



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

**DISEÑO, IMPLEMENTACIÓN Y PRUEBA DE UN MODELO PREDICTIVO
DE CORTO PLAZO, QUE PERMITA PRONOSTICAR LA CANTIDAD DE
PRODUCTOS DEMANDADOS EN GLOBE ITALIA**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

CRISTIAN GERALD CORREA SANDOVAL

PROFESOR GUÍA:
JUAN PABLO ROMERO GODOY

MIEMBROS DE LA COMISIÓN:
CRISTÓBAL GALLARDO MESA
BLAS DUARTE ALLEUY

SANTIAGO DE CHILE
2022

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO
CIVIL INDUSTRIAL
POR: CRISTIAN GERALD CORREA SANDOVAL
FECHA: 2022
PROF. GUÍA: JUAN PABLO ROMERO GODOY

DISEÑO, IMPLEMENTACIÓN Y PRUEBA DE UN MODELO PREDICTIVO DE CORTO PLAZO, QUE PERMITA PRONOSTICAR LA CANTIDAD DE PRODUCTOS DEMANDADOS EN GLOBE ITALIA

Globe Italia es una empresa de ventas de alimentos al por mayor y menor, la cual se encuentra en proceso de crecimiento mostrando un incremento de ventas de \$1.636 millones de pesos, entre el año 2020 y 2021. Este crecimiento los ha llevado a ir expandiendo su operación lo que a su vez les ha hecho encontrar problemas, los cuales no les permite obtener mejores resultados, uno de ellos corresponde a la baja capacidad del proceso de forecasting, en el cual no se predicen más del 47 % de sus productos, por otro lado se observan problemas debido al quiebre de stock, en el cual solo hasta octubre de 2021 no se ha satisfecho la demanda de 84.233 productos, causando perdidas de forma directa a la empresa, además se observan problemas de sobre stock, donde más del 14 % de los productos de inventario se encuentra en la categoría sin ventas lo cual los puede llevar a perder los productos por sus fechas de vencimientos, además de las perdidas por inventario y salvataje.

Para solucionar este problema es que se propone diseñar, implementar y probar un modelo predictivo de corto plazo que permita pronosticar la demanda de 6 meses en el futuro para los productos en Globe Italia, donde se plantea utilizar la metodología de continuous delivery for machine learning, con el fin de implementar modelos de carácter estadístico, como lo son el modelo de medias móviles, los modelos de suavización exponencial simple, doble y triple, además de un modelo auto regresivo como lo es el modelo ARIMA.

El modelo que presenta los mejores resultados, es un modelo mixto compuesto por el modelo ARIMA y el modelo medias móviles, el cual tiene la capacidad de predecir el 76,3 % de los productos, además de presentar los mejores resultados entre los modelos, presentando un MAE promedio de 882 para productos con ventanas temporales de mas de 12 meses y un MAE promedio de 1087 para productos con ventanas temporales de mas de 30 meses.

Al comparar el modelo final seleccionado se observa una disminución del error en 12 puntos porcentuales con el proceso actual de forecasting, lo que situándose en un caso neutral, podría significar en un aumento de las ganancias de Globe Italia de \$60.304.735 pesos.

A Arelis Sandoval y Rodrigo Beytia

Agradecimientos

Con este trabajo culmina una de las etapas mas importantes de mi vida, donde en mi transcurso descubrí lo importante que es tener una familia preocupada que te apoye y que respete las decisiones que tomas, también lo importante que es tener personas con que compartir los buenos momentos y que te apoyen en los malos, dándote los ánimos para lograr cosas que parecieron perdidas.

En primer lugar quiero agradecer a mi familia; a mi mamá Arelis, la cual me enseñó a ser una persona resiliente y esforzada, que puede lograr lo que uno se proponga; A mi papá Rodrigo, que me enseñó a ser lo que soy hoy en día y me mostró como ser un padre ejemplar, que hace lo imposible por su familia; a mis hermanos Rodrigo y Cristóbal, que siempre me han aguantado y preocupado por mi.

En segundo lugar quiero agradecer a mi novia Constanza, que llego de imprevisto a llenar mis días de alegría, que estudio conmigo, que siempre creyó en mí y que me impulso a ser una mejor persona y profesional. También le agradezco enormemente por llevarme a descubrir una de las pasiones mas grandes que tengo en mi vida, el jiu-jitsu brasileño el cual espero pasar toma mi vida haciendo y espero poder pasar esta pasión a otras personas para que puedan ver lo increíble de este deporte.

En tercer lugar a mis amigos; Oscar, Paja y Tito, a los cuales les debo muchas cosas por todos los grandes momentos que hemos vivido y espero seguir viviendo con ellos; tampoco puedo olvidar al Martín, al Acuña, al Seba del Pueblo, al Seba ABC1, el Kevin Byron, el Manolo, el Kesh y el Danner, que fueron compañeros de miles de aventuras y sin los cuales la universidad no hubiera sido lo que fue.

Por ultimo, me gustaría agradecer a Globe Italia por permitirme realizar el presente trabajo de título con ellos y los cuales me trataron como uno más del equipo, ayudándome con cualquier duda o solicitud que me genero el presente trabajo.

Tabla de Contenido

1. Introducción	1
1.1. Antecedentes generales	1
1.2. Justificación del problema	5
1.2.1. Capacidad de predicción del proceso de forecasting	5
1.2.2. Rendimiento de predicción del proceso de forecasting	6
1.3. Objetivos	7
1.4. Metodología	8
1.5. Resultados esperados	9
2. Marco conceptual	10
2.1. Modelos de estimación de demanda	10
2.1.1. Naive Forecasting	11
2.1.2. Medias móviles	11
2.1.3. Suavización exponencial triple de Holt-Winter	11
2.1.4. ARIMA	12
2.2. Entrenamiento y evaluación de los modelos	13
2.3. Indicadores de error	14
2.3.1. MAE	14
2.3.2. MASE	15
2.3.3. Promedio	15
2.3.4. Desviación estándar	15
2.4. Herramientas	15
2.5. Alcances	16
3. Descripción de los datos	17
3.1. Construcción base de datos	17
3.2. Características y comportamiento de la demanda	19
3.3. Error en proceso de forecast actual	23
3.4. Productos sin la cantidad suficientes de datos temporales	27
4. Resultados y discusión	29
4.1. Resultados medias móviles	29
4.2. Resultados suavización exponencial simple	30
4.3. Resultados suavización exponencial doble	30
4.4. Resultados suavización exponencial triple o de Holt-Winter	31
4.5. Resultados ARIMA	31
4.6. Resultados finales	32
4.7. Implementación	33

4.8. Discusión	35
5. Conclusiones	37
5.1. Conclusión	37
5.2. Recomendaciones y trabajos futuros	38
Bibliografía	40

Índice de Tablas

1.1.	Tabla de inventario valorizado.	7
1.2.	Tabla de demanda no satisfecha por quiebre de stock.	7
3.1.	Tabla de productos mas demandados.	20
3.2.	Tabla de productos que presentan el mayor error de predicción.	25
3.3.	Tabla de descripción de los registros.	27
3.4.	Tabla de características del horizonte temporal.	28
4.1.	Resultados modelo medias móviles.	29
4.2.	Resultados modelo suavización exponencial simple.	30
4.3.	Resultados modelo suavización exponencial doble.	31
4.4.	Resultados modelo suavización exponencial triple.	31
4.5.	Resultados modelo ARIMA.	32
4.6.	Resultados modelo mixto.	33

Índice de Ilustraciones

1.1.	Venta neta mensual Globe Italia.	2
1.2.	Organigrama primera línea de Globe Italia.	2
1.3.	Organigrama Gerencia de Supply Chain de Globe Italia.	3
1.4.	Proceso de forecasting de demanda de productos	4
1.5.	Mensualizado de productos a los cuales no se les realizó un forecast	5
1.6.	Demanda mensualizada de productos a los cuales no se les realizó un forecast	6
1.7.	Continuous Delivery For Machine Learning.	9
2.1.	Diagrama de entrenamiento y validación de modelos.	14
3.1.	Serie temporal de la demanda de productos.	19
3.2.	Serie temporal de la demanda de productos por canal.	20
3.3.	Serie temporal de la demanda de productos por familia.	20
3.4.	Ejemplo de series de tiempo de los productos con mayor demanda anual promedio.	22
3.5.	Serie temporal de la demanda total versus el forecast total.	23
3.6.	Ejemplo de series de tiempo de los productos con mayor demanda anual promedio.	24
3.7.	Serie de tiempo de los productos con mayor MAE.	26
3.8.	Cantidad de productos según los datos temporales que presenta a la fecha.	27
4.1.	Diagrama de implementación del modelo.	34
4.2.	Imagen ejemplo de implementación.	35
4.3.	Capacidad del antiguo y nuevo proceso de forecasting.	36

Capítulo 1

Introducción

1.1. Antecedentes generales

Globe Italia es una empresa de ventas de alimentos al por mayor y menor, la cual fue fundada en 1998, buscando proveer a restaurantes de comida italiana los insumos necesarios para sus preparaciones, estos productos son principalmente importados desde Italia siendo esta la principal propuesta de valor de la empresa. Posterior a su fundación y dado su crecimiento sostenido a lo largo de los años, hoy en día presenta 4 canales principales, los cuales se detallan a continuación:

- **Supermercados:** Canal de ventas al por mayor, siendo los principales clientes Walmart, Cencosud y Tottus.
- **HO.RE.CA.:** Canal de ventas al por mayor enfocado en restaurantes, hoteles y casinos.
- **Mayoristas:** Canal de ventas al por mayor enfocado en supermercados mayoristas, siendo el principal cliente SMU.
- **Presencial y web:** Canal de ventas al por menor, en el cual ofrecen productos en su tienda ubicada en Las Condes y también en su portal web.

La misión de Globe Italia según lo muestra su sitio web es, "seguir entregando valor y calidad en todos los productos importados alrededor del mundo"[1], presentando una variedad de 2.540 productos los cuales se agrupan en 58 categorías y 198 marcas distintas, todos estos son vendidos a todo Chile por los canales antes mencionados.

En cuanto a las ventas de la empresa, se puede observar que en el año 2020 ha tenido un aumento con respecto al año anterior (figura 1.1), tanto desde una perspectiva anual como una mensual, obteniendo así durante el año 2020 unas ventas totales por \$8.735 millones de pesos, lo cual corresponde a un aumento de 18 puntos porcentuales en comparación al año 2019, donde se vendió en total \$7.099 millones de pesos.




Figura 1.1: Venta neta mensual Globe Italia.

Respecto a su organización se puede observar en la figura 1.2 que Globe Italia solo esta conformada por 4 gerencias, las cuales deben responder ante el gerente general y el directorio, presentando cada una las siguientes misiones:

- **Gerencia de administración y finanzas** : Encargada de gestionar los recursos humanos y los bienes inmuebles de la empresa, junto con llevar la contabilidad de esta.
- **Gerencia de marketing y retail**: Encargada de la relación con los clientes y de la gestión de los canales de venta.
- **Gerencia de ventas HO.RE.CA. y tradicional**: Encargada de realizar el contacto para la venta en hoteles restaurantes y casinos, además de encargarse de las ventas por el sitio web.
- **Gerencia de supply chain**: Encargada del inventario de la empresa y las labores operativas como la facturación y la distribución de los pedidos.

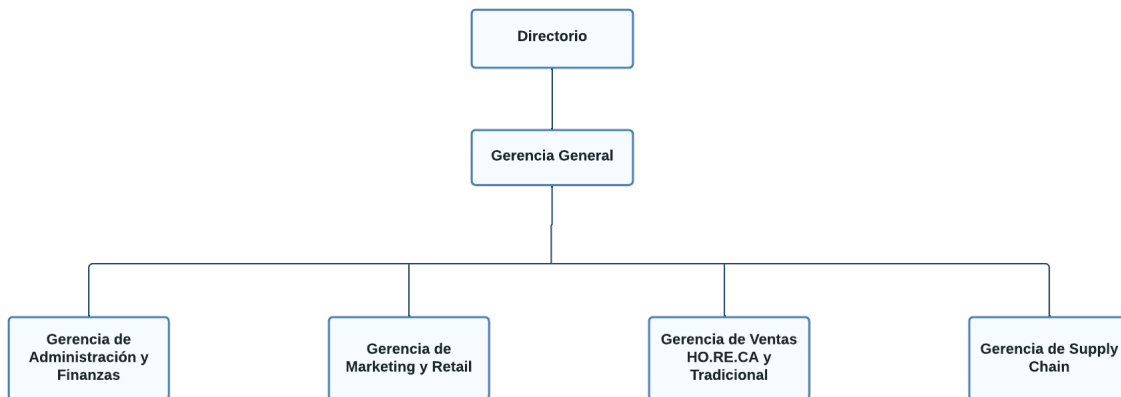


Figura 1.2: Organigramma primera linea de Globe Italia.

El área donde se realiza el presente trabajo de título corresponde a la Gerencia de Supply Chain, la cual se encuentra encargada de:

- **Facturación:** Realizar la facturación de los productos solicitados en los distintos canales de venta.
- **Distribución:** Realizar el transporte de los productos desde la zona de embarque hacia las distintas bodegas de la empresa, además de entregar los productos demandados en los distintos canales de venta.
- **Inventario:** Realizar el óptimo almacenamiento de los productos en las distintas bodegas de la empresa, para minimizar los costos de distribución y mantener el stock disponible en todo Chile, además se encargan de planificar y gestionar las importaciones de los productos.
- **Calidad:** Realizar el constante monitoreo de calidad de los productos, según lo reglamentado por el MINSAL.

Para llevar a cabo las funciones mencionadas anteriormente, la gerencia cuenta con un total de 35 personas, las cuales se subdividen en diferentes áreas que se pueden observar en la figura 1.3. Los colaboradores cuentan con un perfil bastante variado de profesionales debido a que por un lado, existe un trabajo operativo, tales como los procesos de facturación y distribución, los cuales no necesitan de un nivel técnico para su realización, mientras que por otro lado se encuentran trabajos mas técnicos y especializados, como los que realizan los encargados de calidad e inventario de productos, quienes requieren de conocimientos específicos a las tareas que realizan.

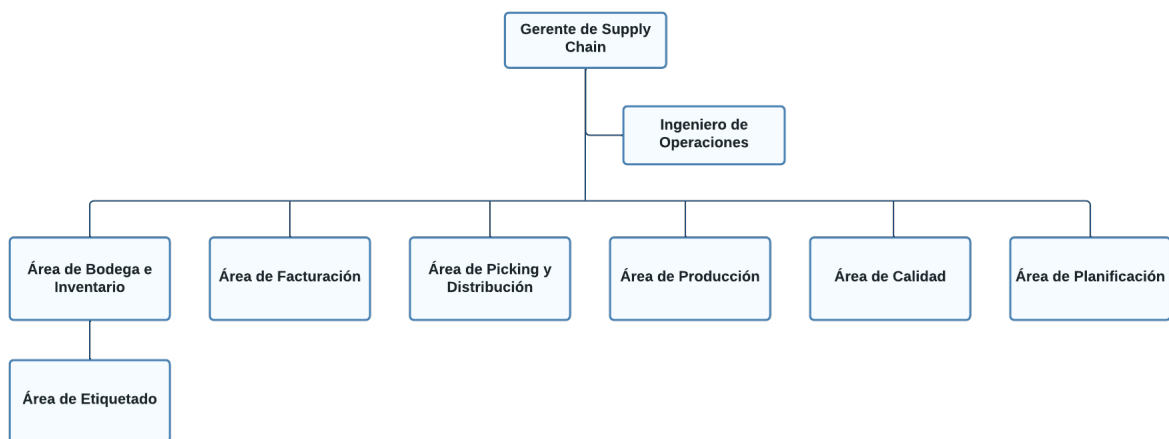


Figura 1.3: Organigrama Gerencia de Supply Chain de Globe Italia.

Los principales clientes que presenta el área dada las labores que desempeñan dentro de la empresa, son el área de Ventas, los que se encargan de generar el forecast de demanda de los productos, que es el principal input del área de Supply Chain para optimizar el inventario y así minimizar los costos de almacenamiento y distribución. Otro cliente importante, es el área de Finanzas con los cuales se gestionan los pagos a los proveedores nacionales e internacionales, además el área de Supply Chain realiza la facturación de la venta de productos en sus distintos canales, las cuales son entregadas al área de Finanzas para que realicen la gestión contable. Por último, como contraparte externa se encuentran los clientes finales de la empresa a los cuales el área esta encargada de entregar los productos vendidos.

El solicitante del trabajo de título es el subgerente del área de Supply Chain, el cual lo sigue debido al error que se presenta al momento de predecir la demanda futura de productos, puesto que esta diferencia entre el forecast y la demanda real generan sobre stock y quiebres de stock en los productos, conllevando pérdidas monetarias debido a los productos vencidos o pérdidas por ventas no concretadas provocadas por el quiebre de stock. Estos errores se presentan principalmente debido a que el área no cuenta con ningún modelo de predicción de demanda.

El proceso de forecasting como muestra la figura 1.4 comienza la primera semana de cada mes, en donde cada product manager se reúne con el subgerente del área de Supply Chain y el jefe de planificación, para pronosticar uno o tres meses en adelante la demanda de los productos, a través del criterio del experto. En la actualidad existen 5 product manager encargados en promedio de 131 productos diferentes, tomándoles 1,5 días realizar a cada uno el pronóstico y en promedio una semana realizar el proceso de forecasting completo.

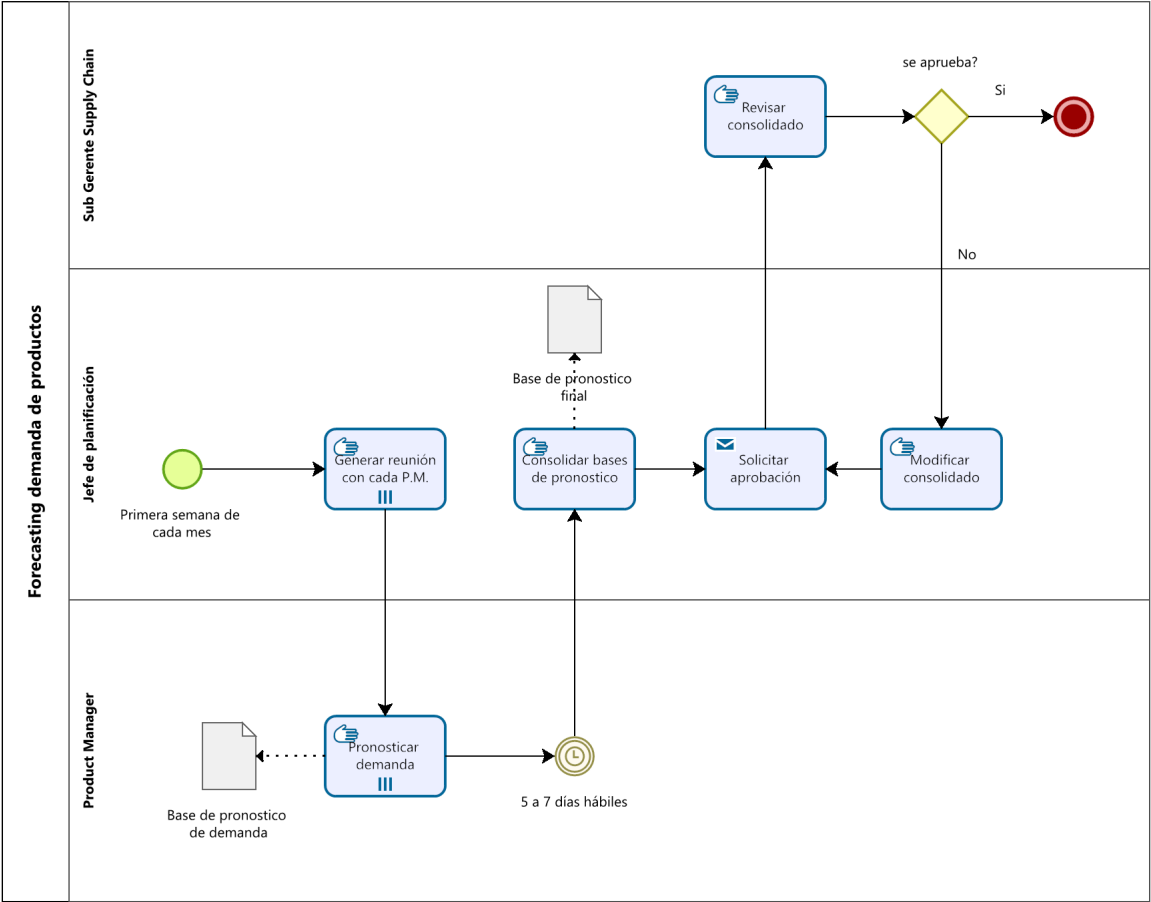


Figura 1.4: Proceso de forecasting de demanda de productos

Las áreas que se verán beneficiadas por el trabajo será por un lado, el área de ventas debido a que les permitirá tener una noción mas precisa de las tendencias futuras de sus productos, mejorando de esta forma la creación de campañas que potencien la compra por parte de los clientes, por otro lado se tiene que los mayores beneficios los tendrá la propia

área de supply chain debido a que conocer las tendencias de los productos les permitirá realizar una mejor optimización del inventario que presentan, reduciendo así los quiebres de stock los cuales llevan a perdidas monetarias o en su caso contrario reduciendo la cantidad de productos en sobre stock que permanecen almacenados en la bodega, los cuales se venden a un precio mucho menor cuando pasan a ser mermas.

1.2. Justificación del problema

Profundizando en los problemas que generan la necesidad de este trabajo de título, se pueden diferenciar dos principalmente, el primero consistiendo en la incapacidad del proceso de forecasting para predecir la creciente cantidad de productos que existen en Globe Italia, por otro lado se tienen los problemas mencionados anteriormente sobre el rendimiento en la calidad del forecasting, los cuales traen problemas de sobre stock y quiebres de stock.

1.2.1. Capacidad de predicción del proceso de forecasting

Como se describió anteriormente el proceso de forecasting es bastante largo, durando aproximadamente una semana y requiriendo la participación de varias personas para su realización, pero esto no significa que los equipos tengan la capacidad de predecir todos los productos que presenta en la actualidad Globe Italia, tomando en consideración los mas de 2000 productos con los que cuentan y que siguen aumentando. Analizando la cantidad de productos pronosticados mensualmente se puede observar en la figura 1.5 como a lo largo del tiempo no se ha podido realizar la predicción del 100 % de los productos activos, teniendo en promedio la capacidad de predecir el 47 % de los productos.




Figura 1.5: Mensualizado de productos a los cuales no se les realizó un forecast

En una primera instancia se podría esperar que los productos a los cuales se les deja fuera del proceso de forecasting, son productos con muy baja demanda la cual puede ser

compensada con un nivel constante y bajo de inventario, pero si se observa la figura 1.6 destaca como el acumulado de estos productos generan una demanda mensual entre 200.000 y 800.000 unidades, lo cual impactará negativamente el proceso de inventario y a la vez acrecentará los problemas de sobre stock y quiebre de stock.




Figura 1.6: Demanda mensualizada de productos a los cuales no se les realizó un forecast

1.2.2. Rendimiento de predicción del proceso de forecasting

Dado el corto tiempo de predicción en el proceso de forecasting, el área tiene problemas para llevar a cabo un correcto proceso de inventario debido a su necesidad de tener 6 meses de predicción por producto, en comparación a los 1 a 3 meses que se les entrega en el proceso de forecasting actual, donde se debe considerar que las predicciones no se realizan para todos los productos activos y estas además presentan problemas de exactitud, debido a el error de predicción generado por el criterio utilizado en el proceso. Esto causa que el área deba mantener en inventario una mayor cantidad de productos, lo cual se puede observar en la tabla 1.1 mostrando una gran cantidad de stock sin venta con una valorización de \$154.256.228 pesos chilenos correspondiente al 15% aproximadamente del stock total, también cabe destacar el gran porcentaje de inventario con mas de 180 días, el cual junto al inventario sin venta representan aproximadamente el 35% del inventario total de la empresa.

Tabla 1.1: Tabla de inventario valorizado.

Rango de días de inventario	Stock valorizado	Stock valorizado %
0 - 5 días	\$4.443.760	0,4 %
5 - 10 días	\$28.640.255	2,7 %
10 - 20 días	\$111.096.009	10,5 %
20 - 35 días	\$153.970.190	14,6 %
35 - 60 días	\$146.403.984	13,9 %
60 - 90 días	\$100.010.877	9,5 %
90 - 180 días	\$125.350.684	11,9 %
180+ días	\$229.284.751	21,8 %
Sin venta	\$154.256.228	14,6 %
Total	\$1.053.456.738	100 %

Los problemas de rendimiento del proceso de forecasting que causan el sobre stock de productos, también pueden llevar a que no se mantenga el inventario suficiente de productos, provocando que no se pueda satisfacer la demanda solicitada por el quiebre de stock que se genera, lo cual queda representado en la tabla 1.2 la cual muestra el gran número de unidades que no se vendieron dado los quiebres de stock generados a lo largo del año y aunque estos hayan disminuido en los últimos meses nada asegura que no se vuelva a la tendencia anterior.

Tabla 1.2: Tabla de demanda no satisfecha por quiebre de stock.

Año	Demanda no satisfecha	Valorización
2019	419.237 Unidades	\$2.712M
2020	489.854 Unidades	\$3.169M
Hasta Octubre 2021	84.233 Unidades	\$545M

1.3. Objetivos

El objetivo general del trabajo de título es diseñar, implementar y probar un modelo predictivo de corto plazo, que permita pronosticar la cantidad de productos demandados para los próximos 6 meses en Globe Italia, donde para lograr esto se proponen los siguientes objetivos específicos:

1. Entender generalmente el negocio y particularmente la problemática a solucionar.
2. Realizar un análisis exploratorio sobre las bases de venta.
3. Construir y evaluar modelos de predicción temporal.
4. Implementar modelo de predicción.
5. Evaluar impacto sobre el negocio.

Para evaluar el éxito del presente trabajo se comparará el rendimiento del proceso anterior versus el proceso que incorpora el modelo predictivo implementado, a través de las métricas de error expuesta en el siguiente capítulo, considerándose como exitoso en el caso que se encuentren mejoras de rendimientos por la disminución de las métricas de error.

1.4. Metodología

Para un proyecto de implementación de distintos modelos matemáticos sobre los datos de una institución o empresa, en la practica se pueden observar las siguientes etapas:

- Construcción del modelo
- Evaluación y experimentación del modelo
- Pasar a productivo el modelo
- Pruebas
- Desarrollos
- Monitoreo y observación

Las cuales dentro de la metodología de “Continuous Delivery For Machine Learning” [2] o abreviado CD4ML que nace de la metodología ágil Continuous Delivery [3] , define su proceso de acción comenzando desde la base de datos, la cual necesita una forma sencilla de administrar, descubrir, acceder y versionar los datos. A continuación se automatiza el proceso de formación y creación del modelo para que sea reproducible, lo que permite experimentar y entrenar múltiples modelos, surgiendo la necesidad de medir y rastrear esos experimentos. Una vez encontrado el modelo adecuado, se puede decidir cómo se producirá y se desarrollará. Debido a que el modelo esta en una constante evolución, para prevenir cualquier problema con los usuarios finales se deben realizar pruebas antes de llevar a cabo la implementación en producción, así posteriormente una vez implementado el modelo en productivo, con la información obtenida del monitoreo y observación se puede tener una retroalimentación, cerrando así el ciclo y permitiendo producir un mejora continua en las próximas iteraciones. Lo anterior se puede ver de forma mas gráfica en la figura 1.7 donde se puede observar el ciclo completo de la metodología, mostrando además las tarea que se realizaran a nivel de datos, modelo y código.

Se selecciona la metodología anterior para realizar el trabajo de título debido al carácter ágil que presenta y debido a la implementación continua de mejores modelos gracias a la información que entrega el monitoreo de los modelos en productivo, lo cual permitirá a Globe Italia ir utilizando modelos mas complejos a medida que pase el tiempo y su base de datos sea mas grande.

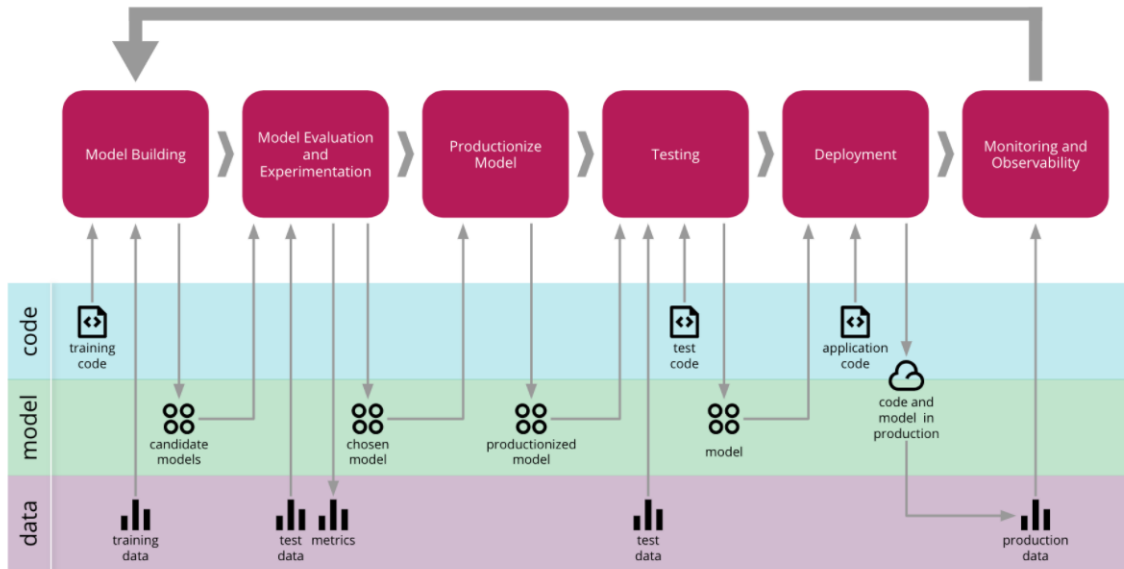


Figura 1.7: Continuous Delivery For Machine Learning.

Como también se puede ver en la metodología propuesta, llevar un ciclo completo requiere de mucho trabajo el cual está pensado para equipos conformados por ingenieros de datos y científicos de datos, es por esto que para el trabajo de título se pretende modificar y acotar la metodología, donde se realizará solo las etapas de construcción del modelo hasta las pruebas, eliminando el paso a producción debido a su complejidad y el tiempo que puede llevar su implementación dadas las propias capacidades de la empresa.

1.5. Resultados esperados

Los resultados esperados del trabajo son coherentes a los objetivos planteados previamente. Por tanto, se esperan los siguientes puntos:

1. Identificar aspectos generales de la empresa, su rendimiento en los últimos años y levantar el proceso de forecasting, para conocer su funcionamiento y cuantificar sus principales problemas.
2. Identificar las bases que serán utilizadas en el modelo, las cuales contienen información desde enero de 2019 hasta octubre de 2021 (última fecha de evaluación de la información para este trabajo). Por último transformar las fuentes de datos para obtener la base final con la cual se realizará un análisis preliminar, con el que se espera conocer los comportamientos históricos de la información y el rendimiento del proceso de forecasting.
3. Identificar y evaluar modelos predictivos temporales univariados.
4. Implementar script de python para que ajuste y prediga la demanda de los próximos 6 meses para los productos activos.
5. Evaluar funcionamiento de los modelos con respecto al rendimiento anterior del proceso de forecasting, además de cuantificar el impacto para el negocio.

Capítulo 2

Marco conceptual

Dado el objetivo del trabajo de título se tiene que el área de estudio al cual corresponde, es el de análisis de series de tiempo, que se define como el esfuerzo de extraer información resumida y estadística de puntos organizados en orden cronológico [4], correspondiendo para este caso, a la demanda de productos realizada mensualmente en Globe Italia.

El estudio de las series de tiempo se ha realizado desde tiempo ancestrales, como se observa en los registros de manchas solares que se hizo en la antigua China en el año 800 a.c. aproximadamente, pero el primer gran propulsor de esta área de estudio fue George Box que en 1970 publica el libro, “Time Series Analysis: Forecasting and control” [5] el cual contiene el reconocido hasta el día de hoy, método de Box-Jenkins. Posteriormente junto al avance de los lenguajes de programación y las computadoras, es que se fue potenciando el análisis de series de tiempo desde una perspectiva estadística, la cual se basa principalmente en la aplicación de modelos autorregresivos, dada la correlación temporal que presentan los datos. Actualmente los modelos de Machine Learning dominan las áreas de estudios de datos, siendo el modelo que aparece en el paper “Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting”[6] el estado del arte para las series de tiempo, basándose principalmente en el uso de redes neuronales, las cuales reconocen patrones de datos y los replican en los pronósticos.

En el caso del presente trabajo de título se descartan los modelos basados en machine learning y redes neuronales, debido a que estos modelos presentan un rendimiento óptimo en grandes bases de datos, lo cual no es el caso de Globe Italia dado que a pesar de la gran cantidad de productos que presentan, estos son correctamente registrados en sus bases de datos desde Enero del año 2019, es por esto que los modelos utilizados serán basados en el enfoque estadísticos y serán presentados a continuación.

2.1. Modelos de estimación de demanda

Los modelos que serán presentados a continuación fueron extraídos de un estudio realizado sobre varios modelos de series de tiempo aplicados en bases de Supply Chain [7], donde como se menciono anteriormente se excluyen los modelos de machine learning y redes neuronales.

2.1.1. Naive Forecasting

Este es el método mas básico que se utiliza para predecir. La premisa de este método es que el punto esperado es igual al ultimo punto observado

$$\hat{y}_{t+1} = y_t \quad (2.1)$$

También se puede asumir que los k puntos esperados son iguales a los k puntos anteriores.

Aunque este método luzca simple o ingenuo es útil para crear un punto de partida en el análisis. Numerosos estudios de predicción lo utilizan cuando los datos no poseen una considerable diferencia entre los días, y algunos demuestran que Naive Forecasting es mejor que otros métodos como Moving Average o Trend, cuando no se ve mucha variación en los datos [8].

2.1.2. Medias móviles

Dada una secuencia $\{a_i\}_{i=1}^N$ una n-media móvil se define como una nueva secuencia $\{s_i\}_{i=1}^{N-n+1}$ la cual proviene de la media aritmética de n elementos de la secuencia, siendo también uno de los modelos mas básicos el cual permite tener una medida base y un primer acercamiento a los datos.

2.1.3. Suavización exponencial triple de Holt-Winter

Este modelo se utiliza para pronosticar series de tiempo y su nombre es porque se utiliza para pronosticar tendencia, temporalidad y estacionalidad. De esta manera, esta metodología utiliza tres ecuaciones para suavizar; una para la atenuación de la serie de tiempo, otra parte de la tendencia y una ultima para la estacionalidad. La ecuación de atenuación de la serie de tiempo o de pronóstico para el periodo t se calcula de la siguiente forma:

$$A_t = \alpha \cdot \left(\frac{y_t}{R_t - L} \right) + (1 - \alpha) \cdot (A_{t-1} + T_{t-1}) \quad (2.2)$$

Donde α corresponde a la constante de atenuación la cual toma valores en el intervalo $0 < \alpha < 1$, T_{t-1} corresponde a la tendencia del periodo $t-1$ y R_{t-L} a la estacionalidad del periodo $t-L$. L considera como el largo del ciclo de estacionalidad. La tendencia del periodo t se modela como sigue:

$$T_t = \beta \cdot (A_t + A_{t-1}) + (1 - \beta) \cdot T_{t-1} \quad (2.3)$$

Donde β es el coeficiente de tendencia el cual toma valores entre el intervalo $0 < \beta < 1$. La estacionalidad del periodo t se formula a continuación:

$$R_t = \gamma \cdot \left(\frac{y_t}{A_t}\right) + (1 - \gamma) \cdot R_{t-L} \quad (2.4)$$

Donde el parámetro γ se refiere al coeficiente de estacionalidad el cual, al igual que los coeficientes anteriores, se encuentra en el intervalo $0 < \gamma < 1$. Finalmente el modelo con el cual se pretende realizar los pronósticos para k periodos en el futuro es:

$$\hat{y}_{t+k} = (A_t + k \cdot T_t) \cdot R_{t-L+k} \quad (2.5)$$

De este modelo se espera capturar todas las componentes que podrían tener los productos en las series de tiempo, donde en el caso que no presenten algunas de estas componentes se puede ir relajando el modelo quitándole las componentes innecesarias.

2.1.4. ARIMA

El modelo autorregresivo integrado de promedio móvil o ARIMA es un modelo que estudia predicciones de series de tiempo, donde estas series de tiempo pueden considerarse como la realización de un proceso estocástico que se observa secuencialmente a lo largo del tiempo. El modelo ARIMA es un caso particular del modelo ARMA el cual es una combinación a su vez del proceso autorregresivo AR(p) y el proceso de media móvil MA(q). Ambos son modelos de series de tiempo que se diferencian en que el primero tiene memoria a largo plazo por lo que le cuesta reaccionar rápidamente ante “shock” o perturbaciones y el segundo, tiene corta memoria, reaccionando ágilmente a perturbaciones pero olvidando la información del pasado.

Los parámetros de un modelo ARIMA(p,d,q) se definen como sigue:

- p es el número de términos autorregresivos.
- d es el número de diferencias que se aplican a la serie de tiempo para que sea estacionaria.
- q es el número de medias móviles que realiza el proceso.

De esta forma, se construye un modelo de regresión lineal que incluye el número y el tipo de términos especificados, de tal manera que la serie de tiempo sea estacionaria. Es necesario que la serie de tiempo sea estacionaria para eliminar tendencias y estructuras estacionales que pueden afectar negativamente el modelo de regresión. Finalmente, el modelo de regresión lineal que se busca tiene la siguiente forma:

$$\hat{y}_t = \delta + \phi_1 \cdot y_{t-1} + \dots + \phi_p \cdot y_{t-p} + \theta_1 \cdot \epsilon_{t-1} + \dots + \theta_p \cdot \epsilon_{t-p} \quad (2.6)$$

Donde:

- δ es una constante.
- $y_{t-1} \dots y_{t-p}$ es la demanda en el periodo $t - 1$ y $t - p$.

- $\epsilon_{t-1} \dots \epsilon_{t-p}$ son los residuos de los periodos $t - 1$ y $t - p$.
- ϕ, θ son los coeficientes de los procesos autorregresivos y de la media móvil, respectivamente.

2.2. Entrenamiento y evaluación de los modelos

Una vez definidos los modelos a utilizar, estos deben ajustarse a los datos con los que cuenta el negocio, para posteriormente evaluar el desempeño de estos modelos, donde de forma general se deben considerar tres aspectos fundamentales:

1. **Conjuntos de entrenamiento y testeo del modelo:** Para construir estos tipos de conjuntos, generalmente se dividen las observaciones de manera aleatoria en dos partes, esto con el objetivo de no generar un sesgo de selección en los modelos, pero debido a que los datos son temporales la segmentación de datos se realiza de forma que se mantenga el orden temporal en la información. Una de las particiones es para el entrenamiento del modelo, con la cual se realiza el ajuste del modelo, mientras que la otra se usa para validar el modelo entrenado y estimar su error de generalización, siendo uno de los objetivos el de minimizar el error evitando el sobre ajuste de los datos (over-fitting).
2. **Error:** Corresponde a la desviación de los datos reales versus los datos predichos por el modelo en el conjunto de validación.
3. **Métricas de desempeño:** Son medidas usadas para calcular la calidad del modelo y el error del modelo. Existe una gran variedad y según la problemática a estudiar, ciertas métricas resultan preferibles a otras.

Dada la variada cantidad de datos temporales que puede tener cada productos, la segmentación de datos no será proporcional, debido a que la evaluación del desempeño de los modelos se vería afectada por la cantidad de datos que presente cada conjunto de evaluación, por esto se fijará el conjunto de evaluación en los últimos 6 meses de demanda de cada producto, esto evitará generar un sesgo en las métricas de desempeño y por otro lado se ajustará el modelo a la necesidad de predicción del negocio. En la figura 2.1 se puede ver ejemplificado la forma de dividir los datos de entrenamiento y de validación, donde con este último conjunto se evaluará el desempeño del modelo según las métricas definidas en la siguiente sub sección.




Figura 2.1: Diagrama de entrenamiento y validación de modelos.

2.3. Indicadores de error

Los estadísticos que se utilizan para comparar los modelos anteriormente descritos son MAE y MASE, los cuales se usan para medir los errores presentes en las predicciones, utilizando el MAE para medir los rendimientos de los modelos para los mismos productos y el MASE para obtener un comparador universal entre los modelos.

2.3.1. MAE

El error absoluto medio o MAE, por su acrónimo en inglés, es una métrica que mide la magnitud de los errores en un conjunto de predicciones, sin considerar la dirección del error.

$$MAE = \frac{1}{n} \cdot \sum_{t=1}^n |y_t - \hat{y}_t| \quad (2.7)$$

Donde y_t es la demanda en t, \hat{y}_t es la demanda pronosticada en t y n es la cantidad de datos pronosticados.

Según Hyndman [9], el indicador más recomendado para comparar modelos para una misma serie es el MAE, porque es de fácil cálculo e interpretación, además de ser una medida objetiva para medir el desempeño de los modelos. Sin embargo, al ser escala-dependiente, hace que pierda el sentido si se quiere comparar modelos para diferentes series.

2.3.2. MASE

El error de escala absoluta media o MASE, por su acrónimo en inglés, fue propuesto por Hyndman y Koehler [9] como una medida general de error al realizar una predicción de series temporales, presentando la principal ventaja de que no depende de la escala de los datos y tampoco presenta problemas con las predicciones nulas como es el caso del MAPE el cual se indefiniría en esta situación, para calcular esta medida se utiliza la siguiente fórmula:

$$\begin{aligned} e_i &= |\hat{y}_i - y_i| \\ q_i &= \frac{e_i}{\frac{1}{n-1} \cdot \sum_{t=2}^n |y_t - y_{t-1}|} \\ MASE &= \frac{1}{n} \cdot \sum_{i=1}^n q_i \end{aligned} \tag{2.8}$$

2.3.3. Promedio

Dado que los modelos serán aplicados a los distintos productos que presenta Globe Italia, es que se utiliza el promedio del MASE para realizar la comparación entre los modelos, obteniendo así una métrica única de comparación.

2.3.4. Desviación estándar

La desviación estándar se utiliza para medir la dispersión de los datos con respecto al promedio y, en este trabajo, se utiliza como ayuda en el análisis de robustez, calculados de la siguiente forma:

$$\sigma = \sqrt{\frac{1}{n} \cdot \sum_{t=1}^n |x_t - \bar{x}_t|} \tag{2.9}$$

Al igual que el caso anterior esta métrica es utilizada sobre las métrica MASE, para tener un comparador de los modelos único para todos los productos.

2.4. Herramientas

Para programar los modelos presentados y para realizar la transformación de los datos se utiliza Python 3.8 junto a Visual Studio Code, el cual es un editor de texto en el que se pueden ejecutar los códigos de forma simple e interactiva, mediante variados plugins especializados que ayudan con el uso de las funciones y la visualización de los resultados. También en Python se pueden usar librerías las cuales son desarrolladas por terceros y tienen variadas funcionalidades, según el enfoque o la tarea que se este programando, de esta forma las librerías utilizadas en el presente trabajo son las siguientes:

- **Pandas, Numpy:** Librerías utilizadas para manejar y transformar las bases de datos.
- **Seaborn, Matplotlib:** Librerías utilizadas para graficar las series de tiempo.
- **Statsmodels:** Librería para ajustar los modelos de suavización exponencial.
- **Pmdarima:** Librería para ajustar el modelo ARIMA.
- **Pyobc:** Librería para generar la conexión con la base de datos de la empresa.

2.5. Alcances

Los alcances del trabajo a realizar se pueden separar en varios aspectos, los cuales permitirán manejar el problema de forma más dinámica sin perder el foco en el proceso. En primer lugar, se debe considerar el alcance del trabajo en términos de tiempo, pues debido a lo acotado que es éste, es una limitación en sí misma. El desarrollo del modelo, la obtención de los resultados, el análisis de los beneficios y la implementación comprenden un poco más de un semestre académico.

En segundo lugar los modelos utilizados se ajustan para obtener los mejores resultados en predicciones de 6 meses, esto debido a la solicitud del área de Supply Chain para que puedan realizar una mejor optimización de inventario, los cuales por otro lado no cuentan con un área especializada en inteligencia de negocio lo cual limita la implementación de los modelos a un script de Python ejecutable que les permita obtener un Excel con los pronósticos de los productos.

En tercer lugar se trabaja con datos con un espacio temporal desde enero del 2019 a octubre del 2021, debido a que en el año 2018 la empresa realizó una modificación completa a sus bases de datos, dejando la información anterior en desuso. esto repercute principalmente en la posibilidad de usar modelos de pronóstico más complejo, como lo serian las redes neuronales, las cuales se descartan de este trabajo por el bajo nivel de información temporal.

Por ultimo como alcance se tiene que los datos provenientes del canal presencial y web, solo se limitan a lo abastecido a la tienda, por lo que el modelo no puede ser utilizado como un predictor de la demanda de los clientes particulares de estos canales.

Capítulo 3

Descripción de los datos

3.1. Construcción base de datos

En una primera instancia con la finalidad de avanzar en el entendimiento del negocio y el comportamiento de los datos, se utilizó una base de ventas con la que contaba el área de Supply Chain y la cual era usada en el proceso de forecasting, pero de forma paralela se construyó una base con el equipo de desarrollo, la cual se encuentra en un servidor junto a las otras bases de la empresa, de esta forma las bases utilizadas para la construcción del modelo y la implementación son:

- **Base de demanda y venta:** Base con las ventas y demandas, la cual fue creada junto al equipo de desarrollo para que tome la información desde enero del 2019 y se mantenga actualizada en tiempo real con la información del negocio. A octubre del 2021 esta base cuenta con 50.833 datos y presenta 6 atributos, como son la clasificación del canal, el código del producto, el mes-año, la cantidad de productos cancelados por quiebre de stock, la cantidad de productos demandados y la cantidad real de productos vendidos.
- **Base de forecast:** Base con el acumulado de predicciones realizado en el proceso de forecast, la cual cuenta con 31.876 datos y 4 atributos, dentro de los que se encuentra la clasificación del canal, el código del producto, el mes-año y la cantidad de productos predichos. Esta base es utilizada solo para analizar el rendimiento del proceso de forecasting, por lo que no es usada dentro de la implementación final.
- **Base de maestros:** Base maestra con la información de los productos por sus códigos, la cual cuenta con 7.971 datos y 8 atributos, dentro de los que se encuentra el código del producto, el código madre, la familia y sub familia a la que pertenece el producto, la marca del producto, el tipo de código del producto, la descripción y su estado. Cabe mencionar que esta base se encuentra en Excel dado que se va actualizando manualmente por el jefe del área de Planificación y se encuentra en un repositorio definido para su uso dentro del proceso de transformación de datos.

En el procesamiento de datos no se encuentra ningún dato nulo dentro de las bases, pero sí como se mencionó anteriormente no todos los productos presentan una predicción, por lo que al momento de realizar el cruce de las base de ventas y de forecasting, se generaron datos nulos los cuales fueron reemplazados por ceros, ya que esto sería lo mismo que hubieran

predicho que ese producto no tendría ventas. Por último, se crear una variable que cuenta con la información del canal de ventas y que es obtenida a través de la agrupación del atributo clasificación del canal, generando así la base final la cual cuenta con 92.433 datos y 16 atributos que se detallan a continuación:

- **Item Code:** Código único del producto, el cual contempla sub categorías del producto, por ejemplo si el producto en ventas o el producto inventariado.
- **Código madre:** Código único por tipo de producto.
- **Canal:** Canal de venta por el cual se realizó la compra o se demandó el producto.
- **Clasificación SN:** Sub agrupación proveniente del atributo canal la cual categoriza la venta o demanda de productos, según los clientes principales de cada canal.
- **Familia:** Agrupación que categoriza a los productos por almacén, bebidas y licores, frescos, nonfood, accesorios y libros, insumos, lujo, congelados.
- **Sub Familia:** Sub agrupación proveniente del atributo familia que categoriza los productos en 58 categorías distintas.
- **Marca:** Marca del producto.
- **Descripción:** Descripción del producto que se vende o demanda.
- **Tipo Código:** Categoría de sub producto al que pertenece, la cual puede ser producto en oferta, producto en venta y producto en inventario.
- **Estado producto:** Representa si el producto se encuentra activo o inactivo.
- **Mes-Año:** Conjunto del mes y año en que se realiza la venta o demanda del producto.
- **Año:** Año en que se realiza la venta o demanda del producto.
- **Cancelados:** Cantidad de productos cancelados por quiebre de stock.
- **Demanda:** Demanda del producto la cual incorpora las ventas no realizadas por falta de stock o problemas de distribución, además se registra desde el día que se hizo la solicitud.
- **Venta:** Venta facturada y despachada del producto.
- **Forecast:** Proyección de la demanda del producto, realizada por el área de ventas y supply chain.

La base final es utilizada a lo largo del presente trabajo para estudiar el comportamiento de los datos y el entendimiento del negocio, además de ser la principal fuente de información para los modelos, los cuales dada su finalidad de predicción por producto, extraen la información de la demanda agrupada por los atributos código madre y mes-año.

3.2. Características y comportamiento de la demanda

Realizando una inspección general a la demanda de productos a lo largo del tiempo se puede observar en la figura 3.1 la tendencia creciente en la demanda de productos, lo cual se ve reflejado en el constante crecimiento que ha tenido la empresa en los últimos años, también es importante recalcar que se observa un aumento frecuente de ventas entre el mes de febrero y marzo de cada año.




Figura 3.1: Serie temporal de la demanda de productos.

Expandiendo el análisis anterior según como se comportan los diferentes canales, se observa en la figura 3.2 que el canal HO.RE.CA y Tienda presentan una venta mínima, comparado con el canal de Supermercados y Mayoristas, donde el primero cuenta con un comportamiento mas regular a lo largo del tiempo sin observarse una tendencia, en comparación al canal supermercados el cual presenta una tendencia al alza y es menos regular. Cabe destacar que ambos canales también presentan la estacionalidad vista en el panorama general, observándose alzas en los meses de febrero y marzo de cada año.




Figura 3.2: Serie temporal de la demanda de productos por canal.

En el caso del comportamiento de la demanda según el tipo de familia que se encuentra representado en la figura 3.3, los productos de almacén, bebidas y licores, junto a frescos presentan las mayores demandas en comparación a las otras categorías, de forma particular en la tabla 3.1 se presentan los 5 productos con la demanda anual promedio mas alta, observándose así que la mayoría de las ventas la realizan los productos que pertenecen a variedades de pan.





Figura 3.3: Serie temporal de la demanda de productos por familia.


Tabla 3.1: Tabla de productos mas demandados.

Código Madre	Familia	Sub Familia	Dem. prom. anual
GRAIN01	Almacén	Harina	3.110.268
MT001	Bebidas y Licores	Bebidas y Agua	1.044.755
GP0001	Almacén	Harina	845.935
PL003	Almacén	Snack	616.408
GRAIN02	Almacén	Harina	480.669


Como ultimo análisis a la demanda de productos, se presenta la figura 3.4 la cual muestra el comportamiento de la demanda en el tiempo de los primeros 3 productos de la tabla 3.1, pudiendo observar que en su gran mayoría estos productos presentan una tendencia al alza, pero no una estacionalidad visible en comparación al análisis general visto en la figuras 3.1 y 3.2. Esto nos muestra que en general cada producto presenta comportamientos diferentes entre sí, lo cual refuerza el hecho de testear diferentes algoritmos para los productos.



(a) GRAIN01



(b) MT001



(c) GP0001

Figura 3.4: Ejemplo de series de tiempo de los productos con mayor demanda anual promedio.

3.3. Error en proceso de forecast actual

Estudiando el comportamiento del error en el actual proceso de forecasting, se puede observar la figura 3.5 que en general se pronostica con un mes de diferencia las tendencias a las altas y bajas de la demanda real y además se tiende a sobre dimensionar los efectos de esta tendencia, provocando un error medio absoluto o MAE de 213.602,73 unidades.






Figura 3.5: Serie temporal de la demanda total versus el forecast total.

Tomando ahora los canales de Mayoristas y supermercados, los cuales cuentan con las mayores ventas y por ende la mayor necesidad de eficiencia en el proceso de forecasting, se puede observar en la figura 3.6 que en general se presentan los mismo errores mencionados anteriormente pero cabe recalcar que el canal Mayoristas tiene los errores mas altos, lo que se contrasta con que a primera vista el canal de supermercados muestra los resultados mas distantes a la realidad. Esto se debe a que para el MAE como se mencionó en el marco conceptual, depende de la escala de la demanda por lo que los errores son mas penalizados en el caso del canal Mayoristas, por otro lado para el caso del MASE este solo mide la calidad de la predicción, por esto es mas correcto decidir el mejor modelo a través de esta métrica.



(a) Canal Mayoristas



(b) Canal supermercados


Figura 3.6: Ejemplo de series de tiempo de los productos con mayor demanda anual promedio.

Dado los problemas para categorizar el nivel de error en las agrupaciones jerárquicas de los productos, es que se procede a analizar directamente el error absoluto medio para los distintos productos en la tabla 3.2, donde se puede observar que esos 5 productos contienen un poco más del 30 % del error de todo el proceso de forecasting, incluso el producto GRAIN01 aporta un décimo de todo el error de predicción para todos los productos. Esto es de vital importancia dado que un correcto ajuste de los modelos para estos productos, repercutirá en un aumento importante en la eficiencia del proceso reduciendo el error en las predicciones. En el caso de los dos últimos productos, se explica su elevado error debido a que son productos recién introducidos, causando así el elevado error por no tener referencias en la predicción.


Tabla 3.2: Tabla de productos que presentan el mayor error de predicción.

Código Madre	Sub Familia	MAE	% MAE Total
GRAIN01	Harina	72.175,6	11,8 %
MT001	Bebidas y Agua	42.560,6	18,7 %
PL003	Snacks	30.518,4	23,7 %
LN0001	Harina	30.349	18,6 %
PO002	Untables Dulces	27.052,6	33 %


De la tabla 3.2 también se puede observar que se encuentran productos que igualmente aparecen en la tabla 3.1, dándole aun mas importancia a estos productos debido a que también representan las mayores ventas de la empresa, pero si se observa la figura 3.7 la cual muestra la demanda y el forecast de los productos en la tabla 3.2, se puede observar que los errores nacen principalmente como es visto anteriormente, debido a los cambios de tendencia que no son capaces de dilucidar en el proceso de forecasting por el criterio del experto.



(a) GRAIN01



(b) MT001



(c) PL003

Figura 3.7: Serie de tiempo de los productos con mayor MAE.

3.4. Productos sin la cantidad suficientes de datos temporales

Dada la gran cantidad de productos que presenta Globe Italia junto a la creciente cantidad de productos nuevos, dentro de los datos se puede observar una gran variedad de horizontes temporales en los productos, lo cual queda ilustrado en la figura 3.8 donde la gran mayoría de productos presenta 34 datos temporales, que corresponden a los 34 meses entre enero de 2019 y octubre de 2021, por otro lado se puede observar en la tabla 3.3 que en promedio los productos cuentan con 22,8 datos temporales y el 50 % de ellos tienen mas de 27 datos temporales.

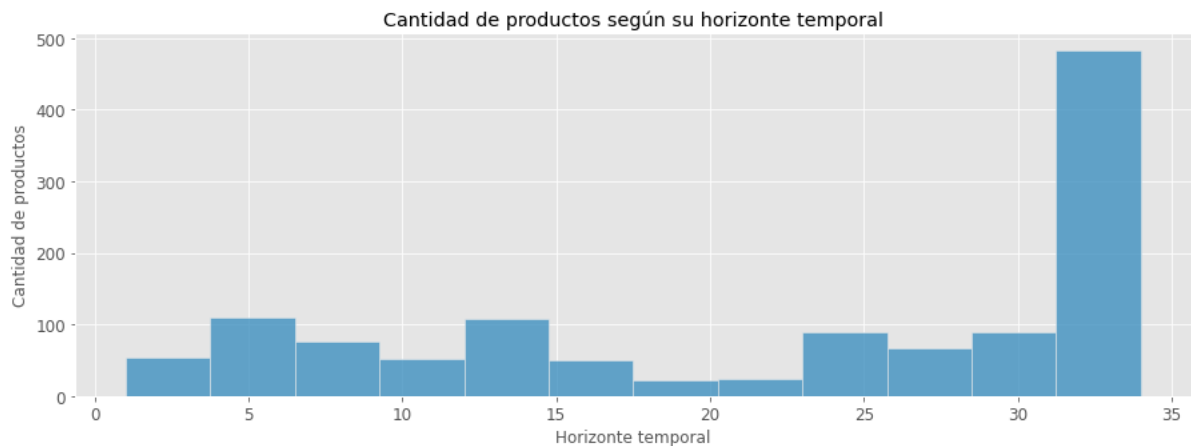


Figura 3.8: Cantidad de productos según los datos temporales que presenta a la fecha.

Tabla 3.3: Tabla de descripción de los registros.

Métrica	Horizonte temporal
promedio	22,8
desviación	11,5
mínimo	1
25 %	12
50 %	27
75 %	34
máximo	34

El principal problema que nace de las diferencias en los horizontes temporales en los productos, es el impacto en el ajuste de los modelos auto regresivos, debido a que estos son modelos mas complejos los cuales necesitan una mayor cantidad de datos para un correcto ajuste [5], por esto lo mas óptimo seria tomar los productos con un horizonte temporal de 34 datos, generando así un problema con la capacidad de predicción del nuevo proceso debido a que por el momento solo podría estimar la demanda de 439 productos que es el 35,9 % del total de datos, que es menor a la capacidad actual del proceso. De esta forma se genera un

trade off entre la capacidad del nuevo proceso y el nivel de ajuste del modelo, debiendo así buscar un óptimo a través de la experimentación en el presente trabajo de título.

Como se observa en la tabla 3.4 se definen los horizontes temporales a usar según la capacidad que tendría el nuevo proceso, la cual debe ser mayor o igual al proceso actual, y por otro lado se van disminuyendo estos horizontes temporales en 6 meses para ver cambios significativos en los ajustes, por ultimo se detienen los horizontes temporales en 12 meses debido a que se debe considerar el conjunto de validación, el cual es de 6 meses dejando así solo 6 meses para el ajuste del modelo, lo que se considera el mínimo aceptable dentro de la experimentación. De esta forma se decide utilizar los horizontes temporales de más de 30, 24, 18 y 12 meses para la comparación de modelos.

En la tabla 3.4 cabe destacar el cambio del MAE promedio en los horizontes temporales, observándose que en los horizontes temporales de 30 a 24 presentan los mayores errores comparados al resto de los productos y que por otro lado en los horizontes temporales de 18 a 12 se encuentra los productos con los menores errores promedios.

Tabla 3.4: Tabla de características del horizonte temporal.

Horizonte temporal	MAE prom.	N productos	N productos %
Más de 34	553,9	439	35,9 %
Más de 30	580,4	543	44,4 %
Más de 24	634,0	701	57,3 %
Más de 18	605,5	776	63,5 %
Más de 12	554,3	933	76,3 %

Capítulo 4

Resultados y discusión

Todos los modelos son entrenados con la misma información, cumpliendo con la separación de datos propuesta anteriormente dejando los últimos 6 meses de cada producto para evaluar el modelo a través de las diferentes métricas descritas anteriormente, siendo el MASE el principal indicador para elegir a los mejores modelos, pero de todas formas se incluye la información del MAE, dado que es más intuitivo generando así de mejor forma la noción de error en el modelo. Cabe destacar que todos los modelos fueron construidos a través de la programación de clases de Python, lo cual hizo más generalizables los modelos y rápidos de implementar.

4.1. Resultados medias móviles

En este modelo la ventana de tiempo en la que se va calculando el promedio, mide la sensibilidad del modelo a las tendencias pasadas, lo cual hace a este parámetro importante a la hora de ajustar el modelo, es por esto que en el entrenamiento del modelo, el cual se realiza a través de fuerza bruta, se van evaluando ventanas de tiempo entre 1 y 6 meses, eligiendo la mejor para cada producto.

En la tabla 4.1 se puede observar claramente como los modelos van empeorando a medida que se tiene un horizonte temporal más largo, lo cual puede deberse en el caso del MAE a que los productos con una mayor cantidad de datos temporales presentan mayores demandas y en el caso del MASE se debe a que estos productos también son mas irregulares.

Tabla 4.1: Resultados modelo medias móviles.

Horizonte Temporal	MAE		MASE	
	Prom.	Std.	Prom.	Std.
Más de 12	894,7	9753,4	1,6	10,6
Más de 18	1022,7	10662,1	1,6	11,6
Más de 24	1080,9	11203,2	1,7	12,2
Más de 30	1128,5	12620,8	1,7	13,7

4.2. Resultados suavización exponencial simple

En este modelo el coeficiente de suavización es el parámetro que va cambiando el ajuste del modelo según su magnitud, por lo que para cada producto se optimiza el valor del parámetro según los datos de entrenamiento y evaluación, a través de la librería mencionada anteriormente la cual con el método de la gradiente encuentra un óptimo local, obteniendo el parámetro que mejor se ajusta a cada producto.

En la tabla 4.2 se puede observar claramente como los modelos van empeorando a medida que se tiene un horizonte temporal más largo, lo cual puede deberse en el caso del MAE a que los productos con una mayor cantidad de datos temporales presentan mayores demandas y en el caso del MASE, se debe a que estos productos también son mas irregulares. Además se observan mejores resultados con respecto al modelo de medias móviles.

Tabla 4.2: Resultados modelo suavización exponencial simple.

Horizonte Temporal	MAE		MASE	
	Prom.	Std.	Prom.	Std.
Más de 12	882,8	9203,6	1,7	10,6
Más de 18	1001,9	10567,1	1,7	11,6
Más de 24	1060,5	10567,8	1,8	12,2
Más de 30	1090,5	11855,4	1,8	13,7

4.3. Resultados suavización exponencial doble

En este modelo el coeficiente de suavización y el de tendencia son los parámetros que van cambiando el ajuste del modelo según su magnitud, por lo que para cada producto se optimiza el valor de los parámetros según los datos de entrenamiento y evaluación, a través de la librería mencionada anteriormente la cual con el método de la gradiente encuentra un óptimo local, obteniendo los parámetros que mejor se ajustan a cada producto.

En la tabla 4.3 se puede observar claramente como los modelos van empeorando a medida que se tiene un horizonte temporal más largo, lo cual es una característica presente en los modelos anteriores, pero cabe destacar que en el horizonte temporal de más de 30 meses, el modelo mejora con respecto al horizonte de más de 24 meses, lo cual muestra como el modelo es mejor cuando se tiene una mayor cantidad de datos. Además no se observan mejoras de rendimiento con respecto a los modelos utilizados anteriormente.

Tabla 4.3: Resultados modelo suavización exponencial doble.

Horizonte Temporal	MAE		MASE	
	Prom.	Std.	Prom.	Std.
Más de 12	939,0	10069,5	2,0	10,6
Más de 18	1057,6	11003,9	2,1	11,6
Más de 24	1125,5	11567,8	2,1	12,2
Más de 30	1173,3	13033,8	2,0	13,7

4.4. Resultados suavización exponencial triple o de Holt-Winter

En este modelo el coeficiente de suavización, el de tendencia y el de estacionalidad son los parámetros que van cambiando el ajuste del modelo según su magnitud, por lo que para cada producto se optimiza el valor de los parámetros según los datos de entrenamiento y evaluación, a través de la librería mencionada anteriormente la cual con el método de la gradiente encuentra un óptimo local, obteniendo los parámetros que mejor se ajustan a cada producto.

En la tabla 4.4 se puede observar primero que el modelo no tiene la capacidad de calcular los productos con menos de 18 datos temporales, por lo que para este caso no se entregan métricas, segundo se puede observar que al igual que en los modelos anteriores las métricas de rendimiento van en aumento junto a los horizontes temporales, pero cabe destacar que en el horizonte temporal de más de 30 meses, el modelo mejora con respecto al horizonte de más de 24 meses, lo cual muestra como el modelo es mejor cuando se tiene una mayor cantidad de datos. Además no se observan mejoras de rendimiento con respecto a los modelos utilizados anteriormente.

Tabla 4.4: Resultados modelo suavización exponencial triple.

Horizonte Temporal	MAE		MASE	
	Prom.	Std.	Prom.	Std.
Más de 12	*	*	*	*
Más de 18	1068,9	10442,6	2,3	11,7
Más de 24	1130,4	10971,0	2,3	12,4
Más de 30	1188,2	12370,8	2,2	13,8

4.5. Resultados ARIMA

En este modelo el coeficiente del número de términos auto regresivos, el numero de diferencia en las series de tiempo y el numero de medias móviles son los parámetros que van cambiando el ajuste del modelo según su magnitud, por lo que para cada producto se optimiza el valor de los parámetros según los datos de entrenamiento y evaluación, a través de la librería mencionada anteriormente se busca a través de la fuerza bruta los parámetros

óptimos.

En la tabla 4.5 se puede observar primero que el modelo no tiene la capacidad de calcular los productos con menos de 18 datos temporales, por lo que para este caso no se entregan métricas, segundo se puede observar que al igual que en los modelos anteriores las métricas de rendimiento van en aumento junto a los horizontes temporales, exceptuando por el horizonte temporal de más de 30 meses el cual muestra una mejora considerable con respecto a los horizontes anteriores, además de presentar los mejores resultados para esta categoría.

Tabla 4.5: Resultados modelo ARIMA.

Horizonte Temporal	MAE		MASE	
	Prom.	Std.	Prom.	Std.
Más de 12	*	*	*	*
Más de 18	1031,9	10012,1	1,8	11,6
Más de 24	1094,0	10521,3	1,9	12,2
Más de 30	1087,0	11756,9	1,6	3,7

4.6. Resultados finales

Dado los resultados obtenidos de la experimentación, se puede observar que el mejor modelo para los horizontes temporales de más de 12, 18 y 24 meses es el modelo de medias móviles y segundo lugar se tiene el modelo de suavización exponencial simple, mientras que para el horizonte temporal de más de 30 meses, son el modelo ARIMA y el de medias móviles. De forma general si se eligiera solo un modelo, por la diferencia del rendimiento de ajuste debería de ser el modelo ARIMA, lo que permitiría generar la capacidad de predecir solo el 44,4 % aproximadamente de todos los productos, lo cual no se considera una gran mejora con respecto a la capacidad actual del proceso la cual se encuentra en el 47 %. Por otro lado si se utiliza el modelo de medias móviles el cual tiene la capacidad de predecir el 76,3 % de los productos, este no funciona correctamente en los productos con un horizonte temporal alto.

Debido a que el ajuste de los modelos se realiza de forma particular por producto y para poder conseguir que mas productos puedan ser ingresados en el modelo, es que se propone utilizar un modelo mixto donde para horizontes temporales menores a 30 meses hasta 12 meses se use el modelo de medias móviles, mientras que para altos horizontes temporales se utilice el modelo ARIMA.

En la tabla 4.6 se puede observar como el modelo mixto mejora los resultados de predicción versus los mejores modelos individuales, a la vez que cuenta con la capacidad de predicción del 76,3 % de los productos, lo cual muestra la superioridad del modelo, siendo así elegido para su uso en la posterior implementación, también se puede observar que aumenta el MAE promedio del modelo lo cual pueda deberse a variabilidad del MAE que introduce el modelo ARIMA en los productos con un horizonte temporal mas alto.

Tabla 4.6: Resultados modelo mixto.

Modelo	MAE		MASE	
	Prom.	Std.	Prom.	Std.
Medias Móviles Más de 12	882,8	9203,6	1,7	10,6
Arima Más de 30	1087,0	11756,9	1,6	3,7
Modelo Mixto	975,5	12169,3	1,5	9,0

4.7. Implementación

Debido a los alcances de tiempo que presenta el trabajo de título, la implementación se procedió a realizar de la forma mas simple posible a través de un ejecutable en Python, el cual también se acordó con el área de Supply Chain era la mejor solución debido a que no existe ninguna persona especializada para monitorizar y mantener un sistema de implementación mas complejo, los cuales podrían haber sido levantar una API o un servidor (maquina virtual) que contenga un automatizador de tareas, el cual de forma automática todos los meses realice el ajuste de los modelos y entregue la información requerida.

El programa como muestra la figura 4.1, primero obtiene la información de la base de venta y demanda a través de una consulta en sql a los servidores de la empresa, segundo obtiene la información de la base maestra que se encuentra en la maquina virtual donde esta alojado el programa, lo que permite tener siempre actualizada la base manual de los maestros. Después de obtener toda la información el programa procede a hacer las transformaciones para obtener la base final comentada anteriormente, a la cual se le agrupa la demanda por el código madre y el año-mes, para así obtener la base con que se ajustan los modelos, cabe considerar que si se realiza la ejecución posterior a la primera semana del mes, el programa sacará el mes actual de la base de datos ya que su demanda es solo parcial, por ultimo al terminar esta fase se muestra en el CMD un mensaje que alerta la correcta carga de los datos y por otro lado muestra la cantidad de productos que serán entrenados con cada modelo.

Una vez obtenida la información final para el entrenamiento de los modelos, el programa procede a separar los productos que serán ajustados con cada modelo según los criterios mencionados en el apartado anterior, para posteriormente realizar el ajuste y el forecasting para 6 meses en adelante del producto, utilizando el modelo de medias móviles o el modelo ARIMA según corresponda. Cuando termina este proceso el programa reporta en el CMD que se ha llevado a cabo el ajuste y predicción de los productos.

Por ultimo, el programa se encarga de armar la base de datos entregada al área de Supply Chain según las necesidades y el formato que ellos solicitaron, componiéndose de los siguientes atributos:

- **Código Madre:** Código único de cada producto.
- **Modelo utilizado:** Modelo utilizado para entrenar y pronosticar cada producto.
- **MAE de entrenamiento:** MAE del modelo entrenado, utilizando la métrica de error obtenida con el conjunto de validación.

- **Primer mes pronosticado:** Primer mes pronosticado por el modelo para el producto.
- **Segundo mes pronosticado:** Segundo mes pronosticado por el modelo para el producto.
- **Tercer mes pronosticado:** Tercer mes pronosticado por el modelo para el producto.
- **Cuarto mes pronosticado:** Cuarto mes pronosticado por el modelo para el producto.
- **Quinto mes pronosticado:** Quinto mes pronosticado por el modelo para el producto.
- **Sexto mes pronosticado:** Sexto mes pronosticado por el modelo para el producto.

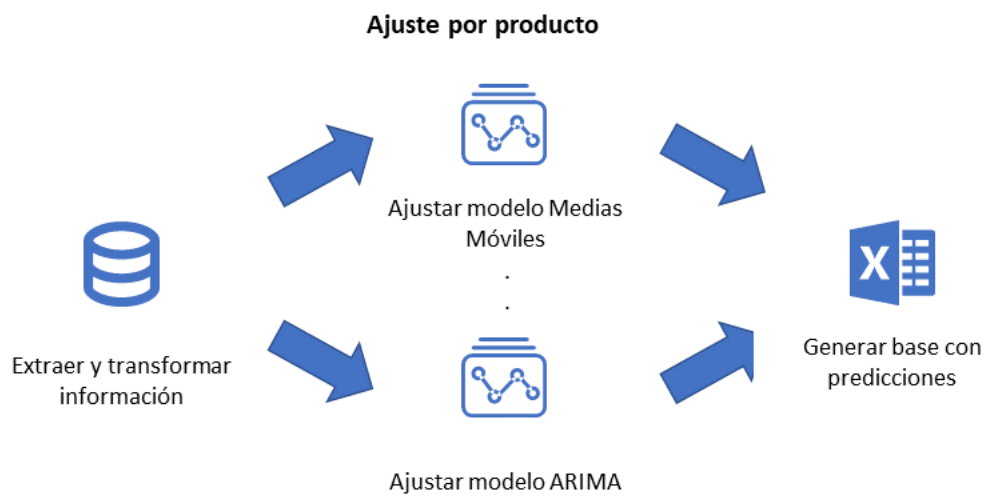


Figura 4.1: Diagrama de implementación del modelo.

Por ultimo en la figura 4.2, se puede observar un ejemplo de la ejecución del programa dentro del CMD o entorno de Python, en el cual cabe destacar la barra de progreso implementada, para dar a conocer cuando termina el proceso de ajuste de los modelos, el cual puede tardar unos minutos según la cantidad de productos a ajustar.

```
La base de datos se cargo correctamente
-----

Los modelo que se pueden utilizar segun la cantidad de datos temporales son:
-----

Arima (Debido a que tienen mas de 30 datos temporales): 164
Medias Moviles: 449

Ajustar modelos y realizar prediccion
-----

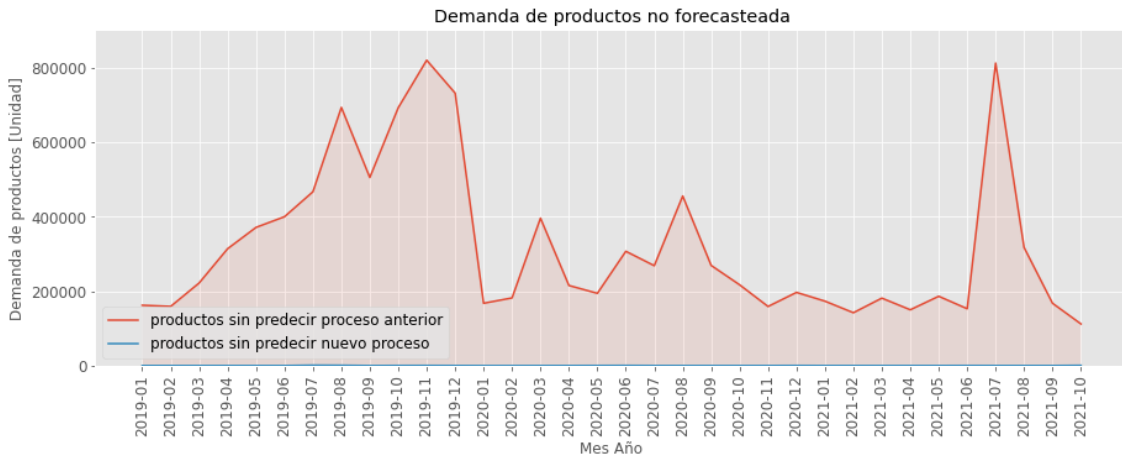
45%|██████ | 676/1504 [01:43<03:59, 3.46it/s]
```

Figura 4.2: Imagen ejemplo de implementación.


4.8. Discusión

Contextualizando los problemas iniciales de la empresa se encuentra que la capacidad de predicción del proceso de forecasting es del 47% la cual es aumentada a un 76,3%, mejorando la capacidad del proceso en 29 puntos porcentuales con la inclusión del modelo mixto. Este aumento de la capacidad del proceso de forecasting impactara positivamente el error promedio, lo que se puede observar en la figura 4.3 la cual se sitúa en el caso que históricamente hubiera existido el modelo mixto, permitiendo bajar considerablemente las unidades no predichas todos los meses, dejando en el nuevo proceso a lo mas mil unidades sin predecir.

El otro problema que presenta el proceso de forecasting consiste en el error del mismo por usar el criterio del experto para predecir la demanda futura, esto causa las problemáticas derivadas que se definieron anteriormente, el problema al intentar comparar ambas formas deriva de la cantidad de predicciones al futuro que se realizan, dado que al aumentar los periodos a predecir se vuelve mas incierta la exactitud de la misma observándose mayores errores en comparación a periodos mas cortos, esto queda en evidencia en los experimentos realizados donde el error promedio del modelo mixto para 6 meses es de 975,5 unidades, el cual es mayor al error promedio del proceso actual. Es por esto que para comparar ambos métodos en términos de error se procede a evaluar el modelo mixto en la predicción de un mes en adelante, como lo hacen en el proceso de forecasting actual, obteniéndose un MAE promedio de 484,6 unidades versus el error promedio del proceso actual de 551,3 unidades, esto considerando solo los productos a los cuales se les aplico el modelo mixto. Se observa entonces una disminución del error en 12 puntos porcentuales lo cual parece bastante pequeño, pero si llevamos esto al error total del proceso se puede observar una mejora total de la predicción en 62.137,8 unidades equivalentes a \$402.031.566 pesos.



(a) Diferencia de capacidad de predicción entre el nuevo y el antiguo proceso.



(b) Falta de capacidad histórica del proceso con la inclusión del modelo.

Figura 4.3: Capacidad del antiguo y nuevo proceso de forecasting.

Capítulo 5

Conclusiones

5.1. Conclusión

Uno de los puntos mas importantes y que se consideraron dentro de los alcances, es el horizonte temporal de los productos a predecir y como este afecta a los modelos más complejos, esto se vio reflejado en la incapacidad de ajustar correctamente los modelos de suavización exponencial triple y el ARIMA para productos con menos de 18 datos de información y que por otro lado al aumentar considerablemente la cantidad de datos para ajustar el modelo (más de 30), siempre llevaba a los modelos mas complejos como el de suavización exponencial doble y triple, junto al ARIMA a mejorar considerablemente su rendimiento. Por otro lado esto se considera también positivo, debido a que a medida que pase el tiempo el modelo mixto ira prediciendo mejor la demanda y se irán incluyendo más productos a los horizontes temporales de más de 30 meses, mejorando aun más el rendimiento del proceso.

Uno de los puntos que no se tuvo en consideración en un principio dentro del trabajo fue la capacidad del proceso de predicción para realizar el forecast a cada uno de los productos existentes, notando que solo el 47% de los productos que presenta la empresa se le realiza una predicción, lo cual como se vio anteriormente genera un enorme impacto negativo al error del proceso, agregando en promedio 322.387 unidades mensuales mal predichas. Esto se considera bastante importante debido a que se puede inferir que en general el proceso de forecasting a través del criterio del experto es bastante acertado, pero que la capacidad del proceso para generar la predicción a todos los productos es lo que genera el alza en el error mensual.

Con respecto a los experimentos realizados en general se observa que el modelo con mejores rendimientos corresponde al de medias móviles, a pesar de ser uno de los modelos más básicos para la predicción temporal univariada, de lo que se puede inferir que esto se pueda deber principalmente a que si bien existen cambios en las tendencias de las demanda de los productos, estas no son intensas ni poco prolongadas lo que hace posible que aunque el modelo se atrase en predecir la tendencia, este error no sea muy alto y por otro lado el modelo pueda en el siguiente periodo tomar en consideración la tendencia pasada, mejorando así el error de la predicción.

Las mayores ganancias que produce el modelo vienen derivadas de la disminución en el error promedio mensual, presentando una mejora equivalente a \$402.031.566 pesos, la cual

no genera una ganancia en su totalidad, debido a que la operación de la empresa juega un rol importante en el porcentaje que se puede convertir en ganancia real para la empresa, ya que se pueden presentar problemas en la entrega, en el almacenamiento de los productos, la calidad de los productos, etc. De esta forma se toman tres diferentes casos de conversión a ganancias reales, los que se pueden ver a continuación:

- Caso pesimista: En el caso pesimista se considera una conversión del 10 %, lo que correspondería a unas ganancias de \$40.203.157 pesos.
- Caso neutral: En el caso neutral se considera una conversión del 15 %, lo que correspondería a unas ganancias de \$60.304.735 pesos.
- Caso optimista: En el caso optimista se considera una conversión del 20 %, lo que correspondería a unas ganancias de \$80.406.313 pesos.

5.2. Recomendaciones y trabajos futuros

Se recomienda con respecto al modelo un monitoreo constante de las medidas de rendimiento entregadas dentro del Excel con predicciones, debido a que esto les permitirá evaluar mensualmente como se está comportando el modelo con la información que se está incluyendo, esto se debe principalmente a lo rápido que se vuelven obsoletos los modelos estadísticos y de machine learning, debido a lo cambiante del mercado o puede que existan meses anómalos que sesgan el modelo en las predicciones futuras, reduciendo el rendimiento del modelo. Esto también es importante considerando que el modelo fue hecho para ajustarse a una gran cantidad de productos, los cuales presentan comportamientos diferentes entre si y están correlacionados con diferentes variables cada uno.

Se recomienda el expandir el uso de la información de esta herramienta con el área de ventas primeramente, debido a que tener una noción del comportamiento de los productos a largo plazo les permitirá poder realizar mejores campañas de venta para reforzar tendencias al alza de la demanda o por el contrario para amortiguar las tendencias a la baja. También esta información sería provechosa llevarla a informes en línea, debido a que sería muy útil cruzarla con información de precios de los productos, quiebres de stock, sobre stock, coste de productos, devoluciones, etc. Esto con el fin de generar indicadores para el área y la alta gerencia que les permitan mejorar sus decisiones estratégicas.

Como trabajos a futuro, primeramente se recomienda la implementación automatizada del proceso, llevándolo a algún servidor o alguna API, lo cual les permitiría reducir los tiempos de ejecución al llevarse a cabo de forma automática, también les ayudaría a tener un mayor control y monitoreo sobre el modelo utilizado. Se pueden usar herramientas como AirFlow y Mlflow que son las herramientas mas comunes para el deployment de modelos de machine learning y que permiten tener un total control de los modelos utilizados, sus versiones, sus parámetros y como estos se comportan en el tiempo.

Como trabajo futuro para los modelos, en un comienzo a medida que se tenga la cantidad suficiente de datos se podrían implementar modelos mas complejos que presenten mejores resultados como son las redes neuronales, en especial las redes recurrentes y los transformers,

esto para modelos temporales univariados, pero también se podría experimentar con modelos temporales multivariados, de esta forma se podrían integrar a cada productos el comportamiento temporal de los productos complementarios y/o suplementarios, además de variables correlacionadas.

Por ultimo, como trabajo futuro se recomienda principalmente la creación de modelos que permitan predecir la demanda de los productos con un horizonte temporal bajo, de esta forma se lograría automatizar por completo el proceso y seria de gran valor por el error que genera introducir un nuevo producto a la venta, debido a que la poca información que se tiene no ayuda a que con el criterio del experto se logre buenos resultados, esto se pudo ver también en el análisis de datos donde dos de los productos con los mayores errores de producción, se debían a su corta introducción al mercado.

Bibliografía

- [1] G. Italia, “Nosotros - emporio globe italia, <https://emporioglobeitalia.cl/nosotros/>, 03 de Enero de 2021.”
- [2] “Continuous delivery for machine learning, <https://martinfowler.com/articles/cd4ml.html>, 03 de Enero de 2021.”
- [3] J. Humble and D. Farley, *Continuous delivery: reliable software releases through build, test, and deployment automation*. Pearson Education, 2010.
- [4] A. Nielsen, *Practical time series analysis: Prediction with statistics and machine learning*. O’Reilly Media, 2019.
- [5] G. E. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [6] H. Zhou, S. Zhang, J. Peng, S. Zhang, J. Li, H. Xiong, and W. Zhang, “Informer: Beyond efficient transformer for long sequence time-series forecasting,” 12 2020.
- [7] R. Tugay and S. G. Oguducu, “Demand prediction using machine learning methods and stacked generalization,” *DATA 2017 - Proceedings of the 6th International Conference on Data Science, Technology and Applications*, pp. 216–222, 9 2020.
- [8] R. Carbonneau, R. Vahidov, and K. Laframboise, “Machine learning-based demand forecasting in supply chains,” *International Journal of Intelligent Information Technologies*, vol. 3, pp. 40–57, 2007.
- [9] R. J. Hyndman *et al.*, “Another look at forecast-accuracy metrics for intermittent demand,” *Foresight: The International Journal of Applied Forecasting*, vol. 4, no. 4, pp. 43–46, 2006.