entrenar y evaluar el desempeño de un modelo predictivo para pronosticar la demanda del banano orgánico de Perú usando algoritmos de aprendizaje supervisado del tipo Redes Neuronales, tales como: MLP1, RNN2, LSTM3 y GRU4. Posteriormente, se seleccionó el modelo con mejor performance, evaluando la precisión de los valores pronosticados y los valores de la serie temporal original. Como

resultado, el modelo entrenado con el algoritmo RNN obtuvo los menores valores de error de predicción (MSE: 0.00147, RMSE: 0.03838, MAE: 0.02885, y MAPE: 2.88516), lo cual demostró ser el modelo predictivo más preciso.

6.2 Pronóstico de demanda mediante series temporales y redes neuronales aplicado a una empresa del sector ferretero (PULZARA, 2020)

En este proyecto se generan 10 modelos diferentes usando modelos Box-Jenkins, Modelos estado-espacio para suavización exponencial (ETS) y una arquitectura de red neuronal con capas convolucionales, long short time memory and dense, los cuales se evalúan sobre una muestra de series mensuales de la M4 Competition para luego escoger un modelo a ser aplicado a los productos de una empresa del sector ferretero. Los mejores resultados, en términos del MAPE, se obtuvieron con el modelo de estado-espacio ETS y con un modelo que es el resultado de la combinación aritmética entre los modelos de suavización exponencial y ARIMA con ciertos parámetros predefinidos.

6.3 Aplicación de la Metodología CRISP-DM a un Proyecto de Minería de Datos en el Entorno Universitario

En este trabajo se aplica cada una de las fases de la metodología CRISP-DM para tratar datos académicos, con la finalidad de poder obtener conclusiones y poder mejorar los servicios que se ofrecen. También en la parte de modelado de la data se escoge la técnica de minería de datos donde al final se verá si cumple con los criterios de éxito o no. Para probar la calidad y validez del modelo se usa la métrica de RMSE, MAE y la confianza predictiva por medio de la herramienta de Oracle Data Mining.

6.4 Análisis y pronóstico de venta de productos para la gestión de inventario de la farmacia comunal San Miguel

En este trabajo se aborda el análisis y pronóstico de venta de productos de una farmacia con el foco en generar un aporte a la gestión de inventarios, aplicando las fases de la metodología CRISP-DM y el uso de modelamientos para encontrar el mejor método de predicción, modelando 350 series de tiempo de los productos con técnicas como medias móviles simples, ARIMA y Prophet con estacionalidad anual forzada, adicionalmente se aplica un clasificador en el método de aprendizaje de Random Forest para la elección de la mejor técnica de predicción para cualquier serie de tiempo. Para la evaluación de la calidad y la precisión de las técnicas se usan las métricas de MAE y MAPE.

6.5 Modelo de Pronóstico de Demanda para Productos del Sector Eléctrico

En este trabajo de grado se presenta una propuesta para la mejora de los modelos de predicción de demanda utilizados actualmente por la empresa, en productos de alta rotación, implementando modelos clásicos de series de tiempo como Estacionalidad Simple, Aditivo y Holt-Winters y Promedio móvil, también se evaluaron metodologías de Machine y Deep Learning, como modelos ARIMA, modelo FB Prophet y Redes Neuronales, con la finalidad de mejorar la predicción de cantidad vendida, para verificar el desempeño de los modelos se usó la métrica RMSE (Raíz del Erro Cuadrático Medio).

Tabla 3: Cuadro comparativo del Estado del arte vs proyecto de grado

| Criterios de Comparación | | | | | | | | | | |
|---|--|-----------------|-------------------|---------------------|--|---------------|---|---------------------------|---|---|
| Título | Autores | Publicación | Sitio de interés | Sector | Variable de interés | Co- Variables | Fuentes de información | Tiempo de estudio | Modelos Utilizados | Resultados |
| Nuestro Proyecto de Grado | James Osorio Fernando Rodas | Junio de 2023 | Colombia | Industria/Ferretero | Demanda de los productos de cintas y adhesivos | Ninguna | Datos reales de demanda de la empresa en estudio | Desde el año 2017 al 2022 | - Medias Móviles. Holt Winters, ARIMA, Prophet | MAPE = 25,7% |
| Pronóstico de la demanda internacional del banano orgánico de Perú usando algoritmos de Machine Learning | Estefani Marie Almeyda | Julio de 2022 | Perú | Agrícola | Exportación de Banano - Demanda | Ninguna | datos del registro mensual de exportación de banano orgánico (kg) de Perú | Desde el año 2001 al 2021 | - RNN (Recurrent Neural Network) - LSTM (long Short-Term Memory STM) | RNN obtuvo los menores valores de error de predicción (MSE: 0.00147, RMSE: 0.03838, MAE: 0.02885, y MAPE: 2.88516). |
| Pronóstico de demanda mediante series temporales y redes neuronales aplicado a una empresa del sector ferretero | NÉSTOR RAFAEL MONTAÑO PULZARA | 2020 | Ecuador-Guayaquil | Ferretero | demanda de los productos del sector ferretero | Ninguna | grupo de series mensuales del M4-Competition | Desde el año 2014 al 2020 | Estado-espacio ETS, ARIMA | Sin info |
| Aplicación de la Metodología CRISP-DM a un Proyecto de Minería de Datos en el Entorno Universitario | Víctor Galá Cortina | Octubre de 2015 | España | Educativo | Demanda de Estudiantes | Ninguna | Base de datos de la Universidad | Desde 1997 al 2011 | Oracle Data Mining (Regresión Lineal, SVM) | MAPE = 34% |
| Análisis y pronóstico de venta de productos para la gestión de inventario de la farmacia comunal San Miguel | Flavia Gigliola Varnero Rain | 2021 | Chile | Farmacéutico | Demanda de los productos | Ninguna | Datos reales de demanda de la empresa en estudio | Desde el 2019 al 2021 | Prophet, ARIMA, Medias Móviles Simples | MAPE = 8,3% |
| Modelo de Pronóstico de Demanda para Productos del Sector Eléctrico | Ingrid Yulieth Hernández Rodríguez, Luis Miguel Torres | 2021 | Colombia | Eléctrico | Demanda de Productos Eléctricos | Ninguna | Base de datos de la Empresa | Desde el 2018 al 2021 | Holt-Winters, Promedio móvil, Árboles, ARIMA, Prophet, RNN | RMSE = 285 |

En la Tabla 3 se realizó un resumen de los cuatro trabajos del estado del arte analizado, donde se detallan cada uno de los criterios de comparación, resaltando en color azul claro si el criterio mencionado para cada proyecto es similar al nuestro.

7.2 Comprensión de los datos.

Esta segunda fase comprende la recolección de los datos con el objetivo de establecer un primer contacto con el problema a resolver, conocer los datos, identificar la calidad y establecer las relaciones más evidentes que permitan establecer las primeras hipótesis, esta fase ocupa la mayoría de tiempo en un proyecto de ciencia de datos, debido a que durante el proyecto se generen varios accesos a la base de datos con el fin de realizar consultas y probablemente se produzcan modificaciones, lo cual podría generar muchos problemas para comprender bien los datos. (IBM, 2021)

7.3 Preparación de los datos.

Una vez que se ha completado la recolección de los datos, es necesario prepararlos adecuadamente para que se ajusten a los modelos de predicción que se utilizarán. Estas técnicas pueden ser de visualización de datos, búsqueda de relaciones entre variables, entre otras. La preparación de los datos abarca tareas generales como la selección de los datos que serán sometidos a una técnica de modelado específica, la limpieza de los datos, la generación de variables adicionales, la integración de datos provenientes de diferentes fuentes y los cambios de formatos necesarios. (IBM, 2021)

7.4 Modelado

En esta fase, se eligen cuidadosamente las técnicas de modelado más adecuadas para el proyecto. Antes de proceder con el modelado de datos, es crucial establecer un método de evaluación que permita medir el rendimiento de cada modelo. Una vez completadas estas tareas iniciales, se pasa a la etapa de generación y evaluación del modelo. Los parámetros

utilizados en la generación del modelo se determinan en base a las características de los datos y el nivel de precisión deseado para el modelo. (IBM, 2021)

7.5 Evaluación

En esta fase, se realiza una evaluación exhaustiva del modelo, teniendo en cuenta el cumplimiento de los criterios de éxito establecidos para abordar el problema. Es importante tener en cuenta que la fiabilidad calculada para el modelo solo se aplica a los datos en los que se realizó el análisis. Es fundamental revisar cuidadosamente el proceso en función de los resultados obtenidos, permitiendo así la posibilidad de repetir alguna etapa anterior en caso de identificar posibles errores cometidos. (IBM, 2021)

7.6 Despliegue

Una vez que se ha construido y validado el modelo, es necesario convertir el conocimiento adquirido en acciones dentro del proceso de negocio. Es importante destacar que un proyecto no concluye con la implementación del modelo, debido a que es necesario documentar y presentar los resultados de manera comprensible para los usuarios, con el objetivo de transmitir el conocimiento. Además, se debe garantizar el mantenimiento de la aplicación y difundir los resultados obtenidos de manera efectiva. (IBM, 2021)

8 Propuesta

Con el objetivo principal de seleccionar y evaluar modelos que permitan estimar la demanda en este sector, se realizó la evaluación de cuatro modelos: Promedio móvil, suavización exponencial triple (Holt-Winters), ARIMA y Prophet. Usando como guía la metodología CRISP-DM donde se fueron desarrollando cada una de sus etapas.

8.1 Comprensión del negocio

En esta etapa se establecen los objetivos y requisitos del proyecto, teniendo en cuenta la perspectiva del negocio, los cuales se desarrollarán de acuerdo con un plan de proyecto estructurado.

8.1.1 Determinar los Objetivos del Negocio

Para el sector de las cintas y adhesivos en Colombia, la capacidad de predecir con precisión la demanda de productos es esencial para garantizar la eficiencia en toda la planeación de la cadena de suministro y la satisfacción del cliente, permitiendo mantener un adecuado nivel de inventarios a un bajo costo.

Para dar un poco de contexto, la empresa cuenta con un software llamado “**i2 Demand Manager**” el cual combina técnicas tradicionales de pronóstico estadístico para determinar el mejor modelo a usar y predecir la demanda de los siguientes 12 meses, pero dicho pronóstico está arrojando valores por encima de los reales, generando incrementos de inventario. Adicionalmente dicho software presenta las siguientes desventajas:

- **Actualizaciones:** se ejecutan solo cuando ocurren de manera global y no local.
- **Mantenimiento:** la optimización de parámetros se realiza cada dos años.
- **Entrenamiento del modelo:** No es un proceso iterativo y automático, pues solo usa los parámetros generales que se le asignan de forma global.
- **Administración:** cuenta con tres usuarios a nivel global, localizados en China, Corea y Taiwán, los cuales realizarán modificaciones solo para quien lo solicite.
- **Modelo de pronóstico por negocio:** se ajusta solo un modelo general para todos los productos del negocio, pero no se ajusta por producto.

Como criterios de éxito del negocio será lograr un pronóstico balanceado con un mínimo error entre las cantidades predichas y las cantidades reales, de tal forma que garantice las necesidades del cliente con un elevado nivel de servicio y evitando al mismo tiempo generar excesos de inventario, pues generar un pronóstico con valores mayores a los valores reales trae como consecuencia incrementos en los niveles de inventario y en caso contrario el pronosticar valores menores a los reales traerá desabastecimientos de productos convirtiéndose en pérdidas de ventas por no tener un inventario disponible para el cliente.

8.1.2 Evaluación de la situación

Por parte de la empresa nos entregaron una base de datos de Excel con información del top 20 de los productos que se han comercializado desde enero del 2017 hasta diciembre del 2022 para la división de cintas y adhesivos industriales en Colombia, que comprende 72 meses de datos históricos por cada producto, adicionalmente contiene el pronóstico que fue calculado para cada producto en el mismo periodo de tiempo, lo cual nos indica que contamos con información suficiente para poder resolver el problema.

Otro recurso será el software de Google Colab, que permite programar y ejecutar lenguaje de programación Python en el navegador Web sin ningún costo, por lo cual no requiere configuración, se tiene acceso a GPUs³ sin costo adicional y permite compartir el contenido facilitando trabajar al mismo tiempo desde diferentes equipos de cómputo.

Al usar el lenguaje de programación Python nos permite el uso de librerías⁴ que proporcionan herramientas para el tratamiento y análisis sobre la base de datos de Excel

³ **GPU:** Es una sigla que significa "Graphics Processing Unit" en inglés, que se traduce al español como "Unidad de Procesamiento de Gráficos".

⁴ **Librería:** "Una biblioteca de programas es una colección de subrutinas convenientes que se han compilado y organizado para uso común, de modo que uno no necesite reescribirlos cada vez que se necesiten." (Knuth, 1997)

donde tenemos los datos almacenados y que por su bajo tamaño de 744Kb con 1.513 filas por 8 columnas puede ser ejecutado desde cualquier computadora de escritorio sin necesidad de requerir características especiales para su procesamiento. Las librerías usadas para tratamiento de los datos, series de tiempo y modelos fueron las siguientes:

- **Google.colab:** cargar los datos almacenados en la nube OneDrive⁵.
- **Numpy:** uso de algebra lineal
- **Pandas:** procesamiento de datos en formatos Excel
- **Random:** generar números aleatorios.
- **Datetime:** Manipulación de formatos de fechas.
- **Matplotlib:** Elaboración de gráficos.
- **Seaborn:** Mejorar el diseño de los gráficos.
- **Statsmodels:** modelos de pronóstico ARIMA, Holt Winters.
- **Prophet:** modelo de pronóstico de series de tiempo propuesto por Facebook.
- **Sklearn:** Calculo de métricas estadísticas (media, error cuadrático, promedio, etc.)
- **Bayes_opt:** optimización de parámetros para encontrar el mejor modelo.

Adicionalmente como restricción no se permitió la divulgación del nombre de la empresa, así como el nombre de los productos ni el uso de las variables monetarias como el precio de venta o la facturación, pues representan un riesgo para los intereses del negocio y los inversionistas de la empresa, por lo cual solo se nos permitió usar las variables de cantidades de unidades y usar los nombres de los productos anonimizados.

Para los costos y beneficios generados, este proyecto por ser de tipo académico no supone ningún costo para la empresa y los recursos utilizados de software son gratuitos, al tiempo

⁵ **Onedrive:** Es un servicio de almacenamiento en la nube desarrollado por Microsoft.

que las personas involucradas son los dos estudiantes que llevamos a cabo el trabajo para optar por el título de posgrado, así mismo el tutor asignado por la universidad la cual cubre sus honorarios por la asesoría.

Para los beneficios, no alcanzamos a calcular algún beneficio económico en cuanto a la reducción de inventarios, pero sí podemos suponerlo debido a que abordamos una de las causas principales que manifiesta la empresa que es mejorar la precisión de los pronósticos cuando la demanda del mercado decrece, y por tanto el error entre los valores predichos y los valores reales será menor, lo cual se traduce en una disminución de los inventarios, logrando que la empresa tenga un menor costo para el mantenimiento de los mismos.

8.1.3 Objetivos para la exploración de los datos

Los objetivos son:

- Identificar patrones estacionales, tendencias, errores, variaciones atípicas que puedan impactar sobre el correcto desempeño de los modelos.
- Encontrar el mejor modelo de pronóstico que se ajuste a la demanda de cada producto después de ser entrenado con los mejores parámetros.
- Predecir la demanda por producto para los siguientes 12 meses con el mínimo error entre las cantidades predichas y los valores reales aportando al mismo tiempo a la reducción de los niveles de inventario.

Como criterios de éxito del negocio será encontrar un mejor desempeño de sus pronósticos mediante otros métodos que permitan detectar nuevos patrones estacionales y una optimización de parámetros en los modelos de pronóstico.

8.2 Comprensión de los datos

La siguiente etapa nos servirá como guía para desarrollar el primer objetivo específico del trabajo que es organizar y anonimizar los datos disponibles para pronosticar la demanda Mensual. Comenzando con la recolección inicial de los datos que nos dará una primera perspectiva de la dimensión de cómo se abordará el problema, para luego empezar a familiarizarse con los datos, revisar la calidad de estos y así poder formular los primeros análisis e hipótesis.

8.2.1 Recolección de los datos






Los datos recolectados en este trabajo se refieren a la demanda que es equivalente a todos los pedidos realizados en los diferentes tipos de producto por cada tipo de cliente como grandes distribuidores donde son comercializados al por mayor y detal o clientes industriales que los utilizan como insumo para su producción, lo cual contiene información sensible de nombres de clientes y ventas en unidades, donde fue necesario realizar la anonimización de los productos así como el nombre de la empresa y sus clientes. A continuación, se muestra en la Tabla 4 el detalle de los productos agrupados por segmento.

Tabla 4: Productos por commodities, Fuente: Empresa

| Grupos de Productos | Total | Muestra para estudio |
|--|------------|----------------------------|
| Cintas flexográficas y de empalme | 43 | 1_Cinta Flexográfica |
| Cintas de espuma / Doble Faz | 30 | 1_Pegante Liquido |
| Cintas adhesivas delgadas | 15 | 1_Cinta Transferible |
| Cintas de Alta Resistencia | 10 | |
| Cintas de mejora y protección | 9 | 1_Cinta Sellado Térmico |
| Adhesivo termofusible y pulverizable | 7 | |
| Productos de protección contra incendios | 5 | |
| Selladores | 5 | |
| Adhesivos Estructurales | 4 | 1_Adhe Liquido Instantáneo |
| Etiquetas duraderas | 4 | |
| GTA VEC Venture | 1 | |
| Grand Total | 133 | 5 |

Por otra parte debido a la gran cantidad de productos no fue posible realizar el análisis para los 133 productos entregados y se seleccionó una muestra de los 5 más importantes que contenían información completa de demanda para todos los meses y adicionalmente que el pronóstico estadístico generado tuviese datos de buena calidad y coherentes con la demanda, debido a que esto es importante para el correcto funcionamiento y evaluación de cada uno de los modelos a experimentar y luego poder compararlos.

Tabla 5: Productos seleccionados para estudio, Fuente: Propia

| Producto Seleccionado | Imagen del Producto |
|---|---|
| 1_Adhe_Liq_Instantaneo: Utilizado para la unión de piezas de caucho y plásticos en la industria en general, metalmecánica, reparaciones, equipos de construcción, electrónicos, militar, transporte y aeroespacial. |  |
| 2_Cinta_Transferible”: Utilizado para la adhesión, unión, fijación, montaje y sostenimiento de varios materiales. Ideal para conversión de papel, iniciación de cores y materiales delgados flexibles. |  |
| 3_Cinta_Sellado_Termico_1: Cinta de fibra de vidrio utilizada en máquinas de sellado al calor y equipos de procesamiento en petroleros, farmacéuticas, químicos ofreciendo alta resistencia a la tensión y a la abrasión. |  |
| 4_Pegante_Liq_Doble_Faz: Promotor de adhesión para uso en conjunto con las cintas doble faz en varios plásticos, cauchos, sustratos metálicos pintados y no pintados. |  |
| 5_Cinta_flexo_1: Usado para necesidades básicas de impresión para tiradas cortas y cambios frecuentes. Ideal para imprimir combinaciones de sólidos y reproducción de tonos, donde el proceso de impresión de empaques o envolturas es importante. |  |

8.3 Descripción de los Datos

La empresa cuenta con dos clasificaciones de productos, los MTS (Make to Stock), que son aquellos que tienen una rotación mensual constante y se les calcula un pronóstico para los siguientes 12 meses, mientras que los MTO (Make to Order), son producidos solo bajo pedido cal ingresar una orden del cliente y este debe esperar hasta que sea producido en el exterior, despachado y recibido en Colombia, por consiguiente, no se les calcula ningún pronóstico por tener ventas son esporádicas. De esta manera nos enfocaremos solo en los productos MTS. A continuación, las descripciones de los campos de la base de datos:

- **Fecha:** Contiene la fecha del mes ejecutado en el formato día, mes, año, ejemplo “01/Ene/2017”, “01/Feb/2017”.
- **Nombre anonimizado:** Lleva el nombre de cada producto de forma anónima ejemplo: “1_Adhe_Liq_Instantaneo”, “2_Cinta_Transferible”.
- **Demanda real:** Pedidos recibidos por los clientes en unidades.
- **Pronostico estadístico:** Cantidades iniciales pronosticadas por el software utilizado por la empresa llamado “i2 Demand Manager”.
- **Pronostico final ajustado:** Ajuste final del pronóstico estadístico según reglas de negocio y de la experiencia del planeador de demanda con cada producto.

8.4 Exploración de los Datos

En esta fase se aplicaron pruebas estadísticas con el fin de examinar las características de los datos, como la presencia de estacionalidad, tendencias y estacionariedad, así como para visualizar las variaciones a lo largo de los 6 años de la demanda histórica. Así mismo para brindar una perspectiva sobre la consistencia y el comportamiento de los datos fue necesario dividir la serie en 6 colores para diferenciar cada año y tener hitos de referencia como los efectos producidos durante los años de pandemia para el 2020 y 2021.

El Gráfico 5, se observa el histórico de demanda del producto 1 presenta una estacionalidad en el 1er trimestre, donde los valores alcanzan su punto máximo en marzo. Sin embargo, en abril se produce una caída como resultado del alto volumen en ventas generado por el equipo comercial en el último mes del cierre trimestral para poder cumplir sus metas. Después de este descenso, la estacionalidad vuelve a repetirse en el 2do trimestre, pero para el 4to trimestre tiene un efecto contrario y decrece por los cambios en los hábitos de consumo para las fiestas Decembrinas.

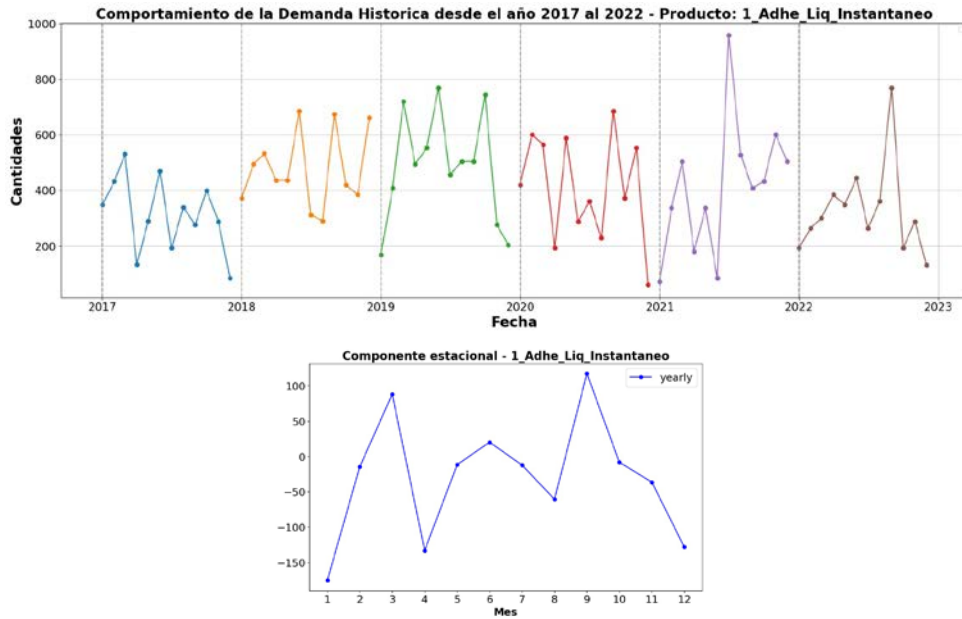


Gráfico 8: Demanda producto 1 y su componente estacional

De igual forma en la Gráfica 8 el periodo de pandemia para el año 2020 resaltado en color rojo parece haber afectado la tendencia creciente que se traía el desde el año 2017, sin embargo, estos datos no serán retirados y serán parte del entrenamiento para los modelos con el fin de lograr un modelo más robusto y evitar problemas de sobreajuste del modelo.

El Gráfico 6, se muestra que el producto 2 presenta altas variaciones en la demanda y no presenta estacionalidad, donde al ser comparado contra el componente estacional no se logró extraer ningún patrón en ninguno de los meses, solo una tendencia creciente del mes 1 al mes 12. De igual forma el periodo de pandemia aparece igual con variaciones y no presenta mayores efectos.

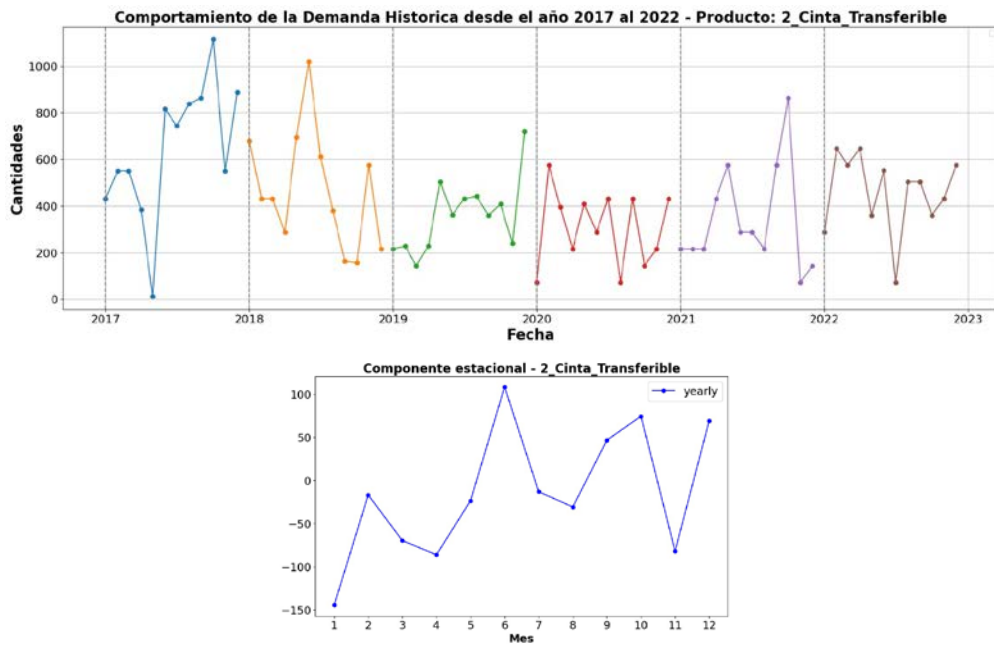


Gráfico 9: Demanda producto 2 y su componente estacional

Para el producto 3 presentado en el Gráfico 7 se observa una leve tendencia creciente y nuevamente una estacionalidad que se repite similar al producto 1 para los dos primeros trimestres del año según el componente estacion que se extrajo. Por otro lado el Periodo de pandemia del año 2020 no presenta efectos en la tendencia pero si lo hace para el año 2021 el cual la demanada presenta un decrecimiento y comienza a recuperarse en el 2022.

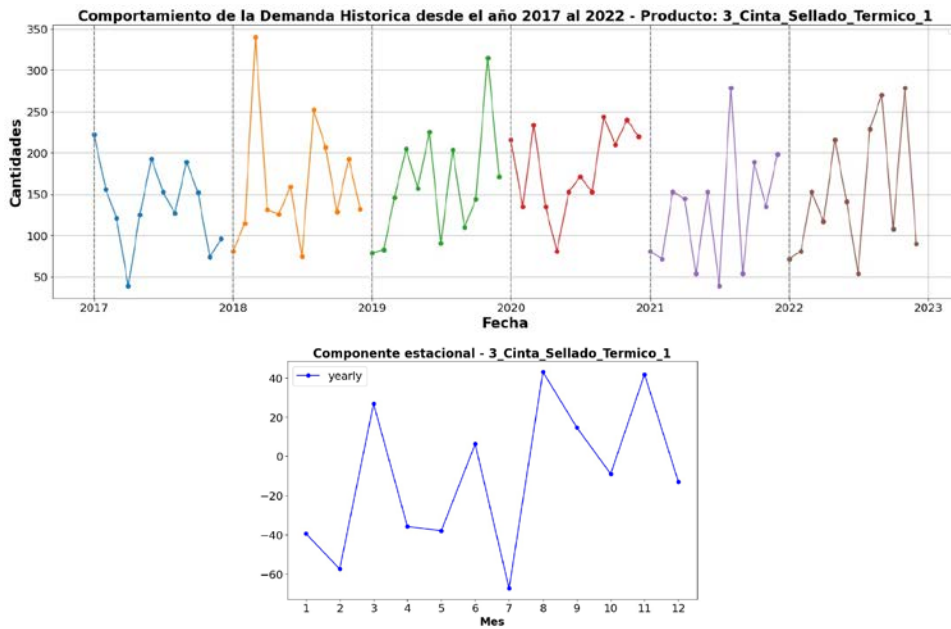


Gráfico 10: Demanda producto 3 y su componente estacional

En el Gráfico 8, se observa que el producto 4 experimenta un crecimiento constante durante los primeros tres años. Sin embargo, a partir del año 2020, en medio de la pandemia, sufre una caída en la demanda donde comienza a recuperarse gradualmente. Por tanto, es crucial que el modelo se entrene con datos de todos los años para capturar esta variación.

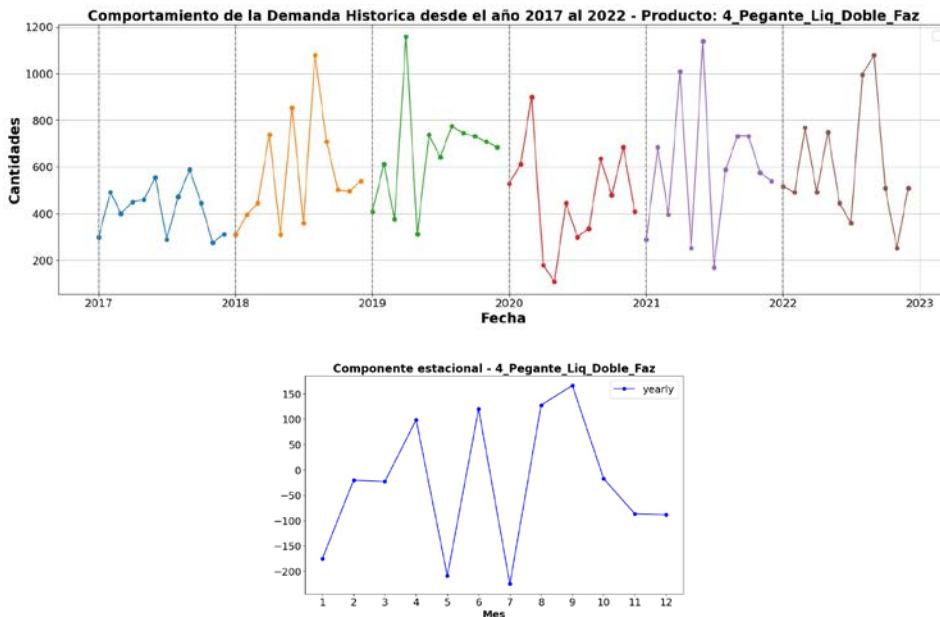


Gráfico 11: Demanda producto 4 y su componente estacional

Este ultimo producto del Gráfico 9, muestra una tendencia creciente en la que se observa que después de cada cierre de mes, que se caracteriza por un pico de ventas, el mes siguiente presenta un decrecimiento. Este patrón es común y se debe a que los clientes ya están abastecidos después de realizar una compra significativa en el mes anterior. Tambien se resalta el periodo de pandemia el cual presentó un crecimiento en la demanda para el año 2020 al ser un insumo utilizado para el empaquetado de productos de consumo masivo.




Gráfico 12: Demanda producto 5 y su componente estacional

8.4.1 Definicion del Base Line por producto

Con el objetivo de asegurar el suministro de productos a los clientes y alcanzar un nivel de servicio mínimo del 95%, la empresa proporciona un historial de pronosticos generados desde el año 2017 hasta el 2022, donde evalúa el rendimiento del pronóstico cada año utilizando la metrica de error MAPE. Estos registros seran nuestra linea base que servirán como punto de referencia para comparar el rendimiento de los modelos que se desarrollarán para evaluar el periodo del año 2022.




Gráfico 13: Demanda vs Pronóstico Empresa – Producto 1, Fuente: Propia

En el Gráfico 10, se muestra el comportamiento histórico de la demanda del producto 1, así como los resultados históricos de los pronósticos generados por el modelo de la empresa y la métrica MAPE de cada año. Es importante destacar que solo en el año 2019 la empresa logró alcanzar la meta con un valor del 31%. No obstante, en el año 2020 se registró el mayor error en los pronósticos para este producto, con un MAPE del 49%.




Gráfico 14: Demanda vs Pronóstico Empresa – Producto 2, Fuente: Propia

En la Gráfica 14, se puede observar que la empresa no logró alcanzar el objetivo de error mínimo del 35% en los últimos 6 años para el producto 2. Donde el año 2018 fue el de mayor error con un 65%, no obstante, el año 2022 presentó el valor más bajo de error con un 37% en comparación con los años anteriores.




Gráfico 15: Demanda vs Pronóstico Empresa – Producto 3, Fuente: Propia

En el producto 3 del Grafico 15 se puede apreciar un cumplimiento satisfactorio de la métrica de error MAPE en los años 2017, 2019 y 2020, siendo afectada en el año 2021 posiblemente por efectos del periodo de postpandemia y donde el consumo recién empezó a normalizarse a partir del año 2022, de igual forma el pronóstico generado presenta valores muy estables sin mayores variaciones.

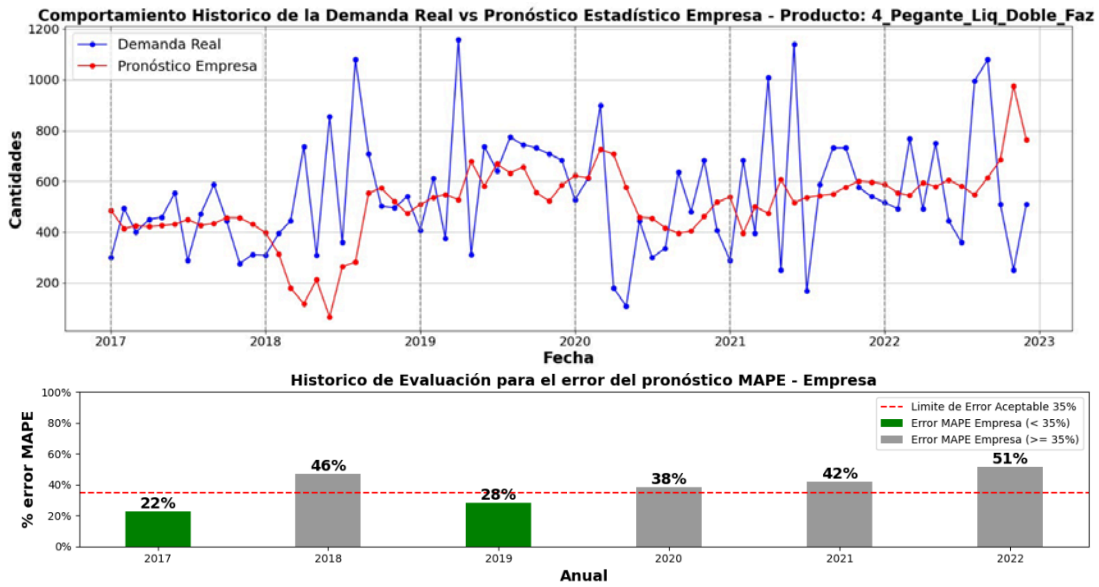


Gráfico 16: Demanda vs Pronóstico Empresa – Producto 4, Fuente: Propia

Para la Gráfica 16, al analizar los últimos 3 años desde el 2020 al 2022, se evidencia que el producto 3 no ha logrado alcanzar el objetivo establecido para la métrica de error. De hecho, se observa un incremento progresivo en los niveles de error durante este período y solo para el año 2017 y 2019 se logró cumplir el objetivo menor al 35%.

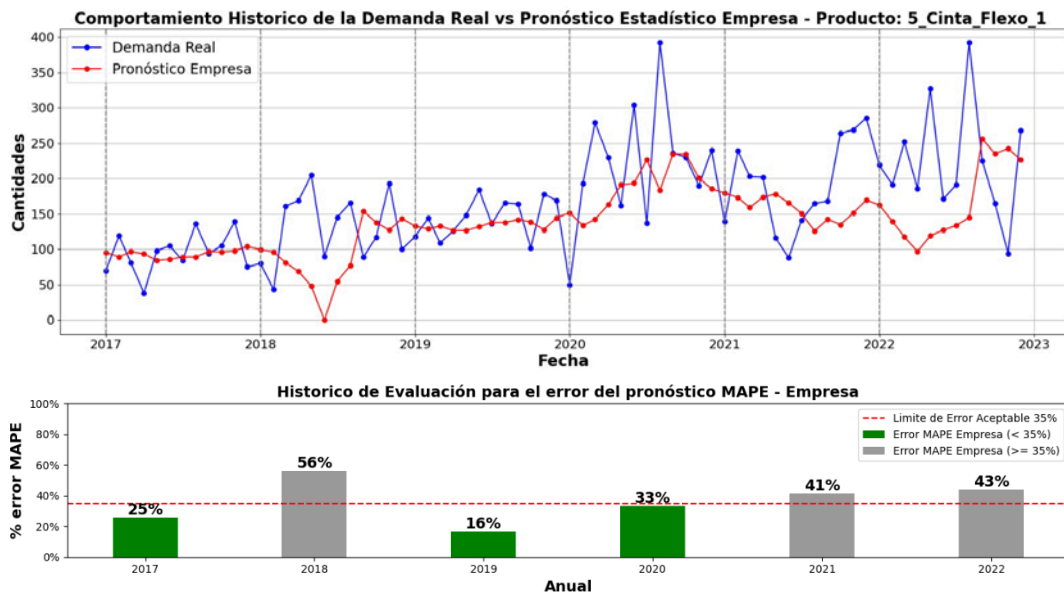


Gráfico 17: Demanda vs Pronóstico Empresa – Producto 5, Fuente: Propia

Este último producto, mostrado en la Gráfica 17, exhibe una tendencia ascendente en la métrica del error MAPE que inicia desde el 2019 y empeora cada año. Es importante destacar que, a pesar del desafiante periodo de pandemia, este producto logró mantener una buena métrica de error en el año 2020.

8.4.2 Verificar la Calidad de los Datos

Terminada la exploración de los datos identificamos que están completos y ningún mes presenta valores nulos, tampoco se encontraron errores, pero sí se detectaron ventas con meses atípicos ubicándose por fuera del rango normal a lo largo de toda la serie, por lo cual deben ser tratados como outliers⁶ más adelante. Esto nos permite continuar trabajando en el desarrollo de los siguientes puntos.

8.5 Preparación de los datos

A continuación, procedemos a la preparación de los datos para ajustarlos a las técnicas de minería de datos que serán utilizadas. Recordemos previamente que se seleccionó un subconjunto de 5 productos, los cuales se debe hacer un tratamiento previo de outliers para mejorar su calidad, así como añadir nuevos datos a partir de los existentes y darles el formato requerido por la herramienta de modelado.

8.5.1 Limpiar los Datos

Fue fundamental tratar los valores atípicos debido a que afectan los resultados y la precisión de los modelos utilizados. En el caso de los productos 2_Cinta_Transferible,

⁶ **Outlier:** “Es un valor atípico que se aleja significativamente del resto de los valores en un conjunto” (Tukey, 1977)

4_Pegante_Liq_Doble_Faz y 6_Cinta_Flexo_1, se detectaron varios picos de demanda generados por descuentos en precios realizados por la empresa para evacuar rápidamente excesos de inventario y evitar su destrucción por obsolescencia o baja rotación.

Por lo cual se aplicó la técnica de la mediana que resulta ser un método robusto y sencillo que permite identificar y corregir valores atípicos en una serie de datos, dicha técnica se realizó mediante la herramienta de Google Colab llamada `numpy.median()` de la biblioteca NumPy del lenguaje de programación de Python, Donde una vez identificados los datos atípicos, se reemplazaron por el valor de la mediana obteniendo una serie de tiempo más suavizada y representativa de la demanda real.

8.5.2 Construir los Datos

Se crearon los campos referentes a los resultados de las métricas del desempeño del pronóstico estadístico de la empresa según la historia proporciona para cada año (MAPE, RMSE y WAPA del pronóstico estadístico), para luego ser comparados con los resultados que obtuvimos en los modelos propuestos y adicionalmente definir nuestro Base Line.

También se dividieron los datos en una parte para entrenamiento y otra para evaluación utilizando el proceso de backtesting, que consiste en evaluar el comportamiento de un modelo predictivo al aplicarlo de forma retrospectiva sobre datos históricos. Por lo tanto, es una estrategia de validación que permite cuantificar la capacidad predictiva de un modelo que se entrena cada vez antes de realizar las predicciones, incorporando la información mediante un conjunto de entrenamiento constante y la ventana de tiempo que abarca siempre se desplaza. Esta estrategia se conoce como *walk-forward validation*. (Joaquín Amat Rodrigo, 2021)

Proporción (75% - 25%), 36 meses de entrenamiento y 12 de evaluación

| Periodo Móvil | Meses | Entrenamiento Ventana Móvil | | Periodo Congelado Lag 2 | | Evaluación Mes Pronosticado |
|---------------|-------|-----------------------------|----------|-------------------------|----------|-----------------------------|
| | | Inicio | Fin | Inicio | Fin | |
| 1 | 36 | nov-2018 | oct-2021 | nov-2021 | dic-2021 | ene-2022 |
| 2 | 36 | dic-2018 | nov-2021 | dic-2021 | ene-2022 | feb-2022 |
| 3 | 36 | ene-2019 | dic-2021 | ene-2022 | feb-2022 | mar-2022 |
| 4 | 36 | feb-2019 | ene-2022 | feb-2022 | mar-2022 | abr-2022 |
| 5 | 36 | mar-2019 | feb-2022 | mar-2022 | abr-2022 | may-2022 |
| 6 | 36 | abr-2019 | mar-2022 | abr-2022 | may-2022 | jun-2022 |
| 7 | 36 | may-2019 | abr-2022 | may-2022 | jun-2022 | jul-2022 |
| 8 | 36 | jun-2019 | may-2022 | jun-2022 | jul-2022 | ago-2022 |
| 9 | 36 | jul-2019 | jun-2022 | jul-2022 | ago-2022 | sep-2022 |
| 10 | 36 | ago-2019 | jul-2022 | ago-2022 | sep-2022 | oct-2022 |
| 11 | 36 | sep-2019 | ago-2022 | sep-2022 | oct-2022 | nov-2022 |
| 12 | 36 | oct-2019 | sep-2022 | oct-2022 | nov-2022 | dic-2022 |

Backtesting con Tamaño de Entrenamiento constante y Ventana de Tiempo Móvil




Gráfico 18: Ventana Móvil para 36 meses de entrenamiento

También la empresa utiliza para su modelo actual un solo rango de entrenamiento de 36 meses, pero para efectos del trabajo se decidió explorar adicionalmente con 48 y 60 meses para tratar de encontrar mejores resultados. Además, utilizan un periodo congelado o "lag 2" de dos meses donde el pronóstico permanece fijo y no se permite realizar modificaciones en este tiempo, debido a que este periodo se utiliza para evaluar la efectividad del pronóstico y compararlo con los resultados reales sin intervenciones adicionales.

Proporción (80% - 20%), 48 meses de entrenamiento y 12 de evaluación

| Periodo Móvil | Meses | Entrenamiento Ventana Móvil | | Periodo Congelado Lag 2 | | Evaluación Mes Pronosticado |
|---------------|-------|-----------------------------|----------|-------------------------|----------|-----------------------------|
| | | Inicio | Fin | Inicio | Fin | |
| 1 | 48 | nov-2017 | oct-2021 | nov-2021 | dic-2021 | ene-2022 |
| 2 | 48 | dic-2017 | nov-2021 | dic-2021 | ene-2022 | feb-2022 |
| 3 | 48 | ene-2018 | dic-2021 | ene-2022 | feb-2022 | mar-2022 |
| 4 | 48 | feb-2018 | ene-2022 | feb-2022 | mar-2022 | abr-2022 |
| 5 | 48 | mar-2018 | feb-2022 | mar-2022 | abr-2022 | may-2022 |
| 6 | 48 | abr-2018 | mar-2022 | abr-2022 | may-2022 | jun-2022 |
| 7 | 48 | may-2018 | abr-2022 | may-2022 | jun-2022 | jul-2022 |
| 8 | 48 | jun-2018 | may-2022 | jun-2022 | jul-2022 | ago-2022 |
| 9 | 48 | jul-2018 | jun-2022 | jul-2022 | ago-2022 | sep-2022 |
| 10 | 48 | ago-2018 | jul-2022 | ago-2022 | sep-2022 | oct-2022 |
| 11 | 48 | sep-2018 | ago-2022 | sep-2022 | oct-2022 | nov-2022 |
| 12 | 48 | oct-2018 | sep-2022 | oct-2022 | nov-2022 | dic-2022 |

Backtesting con Tamaño de Entrenamiento constante y Ventana de Tiempo Móvil




Gráfico 19: Ventana Móvil para 48 meses de entrenamiento

Proporción (83% - 17%), 60 meses de entrenamiento y 12 de evaluación

| Periodo Móvil | Meses | Entrenamiento Ventana Móvil | | Periodo Congelado Lag 2 | | Evaluación |
|---------------|-------|-----------------------------|----------|-------------------------|----------|------------------|
| | | Inicio | Fin | Inicio | Fin | Mes Pronosticado |
| 1 | 60 | nov-2016 | oct-2021 | nov-2021 | dic-2021 | ene-2022 |
| 2 | 60 | dic-2016 | nov-2021 | dic-2021 | ene-2022 | feb-2022 |
| 3 | 60 | ene-2017 | dic-2021 | ene-2022 | feb-2022 | mar-2022 |
| 4 | 60 | feb-2017 | ene-2022 | feb-2022 | mar-2022 | abr-2022 |
| 5 | 60 | mar-2017 | feb-2022 | mar-2022 | abr-2022 | may-2022 |
| 6 | 60 | abr-2017 | mar-2022 | abr-2022 | may-2022 | jun-2022 |
| 7 | 60 | may-2017 | abr-2022 | may-2022 | jun-2022 | jul-2022 |
| 8 | 60 | jun-2017 | may-2022 | jun-2022 | jul-2022 | ago-2022 |
| 9 | 60 | jul-2017 | jun-2022 | jul-2022 | ago-2022 | sep-2022 |
| 10 | 60 | ago-2017 | jul-2022 | ago-2022 | sep-2022 | oct-2022 |
| 11 | 60 | sep-2017 | ago-2022 | sep-2022 | oct-2022 | nov-2022 |
| 12 | 60 | oct-2017 | sep-2022 | oct-2022 | nov-2022 | dic-2022 |

Backtesting con Tamaño de Entrenamiento constante y Ventana de Tiempo Móvil




Gráfico 20: Ventana Móvil para 60 meses de entrenamiento

La ventaja de este proceso de entrenamiento aditivo es que el modelo incorpora la última información disponible por lo que ayuda a incrementar la capacidad predictiva con el tiempo.

8.6 Modelado

En este punto abordamos el segundo objetivo específico donde se identificaron los modelos de series de tiempo utilizados para pronosticar las ventas en periodos mensuales probando diferentes técnicas hasta encontrar la más apropiada y finalmente evaluar si el modelo cumplió los criterios de éxito.

8.6.1 Escoger la Técnica de Modelado

Como el problema que queremos resolver es de predicción de valores continuos de series de tiempo utilizando valores históricos, tenemos por un lado los modelos de estadística tradicional como **medias móviles**, **suavizamiento exponencial triple (Holt Winters)**, **ARIMA**, y por otra parte tenemos el **Prophet** que utiliza algunos elementos de aprendizaje

automático, donde su enfoque se basa en gran medida en técnicas estadísticas clásicas y no en redes neuronales profundas u otros enfoques más avanzados de inteligencia artificial.

Algo para tener en cuenta es que actualmente la empresa utiliza el mismo modelo de pronóstico para todos sus productos, el cual es generado con el software “i2 Demand Manager” y se basa en modelos de estadística tradicional.

8.6.2 Generar el plan de prueba

Este punto se alinea con nuestro siguiente objetivo específico que consiste en definir un protocolo de evaluación que permita estimar el desempeño de los modelos seleccionados.

Tabla 6: Métricas para el protocolo de evaluación, Fuente: Propia

| Métrica | Objetivo | Resultado |
|---|--|--|
| RMSE (Root Mean Squared Error/ error cuadrático medio) | medir el error cuadrático medio de las predicciones del modelo en relación con los valores reales observados. | Entre menor sea el valor del RMSE, mejor será la precisión del modelo. |
| MAPE (Mean Absolute Percentage Error/ Error Porcentual Absoluto medio Ponderado) | Calcular la media de los errores absolutos porcentuales de todas las observaciones. | Un valor menor de MAPE indica una mayor precisión del modelo. |
| WAPA (Weighted Absolute Percent Accuracy/ Precisión porcentual absoluta ponderada) | Es propia de la empresa y se calcula como la diferencia entre el uno y el error, $WAPA = (1 - MAPE)$ lo cual indica la Precisión del pronóstico. | Un valor mayor de WAPA indica una mayor precisión del modelo. |

8.6.3 Construir el Modelo

Iniciamos por ejecutar los 4 modelos en los 3 rangos de datos de entrenamiento y para cada producto. Donde se fueron ajustando los diferentes parámetros de cada modelo con

la ayuda del proceso de optimización bayesiana⁷ el cual realiza varias iteraciones hasta encontrar los mejores parámetros con los que se logra el mejor resultado de la métrica MAPE.

Para aplicar las distintas técnicas de modelado en python, estas fueron ejecutadas en 5 notebooks⁸, uno por producto para ser procesados en códigos independientes, teniendo un mejor orden de estos y evitando errores por cruces de series de tiempo entre productos, adicionalmente nos permitió tener los resultados por separado con los siguientes pasos:

1. Inicializamos en Google Colab las librerías⁹ que contienen las herramientas para procesar los datos y los modelos.
2. Cargar los datos dese Excel al notebook de Google Colab.
3. Se ajustaron los datos con los formatos necesarios para tratar series de tiempo
4. Se realizó el análisis exploratorio de las 5 series de tiempo y se extrajo la información de tendencias, estacionalidad, entre otras.
5. Se dividieron los datos de entrenamiento en 36, 48 y 60 meses y 12 de evaluación.
6. Se cargaron los datos al modelo y se inicializa con parámetros aleatorios para probar su funcionamiento, primeros resultados y corregir errores de código.
7. Luego se ejecuta el modelo utilizando la función Bayesiana para detectar los mejores parámetros que nos entregan un menor error de la métrica MAPE.
8. Se entrena el modelo con los mejores parámetros (Ver Tabla 7, 8) y se guarda cada resultado con las predicciones del año 2022 por producto, modelo y entrenamiento.

⁷ **Optimización Bayesiana:** "La optimización bayesiana es un enfoque para encontrar el óptimo global de una función objetivo costosa, que se basa en la construcción de un modelo probabilístico de la función objetivo y en la iteración entre la exploración y la explotación para guiar la búsqueda eficientemente." (Shahriari B, 2016)

⁸ **Notebooks:** Es un entorno interactivo que permite combinar código, texto explicativo, visualizaciones y otros elementos en un solo documento.

⁹ **Librerías:** "Una librería en Python es un conjunto de módulos y funciones predefinidas que proporcionan una amplia gama de funcionalidades para realizar tareas específicas." (McKinney, 2018)

9. Finalmente se calculan las métricas MAPE, WAPA y RMSE utilizando los valores predichos y los reales para cada técnica, donde son guardados en una tabla para compararlos contra los resultados del modelo actual que utiliza la empresa.
10. Se grafican los resultados para comparar visualmente el desempeño de los patrones de estacionalidad, tendencias y errores en cada uno de los 12 meses del periodo de evaluación para el pronóstico generado, los valores reales de demanda y el pronóstico que genero la empresa con su modelo actual.

Tabla 7: Parámetros usados para el mejor modelo - Producto 1 y 3

| Mejor Modelo: Prophet | | Producto 1 | Producto 3 |
|--------------------------|------------------------------|------------------------|---------------------------|
| Nombre Producto: | | 1_Adhe_Liq_Instantaneo | 3_Cinta_Sellado_Termico_1 |
| Entrenamiento | 36, 48, 60 Meses | 48 Meses | |
| Pbouns | | | |
| changeoint_prior_scale: | (0.0001, 0.2) | 0.0281 | 0.1440 |
| seasonality_prior_scale: | (0.01, 50) | 26.66 | 20,87 |
| growth: | 'linear', 'logistic' | linear | linear |
| seasonality_mode: | 'additive', 'multiplicative' | multiplicative | multiplicative |
| n_changeoints: | | None | None |
| holidays | | None | None |
| seasonality: | 'yearly', 'weekly', 'daily' | yearly | yearly |
| mes_1: | (0.0001 , 1) | 0,601 | -0,395 |
| mes_2: | | 0,753 | -0,309 |
| mes_3: | | 0,789 | -0,206 |
| mes_4: | | -0,830 | 0,078 |
| mes_5: | | -0,922 | -0,162 |
| mes_6: | | -0,660 | 0,370 |
| mes_7: | | 0,756 | -0,591 |
| mes_8: | | -0,803 | 0,756 |
| mes_9: | | -0,158 | -0,945 |
| mes_10: | | 0,937 | -0,706 |
| mes_11: | | -0,373 | -0,815 |
| mes_12: | | 0,385 | -0,627 |
| Target | MAPE % | 29,7% | 21,8% |

Tabla 8: Parámetros usados para el mejor modelo en el Producto 2

| Mejor Modelo: Holt-Winters | | |
|-----------------------------------|---------------------|----------------------|
| Parametros | Rangos | Producto 2 |
| Nombre Producto: | | 2_Cinta_Transferible |
| Entrenamiento | 36, 48, 60 Meses | 48 Meses |
| Pbouns | | |
| alpha: | (0.001, 0.02) | 0,010 |
| beta: | (0.0001, 0.03) | 0,017 |
| gamma: | (0.001, 0.02) | 0,012 |
| seasonal_periods | 12 | 12 |
| error | add', 'mul' | add |
| trend | add', 'mul', 'None' | mul |
| seasonal | add', 'mul', 'None' | None |
| Target: | MAPE % | 27,4% |

Tabla 9: Parámetros usados para el mejor modelo en los Productos 4 y 5

| Mejor Modelo: ARIMA | | |
|--|-------------------------|-----------------|
| Parametros | Producto 4 | Producto 5 |
| Nombre Producto: | 4_Pegante_Liq_Doble_Faz | 5_Cinta_Flexo_1 |
| Entrenamiento: | 36 Meses | 60 Meses |
| Pbouns | | |
| p: (0 ,1) - Componente autoregresivo | 1 | 0 |
| d: (0 ,1) - Orden de diferenciación | 1 | 0 |
| q: (0 ,1) - Componente de media móvil | 1 | 0 |
| P: (0 ,1) - Componente autoregresivo Estacional | 0 | 1 |
| D: (0 ,1) - Orden de diferenciación Estacional | 0 | 0 |
| Q: (0 ,1) - Componente de media móvil Estacional | 0 | 0 |
| S: (12 ,12) - Periodicidad estacional | 12 | 12 |

8.6.4 Resultados de cada técnica

Estos fueron los resultados para los 4 modelos en los 5 productos y en los 3 rangos de entrenamiento definidos, donde se observa que entre mayor es el tiempo de entrenamiento se logra obtener un menor porcentaje de error (MAPE) al pasar de 36 a 48 meses, sin embargo, con 60 meses no sucedió lo mismo y por lo contrario tanto el error como el RMSE aumentaron levemente (Ver Gráfico 21).

| Modelo | Producto | Meses Entrenamiento | | |
|------------------|---------------------------|---------------------|------|------|
| | | 36 | 48 | 60 |
| Baseline Empresa | 1 Adhe Liq Instantaneo | 45,3 | | |
| | 2 Cinta Transferible | 37 | | |
| | 3 Cinta Sellado Termico 1 | 46 | | |
| | 4 Pegante Liq Doble Faz | 51 | | |
| | 5 Cinta Flexo 1 | 43 | | |
| Promedio movil | 1 Adhe Liq Instantaneo | 49,3 | 51,4 | 47,8 |
| | 2 Cinta Transferible | 35,7 | 36,7 | 31,4 |
| | 3 Cinta Sellado Termico 1 | 44,6 | 42,3 | 43,8 |
| | 4 Pegante Liq Doble Faz | 32,3 | 32,2 | 30,9 |
| | 5 Cinta Flexo 1 | 25,4 | 28,7 | 28,2 |
| Arima | 1 Adhe Liq Instantaneo | 44,4 | 45,5 | 48,6 |
| | 2 Cinta Transferible | 34,2 | 33,3 | 32,7 |
| | 3 Cinta Sellado Termico 1 | 36,9 | 30,3 | 36,1 |
| | 4 Pegante Liq Doble Faz | 29,2 | 32,8 | 31,6 |
| | 5 Cinta Flexo 1 | 25,6 | 25,5 | 23,6 |
| Holt Winters | 1 Adhe Liq Instantaneo | 35,4 | 33,4 | 31,1 |
| | 2 Cinta Transferible | 31,2 | 27,8 | 33,5 |
| | 3 Cinta Sellado Termico 1 | 36,6 | 25,4 | 39 |
| | 4 Pegante Liq Doble Faz | 39,2 | 31 | 31,2 |
| | 5 Cinta Flexo 1 | 24,6 | 25,2 | 29,6 |
| Prophet | 1 Adhe Liq Instantaneo | 30,4 | 29,6 | 30,9 |
| | 2 Cinta Transferible | 32,3 | 33,3 | 38,8 |
| | 3 Cinta Sellado Termico 1 | 33,5 | 21,7 | 26,9 |
| | 4 Pegante Liq Doble Faz | 32,8 | 34,7 | 34,3 |
| | 5 Cinta Flexo 1 | 26,9 | 26,4 | 27,1 |
| | | 36 | 48 | 60 |
| | | Meses Entrenamiento | | |


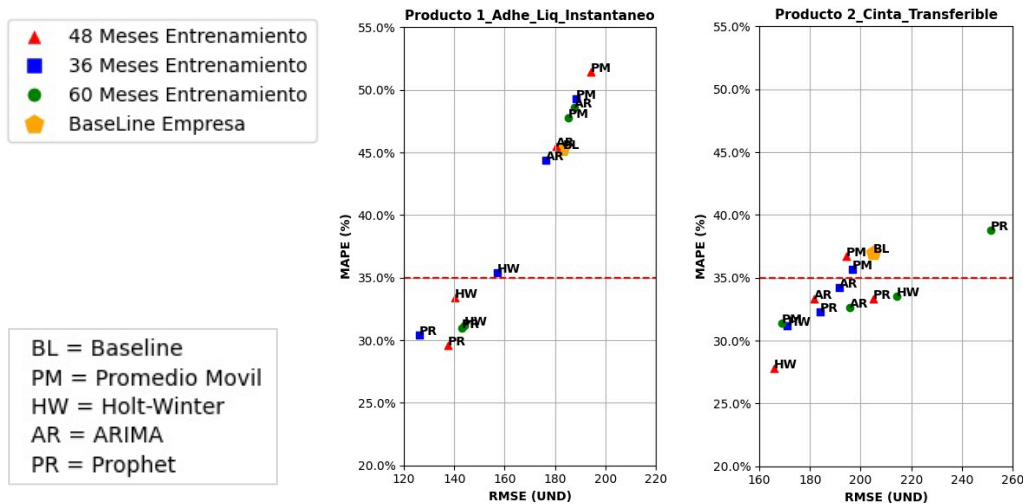


Gráfico 21: Resultados por Modelo para todos los productos

En resumen, los modelos Prophet y Holt-Winters demostraron un buen rendimiento en varios productos, mientras que el Modelo de Promedio móvil presentó dificultades en el primer producto. El modelo Prophet fue especialmente efectivo en el tercer producto, y el Modelo Holt-Winters destacó en el cuarto producto. A excepción del Promedio Móvil, todos los modelos cumplieron con el objetivo establecido de un error inferior al Baseline.



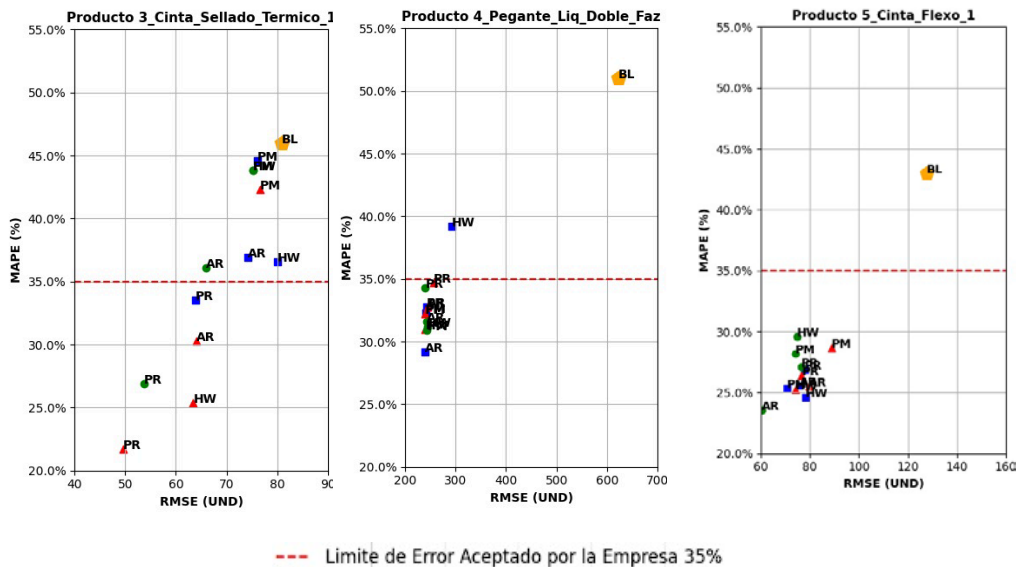


Gráfico 22: Resultado de Métricas de evaluación por producto en cada modelo

En la Gráfica 22, se presentan los resultados de los modelos por producto comparando el MAPE y el RMSE obtenido en los diferentes periodos de entrenamiento, a continuación, algunos puntos importantes a destacar:

- Para el primer producto, los modelos Prophet y Holt-Winters lograron cumplir con el error máximo permitido del 35% y superaron el Baseline de la empresa.
- En el segundo producto, todos los modelos, excepto el Modelo de Promedio móvil, cumplieron con el error del 35%.
- En el tercer producto, se observó que el modelo Prophet fue el más efectivo, logrando un error menor al 35% en los tres periodos de entrenamiento.
- En el cuarto producto, el Modelo ARIMA obtuvo una mínima ventaja en el (MAPE) durante los 36 meses de entrenamiento.
- Para el último producto, todos los modelos cumplieron con el objetivo de un error inferior al 35%, con resultados similares y superando el Baseline de la empresa.

Finalmente se calculó el promedio de los resultados del MAPE para ser comparados con los resultados del modelo utilizado por la empresa y el cual fue definido como nuestro Baseline, obteniendo como mejor resultado el modelo Prophet con un error promedio del 30.6%, seguido por el Modelo Holt-Winters con solo 1% de diferencia y en tercer lugar el modelo ARIMA con 34% como se muestra en la Gráfica 23.




Gráfico 23: Comparación del promedio final del MAPE por modelo

9 Evaluación

Ahora desarrollaremos nuestro último objetivo específico que nos permitió evaluar y seleccionar el mejor modelo de series de tiempo para cada producto que permitan pronosticar la demanda de las ventas de forma mensual.

9.2 Resultados utilizando mejores técnicas

Teniendo como base el menor resultado de porcentaje de error (MAPE) y menor unidades de (RMSE) obtenido de cada modelo esta es la selección final del mejor modelo para cada producto y su mejora obtenida comparada contra el modelo actual:




Gráfico 24: Resultados de los Mejores Modelos por Producto según MAPE

En general se logró una mejora del indicador MAPE en un -18%, obteniendo un error promedio de los 5 productos del 26.4% y un asertividad WAPA que recordemos es el indicador como lo mide la empresa del 73.6%.

Tabla 10: Resumen de resultados para las métricas del protocolo de evaluación

| Producto | Modelo Empresa (Pronóstico Estadístico) | | | | Mejor modelo | | | | | Diferencia lograda en % MAPE |
|---------------------------|---|------|--------|--------|--------------|----------------|------|--------|--------|------------------------------|
| | Meses de Train | RMSE | % MAPE | % WAPA | Mejor Modelo | Meses de Train | RMSE | % MAPE | % WAPA | |
| 1_Adhe Liq Instantaneo | 36 | 183 | 45,3% | 54,7% | Prophet | 48 | 138 | 29,6% | 70,4% | 16% |
| 2_Cinta Flexo 1 | 36 | 205 | 37,0% | 63,0% | Holt Winters | 48 | 166 | 27,8% | 72,2% | 9% |
| 3_Cinta Sellado Termico 1 | 36 | 81 | 46,0% | 54,0% | Prophet | 48 | 50 | 21,7% | 78,3% | 24% |
| 4_Pegante Liq Doble Faz | 36 | 622 | 51,0% | 49,0% | ARIMA | 36 | 239 | 29,2% | 70,8% | 22% |
| 5_Cinta Flexo 1 | 36 | 127 | 43,0% | 57,0% | ARIMA | 60 | 76 | 23,6% | 76,4% | 19% |

9.3 Pronósticos para el año 2022 según el mejor modelo

Para nuestro primer producto el modelo Prophet logra capturar el patrón de estacionalidad que se presenta trimestralmente y como resultado se obtiene un pronóstico muy similar a la demanda real como se observa en la siguiente Gráfica 25:




Gráfico 25: Pronóstico generado por modelo Prophet para el Producto 1

Nuestro segundo producto se ajustó más al modelo Holt-Winter donde a partir del mes de mayo sus valores pronosticados fueron muy cercanos a los reales (Ver Gráfico 26).




Gráfico 26: Pronóstico generado por modelo Holt-Winter para el Producto 2

En el tercer producto el Modelo Prophet logra ajustarse a los cambios estacionales de la demanda y solo en mayo, agosto y septiembre presentó diferencias (Ver Gráfico 27).




Gráfico 27: Pronóstico generado por modelo Prophet para el Producto 3

Es el siguiente Gráfico 28, tenemos el modelo ARIMA que se ajusta a la estacionalidad de los meses desde enero hasta junio de 2022.




Gráfico 28: Pronóstico generado por modelo ARIMA para el Producto 4

Finalmente, el último producto el Modelo ARIMA muestra un pronóstico con tendencia creciente pero no logra mostrar un patrón claro de estacionalidad.




Gráfico 29: Pronóstico generado por modelo ARIMA para el Producto 5

10 Despliegue

Debido al alcance del proyecto no alcanzamos a desarrollar todos los puntos de la metodología CRISP-DM, por eso para este último punto realizaremos algunas recomendaciones de cómo realizar un despliegue del modelo.

Como la empresa cuenta con un servicio de datawarehouse¹⁰ llamado snowflake¹¹, en el cual se encuentran almacenados en la nube todos los datos de demanda y pronósticos, se recomienda hacer el despliegue del modelo haciendo uso del siguiente servicio:

- **AWS SageMaker**: es una integración de snowflake con AWS¹² el cual ofrece un servicio que permite construir, entrenar y desplegar modelos en la nube de forma sencilla, ya que el modelo se entrena y se despliega en una sola plataforma integrada, permitiendo que varios usuarios colaboren en el mismo modelo.

¹⁰ **Datawarehouse**: "Es una colección de datos orientada a temas, integrada, no volátil y variable en el tiempo, que se utiliza para el soporte de la toma de decisiones en una organización." (Inmon, 2005)

¹¹ **Snowflake**: "Es una plataforma de almacenamiento de datos en la nube que proporciona un enfoque único y moderno para el almacenamiento y análisis de datos." (Avila, 2021)

¹² **AWS**: Amazon Web Services, que es una plataforma de servicios en la nube ofrecida por Amazon. AWS proporciona una amplia gama de servicios en la nube, que incluyen almacenamiento, computación, bases de datos, análisis, redes, inteligencia artificial, aprendizaje automático, Internet de las cosas (IoT) y muchas otras funcionalidades.

Conclusiones

Podemos concluir que según el análisis de resultados de cada modelo, logramos explorar su comportamiento en los diferentes productos, parámetros y rangos de entrenamiento, así mismo conocimos todo el tiempo que se requiere para su tratamiento de los datos, análisis y entrenamiento del modelo, encontrando finalmente que los modelos Holt-Winters y Prophet fueron los de mejor rendimiento con base a las métricas de evaluación MAPE, RMSE y WAPA, logrando el mínimo error entre los valores reales y los pronosticados superando los resultados del modelo actual que utiliza la empresa.

Dichos modelos mostraron un buen comportamiento al ser utilizados con productos que presentaron patrones leves de estacionalidad, datos faltantes, cambios en la tendencia, y cambios repentinos o atípicos en la demanda, ayudándonos a explicar cómo es el comportamiento de nuestros datos anualmente. Esto lo pudimos comprobar con los productos 1 y 3 donde el modelo Prophet fue el mejor y para el producto 2 fue el caso del Holt-Winters, mientras que en un tercer lugar se ubicaron los modelos ARIMA.

Por otra parte, la técnica de entrenamiento del modelo actual al usar solo 36 meses de entrenamiento no es suficiente para obtener el mejor rendimiento del modelo y esto lo pudimos demostrar al probar con un entrenamiento de 48 y 60 meses, donde si fuera necesario elegir un solo rango para todos los productos sería de 48 meses donde se obtuvo la mayor parte de los mejores resultados.

Finalmente se obtuvo una disminución del -18% sobre el error promedio de los 5 productos el cual paso de un 44.5% a un 26.4% y el asertividad (WAPA) que recordemos es el

indicador como lo mide la empresa paso de un 55.5% a un 73.6%, con lo que podemos concluir que se cumplió con el objetivo del proyecto.

Si bien estos modelos funcionan muy bien con datos históricos se debe tener en cuenta que la revisión posterior y ajuste con el negocio es importante, debido a que la demanda estará en constante cambio y será necesario identificar las variables futuras que no pueden capturar los modelos y que solo podrán ser adquiridas con la comunicación con el negocio, permitiendo obtener un mejor balance entre los valores predichos y reales que tendrá como resultado unos niveles adecuados de inventario.

Bibliografía

- Agudelo, L. E. (2020). *Anovulación y amorrea secundaria: enfoque fácil y practico* Revista Med. Nueva Granada. Bogotá, Colombia: Editorial Neogranadina.
- Alegre Ibáñez, V., & Lozano Aparicio, J. (2022). *APLICACIÓN DE MÉTODOS DE DEEP LEARNING EN SERIES DE TIEMPO PARA EL PRONÓSTICO DE LA SITUACIÓN MACROECONÓMICA EN AMÉRICA LATINA*. Perú: Universidad Nacional de Ingeniería .
- Almeyda, E. M. (2022). *Pronóstico de la demanda internacional del banano orgánico de Perú usando algoritmos de Machine Learning*. FACULTAD DE INGENIERÍA UNIVERSIDA DE PIURA.
- Alonso, J. C. (2021). *Introducción a los pronósticos con modelos estadístico de series de tiempo para científico de datos (en R)*. Primera Versión para comentarios 8 de septiembre de 2021.
- Avila, J. K. (2021). Building the Snowflake Data Cloud: Monetizing and Democratizing Your Data. En J. K. Avila, *Monetizing and Democratizing Your Data*.
- Bermudez Cespedes, J., Zapata Betancur, V., Lopera Toro, M., & Rodríguez Guevara, D. (2022). *Análisis de tipo de cambio en las monedas latinoamericanas atraves modelos ARIMA Y Redes Neuronales*. México: INSTITUTO TECNOLÓGICO METROPOLITANO.
- Buitrago López, Y. A., & Másmela Caita, L. (2022). Pronóstico del COVID-19 en Colombia utilizando RedesNeuronales Recurrentes con celdas de gran memoria decorto plazo y unidades recurrentes cerradas. En *Comunicaciones en Estadística* (págs. 16–38). Colombia: Universidad de Santo Tomas.

- Cerpa, P. S. (2021). "Proyecciones de producción de cobre considerando consumo de agua, energía y emisiones de gases de efecto invernadero, con redes neuronales recurrentes". CHILE: UNIVERSIDAD DE CONCEPCIÓN - CHILE FACULTAD DE INGENIERÍA DEPARTAMENTO DE INGENIERÍA INDUSTRIAL .
- Cortina, V. G. (2015). *APLICACIÓN DE LA METODOLOGÍA CRISP-DM A UN PROYECTO DE MINERÍA DE DATOS EN EL ENTORNO UNIVERSITARIO* . Madrid: Universidad Carlos III .
- Duong, C. (2023). facebook/prophet in 2023 and beyond. *prophet in 2023 and beyond*.
- Esquivias, P. H. (2021). *ANÁLISIS DE SENTIMIENTOS EN CASTELLANO CON REDES NEURONALES LSTM*. Madrid: Universidad Carlos III de Madrid. Departamento de Informática.
- Fuentes, N. R. (2022). *UNA APROXIMACIÓN AL ANÁLISIS EXPLORATORIO DE DATOS*. España: Universidad de Valladolid.
- Hyndman, R. J. (2006). *Another look at measures of forecast accuracy.*" *International journal of forecasting*,.
- IBM. (15 de Agosto de 2015). *¿Qué es el análisis exploratorio de datos?* Obtenido de Análisis exploratorio de datos: <https://www.ibm.com/mx-es/topics/exploratory-data-analysis>
- IBM, C.-D. (2021). *Introducción CRISP-DM*.
- Inmon, W. H. (2005). *Building the Data Warehouse*, Fourth Edition. En W. H. Inmon, *Building the Data Warehouse*.
- Joaquín Amat Rodrigo, J. E. (Febrero de 2021). *Skforecast: forecasting series temporales con Python y Scikit-learn*. Obtenido de ciencia de datos: <https://www.cienciadedatos.net/documentos/py27-forecasting-series-temporales-python-scikitlearn.html>
- Knuth, D. E. (1997). *The Art of Computer Programming, Volume 1: Fundamental Algorithms*. Addison-Wesley Professional.
- Koehrsen, W. (24 de Junio de 2018). Una explicación conceptual de la optimización de hiperparámetros bayesianos para el aprendizaje automático.
- Koyyada, A. (21 de julio de 2020). *Estudio clínico sobre la interpretación de los trastornos hipo e hipertiroideos*. Visakhapatnam, India: GITAM Institute of Pharmacy.
- Manzanares Gutiérrez, Á., Nicolás Martínez, C., & García Pina, C. (2022). *ANÁLISIS EXPLORATORIO ESPACIAL DEL ÍNDICE DE FEMINIZACIÓN DE LAS OCUPACIONES MILITARES EN LAS DEMANDAS DE EMPLEO*. Investigación y pensamiento crítico.
- McKinney, W. (2018). *Python for Data Analysis*, 2nd Edition. En W. McKinney, *Python for Data Analysis, 2nd Edition* (pág. 1).
- PULZARA, N. R. (2020). *Pronóstico de demanda mediante series temporales y redes neuronales aplicado a una empresa del sector ferretero*. FACULTAD DE

CIENCIAS NATURALES Y MATEMÁTICAS DEPARTAMENTO DE
MATEMÁTICAS .

- Rojas, B. R. (2020). *Machine Learning*. Puebla: Benemérita Universidad Autónoma de Puebla.
- Romero, B. R. (2020). *Una Introducción A Los Modelos De Machine Learning*. Puebla México: Benemérita Universidad Autónoma de Puebla.
- Shahriari B, S. K. (2016). Taking the Human Out of the Loop: A Review of Bayesian Optimization. En S. K. Shahriari B, *Taking the Human Out of the Loop: A Review of Bayesian Optimization*.
- Torres, M. (2021). *Logística Inbound: Tomo I de Logística para Siglo XXI*. Díaz de santos.
- Tukey, J. W. (1977). Exploratory Data Analysis" de John W. Tukey. En J. W. Tukey, *Exploratory Data Analysis" de John W. Tukey*.
- Vandeput, N. (2015). Data Science for Supply Chain Forecasting. En N. Vandeput, *Data Science for Supply Chain Forecasting*.