



**UNIVERSIDAD DE CONCEPCIÓN**  
**FACULTAD DE INGENIERÍA**  
**DEPARTAMENTO DE INGENIERÍA INDUSTRIAL**



**ANÁLISIS Y SELECCIÓN DE MÉTODOS PARA PRONOSTICAR  
LA DEMANDA DE TABLEROS EN EL MERCADO NACIONAL DE  
MASISA S.A**

POR

**Isidora Carolina Morales Villalobos**

Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de Concepción  
para optar al título profesional de Ingeniera Civil Industrial

Profesor Guía

Hernaldo Reinoso Alarcón

Profesional a Cargo

Julio Andrades Carrasco

Diciembre 2022

Concepción (Chile)

**© 2022 Isidora Carolina Morales Villalobos**

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

## Agradecimientos

Quiero agradecer en primer lugar, al área de planificación de Masisa por brindarme apoyo durante todo el desarrollo de mi memoria de título, en especial a Julio quien me acompañó en el proceso.

Además, a mi profesor guía quien me orientó en momentos claves en este proyecto y siempre logró responder a todas mis preguntas con excelente disposición.

A mi familia y amigos quienes han estado incondicionalmente acompañándome durante toda mi etapa universitaria y esta vez no ha sido la excepción.

## Sumario

La planificación de demanda es fundamental para responder a las necesidades de los clientes. Las organizaciones se han enfocado en desarrollar sistemas de planificación eficaces, obteniendo pronósticos que permitan gestionar inventario de manera óptima y evitar situaciones de quiebre de stock o sobrestock. Esta tarea no es fácil, puesto que los niveles de demanda no son constantes en el tiempo, no obstante, existen distintos métodos que permiten hacer una proyección de ella y de su comportamiento en los próximos periodos. Los métodos de pronóstico que se estudiaron en este proyecto se relacionan con el análisis de series de tiempo y regresiones lineales.

MASISA S.A. es una empresa dedicada a la producción y comercialización de tableros de madera, molduras, entre otros, para la fabricación de muebles y arquitectura de interiores. Actualmente, los pronósticos no son los deseados, puesto que las proyecciones son poco realistas y el error MAPE que poseen es de 54%, por lo que ha surgido la necesidad de disminuirlo.

Por lo anterior, esta memoria de título busca mejorar estos ajustes de pronóstico mediante la evaluación de métodos y su validación en el sistema utilizado por la empresa IBP (Integrated Business Planning for Supply Chain), una herramienta que permite almacenar y procesar gran cantidad de información relacionada con la cadena de suministros y, por tanto, con la planificación de demanda. Este instrumento permite configurar modelos que contengan distintos métodos de pronóstico para así, ser ejecutados a un gran número de series de tiempo y obtener resultados de proyecciones que se visualizan en una planilla Excel.

Para ello, se realizó una segmentación de la demanda por su componente sistemática y se proponen tres modelos, con el fin de utilizarlos según el comportamiento que posea la serie de tiempo. El modelo 1 se utiliza en series que posean comportamiento continuo, el modelo 2 para series con tendencia y el modelo 3 para series con estacionalidad. Se observaron mejoras en los resultados, logrando disminuir el error de pronóstico hasta en un 20%.

Por otra parte, se observó el efecto de tres variables independientes (Índice de Precio del Productor (IPP), Índice de Precio del Consumidor (IPC) y el Precio de los productos (P)) en la demanda utilizando regresiones lineales. Se infiere que la variabilidad del IPP genera un efecto en la variabilidad de la demanda.

## Abstract

The planning of the demand is a priority to answer the requirements of the costumers. The organizations are focused to develop efficient systems of planning, which provides sales forecasts that allows an ideal process of inventory, avoiding the broke of stocks or “overstock”. This is an important assignment, considering that the levels of demands are not continuous in time. However, there are different methods that provides a projection of it and its behaviour through the future terms. The methods of forecasting which were studied in this project are related to the analysis of periods of time and their economic rate recessions.

MASISA S.A. is a company related to the production and the marketing of wood boards and frames, among others, for the manufacturing of furniture and architectural interiors. At this moment, the forecasting is not the ideal, since the projections are less realistic and the MAPE error is from 54%, which creates the necessity of decrease it.

As a result, this thesis searches the best adjustments to the forecast through the evaluation of methods and its validation in the used system by the company IBP (Integrated Business Planning for Supply Chain) an analysis tool that allows the storage and process a great amount of information related to the chain supplies and therefore, the planning of the demand. This instrument is able to set models of different methods of forecasting, in order to execute them in a large number of periods of time and obtain results of the projections in an Excel document. To that end, this project developed a segmentation of the demand by its systematic components, which recommends three models, with the purpose of using them according to the behaviour provided by the periods of time. The model 1 is used in series with the same continuous behaviour. The model 2 for series with trends effects and the model 3 for series with stationarity effects. It presented improvement in the results, allowing the decrease of the error forecast up to the 20%. On the other hand, it presented the effect of three independent variables: “Índice Precio del Productor” (IPP), “Índice de Precio del Consumidor (IPC) and the “Precio de los Productos” (P) in the demand by using linear regressions. It follows, therefore, that the variability of IPP produces an effect in the variability of the demand.

# Contenido

<b>1. Introducción.....</b>	<b>1</b>
1.1 Antecedentes generales.....	1
1.2 Descripción de problemática y justificación del tema.....	2
1.3 Objetivos .....	4
1.4 Estructura del informe.....	5
<b>2 Antecedentes de la Empresa.....</b>	<b>6</b>
2.1 Descripción Masisa S.A. ....	6
2.2 Estructura Organizacional .....	8
2.3 Planificación.....	9
<b>3 Marco Teórico.....</b>	<b>11</b>
3.1 Pronóstico de Demanda.....	11
3.2 Métodos de Pronóstico de Demanda.....	12
3.2.1 Cualitativos.....	12
3.2.2 Análisis de Series de Tiempo.....	13
3.2.3 Métodos de Regresiones.....	18
3.3 Pronóstico de Demanda en Masisa.....	21
<b>4 Metodología y Procesamiento de la Base de Datos.....</b>	<b>24</b>
4.1 Identificar los principales factores que influyen en el pronóstico de la demanda.....	24
4.1.1 Segmentación de la Demanda.....	25
4.1.2 Limpieza de Datos Históricos .....	28
4.1.3 Variables Externas.....	28
4.2 Pronosticar a nivel apropiado de demanda.....	30
4.3 Establecer medidas de desempeño.....	32
<b>5 Resultados .....</b>	<b>33</b>
5.1 Identificar los principales factores que influyen en el pronóstico de la demanda.....	33
5.1.1 Segmentación.....	33
5.1.2 Limpieza de Historia.....	35
5.2 Pronosticar a nivel apropiado de demanda.....	37
5.2.1 Análisis de Series de Tiempo.....	37
5.2.2 Métodos de Regresiones.....	45
5.3 Comparación de Medidas de Error para Análisis de Series de Tiempo.....	49
<b>6 Discusión de Resultados.....</b>	<b>50</b>
<b>7 Conclusiones.....</b>	<b>52</b>
<b>8 Referencias.....</b>	<b>55</b>

<b>9 Anexos .....</b>	<b>58</b>
Anexo 1.....	58
Anexo 2.....	59
Anexo 3.....	65
Anexo 4.....	67
Anexo 5.....	74
Anexo 6.....	89

## Índice de Figuras.

Figura 2.1: Distribución de Negocios Masisa. ....	7
Figura 2.2: Estructura Organizacional Masisa. ....	8
Figura 2.3: Organigrama Gerencia Cadena de Suministro.....	9
Figura 2.4: Descripción del Proceso S&OP .....	10
Figura 3.1: Ciclo de Vida del Producto.....	13
Fuente: (Ballou, 2004).....	13
Figura 3.2: Funciones de IBP.....	22
Figura 4.1: Porcentaje de Contribución de cada segmento de productos. ....	27
Figura 4.2.: Clasificación Métodos de Pronóstico Según la Fuente de Datos.....	32
Figura 5.1: Distribución Series de Tiempo para producto AA y A.....	35
Figura 5.2: Limpieza de Historia para producto 78708NH043 TCDC. ....	35
Figura 5.3: Limpieza de Historia General. ....	36
Figura 5.4: Pronóstico con Modelo 1. ....	41
Figura 5.5: Pronóstico con Modelo Inicial.....	41
Figura 5.6: Comparación de Pronósticos.....	41
Figura 5.7: Pronóstico con Modelo 2. ....	43
Figura 5.8: Pronóstico con Modelo Inicial.....	43
Figura 5.9: Comparación de Pronósticos.....	43
Figura 5.10: Pronóstico con Modelo 3. ....	44
Figura 5.11: Pronóstico con Modelo Inicial.....	44
Figura 5.12: Comparación de Pronósticos.....	44
Figura 5.13: Regresiones Significativas por Variables Explicativas.....	45
Figura 9.1: Arquitectura IBP.....	59
Figura 9.2: Interfaz principal de Fiori. ....	60
Figura 9.3: Interfaz de Configuración de un Modelo de Pronóstico. ....	61
Figura 9.4: Configuración de los métodos estadísticos. ....	62
Figura 9.5: Configuración de Suavización Exponencial Triple. ....	63
Figura 9.6: Interfaz de IBP en Excel. ....	64



## Índice de Tablas.

Tabla 3.1: Supuestas RLS y RLM. ....	20
Tabla 4.1: Configuración Perfiles de Automatización de Pronósticos.....	26
Tabla 4.2: Comportamientos de las Series de Tiempo .....	27
Tabla 4.3: Nivel de Agregación para Generar Pronósticos .....	30
Tabla 5.1: Segmentación por Contribución.....	33
Tabla 5.2: Total de Series de Tiempo a Analizar .....	34
Tabla 5.3: Segmentación por Comportamiento de la Serie de Tiempo.....	34
Tabla 5.4: Modelo de Pronóstico Actual.....	37
Tabla 5.5: Definición de Modelos según el Comportamiento de la Serie de Tiempo.....	38
Tabla 5.6: Configuración Modelo 1. ....	39
Tabla 5.7: Configuración Modelo 2. ....	39
Tabla 5.8: Configuración Modelo 3. ....	40
Tabla 5.9: Comparación de Pronóstico para producto con comportamiento Continuo.....	41
Tabla 5.10: Comparación de Pronóstico para Producto con comportamiento con Tendencia. .....	43
Tabla 5.11: Comparación de Pronóstico para producto con Estacionalidad. ....	44
Tabla 5.12: Resultados RLS producto 78935NH037 TCDC. ....	46
Tabla 5.13: Resultados RLM producto 78708NH043 TCDC. ....	48
Tabla 5.14: Comparación de las Métricas de Error. ....	49
Tabla 9.1: Distribución de mercados y productos. ....	58
Tabla 9.2: Métodos de Pronóstico Disponibles en IBP.....	63
Tabla 9.3: Resultados de la Limpieza de Datos Históricos de Pronóstico. ....	66
Tabla 9.4: Resultados Producto 78N25NH043 TCDS. ....	67
Tabla 9.5: Resultados a Nivel Agregado Productos Continuos Segmento AA.....	68
Tabla 9.6: Resultados a Nivel Agregado Productos Continuos Segmento AA.....	69
Tabla 9.7: Resultados Producto 78D43NH037 TCDS. ....	70
Tabla 9.8: Resultados Nivel Agregado Productos con Tendencia Segmento AA.....	71
Tabla 9.9: Resultados Nivel Agregado Productos con Tendencia Segmento A.....	71
Tabla 9.10: Resultados Producto 11995NH085 TCDC.....	72
Tabla 9.11: Resultados Nivel Agregado Productos con Estacionalidad Segmento AA.....	73

Tabla 9.12: Resultados Nivel Agregado Productos con Estacionalidad Segmento A.....	73
Tabla 9.13: Resultados RLS Significativas con IPC. ....	74
Tabla 9.14: Resultados RLS significativas IPP Parte 1.....	76
Tabla 9.15: Resultados RLS significativas IPP Parte 2.....	77
Tabla 9.16: Resultados RLS Significativas P. ....	81
Tabla 9.17: Resultados RLM IPP e IPC. ....	83
Tabla 9.18: Resultados RLM IPP y P.....	85
Tabla 9.19: Resultados RLM IPC, IPP y P.....	87
Tabla 9.20: Comparación Error MAPE a Nivel General.....	89
Tabla 9.21: Comparación Error MAPE Segmento AA. ....	89
Tabla 9.22: Comparación Error MAPE Segmento A. ....	90
Tabla 9.23: Comparación de Error MAPE Segmento AA, Series de Tiempo Continuas. ...	90
Tabla 9.24: Comparación de Error MAPE Segmento A, Series de Tiempo Continuas. ....	90
Tabla 9.25: Comparación Error MAPE Segmento AA, Series de Tiempo con Tendencia..	91
Tabla 9.26: Comparación Error MAPE Segmento A, Series de Tiempo con Tendencia.....	91
Tabla 9.27: Comparación Error MAPE Segmento AA, Series de Tiempo con Estacionalidad.....	91
Tabla 9.28: Comparación Error MAPE Segmento A, Series de Tiempo con Estacionalidad. ....	92

# **1. Introducción.**

## **1.1 Antecedentes generales.**

Masisa S.A. (Masisa) es una empresa chilena dedicada a la fabricación y comercialización, principalmente de tableros y molduras de madera para la elaboración de muebles y arquitectura de interiores.

Fue fundada el año 1960 con el nombre de “Maderas Aglomeradas Ltda.” siendo el primer productor de tableros aglomerados en Chile. En 1992 comienza un plan de expansión internacional de Masisa y se crea Masisa Argentina. Actualmente, se diferencia de su competencia por su posicionamiento en distintos mercados internacionales como Perú, Venezuela, Ecuador, Colombia, EE. UU., México, entre otros.

El negocio de Masisa se divide en dos, el negocio forestal y el negocio industrial/comercial. El primero tiene por objetivo generar productos forestales obtenidos directamente de los bosques, a través de la recuperación de subproductos de la industria de aserrío propia y de terceros.

Por otra parte, el negocio industrial/comercial maximiza la rentabilidad del negocio, gracias a la comercialización de productos y servicios con un mayor valor agregado y el desarrollo de nuevos canales de venta que poseen un modelo de negocio más tecnológico y orientado al cliente.

La estructura organizacional de la empresa está compuesta por diez gerencias, entre ellas la gerencia de Cadena de Suministros, que se encarga de la logística y las redes de suministro en todo el proceso productivo. Entre sus actividades más importantes, está la compra nacional e internacional de suministros, licitaciones, contratos de abastecimiento y gestión inmobiliaria de sus unidades físicas. Dentro de la Gerencia de Cadena de Suministros, se encuentra la gerencia de Planificación y al interior de esta, el jefe de planificación, encargado de planificar la demanda que hay en el mercado de acuerdo con los requerimientos que poseen los clientes.

Masisa, realiza el proceso de planificación de demanda a través de la herramienta SAP IBP (Integrated Business Planning for Supply Chain) que permite almacenar y procesar gran cantidad de información y, dentro de las variadas funciones que posee, genera pronósticos de

demanda mediante del ciclo de vida del producto, análisis de series de tiempo y métodos causales. Para validar el pronóstico realizado, se utilizan distintos indicadores que permiten comparar las ventas reales con la proyección entregada por el sistema. Actualmente, estos indicadores poseen un bajo rendimiento, lo que se refleja en una gran diferencia entre las ventas reales y los pronósticos que se han realizado en el último año. El bajo rendimiento de los indicadores podría ocasionar problemas de sobre stock, quiebres de stock, pérdidas de venta y altos costos logísticos.

Esta diferencia se debe principalmente a que la herramienta SAP IBP no está siendo utilizada eficientemente puesto que hay consideraciones importantes relacionadas al análisis de datos y métodos de pronóstico que no se tienen en cuenta y sólo se utiliza análisis de series de tiempo para proyectar, dejando fuera los métodos causales.

El desarrollo de este proyecto se enfoca en mejorar los pronósticos que realiza la herramienta SAP IBP y con ello sus indicadores de desempeño.

Para abordar este trabajo se realizan mejoras en los análisis de series de tiempo y se investiga el efecto de los métodos causales como regresiones lineales simples y múltiples.

Dado la amplitud del negocio que comprende Masisa y el tiempo dispuesto para realizar esta memoria de título, el desarrollo se centra en el mercado de tableros a nivel nacional y se espera que los resultados se puedan extrapolar a otras familias de productos y negocios. En el Anexo 1 se encuentra más información sobre qué productos comprende cada mercado.

## 1.2 Descripción de problemática y justificación del tema.

La planificación de la demanda es un proceso de gestión de la cadena de suministro que permite a una empresa proyectar la demanda en el futuro y personalizar de forma exitosa la producción de la empresa, ya sean productos o servicios, de acuerdo con esas proyecciones.

Empresas de gran magnitud como Masisa que abarcan distintos negocios y clientes, pueden visualizar con facilidad que todos los productos que ofrecen poseen distintos niveles de demanda y, en consecuencia, la planificación de demanda para cada producto debe responder al comportamiento de las necesidades del mercado, el cual es específico para cada caso.

En general, existen cuatro formas para planificar la demanda de un negocio; el método cualitativo que consiste en investigaciones de mercado y análisis de panel de expertos,

análisis de series de tiempo que utiliza la demanda histórica para hacer pronósticos, métodos de regresión que vinculan el comportamiento de la demanda con factores externos como el estado de la economía, tasa de interés, entre otras variables, y la simulación. Este método imita las preferencias de los clientes para realizar un pronóstico de demanda.

La elección del método dependerá del tipo de producto y el tiempo que lleva en el mercado (ciclo de vida del producto). En el caso de productos que llevan años comercializándose y en donde existe registro de la demanda en los periodos pasados, la planificación se puede realizar mediante del análisis de series de tiempo y métodos causales, por el contrario, productos que están ingresando al mercado y no se posee un historial de ventas que muestre algún comportamiento es preferible planificar su demanda a través del método cualitativo.

En Masisa la planificación de demanda se realiza combinando el método cualitativo con el análisis de series de tiempo.

En primera instancia el área de Marketing define en qué estado del ciclo de vida del producto se encuentra cada producto, si son productos que llevan tiempo en el mercado se aplica algún método de análisis de series de tiempo. Si son productos nuevos la herramienta IBP permite referenciarlos con algún producto que ya es parte del portafolio hace más tiempo y se espera que tenga el mismo comportamiento en ventas. Al referenciar el producto nuevo, se toma un porcentaje de la historia de ventas que ya lleva más tiempo y se utiliza como entrada para realizar un análisis de series de tiempo.

La baja eficiencia de los indicadores de pronóstico de demanda se debe a que al utilizar el análisis de series de tiempo no incluyen la identificación del comportamiento de la serie, es decir, si éstas poseen intermitencia en sus ventas, tendencias al alza o a la baja o estacionalidad, lo que es fundamental para obtener pronósticos coherentes con el historial de demanda.

Para llevar a cabo este proyecto se proponen seis objetivos específicos, los cinco primeros tienen relación con la mejora de los pronósticos con análisis de series de tiempo. En primera instancia, se limpian los datos para suavizar datos atípicos y eliminar datos incoherentes con el comportamiento de la demanda y así obtener una entrada de datos acorde a un comportamiento realista. Por otra parte, se identifica el comportamiento de demanda que poseen los productos observados para segmentarla según su componente sistemática y definir

los métodos de series de tiempo adecuados con sus respectivos parámetros. Esto se realiza con ayuda del software Statgraphics que permite identificar patrones de comportamiento, tendencia y estacionalidad al mismo tiempo que se prueban distintos métodos de pronóstico. El tercer objetivo sustenta una etapa de prueba con los métodos y parámetros obtenidos de Statgraphics en IBP y validación con todas las series de tiempo que se deben pronosticar.

Luego, el objetivo cuatro y cinco se relacionan con la propuesta de modelos y prácticas que contribuyen a una mejora en los pronósticos de demanda y con ello sus indicadores de eficiencia.

Finalmente, el objetivo seis, es de tipo investigativo y en relación estricta con regresiones lineales. Actualmente estos métodos no están siendo utilizados en la organización y se estudia la incorporación de variables externas de tipo macroeconómicas como el Índice de Precio del Productor (IPP), Índice de Precio del Consumidor (IPC) y Precio de los productos (P) para identificar algún grado de correlación e impacto en la demanda según el comportamiento de estas variables explicativas.

### 1.3 Objetivos

#### **Objetivo General**

Comprender e identificar los métodos de análisis de series de tiempo y modelos de regresión que permitan mejorar la precisión del pronóstico de demanda para tableros en el mercado nacional de la empresa MASISA S.A.

#### **Objetivos Específicos**

Los 6 objetivos específicos del proyecto se definen a continuación:

1. Realizar limpieza de datos, suavizando datos atípicos para obtener entradas de datos con mayor representatividad.
2. Identificar la componente sistemática que poseen los datos históricos de cada serie de tiempo para segmentar la demanda según su comportamiento.
3. Evaluar métodos de análisis series de tiempos que sean congruentes al comportamiento de la demanda y generar modelos en IBP para validar a través de su ejecución.
4. Comparar resultados con el método utilizado actualmente.
5. Generar propuesto de el/los modelo/s que realicen un mejor pronóstico de la demanda.

6. Identificar factores externos a la organización de tipo macroeconómico que tengan un grado de correlación con el comportamiento de la demanda actual.

#### 1.4 Estructura del informe

Este informe está compuesto por 7 capítulos, los primeros dos tratan de los antecedentes de la problemática y el contexto de la empresa, su organización y cómo opera.

El capítulo 3 contiene el fundamento teórico de este proyecto, se describen los métodos estadísticos y el sistema utilizado por la empresa para generar pronósticos. Luego, en el apartado 4 se describe la metodología utilizada para el desarrollo de esta memoria.

En la quinta parte, se expone los resultados obtenidos, se muestra sólo una selección de ellos y los indicadores finales.

Finalmente, los capítulos 6 y 7 contienen la propuesta generada y las conclusiones de este proyecto.

Al final del documento se encuentran las referencias utilizadas para desarrollar este trabajo, el cual es apoyado por una sección de Anexos que brindan un mayor detalle en relación a la información de la empresa, el sistema utilizado y los resultados obtenidos.

## **2 Antecedentes de la Empresa.**

Este capítulo tiene por objetivo definir el contexto en el que surge la problemática a resolver en este proyecto y entender el funcionamiento de la empresa, en específico el área de planificación.

### **2.1 Descripción Masisa S.A.**

Masisa lleva 62 años en la industria y la propuesta de valor para sus clientes es ser la empresa líder en valor agregado y soluciones comerciales. Entregan inspiración, asesoría, diseño y servicios que transforman sus productos en los espacios deseados de sus clientes. Poseen cuatro segmentos de clientes que responden a las siguientes necesidades: soluciones para muebles e interiores, soluciones para molduras decorativas, soluciones para madera aserrada y soluciones forestales. Su negocio se divide en dos, el negocio forestal y el negocio industrial/comercial. El negocio forestal genera productos obtenidos directamente del bosque, como así también mediante la recuperación de subproductos de la industria de aserrío propia y de terceros. Por otra parte, el negocio industrial/ comercial se enfoca en maximizar la rentabilidad a través de productos y servicios que poseen un mayor valor agregado y el desarrollo de canales de distribución que poseen mayor tecnología y con un modelo de negocio orientado al cliente.

El patrimonio de forestal de Masisa al 2012 alcanzaba 388.559 hectáreas distribuidas en Chile, Brasil, Argentina y Venezuela. Poseen oficinas comerciales en Chile, Perú, Ecuador y Colombia (PEC), EE. UU., plantas industriales en Chile, México y Venezuela y sus mercados de exportación son Canadá y Asia. Los países que poseen oficinas comerciales son abastecidos por Chile, por otra parte, los países que poseen plantas industriales se autoabastecen. Además, cuentan con una red placancentro que posee un rol fundamental en la distribución y el desarrollo del negocio digital. El 2021 la red placancentro de Masisa mantuvo su posición como la red líder en tiendas especializadas en la entrega de productos y servicios para mueblistas. Masisa cuenta con centros de distribución en Chile, Colombia, Ecuador, Perú, Bolivia, México y Venezuela. En la Figura 2.1 se visualiza la distribución del negocio de Masisa.





**Figura 2.1: Distribución de Negocios Masisa.**

Fuente: (Masisa Corporativo, 2022)

En cuanto a los principios y valores de Masisa, estos se describen a continuación:

**Visión:** “Llevar diseño, desempeño y sustentabilidad para la creación de cada mueble y espacio interior en Latinoamérica”.

**Misión:** “Conquistar la preferencia de los clientes siendo la marca más innovadora, sustentable y confiable de la industria de tableros de fibra y partículas de madera, maximizando la creación de valor económico, social y ambiental”.

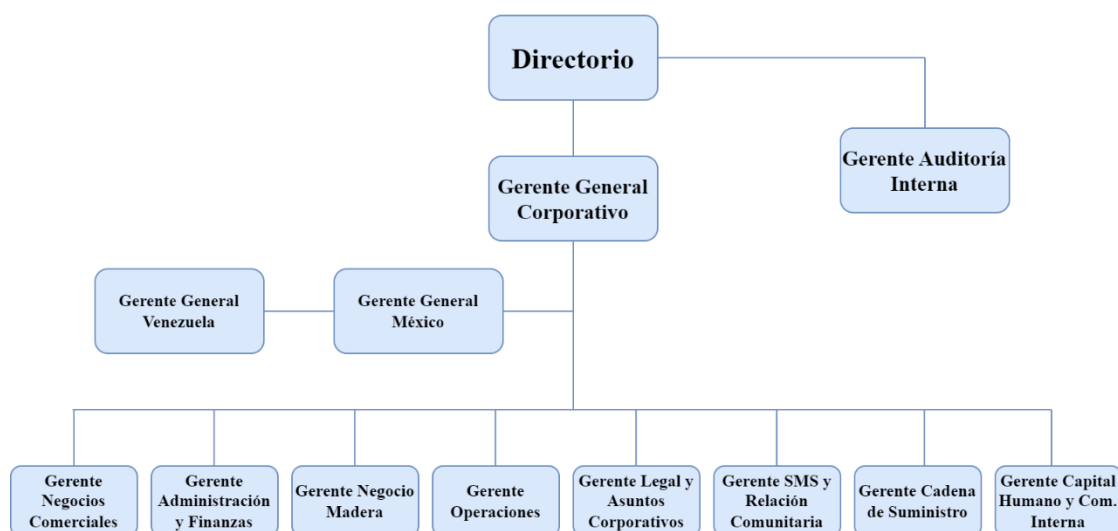
Algunos de sus principios empresariales son:

- Resultados económicos: Buscan permanentemente la creación de valor sostenible.
- Conducta empresarial: Mantienen un compromiso empresarial ético y transparente con niveles elevados de gobernabilidad.
- Conducta individual: Exigen una conducta personal honesta, íntegra y transparente.
- Relaciones con su cliente: Promueven la confianza en el largo plazo, ofrecen productos de calidad, innovadores y sustentables y servicios de excelencia.

- Relaciones con sus colaboradores: Desarrollan equipos de alto desempeño, en un ambiente laboral sano, seguro y basado en el respeto de los Derechos Humanos.
- Relaciones con las comunidades, proveedores, sociedad y medioambiente: Están comprometidos en la interacción con sus vecinos, comunidades, proveedores, sociedad, medio ambiente, fundamentados en el respeto mutuo y la cooperación.

## 2.2 Estructura Organizacional.

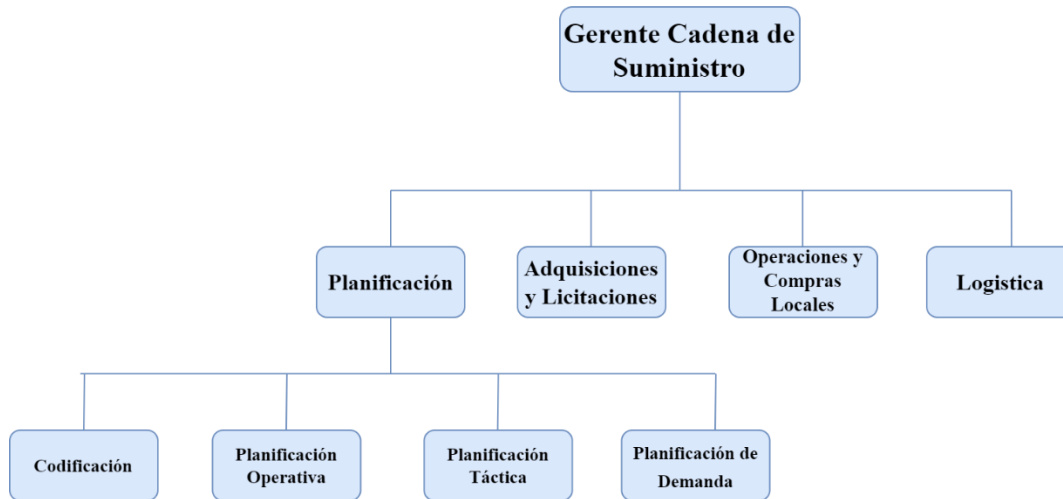
La estructura organizacional de Masisa la lidera el área directiva compuesta por el presidente y seis directores. El área ejecutiva la componen diez gerencias encabezadas por el Gerente General Corporativo, entre estas gerencias se encuentra la Gerencia de Cadena de Suministros. La Figura 2.2 muestra la distribución de las gerencias que componen Masisa.



**Figura 2.2: Estructura Organizacional Masisa.**

Fuente: Elaboración Propia a partir de (Masisa Corporativo, 2022)

Dentro de la Gerencia de Cadena de Suministros se encuentran cuatro departamentos, Planificación, Adquisiciones y Licitaciones, Operaciones y Compras Locales, y Logística. El departamento de Planificación se compone de las áreas de Codificación, Planificación Operativa, Planificación Táctica y Planificación de Demanda. Es esta última área la encargada de generar los pronósticos de demanda de todos los negocios y de donde surge la necesidad de desarrollar este proyecto. En la Figura 2.3 se observa la distribución de los departamentos que componen la Gerencia de Cadena de Suministros.



**Figura 2.3: Organigrama Gerencia Cadena de Suministro**

Fuente: Elaboración Propia

### 2.3 Planificación.

La planificación en Masisa se lleva a cabo siguiendo el proceso S&OP (Sells and Operation Planner) el cual tiene por función de equilibrar los planes de oferta y demanda a nivel agregado (Jacobs, Berry, Clay, & Vollman, 2011). Es una combinación de personas, procesos y tecnología (Lapide, 2005). Las personas que son parte del proceso tienen un rol protagónico en comparación con los modelos o software, es decir, tecnología (Grimson & Pyke, 2007)

El proceso S&OP se entiende como "un proceso para desarrollar planes tácticos que brinden a la gerencia la capacidad de dirigir estratégicamente sus negocios para lograr una ventaja competitiva de forma continua, mediante la integración de planes de marketing centrados en el cliente para productos nuevos y existentes con la gestión de la cadena de suministro" (Noroozi & Wikner, 2017).

El objetivo del Proceso S&OP en Masisa se define como: "maximizar la rentabilidad del negocio integrado de Masisa, balanceando la demanda y la capacidad en un horizonte de 3 a 18 meses, optimizando costos y capital de trabajo (inventarios)" (Masisa, 2020).

Es un proceso de negocio que permite balancear la demanda con las capacidades, enlazando los recursos productivos y logísticos con los objetivos de venta. Además, instala una rutina de actividades rigurosa, repetitiva y transversal, que se enfoca en la resolución de problemas, con un horizonte de 3 a 18 meses. Permite la toma de decisiones en base a hechos e

información, para distintos escenarios, a lo largo de la cadena de valor de la compañía e identifica palancas de mejora de rentabilidad para el negocio.

Cada ciclo del proceso dura un mes y está compuesto por cinco etapas que se describen en la Figura 2.4. El alcance de este proyecto está estrictamente relacionado con la segunda etapa de Planificación de Demanda, donde se ejecutan los modelos de pronóstico y se definen métricas desempeño (Forecast Accuracy y BIAS).

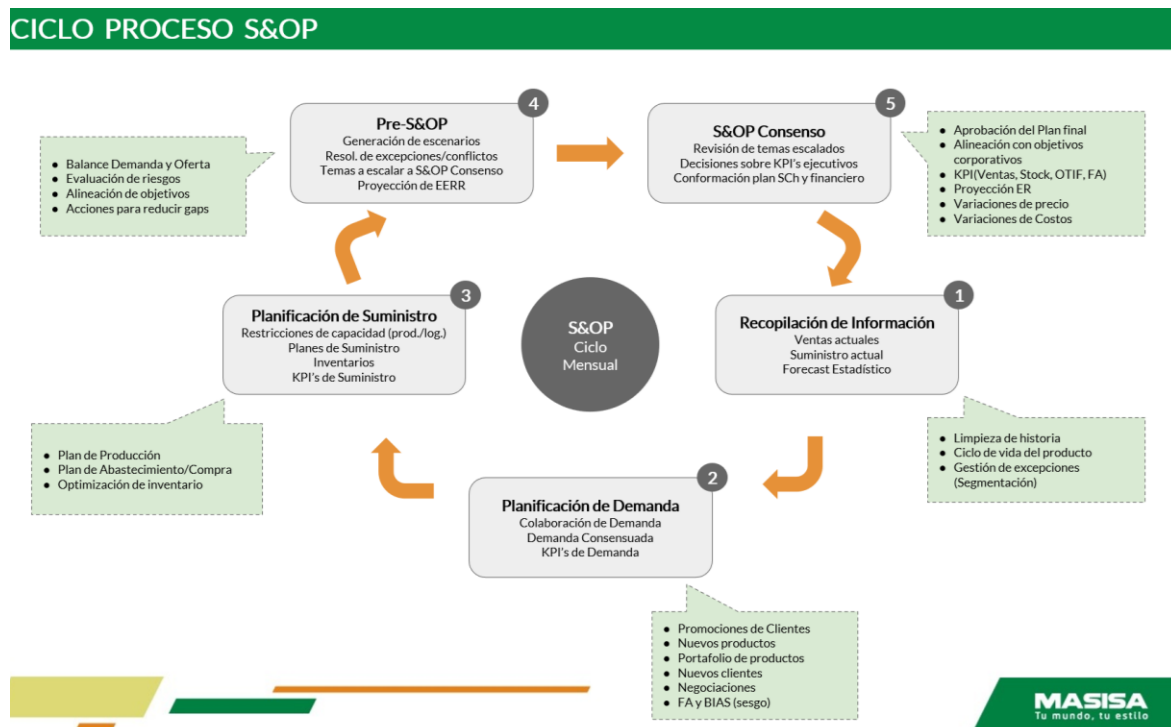


Figura 2.4: Descripción del Proceso S&OP

Fuente: (Masisa, 2020)

### **3 Marco Teórico.**

El objetivo de este capítulo es fundamentar el conocimiento que se utilizará para resolver la problemática descrita, el cual se enfoca principalmente en entender el contexto relacionado a entender el contexto relacionado a lo que es un pronóstico de demanda y cómo estos se pueden llevar a cabo. Comprender qué es una serie de tiempo y en qué consiste su análisis, métodos de regresión y en conjunto con indicadores que se han encontrado en la literatura que sirven para medir el grado de asertividad de los pronósticos. En general, para la elaboración de este capítulo se utiliza información proporcionada por los autores (Chopra & Meindl, 2013) y (Hanke & Wichern, 2010).

Además, se explica la funcionalidad que posee la herramienta IBP (Integrated Business Planning) ya que actúa como el sistema que almacena toda la información que entregan las distintas áreas de la cadena de suministro, ejecuta los métodos de pronóstico y obtiene los resultados que serán de utilidad para el planificador de demanda.

#### **3.1 Pronóstico de Demanda.**

Dentro de las operaciones de gestión de la cadena de suministro se encuentra la planeación de demanda. Todas las decisiones relacionadas con la cadena de suministro tomadas antes de que la demanda se haya materializado se consideran como un pronóstico. Estos están sujetos al nivel de capacidad e inventario disponible.

Para estimar pronósticos de demanda existen factores que se deben tener en cuenta y se describen a continuación:

- Los pronósticos de demanda nunca serán exactos, no existe un método que logre hacer coincidir la demanda real con el pronóstico realizado. Para escoger un método de pronóstico se debe incluir el valor esperado y una medida de error de pronóstico que servirá como indicador.
- En general, los pronósticos en el largo plazo poseen una mayor desviación estándar que los pronósticos de corto plazo, esto se entiende como que los pronósticos a largo plazo son menos precisos que los a corto plazo.
- Los pronósticos agregados suelen ser más precisos que los desagregados, esto es debido a que tienden a tener una menor desviación estándar del error en relación con la media.

### 3.2 Métodos de Pronóstico de Demanda.

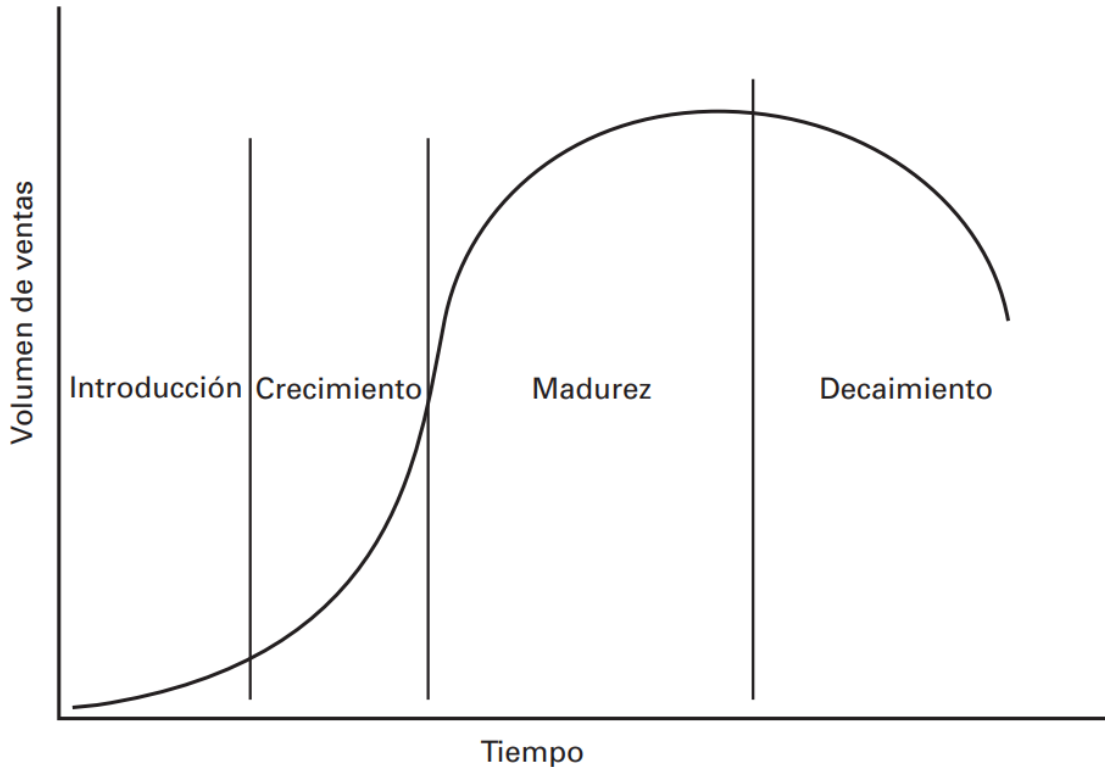
La demanda del cliente depende de varios factores y puede pronosticar, al menos con cierta probabilidad. Es fundamental antes de aplicar cualquier método de pronóstico entender los factores que influyen en la demanda futura y luego de realizar un pronóstico verificar la relación de la demanda proyectados con dichos factores. Dentro de los factores que influyen en el pronóstico de demanda se encuentran la demanda pasada, publicidad planeada o esfuerzos de marketing, descuentos de precios en productos, estado de la economía, acciones que los competidores han realizado.

Existen distintos métodos de pronóstico y se clasifican a continuación:

#### 3.2.1 Cualitativos.

Estos métodos son subjetivos y se sustentan principalmente del juicio humano. Se utilizan cuando se disponen de pocos datos históricos o cuando expertos cuentan con datos de investigación del mercado que puedan afectar el pronóstico. Uno de los métodos cualitativos utilizados es el ciclo de vida del producto que se explica a continuación.

- Análisis del Ciclo de Vida: El ciclo de vida de producto se describe a través de la evolución de las ventas y los beneficios, desde el lanzamiento del producto hasta su retirada (Agueda, García, Narros, Reinares, & Saco, 1997). Se identifican cuatro etapas de este ciclo, *Introducción*, ocurre después de que un nuevo producto haya entrado al mercado y las ventas no poseen un alto nivel, *Crecimiento*, es el punto en el que existe una amplia distribución, se utilizan variados puntos de venta con control sobre la disponibilidad del producto, *Madurez*, el producto es conocido en el mercado y por tanto se enfrenta a nuevos competidores, los beneficios son estables y *Decaimiento*, en esta etapa el volumen de ventas decae producto de cambios tecnológicos de la competencia o producto del desinterés de los consumidores, los beneficios menos e incluso negativos (Ballou, 2004).



**Figura 3.1: Ciclo de Vida del Producto.**

Fuente: (Ballou, 2004)

### 3.2.2 Análisis de Series de Tiempo.

El pronóstico mediante análisis de series de tiempo utiliza la demanda histórica para hacer una proyección. Estos métodos dan un buen pronóstico en casos en los que la demanda base no varía significativamente entre un año y otro.

Antes de definir en qué consiste y la aplicación de cada método de pronóstico es necesario comprender las características y qué componen una serie de tiempo.

La demanda está compuesta por un componente sistemático y un componente aleatorio.

$$\text{Demanda Observada} = \text{Componente Sistemático} + \text{Componente Aleatorio} \quad (1)$$

El **componente sistemático** lo componen:

- **Nivel:** Valor esperado de la demanda, es decir, la demanda desestacionalizada actual.
- **Tendencia:** Tasa de crecimiento (o la declinación) subyacente en una serie de tiempo. Son movimientos a largo plazo que en ocasiones pueden describirse mediante una línea recta o una curva suave.

- Estacionalidad: Fluctuaciones estacionales predecibles de la demanda. Es un patrón que se repite cada año, semestre, trimestre o semana.

El **componente aleatorio** es la parte del pronóstico que se desvía de la parte sistemática, son fluctuaciones impredecibles o aleatorias. Este componente no se puede pronosticar, no obstante, se puede estimar su tamaño y variabilidad lo que permite medir el error de pronóstico. El error de pronóstico mide la diferencia entre el pronóstico y la demanda real.

### **Métodos de Pronóstico de Demanda.**

A continuación, se exponen distintos métodos que sirven para pronosticar la demanda y que se caracterizan por su capacidad de actualizar las estimaciones de nivel, tendencia y estacionalidad después de cada observación. La ventaja de estos métodos es que las estimaciones incorporan todos los datos nuevos observados.

- Media Móvil: Este método es utilizado cuando la demanda no posee tendencia o estacionalidad, es decir, el componente sistemático es igual al nivel. El nivel en el periodo  $t$  se estima como la demanda promedio durante los  $K$  periodos más recientes (Ecuación 2). El peso es igual para cada periodo que componen  $K$ . Mientras mayor sea el valor de  $K$ , el promedio móvil será menos sensible a la demanda más reciente observada.

$$\text{Componente Sistemático} = \text{Nivel} \quad (2)$$

$$L_t = \frac{D_t + D_{t-1} + \dots + D_{t-K+1}}{K} \quad (3)$$

$$F_{t+1} = L_t \quad (4)$$

Donde:

$L_t$  = Estimación del nivel al final del periodo  $t$ .

$D_t$  = Demanda real observada en el periodo  $t$ .

$F_{t+1}$  = Pronóstico de la demanda en el periodo  $t + 1$ .

- Suavizamiento Exponencial Simple (SES): Este método es utilizado cuando la demanda no posee tendencia o estacionalidad, es decir, el componente sistemático es igual al nivel (Ecuación 5). Se aplica para pronosticar la demanda de productos maduros con cifras de ventas estables ya que es capaz de identificar fluctuaciones irrelevantes en los datos y las suaviza. Uno de los beneficios de este método es que no necesita gran volumen de datos



históricos para pronosticar (Ramírez Rodríguez, 2022). El pronóstico de demanda en el periodo t se expresa a continuación:

$$\text{Componente Sistemático} = \text{Nivel} \quad (5)$$

$$L_t = \alpha D_t + (1 - \alpha)F_t \quad (6)$$

$$F_{t+1} = L_t \quad (7)$$

Donde:

$L_t$  = Estimación del nivel al final del periodo t.

$D_t$  = Demanda real observada en el periodo t.

$F_{t+1}$  = Pronóstico de la demanda en el periodo t + 1.

$\alpha$  = Constante de suavizamiento para el nivel.

La constante de suavizamiento de nivel ( $\alpha$ ), puede fluctuar entre  $0 < \alpha < 1$ , no obstante, en la práctica toma valores menores a 0,5 puesto que si al pronosticar con un valor de  $\alpha$  mayor a 0,5 se obtienen buenos resultados, es probable que la serie de tiempo posea tendencia, por lo que se recomienda utilizar otro método.

- Suavizamiento Exponencial Doble (Modelo de Holt) (SED): Este método se utiliza en casos en los que la demanda presenta tendencia en su comportamiento, por tanto, el componente sistemático de demanda se define como la suma entre el nivel y la tendencia (Ecuación 8). Se puede aplicar para productos que estén en fase de crecimiento o declinación, ya que siguen un comportamiento al alza o a la baja respectivamente. El pronóstico de demanda para el periodo t se expresa a continuación:

$$\text{Componente Sistemático} = \text{Nivel} + \text{Tendencia} \quad (8)$$

$$L_t = \alpha D_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (9)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (10)$$

$$F_{t+n} = L_t + nT_t \quad (11)$$

Donde:

$L_t$  = Estimación del nivel al final del periodo  $t$ .

$T_t$  = Estimación de la tendencial al final del periodo  $t$ .

$D_t$  = Demanda real observada en el periodo  $t$ .

$F_{t+1}$  = Pronóstico de la demanda en el periodo  $t + 1$ .

$\alpha$  = Constante de suavizamiento para el nivel.

$\beta$  = Constante de suavizamiento para la tendencia.

Los valores de las constantes de suavización ( $\alpha$  y  $\beta$ ) varían entre 0 y 1, pero al igual que en la SES estos valores suelen ser menores a 0,5. Un valor elevado de  $\alpha$  implica mayor importancia a los datos más recientes, un valor de  $\alpha$  cercano a 0,1, indicará mayor importancia a los datos antiguos. En cuanto a  $\beta$ , un valor elevado indicará respuesta a los cambios de tendencia con mayor velocidad, mientras que un valor más bajo suavizará la tendencia actual.

- Suavización Exponencial Triple (Modelos de Winter) (SET): Este método es utilizado cuando existe estacionalidad en la serie de tiempo, por tanto, el componente sistemático de la demanda se compone de nivel, tendencia y estacionalidad (Ecuación 12). Para poder aplicarlo es necesario contar con al menos dos ciclos de temporada completos de los datos históricos de demanda. El pronóstico de demanda para el periodo  $t$  se expresa cómo:

$$\text{Componente Sistemático: } (Nivel + Tendencia) \times \text{Estacionalidad} \quad (12)$$

$$L_t = \alpha \left( \frac{D_t}{S_t} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (13)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (14)$$

$$S_{t+p} = \gamma \left( \frac{D_t}{L_t} \right) + (1 - \gamma)S_t \quad (15)$$

$$F_{t+l} = (L_t + lT_t) S_{t+l} \quad (16)$$

Donde:

$p$  = Periodicidad de la demanda.

$L_t$  = Estimación del nivel al final del periodo  $t$ .

$T_t$  = Estimación de la tendencial al final del periodo  $t$ .

$S_{t+p}$  = Factor estacional al final del periodo  $t + p$ .

$D_t$  = Demanda real observada en el periodo  $t$ .

$F_{t+1}$  = Pronóstico de la demanda en el periodo  $t + 1$ .

$\alpha$  = Constante de suavizamiento para el nivel.

$\beta$  = Constante de suavizamiento para la tendencia.

$\gamma$  = Constante de suavizamiento para el factor estacional.

Al igual que en los dos métodos de suavización exponencial mencionados anteriormente, ( $\alpha$ ,  $\beta$  y  $\gamma$ ) varían entre 0 y 1, pero estos valores suelen ser menores a 0,5. Este método necesita de al menos dos ciclos de periodos de demanda de historia para poder pronosticar.

### Medidas de Error de Pronóstico

Las medidas de error de pronóstico son utilizadas para determinar si el método de pronóstico predice con precisión el componente sistemático de la demanda, además, se pueden comparar los resultados obtenidos en los métodos de pronóstico y seleccionar el método que posea un menor error. Existen distintos indicadores de error de pronóstico, partiendo de la base, el error de pronóstico para el periodo  $t$  se define como:

$$E_t = F_t - D_t \quad (17)$$

Donde  $F_t$  es el pronóstico de la demanda en el periodo  $t$  y  $D_t$  es la demanda real en el periodo  $t$ .

A continuación, se definen otras medidas de error:

- Error Cuadrático Medio (MSE): Esta medida se relaciona con la varianza del error de pronóstico. Penaliza los errores grandes mucho más significativamente que los pequeños porque todos se elevan al cuadrado. Se determina como:

$$MSE_n = \frac{1}{n} \sum_{t=1}^n E_t^2 \quad (18)$$

- Desviación Media Absoluta (MAD): Es el promedio de la desviación absoluta ( $A_t$ ), esta medida se utiliza para estimar la desviación estándar del componente aleatorio suponiendo que distribuye normal. Se determina como:

$$A_t = |E_t| \quad (19)$$

$$MAD_n = \frac{1}{n} \sum_{t=1}^n A_t \quad (20)$$

- Error Porcentual Medio Absoluto (MAPE): Es el error absoluto promedio como un porcentaje de la demanda. Esta medida se utiliza cuando el pronóstico subyacente posee estacionalidad y la demanda varía considerablemente de un periodo a otro. Se determina como:

$$MAPE_n = \frac{\sum_{t=1}^n \left| \frac{E_t}{D_t} \right| 100}{n} \quad (21)$$

### 3.2.3 Métodos de Regresiones.

Los métodos de pronóstico de regresiones suponen que la proyección de demanda está relacionada con ciertos factores ambientales (el estado de la economía, la tasa de interés, etc.) Estos encuentran correlación entre la demanda y factores externos y generan modelos de pronóstico.

- Regresión Lineal Simple (RLS): Este método mide la asociación lineal entre dos variables, siendo una de ellas los datos de demanda histórica. La regresión lineal es capaz de determinar tendencias en la demanda dado algún factor. El modelo está compuesto por una variable dependiente Y que está relacionada con una variable independiente X y se expresa cómo:

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (22)$$

Donde  $\beta_0$  y  $\beta_1$  son constantes que deben ser estimadas y  $\varepsilon$  representa la variación o desviación de Y ajustado con Y observado que se debe a otros factores no representados en la regresión. Estas desviaciones deben ser independientes uno de otro, no obstante, en pronóstico de demanda se da correlación entre los errores dado que los datos de X e Y se registran en el mismo periodo de tiempo y la demanda está correlacionada mes a mes pues surgen situaciones como promociones, sobre stock en los productos, quiebres de stock o free rebate. Por otra parte,  $\beta_1$  representa la cantidad que se incremente o decrece la demanda (Y) cuando la variable explicativa (X) aumenta en una unidad.

- Regresión Lineal Múltiple (RLM): Este modelo de regresión implica el uso de más de una variable independiente para predecir la variable dependiente. La variable dependiente se denota por Y y las variables independientes (predictivas) por  $X_1, X_2, \dots, X_k$  y se relacionan de la forma:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (23)$$

Donde k es el número de variables explicativas. La interpretación de los parámetros que acompañan a las variables independientes y del error ( $\varepsilon$ ) es la misma que para la regresión lineal simple.

Tanto para la RLS como para la RLM hay que determinar los valores de  $\beta_0$  y las constantes que acompañan a las variables explicativas. Para esto, se utiliza el **principio de mínimos cuadrados** que permite seleccionar los valores de las constantes que minimizan los errores de la suma de los cuadrados (distancia). La ecuación (23) y (24) indican cómo calcular los parámetros en el caso de una RLS. Para una RLM se utiliza el mismo principio, pero el cálculo de los parámetros se realiza con el apoyo de software. En este proyecto se utilizó el software estadístico Gretl.

$$\beta_1 = \frac{n \sum XY - \sum X \sum Y}{n \sum X^2 - (\sum X)^2} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sum (X - \bar{X})^2} \quad (23)$$

$$\beta_0 = \frac{\sum Y}{n} - \frac{\beta_1 \sum X}{n} = \bar{Y} - \beta_1 \bar{X} \quad (24)$$

Donde:

$n$  = numero de observaciones.

$X$  = Valor observado de la variable independiente.

$Y$  = Valor observado de la variable dependiente.

Para realizar una RLS o RLM existen supuestos que se deben cumplir en cuanto al comportamiento de los datos que sirven para validar la confiabilidad del modelo obtenido. Estos supuestos se definen en la Tabla 3.1 que relaciona los supuestos que se deben cumplir para cada tipo de regresión.

**Tabla 3.1: Supuestas RLS y RLM.**

Fuente: Elaboración Propia

Supuesto	RLS	RLM	Método de Validación
Debe existir una relación lineal entre las variables independientes y la dependiente.	X	X	Estadístico T
Las variables explicativas no deben estar correlacionadas con el error ( $\epsilon$ ).	X	X	Covarianza entre el Error y la Variable Explicativa debe ser cero.
Se debe cumplir el principio de homocedasticidad, es decir, la varianza de los errores debe ser constante para toda la muestra.	X	X	Prueba de White
No debe existir multicolinealidad entre las variables explicativas, es decir, las variables independientes no deben estar correlacionadas puesto que si sucede este evento se podría dar que dos variables están explicando la misma variabilidad en la variable dependiente.		X	Matriz de correlación y Factor de Inflación de la Varianza (VIF)
Los residuos ( $\epsilon$ ) deben tener distribución normal.	X	X	Histograma de los residuos.

Una vez obtenidos los estimadores de la regresión y comprobados los supuestos de la Tabla 1.1 se pueden realizar distintas pruebas que indican la confiabilidad de la regresión además de indicadores que darán más información y describen el resultado obtenido.

Dentro de los indicadores se encuentra el **coeficiente de correlación ( $r$ )**, que indica la fortaleza y dirección de la relación lineal. En base a este parámetro se obtiene el **coeficiente de determinación ( $r^2$ )** que mide el porcentaje de variabilidad de Y que se puede explicar a través del conocimiento de la variabilidad (diferencias) de las variables explicativas. Este coeficiente se estima en la ecuación (25).

$$r^2 = 1 - \frac{\sum(Y - \hat{Y})^2}{\sum(Y - \bar{Y})^2} \quad (25)$$

Donde:

$\hat{Y}$  = Valor ajustado de Y.

$\bar{Y}$  = media de los valores observados de Y.

El **error estándar de la estimación ( $s_{y,x's}$ )** mide el cambio promedio de la variable dependiente por unidad de cambio en la variable independiente relevante cuando las demás

variables explicativas se mantienen constantes. El **error estándar del pronóstico** ( $s_f$ ) mide la variabilidad de Y ajustado con respecto a Y observado.

Otra prueba para verificar el modelo es significativa es la **prueba de hipótesis**, que se basa en probar si existe significancia o relación entre la/s variable/s independiente/s y la dependiente. Para corroborar esta afirmación se define una hipótesis nula y una alternativa.

$H_0$  = El modelo de RLS/RLM no es significativo.

$H_1$  = El modelo de RLS/RLM es significativo.

Para determinar la aceptación o rechazo de la hipótesis nula se ocupan los valores disponibles en la tabla ANOVA, donde se obtiene el valor de F obtenido a partir de la ecuación (26). Este valor se compara con el valor F de tabla obtenido de la tabla de distribución de Fisher con 1, n-2 grados de libertad o el valor p que también está disponible en la tabla.

$$F = \frac{\text{Cuadrado medio de la regresión}}{\text{Error Cuadrático Medio}} = \frac{MSR}{MSR} \quad (26)$$

Los criterios de aceptación se definen como:

Si  $F > F_{\text{tabla}}$  o valor  $p < 0,05$  se rechaza  $H_0$

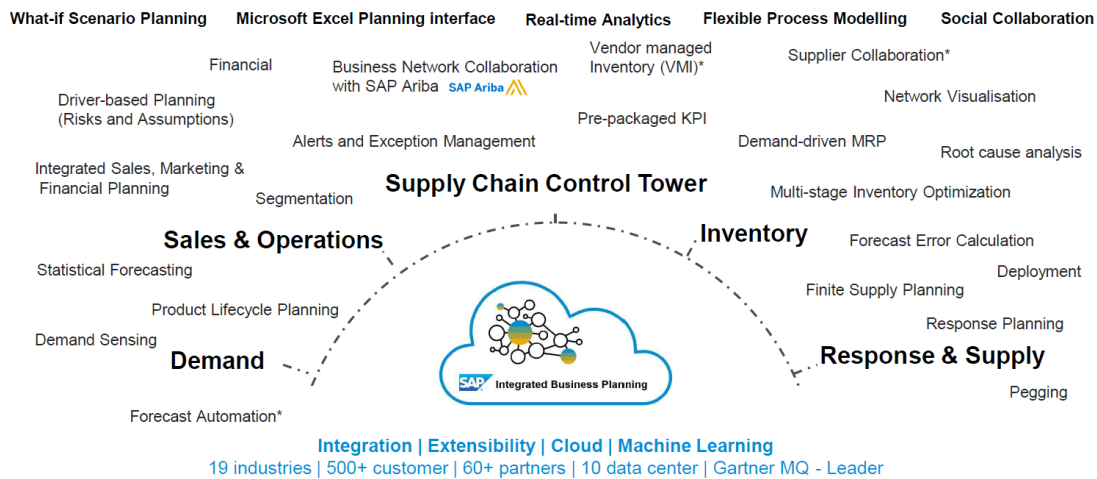
Si  $F < F_{\text{tabla}}$  o valor  $p > 0,05$  se acepta  $H_0$

### 3.3 Pronóstico de Demanda en Masisa.

Como se menciona en el capítulo 2, la planificación en Masisa se basa en el proceso S&OP. Para apoyar el ciclo se utiliza la herramienta de SAP, IBP (Integrated Business Planning), un sistema que funciona tomando datos de SAP y almacenándolos en una nube para ser manipulados a través de dos interfaces, Fiori y una aplicación de Excel (Masisa, 2020).

Posee múltiples funciones que se observan en la Figura 3.2. En relación con la planificación de demanda esta se realiza utilizando tanto Fiori como la aplicación de Excel.

Fiori es una interfaz web que posee múltiples aplicaciones que permiten configurar las variables y datos con lo que se trabajan. Una de las aplicaciones utilizadas en la planificación de demanda es “Modelos de Pronóstico (Forecast Models)”. En esta aplicación el usuario puede crear distintos modelos que contengan varios métodos predictivos de pronóstico.



**Figura 3.2: Funciones de IBP**

Fuente: (Vanam, 2019)

Al generar un nuevo modelo, se deben especificar una serie de campos. Inicialmente en la primera sección se define el tipo de periodo (mes, semana, año, etc.) con el que se analizarán los datos, el número de periodos de historia que se utilizarán para pronosticar y el horizonte de pronóstico.

Luego, en la segunda sección se puede definir un preprocesamiento de los datos, su función es limpiar la historia de demanda suavizando observaciones atípicas o eliminando ceros que estén contenidos en las series de tiempo.

En la tercera ventana el usuario incluye distintos métodos de pronóstico como suavizaciones exponenciales, medias móviles, modelos ARIMA/SARIMA, RLS, RLM, entre otros. Se pueden añadir los modelos que el usuario estime conveniente y para cada modelo debe especificar los parámetros a utilizar, es decir, si se selecciona una suavización exponencial simple, el usuario debe definir el valor de  $\alpha$ .

Una vez agregados todos los modelos se define la medida de error de pronóstico a utilizar para comparar los métodos y hacer la selección del resultado de pronóstico. Además, los periodos que funcionarán como fase de prueba.



Al configurar un modelo y ejecutarlo, se obtiene los resultados de todos los métodos definidos, pero se utilizará el que posea menor error de pronóstico en la fase de prueba para proyectar la demanda.

Luego de crear un modelo este queda disponible para ejecutarlo en la aplicación de Excel. En esta aplicación se observa el comportamiento de la demanda y su proyección para cada serie de tiempo. Además, se puede filtrar por características del negocio, producto, variabilidad del producto, contribución del producto, entre otros factores y se visualizan en una planilla.

Una vez que se ejecuta un modelo configurado por el planificador de demanda en Fiori, los resultados obtenidos se visualizan en la planilla Excel como proyecciones de demanda que servirán para la toma de decisiones y son un gran input la etapa de Planificación de Demanda del ciclo S&OP.

Para comprender con mayor especificación el proceso de planificación de demanda en IBP revisar el Anexo 2.

## **4 Metodología y Procesamiento de la Base de Datos**

Los autores (Chopra & Meindl, 2013) proponen un método para pronosticar demanda compuesto por cinco puntos que se describen a continuación.

1. Entender el objetivo del pronóstico que está relacionado con la cantidad a producir de cada producto considerando los niveles de capacidad e inventario disponibles.
2. Integrar planeación y el pronóstico de la demanda a través de la cadena de suministro, vinculado con todas las actividades de planeación que son parte del proceso como planeación de capacidad, de producción, de promoción y de compras. Dentro de Masisa esta integración se representa a través del proceso S&OP descrito en el capítulo 2.
3. Identificar los principales factores que influyen en el pronóstico de la demanda, como la oferta y demanda, fenómenos relacionados con el comportamiento del producto, identificar tendencias y estacionalidad y factores externos (economía del país e indicadores de la industria).
4. Pronosticar al nivel apropiado de agregación considerando que los pronósticos agregados son más precisos que los desagregados.
5. Establecer medidas de desempeño y error para el pronóstico que deben estar correlacionadas con los objetivos de las decisiones del negocio.

Para efectos de este proyecto, los puntos tres, cuatro y cinco se trabajaron y los métodos utilizados se describen en las siguientes secciones.

### **4.1 Identificar los principales factores que influyen en el pronóstico de la demanda.**

El bajo desempeño de los pronósticos de demanda en Masisa se debe principalmente a dos factores: deficiencia en la calidad de los datos utilizados y aplicación los métodos de pronóstico a los productos sin importar el comportamiento de la serie de tiempo.

Bajo esta premisa, se realizan tres actividades principales, limpieza de datos históricos, segmentación de la demanda por comportamiento y relacionar nuevos factores a los pronósticos de demanda.

#### 4.1.1 Segmentación de la Demanda.

Una de las funciones que posee IBP es que permite crear variables que almacenen información de datos maestros y datos transaccionales. Los datos maestros son fijos y pueden cambiar, pero con muy poca frecuencia (código del producto, nombre del producto, nombre de los clientes, etapa del ciclo de vida del producto en la que se encuentra el producto, familia a la que pertenece, etc.). Por otra parte, los datos transaccionales se actualizan con frecuencia periodo a periodo y almacenan información relacionada con las ventas, facturaciones, pedidos, stock disponible, entre otros. ( Arribas, 2022)

La aplicación de Fiori “Perfiles de automatización de pronósticos” permite crear una variable que contenga los datos maestros referidos al comportamiento de la serie de tiempo. Al crear esta variable se deben configurar los siguientes ámbitos:

**Tabla 4.1: Configuración Perfiles de Automatización de Pronósticos.**

Fuente: Elaboración Propia en base a información obtenida de (IBP Fiori, 2022)

<b>Criterio</b>	<b>Especificación</b>
Nivel de Agregación <sup>1</sup>	ID de Producto – ID de Ubicación
Periodicidad	Mensual
Periodos de Historia	36
Puntos de datos mínimos requeridos <sup>2</sup>	8
Tipo de Estacionalidad <sup>3</sup>	El sistema escoge automáticamente.
<b>Detección de Punto de Cambio<sup>4</sup></b>	
Intervalo Mínimo <sup>5</sup>	6
Cambio de Nivel Mínimo <sup>6</sup>	20%
Cambio Mínimo de Tendencia <sup>7</sup>	20%

Al ejecutar esta configuración la información queda almacenada en Fiori y puede ser guardada en una variable para que quede disponible en Excel y sea utilizada como filtro de visualización. Esta variable logra segmentar la demanda en 9 comportamientos.

<sup>1</sup> En apartado 4.2. se especifica por qué se define este nivel de agregación.

<sup>2</sup> Especificar el número mínimo de períodos históricos con datos necesarios para ejecutar el análisis de series temporales.

<sup>3</sup> El sistema identifica si hay estacionalidad aditiva o multiplicativa y lo almacena. (IBP Fiori, 2022)

<sup>4</sup> Son datos en los que se pueden observar cambios significativos con efectos duraderos en las características de la serie temporal, es decir, identifica el nivel, tendencia, estacionalidad e intermitencia. (IBP Fiori, 2022)

<sup>5</sup> Al detectar puntos de cambio, el sistema divide el horizonte histórico en intervalos de tiempo que están delimitados por dos puntos de cambio o por el primer y último punto de cambio y los extremos respectivos del horizonte histórico. (IBP Fiori, 2022)

<sup>6</sup>El sistema solo debe identificar un cambio de nivel si existe una diferencia mínima del 20 % entre la media de los valores de un nivel y la media de los valores del siguiente nivel. (IBP Fiori, 2022)


<sup>7</sup> El sistema solo debe identificar un cambio de tendencia si la tendencia se aleja de su pendiente original en más del 20%. (IBP Fiori, 2022)

**Tabla 4.2: Comportamientos de las Series de Tiempo**

Fuente: Elaboración Propia en base a información obtenida de (IBP Fiori, 2022).

Comportamiento de la Serie de Tiempo
Continuos
Continuos con Tendencia
Continuos con Estacionalidad
Continuos con Estacionalidad y Tendencia
Intermitentes
Intermitentes con tendencia
Intermitentes con Estacionalidad
Intermitentes con Estacionalidad y Tendencia
Sin Datos/Datos Insuficientes

El negocio de tableros a nivel nacional posee 158 productos, para efectos de análisis de este proyecto la demanda se segmenta según la metodología ABC (Activity Based Costing), la que se centra en la gestión de las actividades dando prioridad a los productos que posean una mayor importancia (da Costa & da Conceicao, 2012). En Masisa la clasificación es en base a la ganancia que proporciona cada producto, agrupando los que generan mayor ganancia como AA, luego un porcentaje menor son los productos definidos como A, finalmente los que generan menos beneficios son catalogados como B y C. El porcentaje de contribución de cada segmento se observa en la Figura 4.1:



**Figura 4.1: Porcentaje de Contribución de cada segmento de productos.**

Fuente: Elaboración Propia

#### 4.1.2 Limpieza de Datos Históricos

Un mal input de datos influye en la precisión de los pronósticos, por tanto, es fundamental identificar errores, detectarlos y corregirlos (Ridzuan & Wan Zainon, 2019). Para pronosticar, IBP cuenta con la historia de 3 años de ventas que se pueden definir en periodos de trimestres, meses y semanas. En la mayoría de los casos el periodo se define mensual, por tanto, se seleccionan 36 periodos de historia (existen casos particulares en los que se utiliza menos historia para pronosticar que serán mencionados en el capítulo de resultados). La historia utilizada de ventas inicia en noviembre del 2019 y finaliza en octubre del 2022.

Los años 2020 y 2021 son particulares y atípicos. Dado la pandemia del COVID – 19 se generaron distintos fenómenos sanitarios, sociales y económicos.

En la industria de la construcción hubo una paulatina reactivación económica después del primer semestre del 2020 (Camara Chilena de la Construcción, 2021). Masisa se vio afectado por esta reactivación y se refleja en un alza en la demanda del negocio de tableros, no obstante, esta demanda no es fidedigna para pronosticar en la actualidad ya que está relacionada con los factores mencionados anteriormente.

La demanda se puede suavizar a través de tres métodos. En primer lugar, los datos atípicos son sustituidos por la media de tres periodos aledaños. Además, hay periodos en los que la demanda es baja o nula y le sigue un periodo con demanda muy alta esto se debe a posibles quiebres de stock o promociones que generan que las ventas bajen considerablemente, pero a la vez aumenten de manera importante en los siguientes periodos, por tanto, una de las técnicas utilizadas es distribuir la demanda en ambos periodos.

Finalmente, el tercer método que se aplica para toda la historia de ventas es contrastar las ventas con las ordenes generadas por parte de los clientes. Esta práctica se realiza debido a que las ventas están restringidas por la capacidad e inventario, por lo que no reflejan toda la demanda de los clientes. Las ordenes son un reflejo más verídico de la demanda en el mercado.

#### 4.1.3 Variables Externas

Con el objetivo de asociar el comportamiento de la demanda con factores macroeconómicos, se realiza una revisión bibliográfica que indiquen variables que puedan tener impacto en el

nivel de demanda en la industria maderera. Los autores (Adamowicz & Noga, 2017) proponen un modelo predictivo de Análisis Discriminante Múltiple para empresas polacas del sector maderero en el que utilizan tres variables independientes: ingresos netos / activos totales, activo circulante e ingresos por venta. Por otra parte, (Liao & Zhang, 2008) realizan un análisis econométrico de la producción de madera blanda en el sur de EE. UU. donde una de las variables utilizadas fue el índice del precio del productor.

A partir de esta investigación, se relacionan las variables mencionadas con la realidad nacional. El índice de precios del productor es un indicador que se estima por sector industrial cada mes. A su vez el activo circulante se relaciona con el nivel de inflación, por tanto, se escoge el índice de precio del consumidor ya que la variación de esta impacta directamente la variación de la tasa de inflación (Dornbusch, Fischer, & Startz, 2005).

Las variables seleccionadas son utilizadas para analizarlas en modelos de RLS y RLM como variables independientes o explicativas, estas se definen cómo:

- **Precio de Venta (P):** Se utiliza el precio de venta de cada producto para cada periodo. Este valor se mide en USD/m<sup>3</sup>, sin embargo, para aislar el efecto del tipo de cambio en el precio de venta y dado que se está analizando un negocio a nivel nacional, se realiza la conversión de dólares a pesos chilenos. El valor histórico del dólar se obtiene de (Investing.com, 2022). Al realizar la transformación, la variable “Precio de Venta” se mide en CLP/m<sup>3</sup>.
- **Índice de Precio del Producto (IPP):** Este indicador mide la variación de los precios de bienes producidos y vendidos por productores del país, correspondientes al primer canal de comercialización o distribución de los bienes transados en la economía (INE, 2022). El Banco Central de Chile publica el valor del IPP a nivel agregador y a un nivel desagregado, donde lo sectoriza según la industria (manufacturera, minera, electricidad, gas y agua y agricultura y ganadería). La industria manufacturera comprende industrias tradicionales, intermedias, mecánicas y residuales. Masisa al ser una empresa de la industria maderera califica como tradicional (convierte la materia prima en productos listos para su comercialización y consumo final (Equipo editorial, Etecé, 2021)) e intermedia (fabrica bienes semielaborados para alimentar otras industrias manufactureras (Equipo editorial,

Etecé, 2021)). Mencionado lo anterior, se selecciona el IPP de la industria manufacturera.

- **Índice de Precio del Consumidor (IPC):** Es un indicador, que mide mes a mes la variación conjunta de los precios de una canasta de bienes y servicios representativa del consumo de los hogares del país, se usa para reajustar arriendos, créditos, sueldos y salarios, y diferentes contratos públicos y privados. (INE, 2022).

La base de datos creada con la información de las variables descritas posee una periodicidad mensual iniciada en enero del 2017 y finaliza en diciembre del 2019. Se utiliza el año 2017, 2018, y 2019 puesto que son años previos al periodo de pandemia con el fin de eliminar datos macroeconómicos atípicos que se generaron producto de la crisis sanitaria a nivel mundial que tuvo impacto en la economía del país.

#### 4.2 Pronosticar a nivel apropiado de demanda.

Los pronósticos de demanda en Masisa se pueden aperturar a distintos niveles de agregación.

**Tabla 4.3: Nivel de Agregación para Generar Pronósticos**

Fuente: Elaboración Propia

Nivel de Agregación	Descripción
Producto	Cada serie de tiempo contiene la demanda agregada de cada producto para cada periodo. Este nivel de agregación es útil para estimar medidas de desempeño generales y ayudan a la toma de decisiones gerenciales.
Producto – Ubicación <sup>8</sup>	La demanda se desagrega a nivel de producto y centro concentrador de la demanda para cada periodo. Existen dos centros concentradores en Chile para el negocio de tableros, por lo que el número de series de tiempo que se pueden observar en esta apertura es el doble de la agregación a nivel producto. Este nivel de agregación es útil para definir la demanda a producir en cada centro concentrador.
Producto – Ubicación – Cliente <sup>9</sup>	La demanda se desagrega a nivel Cliente, por tanto, el número de series de tiempo aumenta considerablemente y los valores de demanda son menores para cada periodo. Este nivel de desagregación es útil para observar la demanda específica de cada cliente y observar el efecto de promociones, ofertas y free rebate <sup>10</sup> en grandes clientes.

<sup>8</sup> Ubicación: Centro concentrador desde donde sale la demanda o las ordenes facturadas.

<sup>9</sup> En esta apertura se toma el ID de Cliente, lo que toma importancia en casos de grandes clientes, por ejemplo, un cliente como Chilemat S.A. que es una cadena nacional de ferreterías poseerá distintos ID para cada ferretería ya que la demanda de una ferretería en Santiago no es la misma que la de la ferretería de Concepción y en cuanto a la logística su ID indicará hacia donde debe ser dirigida esa demanda.

<sup>10</sup> Free Rebate: Es una estrategia de marketing utilizada para aumentar la participación del cliente a través de ofertas de incentivos o reembolsos (Incentive Insights, 2020). En Masisa ciertos clientes poseen este beneficio que les permite obtener un reembolso cada tres meses por compras de gran volumen, en consecuencia, la demanda se puede ver incrementada cada tres meses producto de esta estrategia.



A partir de las aperturas propuestas en la Tabla 4.3, estas pueden obtenerse con una periodicidad mensual, semanal o semana técnica. Las aperturas semanales o semana técnica son utilizadas por las áreas de fabricación y capacidad ya que deben ir semana a semana fabricando productos que tienen fechas comprometidas de entrega durante el mes. La apertura mensual, permite visualizar el comportamiento de la demanda a un nivel agregado lo que es útil para el área de comercial y de marketing a la hora de generar metas de venta y nuevas promociones.

La apertura escogida para realizar los análisis es a nivel Producto – Ubicación con periodicidad mensual. Esta selección se justifica en primer lugar, porque va en línea con el objetivo general de este proyecto (seleccionar métodos que logren identificar tendencias, estacionalidad e intermitencia y generen un buen pronóstico). Un nivel desagregado implica poco volumen de datos para cada periodo lo que dificulta identificar estos patrones de comportamiento.

Por otro lado, los atributos que describen la variabilidad de los productos<sup>11</sup> y la segmentación de la demanda están definidos a nivel Producto – Ubicación, ya que productos que se comercializan a nivel internacional poseen el mismo ID que productos que se distribuyen en el negocio nacional, en consecuencia, si el nivel de agregación es por Producto se estará concentrando la demanda a nivel nacional e internacional. Al incluir la apertura de ubicación y filtrar por los centros concentradores que se encuentran en Chile se obtiene la demanda nacional.

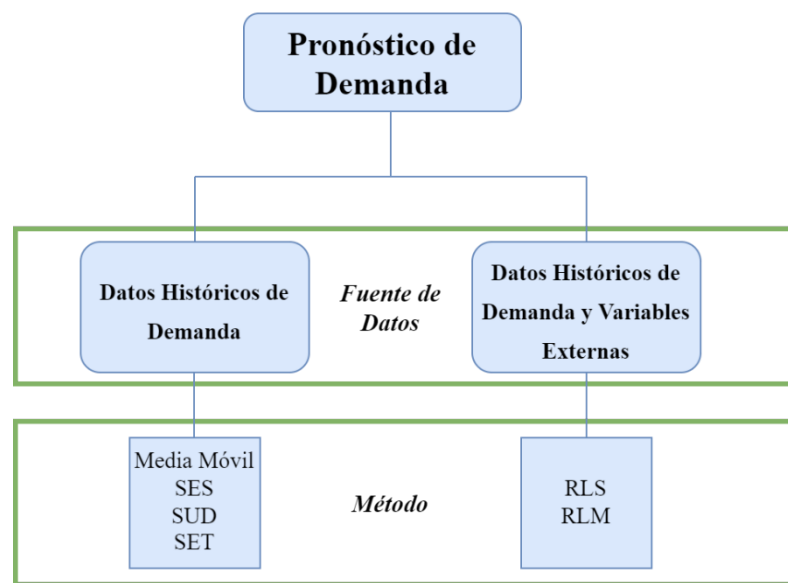
La periodicidad mensual permite estabilizar el valor de la demanda, se obtienen valores más grandes y por tanto si hay diferencias entre un mes y otro será más fácil identificar patrones de comportamiento. El nivel semanal posee gran volatilidad ya que no todas las semanas se fabrica la misma cantidad o para ciertos productos sólo se fabrica la última semana del mes u otros comportamientos que se dan en el área de fabricación e influyen en los valores de demanda.

---

<sup>11</sup> La variabilidad de la demanda permite clasificar los productos según su variabilidad de demanda, es decir, qué productos tienen una demanda constante y qué productos tienen una demanda impredecible para que las empresas puedan tomar mejores decisiones y establecer políticas de pedido adecuadas (Díaz, 2022).

Una vez seleccionando el nivel de agregación e identificando el comportamiento de cada serie de tiempo se utilizan los métodos de pronóstico de análisis de series de tiempo y métodos causales (Figura 4.2).

En el caso del análisis de series de tiempo los métodos son ejecutados en StatGraphics a una selección de series de tiempo para identificar los parámetros de  $K$ ,  $\alpha$ ,  $\beta$  y  $\gamma$  utilizados en cada método. Una vez identificados los parámetros se crean los modelos en IBP en la interfaz web Fiori a través de la aplicación “Administrar Modelos de Pronóstico” y se ejecutan para ver los resultados obtenidos de pronóstico en la aplicación IBP de Excel.



**Figura 4.2.: Clasificación Métodos de Pronóstico Según la Fuente de Datos**

Fuente: Elaboración Propia

En relación con los métodos causales, las variables definidas en el apartado 4.1.3. se validan a través de RLS y RLM ejecutadas en los softwares estadísticos StatGraphics y Gretl. Se realizan las pruebas de validación para cada regresión definidas en el capítulo 3 y los resultados obtenidos se exponen en el capítulo 5.

#### 4.3 Establecer medidas de desempeño.

Luego de realizar las pruebas e iteraciones, los resultados se validan a través de medidas de desempeño como son el Error MSE, MAD y MAPE. Los métodos que posean un mejor desempeño serán preferidos en comparación al resto. Estas comparaciones son acompañadas de gráficas y ayudan sacar conclusiones que servirán para mejorar el proceso de pronóstico.

## 5 Resultados

En este capítulo se exponen los resultados de este proyecto siguiendo luego de ejecutar la metodología descrita en el capítulo 4.

### 5.1 Identificar los principales factores que influyen en el pronóstico de la demanda.

De acuerdo con la metodología descrita en el capítulo cuatro, la identificación de factores que influyen en el pronóstico de demanda consiste en segmentación, limpieza de datos y selección de variables externas. A continuación, se describen los resultados obtenidos para la segmentación y limpieza de historia (ver apartado 4.1. para selección de variables externas).

#### 5.1.1 Segmentación.

En primer lugar, la segmentación se realiza según la contribución económica de los productos (Segmentación ABC). La Tabla 5.1 describe la cantidad de productos correspondientes a cada segmento. Para efectos de este proyecto, se consideran los productos de tipo AA y A, es decir, los productos que aportan en un 80% en las ganancias de la empresa para el negocio de tableros a nivel país.

**Tabla 5.1: Segmentación por Contribución.**

Fuente: Elaboración Propia

<b>Tipo de Producto</b>	<b>Numero de Productos</b>
AA	12
A	37
B	40
C	69
Total	158
Porcentaje de Análisis	31%
Porcentaje de Contribución	80%

Según la apertura descrita en el punto 4.2. (Producto – Ubicación) este análisis se extiende a dividir las series de tiempo de cada producto por su centro de distribución (Ubicación). A nivel nacional existen dos centros de distribución, uno en Santiago y otro en Cabrero, los cuales se identifican por el código TCDS y TCDC respectivamente. Por otra parte, cada producto es distribuido desde ambos centros, por tanto, para cada producto seleccionado

existen dos series de tiempo que describen su comportamiento de demanda. La distribución de series de tiempo a analizar se observa en la Tabla 5.2.

**Tabla 5.2: Total de Series de Tiempo a Analizar**

Fuente: Elaboración Propia

	<b>AA</b>	<b>A</b>	<b>B</b>	<b>C</b>
Continuo (C)	10	34	29	31
Continuo con Tendencia (CT)	4	14	7	5
Continuo con Estacionalidad (CE)	7	22	36	27
Continuo con Tendencia y Estacionalidad (CTE)	3	4	6	7
Intermitencia (I)				25
Intermitencia con Tendencia (IT)			2	19
Intermitencia con Estacionalidad (IE)				9
Intermitencia con Tendencia y Estacionalidad (ITE)				9
Sin Datos/Datos Insuficientes (SD)				6
Subtotal	24	74	80	138
Total			316	


La segunda segmentación refiere al comportamiento de las series de tiempo, al configurar el atributo que identifica el comportamiento de cada serie de tiempo se obtienen los resultados expuestos en la Tabla 5.3.

**Tabla 5.3: Segmentación por Comportamiento de la Serie de Tiempo**

Fuente: Elaboración Propia

<b>Tipo de Producto</b>	<b>Numero de Series de Tiempo</b>
AA	24
A	74
Total	98

En consideración de la selección mencionada, la distribución de series para los productos AA y A se observa en la Figura 5.1.




**Figura 5.1: Distribución Series de Tiempo para producto AA y A.**

Fuente: Elaboración Propia.

Como se observa, todas las series de tiempo a analizar se comportan de manera continua y la mayor concentración se encuentra en las series que posee solo componente sistemático de nivel y componente estacional.

### 5.1.2 Limpieza de Historia.

La limpieza de historia se realiza siguiente los tres métodos descritos en la sección 4.1.2. A continuación se exponen los resultados para el producto con código 78708NH043 TCDC, este producto es uno de los que posee mayor nivel de demanda en Masisa. En la Figura 5.2 se observa el resultado de la limpieza de historia realizada en el periodo comprendido por diciembre del 2019 hasta octubre del 2022.




**Figura 5.2: Limpieza de Historia para producto 78708NH043 TCDC.**

Fuente: Elaboración Propia.

A partir de la Figura 10 se pueden realizar dos importantes observaciones, en primer lugar, se logran suavizar las alzas y bajas de demanda ocurridas en septiembre del 2020 y abril del 2020 respectivamente. Por otra parte, en los últimos periodos del 2022 la demanda ajustada posee una diferencia con las ventas debido a que la demanda ajustada está contrastada con las ordenes que se ingresaron, sin embargo, no todas las ordenes pudieron ser atendidas debido a falta de capacidad, quiebres de stock o inventario. No obstante, la planificación de demanda que se estudia en este proyecto es previa a las restricciones que se realizan con el área de capacidad, por tanto, las ordenes permiten captar la demanda real del mercado y reflejan con mayor certeza las necesidades de los clientes.

La limpieza de historia se realiza para todas las series de tiempo estudiadas. El Anexo 3 contiene la limpieza de historias para otros productos seleccionados.

Observando el ajuste de los datos desde una perspectiva general, se agrupan las ventas totales y demanda ajustada para cada periodo. La Figura 5.3 expone los resultados.



**Figura 5.3: Limpieza de Historia General.**

Fuente: Elaboración Propia.

En general, se mantiene una tendencia al alza que alcanza su peak entre octubre y diciembre del 2021 para luego ir a la baja hasta los últimos periodos. Nuevamente se observa en los últimos una diferencia entre la demanda ajustada y las ventas.

## 5.2 Pronosticar a nivel apropiado de demanda.

En este apartado se observan los resultados de los pronósticos luego de ser evaluados a través de análisis de series de tiempo y métodos causales. Además, estos se comparan con los resultados de los pronósticos de demanda con los que se planifica actualmente en Masisa.

### 5.2.1 Análisis de Series de Tiempo.

Actualmente para realizar los pronósticos de demanda se utiliza un modelo configurado con varios métodos estadísticos que se encuentran en la Tabla 5.4. Este modelo se ejecuta en la aplicación de Excel y se visualizan los resultados de los pronósticos estimados para cada serie.

El modelo inicial analiza 30 periodos de historia y posee 6 periodos en la fase de testeo. El método que posea un menor error MAPE será el seleccionado para pronosticar.

El principal problema es que hay pronósticos sobrestimados o no siguen un comportamiento consecuente con los datos, esto es debido a que los métodos estadísticos no están asociados al componente sistemático de la serie de tiempo, por ejemplo, una serie que tiene estacionalidad podría ser pronosticada con una media móvil si esta posee un menor error MAPE en la fase de testeo que una suavización exponencial triple (método que proyecta la estacionalidad).

**Tabla 5.4: Modelo de Pronóstico Actual.**

Fuente: Elaboración Propia

<b>Método</b>	<b>Parámetro</b>
Media Móvil (1)	$K = 6$
Media Móvil (2)	$K = 3$
Suavización Exponencial Doble (SED)	$\alpha = 0,5 ; \beta = 0,5$
Suavización Exponencial Triple (SET)	$\alpha = 0,5 ; \beta = 0,5 ; \gamma = 0,3$ Estacionalidad Multiplicativa
ARIMA/SARIMA <sup>12</sup>	$(p, q, d) = (3,1,3); (P, Q, D) = (3,1,3)$

A partir del modelo descrito en la Tabla 5.4 se identifican falencias que a su vez actúan como una oportunidad de mejora para esta propuesta.

<sup>12</sup> En IBP el método ARIMA/SARIMA funciona a través de iteraciones con los parámetros configurados, es decir, para cada serie de tiempo encuentra la configuración de (p,q,d)(P,Q,D) que genere el menor el error MAPE y esa se selecciona para luego ser comparada con los pronósticos que se realizan con los otros métodos estadísticos configurados.

En primer lugar, los métodos de suavización exponencial están configurados con un  $\alpha$  y  $\beta$  altos, lo que implica que responden rápidamente a los cambios de nivel y tendencia que puedan presentarse en la demanda lo cual puede funcionar para ciertas series de tiempo, sin embargo, estos métodos son aplicados a todas las series, por tanto si estos coeficientes son altos y en los últimos meses han habido alzas de demanda que no son regulares se podrían sobrestimar los pronósticos elevándolos a niveles poco consecuentes con la historia.

En segundo lugar, el modelo incluye el método ARIMA/SARIMA, según los autores de este método (Pelham Box & Jenkins, 1970) para utilizar este método es recomendable disponer de 50 o más datos, y en casos de series mensuales trabajar entre seis y diez años completos, por lo que los datos históricos no son suficientes para trabajar con este método.

Por último, el modelo incluye una única especificación de parámetros para cada  $\alpha$  y  $\beta$  de suavización exponencial doble y  $\alpha$ ,  $\beta$  y  $\gamma$  de suavización exponencial triple, lo que genera poca iteración en estos métodos para las series de tiempo, mayor probabilidad de obtener errores altos y, en consecuencia, no generan los pronósticos esperados.

Antes de generar una propuesta se realizaron diversas pruebas en StatGraphics y gráficas para comprender cómo se comporta la demanda para cada serie de tiempo y formular la configuración de una serie de métodos que respondan al comportamiento real del negocio.

- Configuración de los modelos.

Siguiendo con la línea de segmentación de la demanda, en relación con el análisis de series de tiempo se proponen tres modelos cada uno compuesto por métodos de pronóstico de series de tiempo que sean congruentes con un tipo de comportamiento (Ver Tabla 5.5).

**Tabla 5.5: Definición de Modelos según el Comportamiento de la Serie de Tiempo**

Fuente: Elaboración Propia

<b>Modelos</b>	<b>Comportamiento de la Serie de Tiempo</b>
Modelo 1	Series de Tiempo Continuas.
Modelo 2	Series de Tiempo con Tendencia.
Modelo 3	Series de Tiempo con Estacionalidad.

El primer modelo, al ser destinado a series de tiempo continuas, no se necesita un gran volumen de datos históricos para generar el pronóstico. En este caso se utilizan 12 periodos



de historia con 4 periodos en la fase de testeo. La configuración del modelo se observa en la Tabla 5.6.

**Tabla 5.6: Configuración Modelo 1.**

Fuente: Elaboración Propia

<b>Método</b>	<b>Parámetro</b>
Media Móvil	$K = 3$
Suavización Exponencial Simple 1 (SES1)	$\alpha = 0,5$
Suavización Exponencial Simple 2 (SES2)	$\alpha = 0,2$
Suavización Exponencial Simple 3 (SES3)	$\alpha = 0,1$

En cuanto a los métodos seleccionados, la media móvil y la SES1 les dan mayor importancia a los datos recientes que a la historia, por otra parte, la SES2 y SES3 le dan un mayor peso a los datos históricos. El beneficio de esta configuración es que las series de tiempo que se poseen un comportamiento continuo se iteran bajo tres parámetros de  $\alpha$  distintos, es decir, en la fase de testeo se seleccionará el mejor ajuste con el contraste de tres SES y una media móvil.

El segundo método se configura con 24 periodos de historia de datos para identificar tendencias que puedan estar relacionadas con la configuración del ciclo de vida del producto. Posee 6 periodos en la fase de testeo y la configuración del modelo se observa en la Tabla 5.7.

**Tabla 5.7: Configuración Modelo 2.**

Fuente: Elaboración Propia

<b>Método</b>	<b>Parámetro</b>
Suavización Exponencial Doble 1 (SED1)	$\alpha = 0,5 ; \beta = 0,3$
Suavización Exponencial Doble 2 (SED2)	$\alpha = 0,4 ; \beta = 0,3$

La elección de los coeficientes de nivel se basa en general, las series de tiempo que poseen tendencia necesitan responder rápidamente antes los cambios que hay en las ventas en los últimos periodos. Por otra parte, los coeficientes de tendencia son 0,3 ya que al iterar con parámetros altos los pronósticos se inflan a niveles poco realistas, en caso contrario al utilizar coeficientes menores a 0,3 los pronósticos se van a cero rápidamente lo que tampoco evidencia un comportamiento esperado.

El tercer modelo, utilizado para series de tiempo que posean estacionalidad, está configurado con 24 periodos de historia, donde cada ciclo está compuesto por 3 de ellos y se define estacionalidad multiplicativa para cada método. La configuración del modelo se observa en la Tabla 5.8.

**Tabla 5.8: Configuración Modelo 3.**

Fuente: Elaboración Propia

<b>Método</b>	<b>Parámetro</b>
Suavización Exponencial Triple 1 (SET1)	$\alpha = 0,5 ; \beta = 0,3 ; \gamma = 0,4$
Suavización Exponencial Triple 2 (SET2)	$\alpha = 0,5 ; \beta = 0,5 ; \gamma = 0,2$
Suavización Exponencial Triple 3 (SET3)	$\alpha = 0,2 ; \beta = 0,1 ; \gamma = 0,1$
Suavización Exponencial Triple 4 (SET4)	$\alpha = 0,4 ; \beta = 0,1 ; \gamma = 0,1$

El objetivo de este modelo es identificar distintos tipos de estacionalidad al iterar con los coeficientes de nivel, tendencia y estacionalidad para que las series de tiempo en la fase de prueba tengan mayor probabilidad de ajustarse a un pronóstico acertado.

▪ Ejecución y Resultados de los Modelos

En este apartado se observan los resultados al ejecutar los modelos propuestos en el apartado anterior y se comparan con los resultados que se obtienen actualmente con el modelo definido en la Tabla 5.4. Se compara en detalle un producto para cada comportamiento, los resultados de pronóstico de más productos se encuentran en el Anexo 4. Además, para cada modelo se presentan los resultados a un nivel agregado por segmento, es decir, se agrupa la demanda total de cada periodo y se compara con el pronóstico realizado por el modelo inicial y por el modelo propuesto.

Para este análisis se observan las comparaciones en un periodo de seis meses comprendido desde mayo del 2022 hasta octubre del 2022.

▪ Resultados Modelo 1.

Como se ha mencionado, IBP ejecuta un modelo con todos los métodos estadísticos definidos y escoge el que posea menor error MAPE en la fase de testeo.


En la Tabla 5.9 se observan los resultados para un producto del segmento AA, para mayor detalle de los resultados de otros productos de con comportamiento continuo ver el Anexo 4.

**Tabla 5.9: Comparación de Pronóstico para producto con comportamiento Continuo.**

Fuente: Elaboración Propia.


Código del Producto	78708NH043 TCDC	78708NH043 TCDC
Método Seleccionada	SES1	ARIMA (1,0,0)

Comparación de Pronóstico y Ventas Reales en los últimos 6 meses



**Figura 5.4: Pronóstico con Modelo 1.**


Fuente: Elaboración Propia.



**Figura 5.5: Pronóstico con Modelo Inicial.**

Fuente: Elaboración Propia.

Proyección de Pronóstico



**Figura 5.6: Comparación de Pronósticos.**

Fuente: Elaboración Propia.

En la Figura 5.5 se observa una gran diferencia entre las ventas y el pronóstico estimado con el método ARIMA, por otra parte, en la Figura 5.4 esta diferencia es menor ya que selecciona el método de SES1, que posee un  $\alpha = 0,5$  por tanto responde con mayor rapidez a las bajas de demanda que se han presentado en los últimos meses. Respecto a la comparación de los errores MAPE, este disminuye de un 89% a un 39%, lo que indica un mejor pronóstico en el modelo 1. En cuanto a los pronósticos proyectados, el modelo inicial propone una demanda

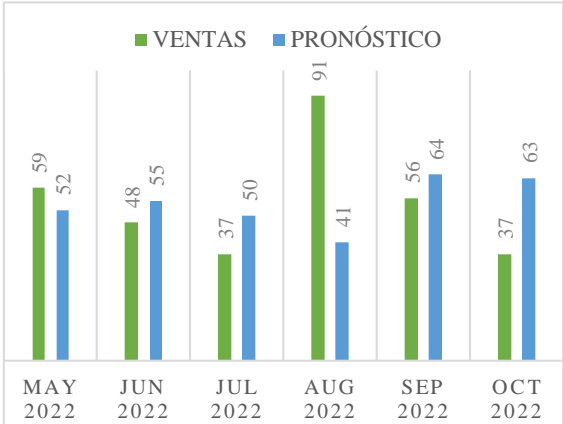
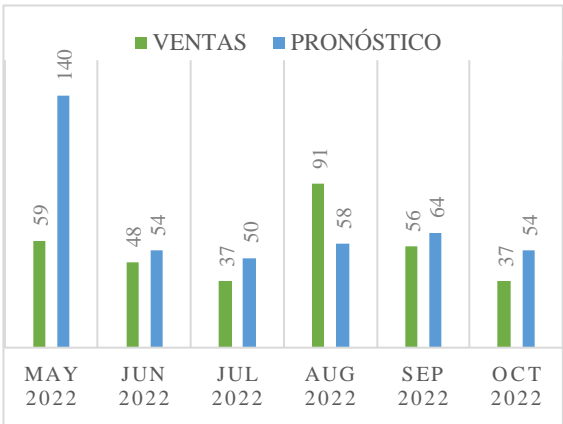
alta hasta mayo del 2023 y recién en junio del 2023 refleja las bajas que se han presentado en los últimos meses. Por su parte, el pronóstico realizado con el modelo 1 refleja un pronóstico estable y lo mantiene para los siguientes 12 periodos. Hay que tener en consideración que IBP vuelve a estimar los pronósticos mes a mes tomando los nuevos datos de ventas que se van ingresando al sistema, por tanto, el pronóstico que se proyecta es con los datos hasta octubre del 2022. Si existieran alzas o bajas en la demanda en los próximos meses, este pronóstico se verá alterado respondiendo rápidamente a estos cambios.

- Resultados Modelo 2.

La Tabla 14 expone los resultados para un producto del segmento AA, para visualizar más resultados de la ejecución de este modelo ver el Anexo 4.

**Tabla 5.10: Comparación de Pronóstico para Producto con comportamiento con Tendencia.**

Fuente: Elaboración Propia.


Código del Producto	78057NH042 TCDC	78057NH042 TCDC
Método Seleccionada	SED1	Media Móvil 1
Comparación de Pronóstico y Ventas Reales en los últimos 6 meses		

**Figura 5.7: Pronóstico con Modelo 2.**

Fuente: Elaboración Propia.

**Figura 5.8: Pronóstico con Modelo Inicial.**

Fuente: Elaboración Propia.



**Figura 5.9: Comparación de Pronósticos.**

Fuente: Elaboración Propia.

El error MAPE disminuye desde un 47% hasta un 34% y para el pronóstico inicial la mayor diferencia se presenta en mayo del 2022, en cuanto al modelo 2 esta es en agosto del 2022. Comparando entre la SED1 y la media móvil, es la primera la que identifica la tendencia con mayor facilidad y se reflejado en el gráfico expuesto en la Figura 5.7. El pronóstico inicial estabiliza la demanda constante y luego hay una baja en junio del 2023 pero esta no es gradual como debería reflejarse.

▪ Resultados Modelo 3.

La Tabla 5.11 expone los resultados para un producto del segmento AA, para visualizar más resultados de la ejecución de este modelo ver el Anexo 4.

**Tabla 5.11: Comparación de Pronóstico para producto con Estacionalidad.**

Fuente: Elaboración Propia.


Código del Producto	78N47NH036 TCDS	78N47NH036 TCDS																																										
Método Seleccionada	SET3	SET																																										
Comparación de Pronóstico y Ventas Reales en los últimos 6 meses	<table border="1"> <caption>Data for Figure 5.10: Model 3</caption> <thead> <tr> <th>Mes</th> <th>Ventas</th> <th>Pronóstico</th> </tr> </thead> <tbody> <tr><td>MAY 2022</td><td>406</td><td>226</td></tr> <tr><td>JUN 2022</td><td>74</td><td>196</td></tr> <tr><td>JUL 2022</td><td>292</td><td>188</td></tr> <tr><td>AUG 2022</td><td>266</td><td>185</td></tr> <tr><td>SEP 2022</td><td>384</td><td>185</td></tr> <tr><td>OCT 2022</td><td>223</td><td>184</td></tr> </tbody> </table>	Mes	Ventas	Pronóstico	MAY 2022	406	226	JUN 2022	74	196	JUL 2022	292	188	AUG 2022	266	185	SEP 2022	384	185	OCT 2022	223	184	<table border="1"> <caption>Data for Figure 5.11: Model Initial</caption> <thead> <tr> <th>Mes</th> <th>Ventas</th> <th>Pronóstico</th> </tr> </thead> <tbody> <tr><td>MAY 2022</td><td>406</td><td>226</td></tr> <tr><td>JUN 2022</td><td>74</td><td>717</td></tr> <tr><td>JUL 2022</td><td>292</td><td>744</td></tr> <tr><td>AUG 2022</td><td>266</td><td>602</td></tr> <tr><td>SEP 2022</td><td>384</td><td>1.163</td></tr> <tr><td>OCT 2022</td><td>223</td><td>1.127</td></tr> </tbody> </table>	Mes	Ventas	Pronóstico	MAY 2022	406	226	JUN 2022	74	717	JUL 2022	292	744	AUG 2022	266	602	SEP 2022	384	1.163	OCT 2022	223	1.127
Mes	Ventas	Pronóstico																																										
MAY 2022	406	226																																										
JUN 2022	74	196																																										
JUL 2022	292	188																																										
AUG 2022	266	185																																										
SEP 2022	384	185																																										
OCT 2022	223	184																																										
Mes	Ventas	Pronóstico																																										
MAY 2022	406	226																																										
JUN 2022	74	717																																										
JUL 2022	292	744																																										
AUG 2022	266	602																																										
SEP 2022	384	1.163																																										
OCT 2022	223	1.127																																										

**Figura 5.10: Pronóstico con Modelo 3.**

Fuente: Elaboración Propia.

**Figura 5.11: Pronóstico con Modelo Inicial.**

Fuente: Elaboración Propia.



**Figura 5.12: Comparación de Pronósticos.**

Fuente: Elaboración Propia.

En general, las series de tiempo con estacionalidad son las que poseen mayor porcentaje de mejora y los resultados expuestos en la Tabla 5.11 son un claro ejemplo, el error MAPE disminuye de un 300% hasta un 57%. Si bien, ambos modelos seleccionaron suavización

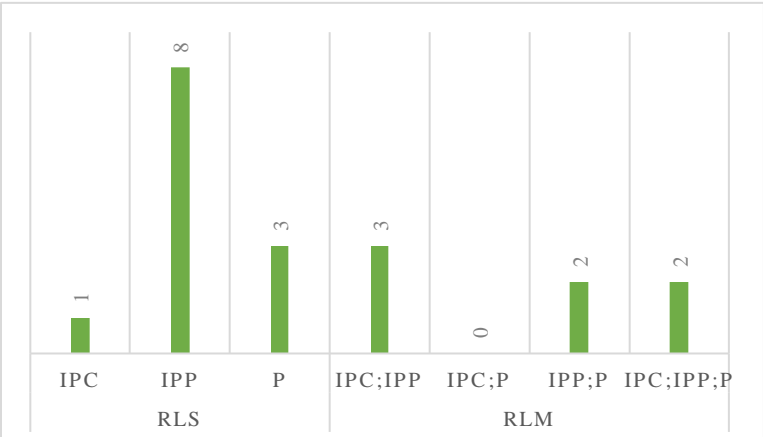
exponencial triple, la SET inicial está compuesta por coeficientes altos por tanto la demanda se sobrestimó incluso proyectando casi 2000 m<sup>3</sup> para marzo del 2023 lo que es poco coherente con el comportamiento de los datos históricos. En cuanto a la SET3 definida en el modelo 3, esta posee coeficientes bajos que se pueden observar en la Tabla 5.8, lo que permite dar mayor peso a los datos históricos y logra proyectar estacionalmente identificando alzas y bajas dentro del horizonte de pronóstico.

**5.2.2 Métodos de Regresiones.**

Se analizaron RLS y RLM para 10 de las series de tiempo que componen el segmento AA con las variables explicativas propuestas en el apartado 4.1.3. En la Figura 5.13 se observa el número de regresiones que fueron significativas por variables explicativas. En relación con la RLS la que obtuvo mayor significancia fue la relacionada con el IPP que logró aportar con explicación al comportamiento de demanda en un 80% de las series de tiempo estudiadas, se presenta el resultado asociado la demanda de un producto con la variable independiente IPP.

En cuanto a las RLM no se obtuvo un patrón de significancia superior al 50% de las series de tiempo estudiadas, no obstante, se presentan los resultados referidos a las RLM compuestas por el IPC e IPP como variables explicativas para uno de los productos analizados.

En el Anexo 5 se encuentran más resultados y los gráficos de normalidad de residuos para cada caso con mayor detalle.



**Figura 5.13: Regresiones Significativas por Variables Explicativas.**

Fuente: Elaboración Propia.

- Resultados Regresión Lineal Simple (RLS).

En la Tabla 5.12 se encuentra el resultado asociado al estudio del producto con código 78935NH037 TCDC. La variable independiente de esta regresión es el IPP. El modelo de regresión propuesto se expresa como:

$$D = -1.217 + 12IPP + \varepsilon$$

Donde:

$D$ : Demanda.

$IPP$ : Índice de Precio del Producto de la industria Manufacturera.

$\varepsilon$ : Error de pronóstico.

Es decir, a medida que aumenta el IPP, lo hará la demanda.

En la Tabla 5.12 se exponen los estadísticos que validan esta regresión.

**Tabla 5.12: Resultados RLS producto 78935NH037 TCDC.**

Fuente: Elaboración Propia.

<b>78935NH037 TCDC</b>		
<b>Coeficientes</b>		
Estadístico T	$\beta_0$	-3,88
	$\beta_1$	4,41
Valor p	$\beta_0$	0,0005 ***
	$\beta_1$	0,0001 ***
<b>ANOVA</b>		
Estadístico F	Modelo	19,43
Valor p	Modelo	0,0001***
	$r$	0,60
	$r^2$ ajustado	34,50%
	Estadístico	1,43
	Durbin- Watson	
	Estadístico	0,986
	Shapiro Wilks	
	Valor p	0,957

En relación con la significancia de los parámetros se observa que  $\beta_0$  y  $\beta_1$  poseen un valor p menor a 0,01, por tanto, son significativos al 99%. El valor p del estadístico F es menor a 0,01, lo que implica que la regresión es significativa.

El estadístico de Durbin-Watson es de 1,43 por tanto no logra ser cercano 2, lo que implica una autocorrelación entre los residuos, no obstante, al ser pronósticos con series de tiempo, es probable que este supuesto no sea el esperado y pierde relevancia dado que la demanda de



un mes tiene relación con la del mes siguiente, producto de los niveles de abastecimiento que tengan los clientes, la capacidad productiva o promociones.

Respecto a la normalidad de los residuos, la prueba de Shapiro Wilks posee un valor  $p$  superior a 0,05, es decir, no se puede rechazar la idea de que los residuos provienen de una distribución normal con 95% de confianza.

Finalmente, el  $r^2$  ajustado posee un valor de 34,50%, es decir, el IPP explica en un 34,50% la variabilidad de la demanda del producto 78935NH037 TCDC.

- Resultados Regresión Lineal Múltiple (RLM).

Se analiza el modelo resultante para el producto con código 78708NH043 TCDC relacionado con las variables macroeconómicas IPC e IPP, el cual se estima como:

$$D = -9.523 + 105 \times IPP + 972 \times IPC + \varepsilon$$

Donde:

$D$ : Demanda.

$IPP$ : Índice de Precio del Producto de la industria Manufacturera.

$IPC$ : Índice de Precio del Consumidor.

$\varepsilon$ : Error de pronóstico.

Existe una relación directamente proporcional entre la demanda el IPC y el IPP.

En la Tabla 5.13 se encuentran los resultados de los estadísticos que validan esta RLM.

**Tabla 5.13: Resultados RLM producto 78708NH043 TCDC.**

Fuente: Elaboración Propia

<b>78708NH043 TCDC</b>		
<b>Coefficientes</b>		
Estadístico T	$\beta_0$	-4,21
	$\beta_1$	5,20
	$\beta_2$	3,28
Valor p	$\beta_0$	0,0002 ***
	$\beta_1$	0,0000 ***
	$\beta_2$	0,0025 ***
<b>ANOVA</b>		
Estadístico F	Modelo	16,386
Valor p	Modelo	0,0000014***
	$r^2$	50%
	$r^2$ ajustado	46,79%
	Estadístico Prueba de Normalidad de Residuos	4,277
	Valor p	0,1177
	Estadístico Prueba de White	3,711
	Valor p	0,5916
	Valor de Inflación de Varianza (VIF)	
	IPP	1,033
	IPC	1,033

En relación con la significancia de  $\beta_0$ ,  $\beta_1$  y  $\beta_2$ , el valor p del estadístico T para los tres casos es menor a 0,1, por tanto, los tres parámetros son significativos en un 99%. La misma situación ocurre para el valor p del estadístico F, lo que implica que el modelo de RLM es significativo en un 99%.

La prueba de normalidad posee un valor p igual a 0,117, por lo que no se rechaza que los residuos poseen distribución normal. En cuanto al estadístico de prueba de White, el valor p es mayor a 0,01, entonces se concluye que no existe heterocedasticidad. Finalmente, para verificar la existencia de multicolinealidad se utiliza el VIF. Tanto para el IPP como el IPC este valor es menor a 10. Se infiere que no existe multicolinealidad.

Bajo los resultados analizados, se concluye que la RLM es válida y la variabilidad de la demanda es explicada en un 46,79% por la variabilidad de las variables explicativas.

### 5.3 Comparación de Medidas de Error para Análisis de Series de Tiempo.

Luego de haber estimado los modelos descritos en el punto 5.2. para todas las series de tiempo, se comparan las métricas de error de pronóstico de los modelos propuestos en el apartado 5.2.1. comparándolo con el modelo inicial.

Los resultados se presentan a un nivel agregado dividido por segmento AA y A.

**Tabla 5.14: Comparación de las Métricas de Error.**

Fuente: Elaboración Propia

	<b>MAPE INICIAL</b>	<b>MAPE FINAL</b>	<b>MAD INICIAL</b>	<b>MAD FINAL</b>	<b>MSE INICIAL</b>	<b>MSE FINAL</b>
<b>AA</b>	45%	40%	2.855	2.497	9.375	9.017
<b>A</b>	45%	38%	1.230	1.025	4.241	4.037
<b>Total</b>	54%	38%	4.863	3.523	14.395	13.054

Al observar la Tabla 5.14 las tres métricas de error son menores en los pronósticos finales, es decir, utilizando los modelos propuestos. Esto indica que la segmentación de la demanda ha funcionado y es congruente con la configuración de modelos que son definidos con métodos estadísticos que responden a los cambios de los componentes sistemáticos nivel, tendencia y estacionalidad.

## 6 Discusión de Resultados.

La propuesta de mejora de pronósticos se basa en la segmentación y responde a la teoría planteada fundamentalmente por los autores (Chopra & Meindl, 2013) y (Hanke & Wichern, 2010) acerca de métodos estadísticos de pronóstico utilizados en series de tiempo.

Se observa que es fundamental la limpieza de historia de los datos, ya que los datos son la fuente de información de los métodos de pronóstico. Si las series de tiempo incluyen peaks de demanda y bajas abruptas será difícil obtener un pronóstico que no esté sobrestimado o subestimado. Esta situación ocurre bastante en Masisa debido a que poseen un gran portafolio de productos, lo que implica un gran número de series de tiempo que limpiar todos los meses, lo que muchas veces queda fuera del alcance del jefe de planificación que posee más labores que desarrollar.

Dentro de IBP en la aplicación de administración de modelos de pronóstico, existe una sección de preprocesamiento de datos que permite configurar métodos para limpiar la historia eliminando datos atípicos a través del método del rango intercuartílico o el test de varianza (IBP Fiori, 2022). Se propone investigar estas funciones que si bien no lograrán limpiar la historia a la perfección podrían hacer el proceso más corto para luego contrastar este resultado con las órdenes.

La segmentación fue fundamental al generar esta propuesta, si bien la diferencia en error MAPE entre los pronósticos actuales y los propuestos no superan una diferencia de un 20% a nivel agregado, a un nivel desagregado, es decir, analizando cada serie de tiempo es donde se puede ver la diferencia tanto en la etapa de prueba como en el pronóstico proyectado a 12 meses. A través de esta propuesta disminuye la sobrestimación y subestimación que suele ocurrir y se logra simular una curva similar a la de la historia.

Se propone crear una variable que almacene la información referida al comportamiento de las series de tiempo para utilizar la función “Considerar el comportamiento de la Serie de Tiempo” en la aplicación de administración de modelos de pronóstico.

Esta función permite analizar la historia de la serie de tiempo y utilizar métodos estadísticos que sean congruentes con su comportamiento dentro de un mismo modelo, es decir, se

podrían unir los tres modelos propuestos en uno solo y ejecutarlo para todas las series de tiempo que posean continuidad, tendencia y/o estacionalidad.

Además, se sugiere eliminar el método ARIMA/SARIMA de los análisis con periodicidad mensual, ya que IBP permite trabajar con un máximo de 36 periodos, lo cual es poco según la definición realizada por los autores de este método (Pelham Box & Jenkins, 1970).

No obstante, este método se puede utilizar al ocupar una periodicidad semanal ya que se podrían utilizar hasta 156 periodos de análisis. En cuanto a la configuración de este modelo, se sugiere que los valores de iteración de  $(p, q, d)$   $(P, Q, D)$  no superen los valores  $(2,1,2)(2,1,2)$  para evitar sobrestimación de pronóstico.

En relación con los métodos causales, actualmente en Masisa no se ha investigado sobre los pronósticos utilizando estos métodos, por lo que, el análisis realizado da las directrices de una investigación que se puede aperturar aún más, analizando un mayor número de series de tiempo e incluyendo nuevas variables.

Según el análisis realizado se observa que el Índice del Precio del productor es una variable que podría influir en la variabilidad de la demanda, relacionándose directamente proporcional, es decir, si este aumenta, aumentará la demanda y si este indicador baja, la demanda podría bajar.

Una mirada importante que se podría generar a partir de métodos causales es incluir en estos análisis variables de producción propias de la empresa. Según el estudio realizado por (Adamowicz & Noga, 2017) algunos de los modelos que poseen mejores resultados están relacionados con el nivel de inventario, capacidad, ventas, promociones, etc. Esta propuesta hace sentido ya que, si bien la demanda depende de las necesidades que existan en el mercado, las ventas están restringidas por los factores mencionados.

Finalmente, los resultados obtenidos son los esperados, pues si bien nunca se podrá pronosticar con exactitud, se logra mejorar la calidad de los pronósticos y en consecuencia se podrían obtener beneficios como aumentar la precisión de los pronósticos de rentabilidad, controlar los niveles de inventarios, es decir, mantener el inventario necesario y no más de lo solicitado, además, generar un mayor cumplimiento de los pedidos y evitar el desabastecimiento de existencias (Thrive Technologies, 2022).

## **7 Conclusiones.**

Este proyecto surge de la necesidad de mejorar los pronósticos de demanda, dado el tiempo disponible para su realización se acota su alcance. Luego de obtener los resultados y generar la propuesta, se recomienda evaluar los modelos en el negocio de molduras y complementarios y a nivel internacional, tomando en cuenta las consideraciones mencionadas en la discusión.

Respecto al cumplimiento de los objetivos específicos, se logra limpiar la historia de demanda de todas las series de tiempo evaluadas, una de las dificultades de este proceso fue la magnitud de datos que se debieron evaluar, puesto que el portafolio de tableros en Masisa es amplio y al iniciar este proyecto se iteraron los modelos a distintos niveles de agregación, por tanto, para cada nivel de agregación se debía realizar la limpieza de datos lo que demandó más tiempo de lo planificado.

A su vez se evidencia que el comportamiento de la demanda en la mayoría de los casos estudiados de observa inestable, con periodos en los que las ventas están muy altas y al periodo siguiente bajan abruptamente. Estas situaciones son importantes de evaluar y comprender lo que pudo ocasionar este tipo de comportamientos. En general, se debe a promociones, faltas de stock y de capacidad, en cuanto a los dos últimos aspectos mencionados, pueden mejorar si los pronósticos de demanda son más certeros, así el plan de demanda que llegue al área de capacidad será más confiable.

Identificar el comportamiento de los datos históricos y realizar la segmentación fue un proceso apoyado inicialmente por StatGraphics y luego por la aplicación de IBP “Perfiles de automatización de pronósticos” en la que al ejecutar el perfil se pudo segmentar fácilmente las series de tiempo por su comportamiento. No obstante, esta información no quedó almacenada en una variable por lo que se sugiere crear esta variable para que el planificador de demanda pueda ejecutar los modelos filtrando por comportamiento facilitando el proceso.

La etapa de evaluación de métodos de análisis de series de tiempo se vio dificultada por la selección del nivel de agregación. A un nivel más desagregado fue más difícil generar una propuesta, ya que es un mayor número de series de tiempo que analizar y en el caso de considerar la variable “Cliente” se generan series de tiempo por sucursales que posea cada cliente. Esta situación se resuelve con la variable que segmenta las series de tiempo según su

componente sistemática, pues el usuario no tendrá que preocuparse de seleccionar manualmente las series que posean un comportamiento específico, el sistema lo hará automáticamente.

Por otra parte, la evaluación de los métodos se vio apoyada por StatGraphics ya que en ocasiones IBP no genera pronósticos congruentes con los métodos y coeficientes definidos, al contrastar el mismo método con los mismos coeficientes en StatGraphics los resultados difieren, siendo las proyecciones de StatGraphics mejores que las de IBP.

Cuando ocurren estas situaciones se sugiere inferir en el ciclo de vida del producto definido por el área de marketing en IBP y verificar si los productos están referenciados con otros, es decir, se toma un porcentaje de ventas de otro producto para pronosticar uno que es más nuevo y no tiene tantos meses de venta. Al tomar otros productos de referencia los pronósticos al inicio se pueden mostrar congruentes con la historia, no obstante, al pasar el tiempo las proyecciones se pueden ver alteradas, por tanto, si el producto lleva un tiempo superior a 9 meses en el mercado se sugiere eliminar esta referencia.

En cuanto a la aplicación de métodos causales, se da de una forma más exploratoria pues es un método sin precedente en el área de planificación de demanda en Masisa y se está evaluando su incorporación al sistema.

La investigación se orientó en definir variables macroeconómicas, se observan resultados con el IPP, IPC, P y la Tasa de Política Monetaria (TPM), no obstante, esta última no obtuvo resultados positivos por lo que se concluye que no influye en el comportamiento de la demanda. Lo mismo sucede con el P por sí solo (en una RLS), no aporta en la explicación de la variabilidad de la demanda. Sin embargo, se encuentran resultados positivos al estimar modelos de RLM considerando el P y el IPP o el IPC.

El IPP fue la variable que mejores resultados entregó, por tanto, se podría considerar configurarla con una RLS en algún modelo de pronóstico.

Se sugiere ampliar esta investigación incluyendo un mayor número de series de tiempo que sustenten estos resultados e investigar otras variables nuevas que se podrían ver involucradas en el comportamiento de la demanda.

Finalmente, a modo general se concluye que si bien la teoría se aleja de la práctica pues las series de tiempo en empresas con negocios dinámicos como Masisa no siguen un comportamiento lógico o secuencial, es fundamental considerar la teoría al utilizar programas inteligentes como lo son IBP, pues una mala configuración de un modelo implica malos pronósticos con sobrestimaciones o subestimaciones. Si bien un modelo que no responda al comportamiento específico de la serie de tiempo puede funcionar ocasionalmente, tiene mayor riesgo de errar en un futuro que uno que es congruente con el comportamiento de la serie.

Además, es importante enfatizar que siempre existirá una diferencia entre los pronósticos y las ventas reales, pues no existe un método capaz de predecir con exactitud, pero un buen pronóstico ayuda al planificador de demanda a tomar una decisión más certera al crear el plan de demanda.



## 8 Referencias

- Arribas, I. (22 de julio de 2022). *DATADEC*. Obtenido de <https://www.datadec.es/blog/implementacion-del-erp-la-limpieza-de-datos#:~:text=Los%20datos%20de%20una%20empresa,de%20la%20actividad%20que%20representan>.
- Pelham Box , G. E., & Jenkins, G. M. (1970). *Análisis de series temporales. Predicción y control*.
- Adamowicz, K., & Noga, T. (2017). Assessment applicability of selected models of multiple discriminant analyses to forecast financial situation of Polish wood sector enterprises. *Folia Forestalia Polonica*, 59-67.
- Agueda, E., García, J., Narros, J., Reinares, E., & Saco, M. (1997). *Principios de Marketing*. Madrid, España: ESIC.
- Ballou, R. (2004). Logística. Administración de la cadena de suministro. Quinta Edición. En R. H. Ballou, *Logística. Administración de la cadena de suministro*. (págs. 65-66). México: Pearson Educación.
- Banco Central de Chile. (2022). *Banco Central de Chile* . Obtenido de <https://www.bcentral.cl/web/banco-central/areas/politica-monetaria>
- Camara Chilena de la Construcción. (29 de 03 de 2021). *Camara Chilena de la Construcción*. Obtenido de <https://cchc.cl/comunicaciones/opiniones/escasez-de-insumos-para-la-construccion>
- Chopra, S., & Meindl, P. (2013). *Administración de la Cadena de Suministro*. México: Pearson Educación.
- Croston, J. (1972). Forecasting and stock control for intermittent demands. *Operational Research Society*, 289-303.
- da Costa, M., & da Conceicao, M. (2012). Contribución del modelo ABC en la toma de decisiones: el caso universidades. *Cuadernos de Contabilidad* , 527-543.
- Díaz, C. (14 de julio de 2022). *netLogistik*. Obtenido de <https://www.netlogistik.com/es/blog/el-metodo-xyz-de-clasificacion-de-inventarios#:~:text=El%20objetivo%20de%20este%20m%C3%A9todo,establecer%20pol%C3%ADticas%20de%20pedido%20adecuadas>.
- Dornbusch, R., Fischer, S., & Startz, R. (2005). Macroeconomía, novena edición. En R. Dornbusch, S. Fischer, & R. Startz, *Macroeconomía, novena edición* (págs. 40-42). Madrid: Mc Graw Hill.
- Equipo editorial, Etecé. (15 de julio de 2021). *Concepto*. Obtenido de <https://concepto.de/industria-manufacturera/#:~:text=Algunos%20ejemplos%20de%20industria%20manufacturera,o%20herramientas%20de%20todo%20tipo>.

- Gonzalez Gonzalez, J. M., Cruz Vera, D. A., Cruz, T. H., & Gonzalez Torres, J. G. (2016). *Administración de Operaciones*. Tijuana Baja California: Tecnológico Nacional de México.
- Grimson, J., & Pyke, D. (2007). Planeación de ventas y operaciones: un estudio exploratorio y estructural. *J. Logista*, 322-346.
- Hanke, J., & Wichern, D. (2010). *Pronósticos en los Negocios*. México: Pearson Educación.
- IBP. (2022). Interfaz de IBP en Excel.
- IBP Fiori. (2022). *IBP Fiori*. Obtenido de <https://my301523.scmibp1.ondemand.com/ui#IBPForecastAutomationProfile-manage&/S2FAEdit/edit/MASISA/1668605137250>true>
- Incentive Insights. (28 de enero de 2020). *Incentive Insights*. Obtenido de <https://incentiveinsights.com/what-is-rebate-marketing/>
- INE. (2022). Obtenido de <https://www.ine.gob.cl/estadisticas/economia/indices-de-precio-e-inflacion/indice-de-precios-de-productor>
- INE. (2022). *INE*. Obtenido de [https://www.ine.gob.cl/ine-ciudadano/definiciones-estadisticas/economia/indice-de-precios-al-consumidor#:~:text=El%20C3%8Dndice%20de%20Precios%20al%20Consumidor%20\(IPC\)%20es%20un%20indicador,de%20los%20hogares%20del%20pa%C3%ADs.](https://www.ine.gob.cl/ine-ciudadano/definiciones-estadisticas/economia/indice-de-precios-al-consumidor#:~:text=El%20C3%8Dndice%20de%20Precios%20al%20Consumidor%20(IPC)%20es%20un%20indicador,de%20los%20hogares%20del%20pa%C3%ADs.)
- Investing.com. (2022). *Investing.com*. Obtenido de <https://es.investing.com/currencies/usd-clp-historical-data>
- Jacobs, R., Berry, W., Clay, W., & Vollman, T. (2011). *Manufacturing Planning and Control for Supply Chain Management: APICS/CPIM*. McGraw-Hill Education.
- Lapide, L. (2005). Planificación de ventas y operaciones Parte II: tecnología habilitadora. *J. Autobús Pronóstico*, 13-16.
- Liao, X., & Zhang, Y. (2008). Análisis econométrico de la producción de madera blanda en el sur de EE.UU.: Comparación entre la propiedad forestal industrial y la no industrial. *Revista de Productos Forestales*, 69-76.
- Loaiza Torres, J. (2018). Del ciclo de vida del producto al ciclo de vida del cliente: Una aproximación hacia una construcción teórica del ciclo de vida del cliente. *Investigación y Negocios*, 100-110.
- Masisa. (2020). *Manual IBP for Demand*. GoSCM Consulting.
- Masisa. (septiembre de 2020). Proceso S&OP Masisa.
- Masisa. (febrero de 2021). Planificación de Demanda. *Presentación*. Chile.
- Masisa. (2022). *Masisa (Your World, Your Site)*. Obtenido de <https://english.masisa.com/nosotros/nuestra-empresa/principios-y-valores/>

- Masisa. (2022). *Masisa, Tu mundo, Tu estilo*. Obtenido de Cadena de Suministros:  
<https://trabajos.masisa.com/go/Cadena-de-Suministros/8235300/>
- Masisa Corporativo. (2022). *Masisa Corporativo*. Obtenido de <https://corporativo.masisa.com/nuestra-empresa/gobierno-corporativo/nuestra-presencia/>
- Masisa Corporativo. (2022). *Masisa Corporativo*. Obtenido de Nuestros Negocios:  
<https://corporativo.masisa.com/nuestros-negocios/propuesta-de-valor/negocio-forestal/>
- Masisa Corporativo. (2022). *Masisa Corporativo, Estructura Organizacional*. Obtenido de  
<https://corporativo.masisa.com/nuestra-empresa/gobierno-corporativo/estructura-organizacional/>
- Navarrete, M. A. (2015). *Análisis Financiero Masisa S.A.* Concepción.
- Noroozi, S., & Wikner, J. (2017). Sales and operations planning in the process industry: A literature review. *International Journal of Production Economics*.
- Ramírez Rodríguez, I. (2022). *Mejora del proceso de pronóstico de demanda en productos de consumo masivo en el mercado nacional de Agrosuper, mediante un enfoque de rediseño de procesos y la aplicación de técnicas de Deep Learning*. Santiago, Chile.
- Ridzuan, F., & Wan Zainon, W. (2019). A Review on Data Cleansing Methods for Big Data. *Procedia Computer Science*, 731-738.
- Thrive Technologies. (2022). *Thrive Technologies*. Obtenido de <https://www.thrivetech.com/forecast-accuracy-metrics>
- Vanam, L. (24 de julio de 2019). *SAP Integrated Business Planning 1908 Innovations*. Obtenido de SAP Community: <https://blogs.sap.com/2019/07/24/sap-integrated-business-planning-1908-innovations/>

## 9 Anexos

### Anexo 1

Este Anexo contiene información sobre los mercados y productos que se comercializan en Masisa. En la Tabla 9.1 se observa que el mayor volumen de ventas es a nivel nacional, luego le sigue PEC y México y las exportaciones son las que aportan menos en volumen de ventas.

**Tabla 9.1: Distribución de mercados y productos.**

Fuente: Elaboración Propia a partir de (Masisa, 2021)

	<b>Nacional</b>	<b>Exportaciones</b>	<b>PEC<sup>13</sup></b>	<b>México</b>
Tableros	X	X	X	X
Maderos	X	X	X	
Molduras	X	X	X	
Complementarios <sup>14</sup>	X	X	X	
<b>Promedio de Ventas</b>	21.000 m <sup>3</sup> /mes	7.000 m <sup>3</sup> /mes	11.000 m <sup>3</sup> /mes	11.000 m <sup>3</sup> /mes

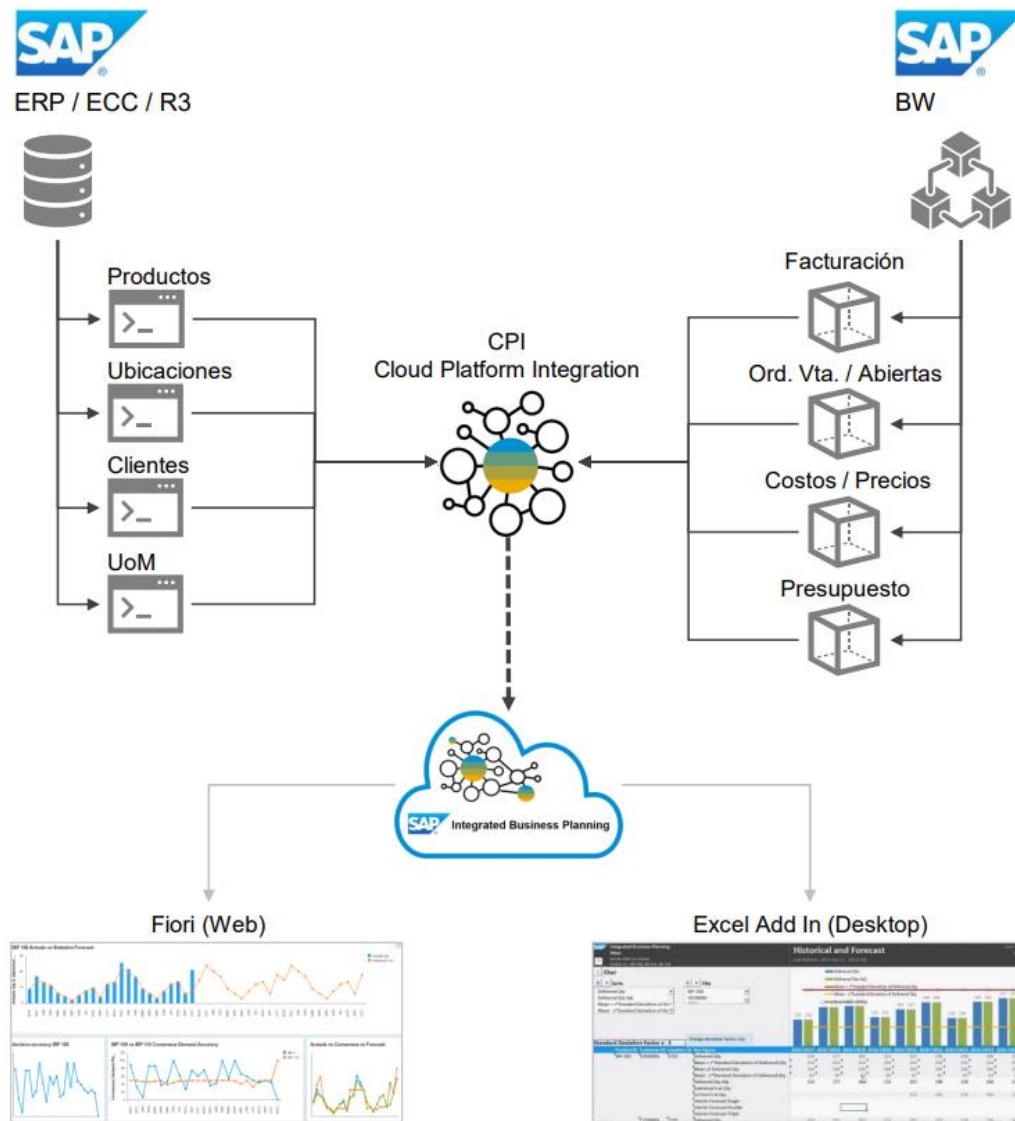
<sup>13</sup> PEC: Perú, Ecuador y Colombia.

<sup>14</sup> Complementarios: Compuesto por herrajes, cantos y tableros de alta gama.

## Anexo 2

Este Anexo contiene la descripción gráfica del proceso de planificación de demanda en Masisa, fue desarrollado en su mayoría con la información disponible en (IBP Fiori, 2022).

En primer lugar, para comprender el funcionamiento de IBP la Figura 9.1 presenta la arquitectura general del software.



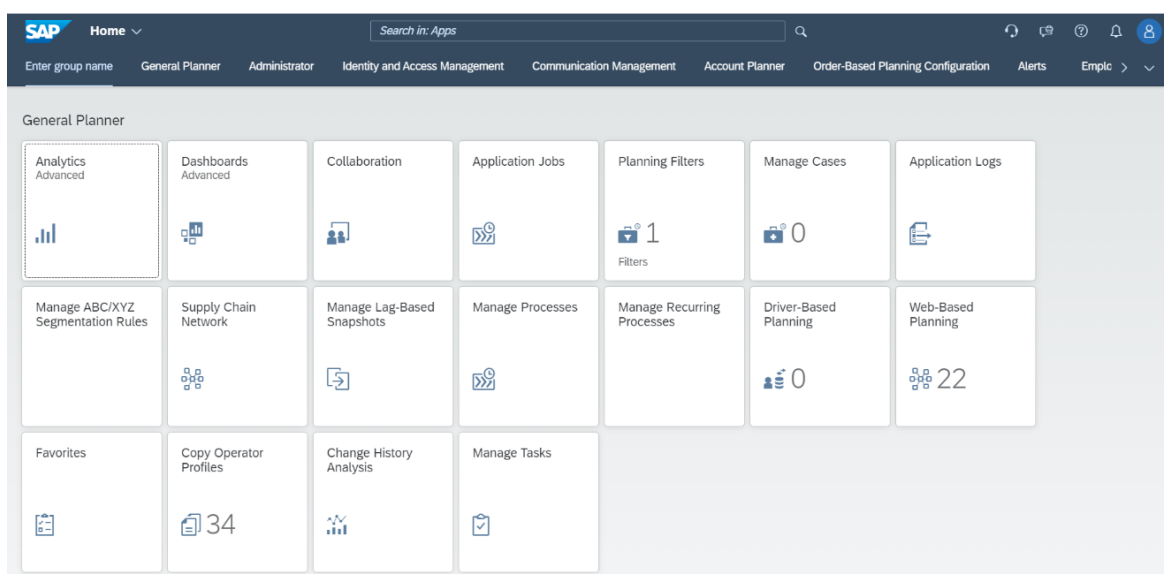
**Figura 9.1: Arquitectura IBP.**

Fuente: (Masisa, 2020)

El planificador de demanda utiliza tanto la interfaz de Fiori (Web) como la aplicación de Excel.

En la Figura 9.2 se observa la interfaz principal de Fiori en donde se encuentran algunas de las aplicaciones que sirven de apoyo a la gestión de actividades del área de cadena de suministro.

En particular, para la planificación de demanda se utiliza la aplicación “Manage Forecast Models” o “Administración de modelos de pronóstico”.



**Figura 9.2: Interfaz principal de Fiori.**

Fuente: (IBP Fiori, 2022)

Dentro de esta aplicación se pueden crear varios modelos que contengan distintos métodos estadísticos. En la Figura 9.3 se observa un modelo que lleva por nombre “Estacionalidad\_Month”, este nombre es definido por el planificador de demanda. En la primera ventana, “General”, se configura la periodicidad, cuántos periodos de historia se utilizarán para generar el pronóstico y cuántos periodos se van a pronosticar hacia el futuro.

Además, se puede definir el número de periodos de tiempo para los que se desea que el sistema calcule las medidas de error. Otro aspecto importante que se puede configurar en esta ventana es la selección de la opción que permite relacionar los métodos de pronóstico con el ciclo de vida del producto, es decir, si un producto se encuentra configurado en crecimiento probablemente se identifique una tendencia positiva y se ejecutarán métodos estadísticos que permitan proyectar ese tipo de series de tiempo. El problema de seleccionar esta opción es que hay productos que están desactualizados en la etapa del ciclo de vida en la que están o que están referenciados con otros productos y se ha observado que en estos casos la demanda

se sobrestima o se subestima, por lo que el área de marketing debe mantener el campo de ciclo de vida del producto actualizado para poder considerar esta función en los pronósticos.

**Figura 9.3: Interfaz de Configuración de un Modelo de Pronóstico.**

Fuente: (IBP Fiori, 2022)

Al pasar a la ventana de “Forecasting Steps” (ver Figura 9.4) se pueden agregar distintos métodos estadísticos con sus respectivos parámetros. En primer lugar, se define la variable que será el input con los datos históricos, esta selección se hace en “Main Input for Forecasting Steps” y la variable seleccionada es “Actuals Qty Adj” que contiene los datos históricos de demanda limpios, es decir, suavizando datos atípicos y contrastándola con el número de órdenes. Luego, en “Target Key Figure for Forecast” se selecciona la variable en la que se guardará el pronóstico, en este caso los pronósticos se guardan en la variable “Statistical Fest Qty”.

Pasando a la sección de algoritmos, al lado izquierdo se observa un ícono con un signo +, al presionar este ícono se despliegan todos los algoritmos que posee IBP para realizar pronósticos. IBP cuenta con 18 métodos de pronósticos que se observan en la Tabla 9.2, no obstante, en Masisa se utilizan 8 métodos, entre ellos suavizaciones exponenciales, media móvil, ARIMA/SARIMA y Croston (método utilizado para pronosticar demanda que posee intermitencia (Croston, 1972)).

En el caso de la Figura 25 se seleccionan 4 suavizaciones exponenciales triples, donde para cada una se configuran sus coeficientes de suavización, el número de periodos por estación

y el tipo de estacionalidad (aditiva o multiplicativa) (Ver Figura 9.5). En la parte inferior donde se muestra la configuración “Utilize Multiple Forecast” es donde se define cuál será el método de selección de pronóstico, en este caso, se escoge el mejor pronóstico comparando los errores MAPE que posean los métodos de pronóstico para cada serie de tiempo. Además, se especifica la fase de testeo que para este ejemplo son 7 periodos. Bajo la fase de testeo, existe la opción “Consider Time Series Properties” que tiene por función identificar el comportamiento de la serie de tiempo y en base a este ejecutar métodos que sean congruentes. Esta opción se puede utilizar si se crea la variable que identifique el comportamiento de la serie de tiempo que se propone en el capítulo de discusión de resultados.

Finalmente, una vez configurados todos los campos el modelo se puede guardar al seleccionar la opción “Save” y ya está listo para ser ejecutado en la aplicación de Excel.

The screenshot displays the SAP 'Manage Forecast Model' interface, specifically the 'FORECASTING STEPS' configuration page. The 'Utilize Multiple Forecasts' section is active, showing the following settings:

- Method:** Choose Best Forecast
- Measure Used for Forecast Comparison:** Mean Absolute Percentage Error (MAPE)
- Test Phase Periods:** 7
- Consider Time Series Properties:**

Other visible sections include 'Overall Parameters' with fields for 'Main Input for Forecasting Steps' (Actuals Qty Adj.) and 'Target Key Figure for Calculated Forecast Input' (Select a key figure), and 'Algorithms' with four 'Triple Exponential Smoothing' entries, each with a selection icon.

**Figura 9.4: Configuración de los métodos estadísticos.**

Fuente: (IBP Fiori, 2022)



**Tabla 9.2: Métodos de Pronóstico Disponibles en IBP.**

Fuente: (IBP Fiori, 2022)

<b>Métodos</b>
Auto- ARIMA/SARIMA.
Auto-ARIMX/SARIMAX.
Suavización Exponencial Automatizada.
Suavización Exponencial Simple.
Suavización Exponencial Única de tasa de Respuesta Adaptativa.
Suavización Exponencial Doble.
Suavización Exponencial de Brown.
Suavización Exponencial Triple.
Media Móvil Simple.
Media Simple.
Media Móvil Ponderada.
Media Ponderada.
Método de Croston.
Método de Croston TSB.
Regresión Lineal Múltiple.
Árboles de Decisión.
Regresión Lineal Simple.
Copiar Periodos Pasados.

The screenshot displays the configuration panel for 'Triple Exponential Smoothing (1)'. The parameters are as follows:

- Periods in a Season: 3
- Type of Seasonality: Additive Seasonality
- Alpha Coefficient: 0.5
- Beta Coefficient: 0.3
- Gamma Coefficient: 0.4
- Enable Trend Dampening:
- Phi Coefficient: 0.8
- Target Key Figures: Select a key figure (for both Forecast and Ex-Post Forecast)

**Figura 9.5: Configuración de Suavización Exponencial Triple.**

Fuente: (IBP Fiori, 2022)

La interfaz de la aplicación de IBP en Excel se visualiza en la Figura 9.6, en esta imagen se observa la plantilla que utiliza el planificador de demanda. En la parte superior se encuentran distintas opciones de vistas de planificación, alertas, datos maestros, trabajos de aplicación, administración de la plantilla entre otros.

Dentro de las vistas de planificación se pueden realizar filtros de visualización, donde se definen las variables que contengan datos maestros y datos transaccionales que se quieran visualizar. Si se quiere observar al nivel de agregación Producto – Ubicación, es en esta configuración en donde se selecciona, además de la periodicidad y el horizonte de datos que

se quieren observar. Usualmente se seleccionan las variables que incluyen las ventas (“Actuals Qty.”), la demanda ajustada o limpia (“Actuals Qty. Adj.”) y los pronósticos (“Statistical Fcst Qty.”), estas variables el sistema las reconoce como “Key Figures”.

En la sección de “trabajos de aplicación” o “Application Jobs” en la opción “Run” es donde se ejecutan los modelos configurados en Fiori, al seleccionar esta opción se escoge el modelo y el nivel de agregación al cual se quiere ejecutar.

Luego de ejecutarlo, los resultados se guardan en la variable “Statistical Fcst Qty.”, como se observa en la Figura 9.6 a partir de enero del 2023 solo se visualizan resultados en esta variable ya que es una mirada hacia el pronóstico en el futuro, es decir, no existen datos de ventas y las otras dos variables no han almacenado datos.

SAP Integrated Business Planning				Key Figure																		
MASISA				MAR 23	APR 23	MAY 23	JUN 23	JUL 23	AUG 23	SEP 23	OCT 23	NOV 23	DEC 23	JAN 24	FEB 24	MAR 24	APR 24	MAY 24	JUN 24	JUL 24	AUG 24	
1	11991NH085	TCDC	ECOPLAC 8X1520X2440	Actuals Qty	151	66	235	119	91	58	108	108	98	35								
2	11991NH085	TCDC	ECOPLAC 8X1520X2440	Actuals Qty Adj.	154	145	260	132	103	133	121	108	98	35								
3	11991NH085	TCDC	ECOPLAC 8X1520X2440	Statistical Fcst Qty	214	127	186	206	196	240	261	275	235	120	121	119	110	107	118	124	117	
4	11991NH085	TCDS	ECOPLAC 8X1520X2440	Actuals Qty	45	45	53	43	45	28	88	40	0	8								
5	11991NH085	TCDS	ECOPLAC 8X1520X2440	Actuals Qty Adj.	65	69	55	28	33	48	78	40	20	8								
6	11991NH085	TCDS	ECOPLAC 8X1520X2440	Statistical Fcst Qty	104	47	93	78	93	77	117	92	58	37	35	41	46	42	31	30	37	
7	11995NH085	TCDC	ECOPLAC 8X1080X2440	Actuals Qty	280	446	346	204	177	149	159	217	226	75								
8	11995NH085	TCDC	ECOPLAC 8X1080X2440	Actuals Qty Adj.	339	446	346	241	206	211	187	219	226	75								
9	11995NH085	TCDC	ECOPLAC 8X1080X2440	Statistical Fcst Qty	209	251	355	305	337	244	300	335	312	273	260	252	236	245	250	254	265	
10	11995NH085	TCDS	ECOPLAC 8X1080X2440	Actuals Qty	161	190	167	179	174	176	143	113	159	48								
11	11995NH085	TCDS	ECOPLAC 8X1080X2440	Actuals Qty Adj.	163	190	160	142	145	113	115	110	159	48								
12	11995NH085	TCDS	ECOPLAC 8X1080X2440	Statistical Fcst Qty	126	144	172	131	121	233	202	167	168	140	143	125	127	115	112	112	108	
13	12817NH085	TCDC	OLB 8X1220X2440	Actuals Qty	1.743	2.200	957	640	518	559	559	557	573	330								
14	12817NH085	TCDC	OLB 8X1220X2440	Actuals Qty Adj.	880	900	967	640	518	559	559	557	573	330								
15	12817NH085	TCDC	OLB 8X1220X2440	Statistical Fcst Qty	1.410	1.391	2.104	1.769	1.721	1.708	1.912	1.812	1.834	789	758	763	781	775	786	778		
16	12817NH085	TCDS	OLB 8X1220X2440	Actuals Qty	1.579	1.668	1.387	895	798	636	848	445	723	514								
17	12817NH085	TCDS	OLB 8X1220X2440	Actuals Qty Adj.	1.556	1.668	1.456	1.109	862	697	848	800	723	514								
18	12817NH085	TCDS	OLB 8X1220X2440	Statistical Fcst Qty	1.357	992	1.408	1.409	1.548	1.673	1.559	1.744	1.806	761	782	737	736	680	705	718	721	
19	13012NH060	TCDC	OLB 12X1220X2440	Actuals Qty		69	34			11		24	21	43								
20	13012NH060	TCDC	OLB 12X1220X2440	Actuals Qty Adj.	20	27	34	46	42	40	65	45	21	43								
21	13012NH060	TCDC	OLB 12X1220X2440	Statistical Fcst Qty	0	0	19	42	48	49	46	90	43	45	80	75	24	65	70	29	72	
22	13012NH060	TCDS	OLB 12X1220X2440	Actuals Qty		171	34			114		26	13	19								
23	13012NH060	TCDS	OLB 12X1220X2440	Actuals Qty Adj.	30	66	88	45	76	82	26	13	19									
24	13012NH060	TCDS	OLB 12X1220X2440	Statistical Fcst Qty	83	0	11	24	27	29	27	11	58	45	6	3	46	2	1	48	3	
25	31086NH022	TCDC	MDF 30X1280X2240	Actuals Qty	81	0	79	40		44	21		102	4								
26	31086NH022	TCDC	MDF 30X1280X2240	Actuals Qty Adj.	125	167	206	150	100	176	120	121	102	4								
27	31086NH022	TCDC	MDF 30X1280X2240	Statistical Fcst Qty	84	60	60	115	97	196	176	169	250	212	202	213	202	195	226	204	212	
28	31086NH022	TCDS	MDF 30X1280X2240	Actuals Qty	121	129	167			40		248	167									
29	31086NH022	TCDS	MDF 30X1280X2240	Actuals Qty Adj.	121	129	167	101	88	121	156	143	248	167								
30	31086NH022	TCDS	MDF 30X1280X2240	Statistical Fcst Qty	58	97	103	179	228	99	167	126	86	59	72	75	85	94	67	80	74	
31	51416NH036	TCDC	MDF UL 18X1220X3050	Actuals Qty	27	2	24	39	12	46		58	7									
32	51416NH036	TCDC	MDF UL 18X1220X3050	Actuals Qty Adj.	87	99	76	43	25	46	48	72	58	7								
33	51416NH036	TCDC	MDF UL 18X1220X3050	Statistical Fcst Qty	52	71	80	17	31	68	36	46	78	41	45	46	38	36	46	45	47	

Figura 9.6: Interfaz de IBP en Excel.

Fuente: (IBP, 2022)

### Anexo 3


Este Anexo contiene mayor detalle de los resultados obtenidos al limpiar la historia de demanda. En los casos ilustrados en la Tabla 9.3 se observa que se logran suavizar los peaks de demanda y hay casos particulares como el producto 36514NH089 TCDC que la limpieza de historia difiere de las ventas siendo la primera superior, esto se debe a que cómo se ha comentado anteriormente las órdenes han sido mayores en los últimos periodos que las ventas lo que indica una falta de capacidad productiva o falta de inventario.

Todos los gráficos están en el horizonte comprendido por diciembre del 2019 hasta octubre del 2022.


**Tabla 9.3: Resultados de la Limpieza de Datos Históricos de Pronóstico.**

Fuente: Elaboración Propia.

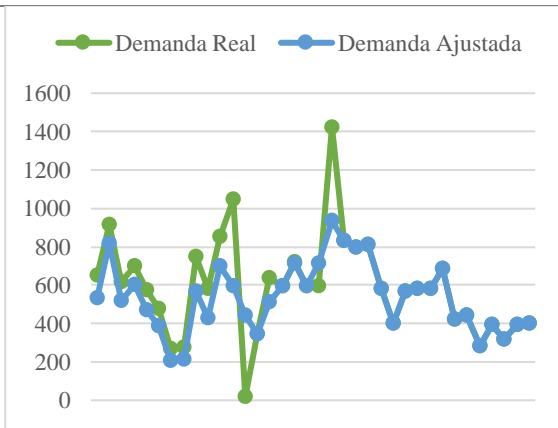
78708NH043 TCDS




78N25NH043 TCDS




79273NH037 TCDS



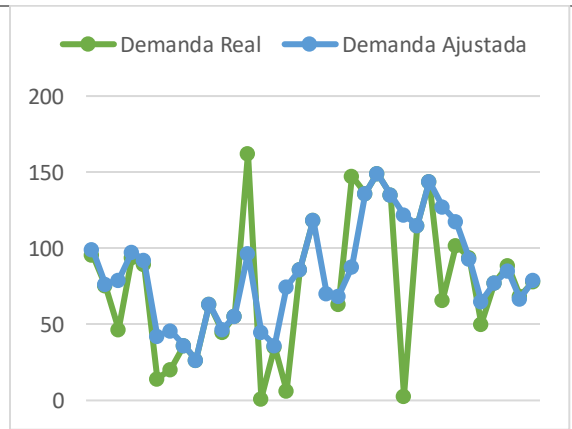
31416NH036 TCDS



78O57NH042 TCDC



78802NH037 TCDS



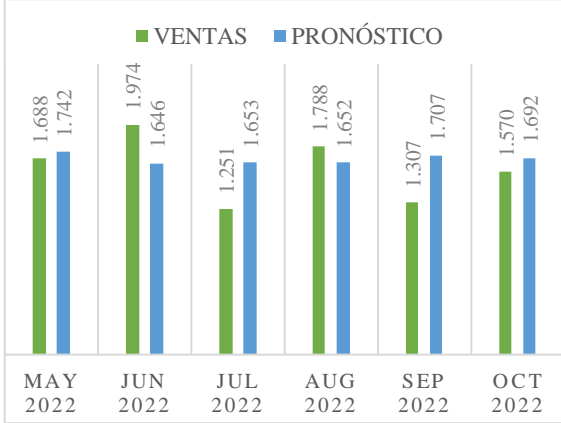
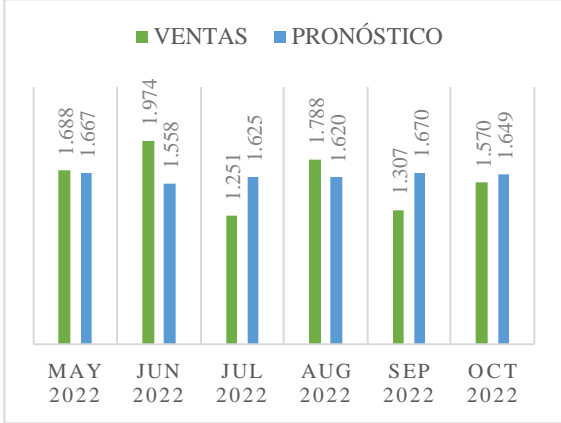
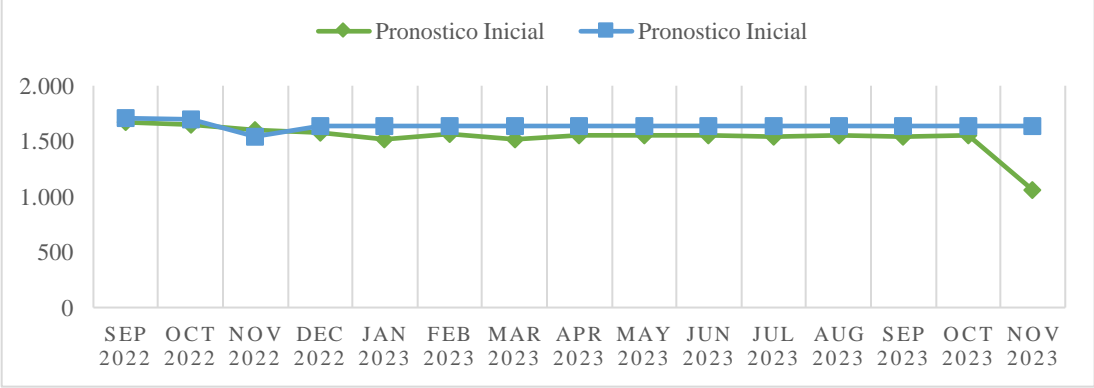
## Anexo 4

Este Anexo contiene los resultados relacionados a las comparaciones de pronósticos para una selección de productos y a nivel agregado para cada modelo propuesto y segmento (AA/A).

- Resultados Modelo 1.

**Tabla 9.4: Resultados Producto 78N25NH043 TCDS.**

Fuente: Elaboración Propia.


Código del Producto	78N25NH043 TCDS	78N25NH043 TCDS
Método Seleccionada	SED1 Modelo 1	SARIMA (0,1,1) (1,0,0) Modelo Inicial
Comparación de Pronóstico y Ventas Reales en los últimos 6 meses		
Proyección de Pronóstico		
Error MAPE	16%	16%

A continuación, la Tabla 9.5 y Tabla 9.6 contienen la comparación de los pronósticos a un nivel agregado, es decir, se suma toda la demanda de un mismo segmento por periodo de

tiempo. La Tabla 9.5 contiene los resultados para el segmento de productos AA y la Tabla 9.6 para productos del segmento A.

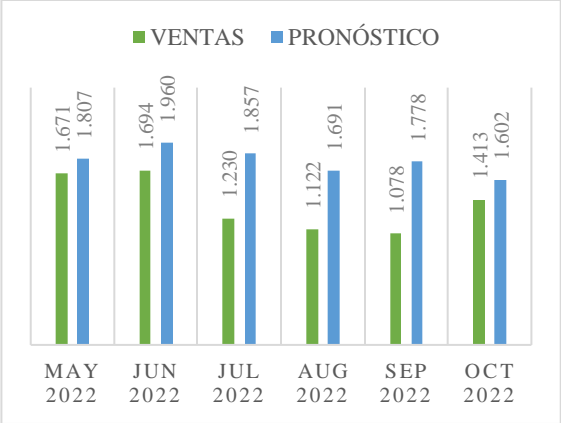
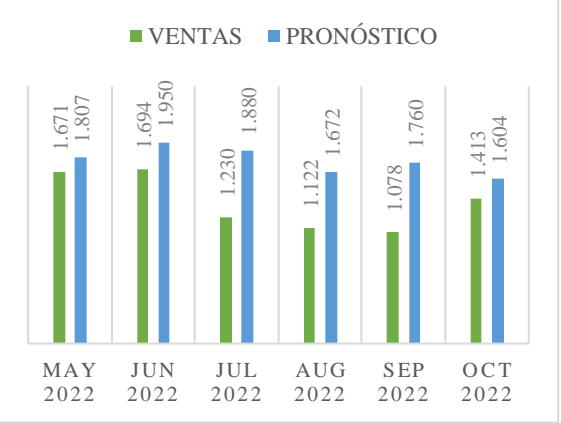
**Tabla 9.5: Resultados a Nivel Agregado Productos Continuos Segmento AA.**

Fuente: Elaboración Propia.



**Tabla 9.6: Resultados a Nivel Agregado Productos Continuos Segmento AA.**

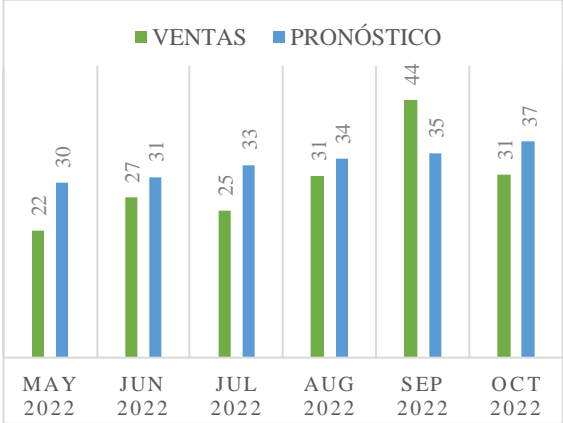
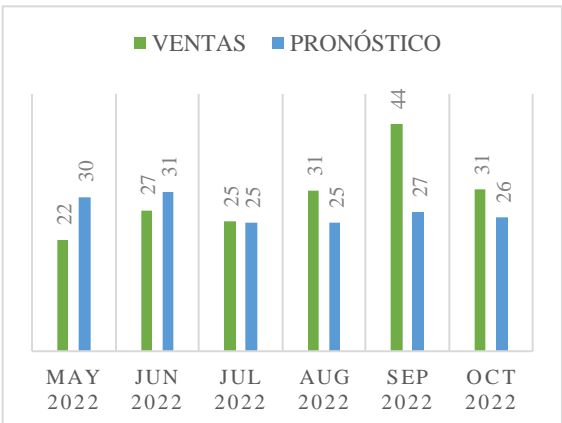
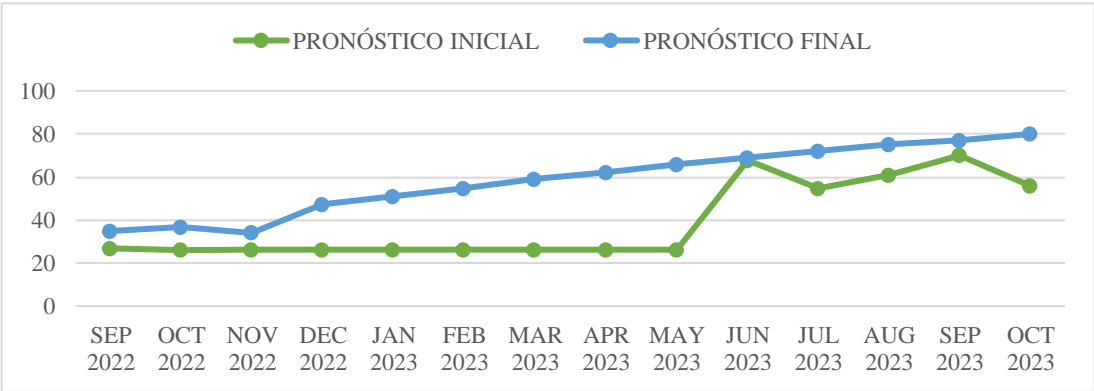
Fuente: Elaboración Propia.

Segmento	A	A
Comparación de Pronóstico y Ventas Reales en los últimos 6 meses	Pronóstico Agregado Modelo 1.	Pronóstico Agregado Inicial.
		
	Error MAPE	34%

▪ Resultados Modelo 2.

**Tabla 9.7: Resultados Producto 78D43NH037 TCDS.**

Fuente: Elaboración Propia.


Código del Producto	78D43NH037 TCDS	78D43NH037 TCDS
Método Seleccionada	SED2	SARIMA (0,0,1) (0,0,1)
	Pronóstico Modelo 2.	Pronóstico Modelo Inicial.
Comparación de Pronóstico y Ventas Reales en los últimos 6 meses		
Proyección de Pronóstico	<p>Comparación de Pronósticos.</p> 	
Error MAPE	22%	21%

A continuación, la Tabla 9.8 y Tabla 9.9 contienen la comparación de los pronósticos a un nivel agregado, es decir, se suma toda la demanda de un mismo segmento por periodo de tiempo. La Tabla 9.8 contiene los resultados para el segmento de productos AA y la Tabla 9.9 para productos del segmento A.




**Tabla 9.8: Resultados Nivel Agregado Productos con Tendencia Segmento AA.**

Fuente: Elaboración Propia.



**Tabla 9.9: Resultados Nivel Agregado Productos con Tendencia Segmento A.**

Fuente: Elaboración Propia.



▪ Resultados Modelo 3.

**Tabla 9.10: Resultados Producto 11995NH085 TCDC.**


Fuente: Elaboración Propia.

Código del Producto	11995NH085 TCDC	11995NH085 TCDC																																													
Método Seleccionada	SET4	SARIMA (0,0,0) (0,0,2)																																													
	Pronóstico Modelo 3.	Pronóstico Modelo Inicial.																																													
Comparación de Pronóstico y Ventas Reales en los últimos 6 meses	<table border="1"> <caption>Comparación de Pronóstico y Ventas Reales en los últimos 6 meses (Modelo 3)</caption> <thead> <tr> <th>Mes</th> <th>Ventas</th> <th>Pronóstico</th> </tr> </thead> <tbody> <tr> <td>MAY 2022</td> <td>346</td> <td>363</td> </tr> <tr> <td>JUN 2022</td> <td>204</td> <td>353</td> </tr> <tr> <td>JUL 2022</td> <td>177</td> <td>318</td> </tr> <tr> <td>AUG 2022</td> <td>149</td> <td>318</td> </tr> <tr> <td>SEP 2022</td> <td>159</td> <td>269</td> </tr> <tr> <td>OCT 2022</td> <td>217</td> <td>289</td> </tr> </tbody> </table>	Mes	Ventas	Pronóstico	MAY 2022	346	363	JUN 2022	204	353	JUL 2022	177	318	AUG 2022	149	318	SEP 2022	159	269	OCT 2022	217	289	<table border="1"> <caption>Comparación de Pronóstico y Ventas Reales en los últimos 6 meses (Modelo Inicial)</caption> <thead> <tr> <th>Mes</th> <th>Ventas</th> <th>Pronóstico</th> </tr> </thead> <tbody> <tr> <td>MAY 2022</td> <td>346</td> <td>362</td> </tr> <tr> <td>JUN 2022</td> <td>204</td> <td>423</td> </tr> <tr> <td>JUL 2022</td> <td>177</td> <td>637</td> </tr> <tr> <td>AUG 2022</td> <td>149</td> <td>536</td> </tr> <tr> <td>SEP 2022</td> <td>159</td> <td>599</td> </tr> <tr> <td>OCT 2022</td> <td>217</td> <td>869</td> </tr> </tbody> </table>	Mes	Ventas	Pronóstico	MAY 2022	346	362	JUN 2022	204	423	JUL 2022	177	637	AUG 2022	149	536	SEP 2022	159	599	OCT 2022	217	869			
Mes	Ventas	Pronóstico																																													
MAY 2022	346	363																																													
JUN 2022	204	353																																													
JUL 2022	177	318																																													
AUG 2022	149	318																																													
SEP 2022	159	269																																													
OCT 2022	217	289																																													
Mes	Ventas	Pronóstico																																													
MAY 2022	346	362																																													
JUN 2022	204	423																																													
JUL 2022	177	637																																													
AUG 2022	149	536																																													
SEP 2022	159	599																																													
OCT 2022	217	869																																													
Proyección de Pronóstico	<p>Comparación de Pronósticos.</p> <table border="1"> <caption>Comparación de Pronósticos</caption> <thead> <tr> <th>Mes</th> <th>Pronóstico Inicial</th> <th>Pronóstico Final</th> </tr> </thead> <tbody> <tr> <td>SEP 2022</td> <td>600</td> <td>280</td> </tr> <tr> <td>OCT 2022</td> <td>850</td> <td>300</td> </tr> <tr> <td>NOV 2022</td> <td>220</td> <td>250</td> </tr> <tr> <td>DEC 2022</td> <td>200</td> <td>250</td> </tr> <tr> <td>JAN 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>FEB 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>MAR 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>APR 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>MAY 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>JUN 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>JUL 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>AUG 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>SEP 2023</td> <td>200</td> <td>250</td> </tr> <tr> <td>OCT 2023</td> <td>200</td> <td>250</td> </tr> </tbody> </table>		Mes	Pronóstico Inicial	Pronóstico Final	SEP 2022	600	280	OCT 2022	850	300	NOV 2022	220	250	DEC 2022	200	250	JAN 2023	200	250	FEB 2023	200	250	MAR 2023	200	250	APR 2023	200	250	MAY 2023	200	250	JUN 2023	200	250	JUL 2023	200	250	AUG 2023	200	250	SEP 2023	200	250	OCT 2023	200	250
Mes	Pronóstico Inicial	Pronóstico Final																																													
SEP 2022	600	280																																													
OCT 2022	850	300																																													
NOV 2022	220	250																																													
DEC 2022	200	250																																													
JAN 2023	200	250																																													
FEB 2023	200	250																																													
MAR 2023	200	250																																													
APR 2023	200	250																																													
MAY 2023	200	250																																													
JUN 2023	200	250																																													
JUL 2023	200	250																																													
AUG 2023	200	250																																													
SEP 2023	200	250																																													
OCT 2023	200	250																																													
Error MAPE	62%	201%																																													

A continuación, la Tabla 9.11 y Tabla 9.12 contienen la comparación de los pronósticos a un nivel agregado, es decir, se suma toda la demanda de un mismo segmento por periodo de tiempo. La Tabla 9.11 contiene los resultados para el segmento de productos AA y la Tabla 9.12 para productos del segmento A.


**Tabla 9.11: Resultados Nivel Agregado Productos con Estacionalidad Segmento AA.**

Fuente: Elaboración Propia.



**Tabla 9.12: Resultados Nivel Agregado Productos con Estacionalidad Segmento A.**

Fuente: Elaboración Propia.



## Anexo 5

Este Anexo contiene una extensión de los resultados de las RLS y RLM obtenidas. Todas las regresiones lineales que contiene este Anexo son significativas. Además, se observan los resultados gráficos del ajuste de normalidad de residuos y el modelo ajustado con los intervalos de confianza e intervalos de pronóstico. Las gráficas son resultados de los softwares Statgraphics y Gretl.

### Resultados RLS.

En las siguientes tablas se encuentran los resultados complementarios en el que se observan las regresiones que son significativas para las variables explicativas IPC, IPP y P.

**Tabla 9.13: Resultados RLS Significativas con IPC.**

Fuente: Elaboración Propia a partir de resultados entregados por StatGraphics.


<b>78708NH043 TCDC</b>		
<b>Coefficientes</b>		
Mínimos	$\beta_0$	2.235
Cuadrados	$\beta_1$	698
Error Estándar	$\beta_0$	104
	$\beta_1$	387
Estadístico T	$\beta_0$	21,45
	$\beta_1$	1,80
Valor p	$\beta_0$	0,0000 ***
	$\beta_1$	0,0807 *
<b>ANOVA</b>		
Suma de Cuadrados	Modelo	634.410
	Residuo	6.654.750
	Total	7.289.160
Cuadrado Medio	Modelo	634.410
	Residuo	195.728
Estadístico F	Modelo	3,24
Valor p	Modelo	0,08*
	$r$	0,29
	$r^2$ ajustado	6,01%
	$s_{y,x}$	442
	Error absoluto medio	317
	Estadístico	1,28
	Durbin- Watson Estadístico	0,944
	Shapiro Wilks	
	Valor p	0,095

---


Producto: 78708NH043 TCDC  
Ajuste:  $D = 2235,48 + 697 \times IPC$

---

Ajuste de Modelo



Ajuste de Normalidad de Residuos.



**Tabla 9.14: Resultados RLS significativas IPP Parte 1.**

Fuente: Elaboración Propia a partir de resultados entregados por StatGraphics.

		12817NH085 TCDC	12817NH085 TCDS	31086NH022 TCDC	78708NH043 TCDC
<b>Coefficientes</b>					
Mínimos	$\beta_0$	-4.725	-1.484	-783	-8.025
Cuadrados	$\beta_1$	50	16	8	93
Error Estándar	$\beta_0$	2.098,51	681,41	296,01	2.512,60
	$\beta_1$	18,81	6,11	2,65	22,53
Estadístico T	$\beta_0$	-2,25	-2,17	-2,65	-3,19
	$\beta_1$	2,67	2,60	3,10	4,14
Valor p	$\beta_0$	0,0309**	0,0365**	0,0123**	0,0030***
	$\beta_1$	0,0115**	0,0134**	0,0038***	0,0002***
<b>ANOVA</b>					
Suma de Cuadrados	Modelo	710.226	71.322	19.064	2.441.050
	Residuo	3.381.810	356.563	67.287	4.848.110
	Total	4.092.030	427.885	86.351	7.289.160
Cuadrado Medio	Modelo	710.226	71.322	19.064	2.441.050
	Residuo	99.465	10.487	1.979	142.591
Estadístico F	Modelo	7,14	6,80	9,63	17,12
Valor p	Modelo	0,0115**	0,0134**	0,0038***	0,0002***
	$r^2$	17,35%	16,66%	22,07%	33,48%
	$r^2$ ajustado	14,92%	14,21%	19,78%	31,53%
	$s_{y,x}$	315	102	44	378
Error absoluto medio		267	77	36	281
Estadístico Durbin-Watson		0,83	0,86	1,27	2,07
Estadístico Shapiro Wilks		0,930	0,9388	0,9664	0,975
Valor p		0,031**	0,060*	0,418	0,6708


**Tabla 9.15: Resultados RLS significativas IPP Parte 2.**

Fuente: Elaboración Propia a partir de resultados entregados por StatGraphics.


		78708NH043 TCDS	79273NH037 TCDC	79293NH037 TCDS
<b>Coefficientes</b>				
Mínimos Cuadrados	$\beta_0$	2.561	-1.852	884
	$\beta_1$	-18	23	-6
Error Estándar	$\beta_0$	996,16	809,46	370,43
	$\beta_1$	8,93	7,26	3,32
Estadístico T	$\beta_0$	2,57	-2,29	2,39
	$\beta_1$	-2,00	3,14	-1,93
Valor p	$\beta_0$	0,0147**	0,0285**	0,0227**
	$\beta_1$	0,0541*	0,0035***	0,0620*
<b>ANOVA</b>				
Suma de Cuadrados	Modelo	89.209	146.198	11.539
	Residuo	762.048	503.175	105.374
	Total	851.256	649.373	116.913
Cuadrado Medio	Modelo	89.209	146.198	11.539
	Residuo	22.413	14.799	3.099
Estadístico F	Modelo	3,98	9,88	3,72
Valor p	Modelo	0,0541*	0,0035***	0,062*
	$r^2$	10,47%	22,51%	9,87%
	$r^2$ ajustado	7,84%	20,23%	7,22%
	$s_{y,x}$	150	122	56
Error absoluto medio		95	99	37
	Estadístico Durbin-Watson	1,97	2,36	1,51
	Estadístico Shapiro Wilks	0,772	0,934	0,874
	Valor p	0,00000069	0,0433	0,00051

Producto: 12817NH085 TCDC  
Ajuste:  $D = -4.725 + 50 \times IPP$

Ajuste de Modelo




Ajuste de Residuos




Producto: 12817NH085 TCDS  
Ajuste:  $D = -1.484 + 16 \times IPP$

Ajuste de Modelo




Ajuste de Residuos




Producto: 31086NH022 TCDC  
Ajuste:  $D = -783 + 8 \times IPP$

Ajuste de Modelo




Ajuste de Residuos.




Producto: 78708NH043 TCDC  
Ajuste:  $D = -8.025 + 93 \times IPP$



Ajuste de Modelo.




Ajuste de Residuos.




Producto: 78708NH043 TCDS  
Ajuste:  $D = 2.561 - 18 \times IPP$

Ajuste de Modelo.




Ajuste de Residuos.




Producto: 79273NH037 TCDC  
Ajuste:  $D = -1.852 + 23 \times IPP$

Ajuste de Modelo.




Ajuste de Residuos.




Producto: 79293NH037 TCDS  
Ajuste:  $D = 884 - 6 \times IPP$

Ajuste de Modelo



Ajuste de Residuos.



**Tabla 9.16: Resultados RLS Significativas P.**

Fuente: Elaboración Propia a partir de resultados entregados por StatGraphics.


		78935NH037 TCDC	79273NH037 TCDC
<b>Coefficientes</b>			
Mínimos	$\beta_0$	-258,68	2.166,97
Cuadrados	$\beta_1$	0,001	-0,006
Error Estándar	$\beta_0$	95	538
	$\beta_1$	0,0003	0,0023
Estadístico T	$\beta_0$	-2,73	4,03
	$\beta_1$	4,49	-2,74
Valor p	$\beta_0$	0,0098***	0,0003***
	$\beta_1$	0,0001***	0,0096***
<b>ANOVA</b>			
Suma de Cuadrados	Modelo	44.112	117.742
	Residuo	74.450	531.631
	Total	118.562	649.373
Cuadrado Medio	Modelo	44.112	117.742
	Residuo	2.190	15.636
Estadístico F	Modelo	20,15	7,53
Valor p	Modelo	0,0001***	0,0096***
	$r$	0,61	-0,43
	$r^2$ ajustado	35,35%	15,72%
	$s_{y,x}$	46,79	125,05
	Error absoluto medio	38,44	95,26
	Estadístico Durbin-Watson	1,60	1,82
	Estadístico Shapiro Wilks	0,964	0,9309
	Valor p	0,364	0,033**

---


Producto: 78935NH037 TCDC  
Ajuste:  $D = -258,6 + 0,001 \times P$

---

Ajuste de Modelo



Ajuste de Residuos.




---


Producto: 79273NH037 TCDC  
Ajuste:  $D = 2.166,9 - 0,006 \times P$

---

Ajuste de Modelo.



Ajuste de Residuos.



### Resultados RLM.

En las siguientes tablas se encuentran los resultados complementarios en el que se observan las regresiones que son significativas para las variables explicativas IPC, IPP y P.

**Tabla 9.17: Resultados RLM IPP e IPC.**


Fuente: Elaboración propia a partir de resultados obtenidos en Gretl.

		12817NH085 TCDC	12817NH085 TCDS
<b>Coefficientes</b>			
Mínimos Cuadrados	$\beta_0$	-5.522	-1770,31
	$\beta_1$	57	18,1868
	$\beta_2$	527	186
Desviación Típica	$\beta_0$	2.063,63	661,60
	$\beta_1$	18,41	5,90
	$\beta_2$	270,41	86,69
Estadístico T	$\beta_0$	-2,67	-2,67
	$\beta_1$	3,07	2,14
	$\beta_2$	1,91	3,08
Valor p	$\beta_0$	0,0115	0,0115
	$\beta_1$	0,0043	0,0394
	$\beta_2$	0,0646	0,0041
<b>ANOVA</b>			
Suma de Cuadrados	Modelo	1.047.490	114.952
	Residuo	3.044.540	312.932
	Total	4.092.030	427.885
Cuadrado Medio	Modelo	523.745	57.476
	Residuo	92.259	9.483
Estadístico F	Modelo	5,68	6,06
Valor p	Modelo	0,0076	0,0057
	$r^2$	25,59%	27%
	$r^2$ ajustado	21,08%	22%
Estadístico Prueba de Normalidad de Residuos		6,23	3,90
Valor p		0,0443045	0,14193
Estadístico Prueba de White		8,93	5,55
Valor p		0,111487	0,352
Valor de Inflación de Varianza (VIF)			
	IPP	1,033	1,033
	IPC	1,033	1,033


Producto: 12817NH085 TCDC

$$\text{Ajuste: } D = -5.522 + 57 \times \text{IPP} + 527 \times \text{IPC}$$

Ajuste Modelo




Ajuste Residuos.




Producto: 12817NH085 TCDS

$$\text{Ajuste: } D = -1.770 + 18 \times \text{IPP} + 186 \times \text{IPC}$$

Ajuste Modelo.



Ajuste Residuos.



**Tabla 9.18: Resultados RLM IPP y P.**


Fuente: Elaboración propia a partir de resultados obtenidos en Gretl.

		78935NH037 TCDC	79273NH037 TCDC
<b>Coefficientes</b>			
Mínimos Cuadrados	$\beta_0$	-1242,80	-1806,22
	$\beta_1$	11	25,7278
	$\beta_2$	0,00064	-0,00113802
Desviación Típica	$\beta_0$	284,68	782,52
	$\beta_1$	0,00	7,19
	$\beta_2$	270,41	0,000616
Estadístico T	$\beta_0$	-4,366	-2,308
	$\beta_1$	4,11	3,58
	$\beta_2$	2,87	-1,849
Valor p	$\beta_0$	0,0001	0,0274
	$\beta_1$	0,0002	0,0011
	$\beta_2$	0,0071	0,0735
<b>ANOVA</b>			
Suma de Cuadrados	Modelo	58.216	193.427
	Residuo	60.346	455.946
	Total	118.562	649.373
Cuadrado Medio	Modelo	29.108	96.714
	Residuo	92.259	13.817
Estadístico F	Modelo	15,92	7,00
Valor p	Modelo	0,000015	0,0029
	$r^2$	49,00%	30%
	$r^2$ ajustado	46,00%	26%
Estadístico Prueba de Normalidad de Residuos		0,17	5,201
Valor p		0,914085	0,0742159
Estadístico Prueba de White		6,84	8,52
Valor p		0,2323	0,1297
Valor de Inflación de Varianza (VIF)			
	IPP	1,051	1,051
	IPC	1,051	1,051


Producto: 78935NH037 TCDC

$$\text{Ajuste: } D = -1.242 + 11 \times \text{IPP} + 0,00064 \times P$$

Ajuste Modelo.




Ajuste Residuos.




Producto: 79273NH037 TCDC

$$\text{Ajuste: } D = -1.806 + 26 \times \text{IPP} - 0,0011 \times P$$

Ajuste Modelo



Ajuste Residuos.





**Tabla 9.19: Resultados RLM IPC, IPP y P.**


Fuente: Elaboración propia a partir de resultados obtenidos en Gretl.

		12817NH085 TCDC	12817NH085 TCDS
<b>Coefficientes</b>			
Mínimos Cuadrados	$\beta_0$	-5759,56	-1841,74
	$\beta_1$	685	236,625
	$\beta_2$	77	24,1959
	$\beta_3$	-0,0114926	-0,00345907
Desviación Típica	$\beta_0$	1.980,46	639,58
	$\beta_1$	272,51	88,00
	$\beta_2$	20,29	6,55
	$\beta_3$	0,01	0,00
Estadístico T	$\beta_0$	-2,908	-2,880
	$\beta_1$	2,52	2,69
	$\beta_2$	3,77	3,69
	$\beta_3$	-1,990	-1,855
Valor p	$\beta_0$	0,0066	0,0070
	$\beta_1$	0,0171	0,0113
	$\beta_2$	0,0007	0,0008
	$\beta_3$	0,0552	0,0729
<b>ANOVA</b>			
Suma de Cuadrados	Modelo	0,00000138	145.327
	Residuo	0,00000271	282.558
	Total	0,00000409	427.885
Cuadrado Medio	Modelo	460.928	48.442
	Residuo	84.664	8.830
Estadístico F	Modelo	5,44	7,00
Valor p	Modelo	0,003900	0,0037
	$r^2$	34%	34%
	$r^2$ ajustado	28%	28%
Estadístico Prueba de Normalidad de Residuos		6,126	5,933
	Valor p	0,046732	0,051
Estadístico Prueba de White		12,44	7,68
	Valor p	0,189376	0,566
Valor de Inflación de Varianza (VIF)			
	IPC	1,143	1,143
	IPP	1,367	1,367
	P	1,376	1,376


Producto: 12817NH085 TCDC

$$\text{Ajuste: } D = -5.759 + 685 \times \text{IPC} + 77 \times \text{IPP} - 0,01149 \times P$$

Ajuste Modelo



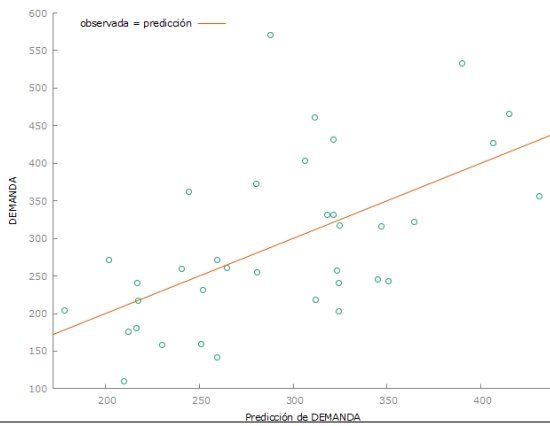
Ajuste Residuos.




Producto: 12817NH085 TCDC

$$\text{Ajuste: } D = -1.841 + 236 \times \text{IPC} + 24 \times \text{IPP} - 0,00345 \times P$$

Ajuste Modelo.



Ajuste Residuos.



## Anexo 6

Este Anexo contiene la comparación de los errores MAPE del periodo comprendido entre mayo 2022 hasta octubre del 2022 para distintos niveles de análisis.

En primer lugar, se observan a un nivel agregado, agrupando la demanda sin segmentar según contribución, luego se expone la comparación para cada segmento.

El inicial corresponde al MAPE que se estima al ejecutar el modelo inicial que posee la empresa, por otra parte, el final se estima con la demanda proyectada utilizando la segmentación por comportamiento, es decir, los tres modelos propuestos.

**Tabla 9.20: Comparación Error MAPE a Nivel General.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	17%	27%
JUN 2022	32%	27%
JUL 2022	84%	67%
AUG 2022	55%	41%
SEP 2022	69%	39%
OCT 2022	66%	29%

**Tabla 9.21: Comparación Error MAPE Segmento AA.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	35%	35%
JUN 2022	40%	35%
JUL 2022	81%	74%
AUG 2022	38%	36%
SEP 2022	38%	28%
OCT 2022	40%	29%

**Tabla 9.22: Comparación Error MAPE Segmento A.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	11%	10%
JUN 2022	13%	13%
JUL 2022	63%	52%
AUG 2022	55%	53%
SEP 2022	82%	69%
OCT 2022	48%	31%

Luego, se realiza esta comparación para cada segmento y comportamiento.

**Tabla 9.23: Comparación de Error MAPE Segmento AA, Series de Tiempo Continuas.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	38%	50%
JUN 2022	31%	25%
JUL 2022	100%	67%
AUG 2022	50%	17%
SEP 2022	67%	26%
OCT 2022	51%	15%

**Tabla 9.24: Comparación de Error MAPE Segmento A, Series de Tiempo Continuas.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	8%	8%
JUN 2022	15%	16%
JUL 2022	53%	51%
AUG 2022	49%	51%
SEP 2022	63%	65%
OCT 2022	13%	13%

**Tabla 9.25: Comparación Error MAPE Segmento AA, Series de Tiempo con Tendencia.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	3%	49%
JUN 2022	84%	93%
JUL 2022	124%	137%
AUG 2022	162%	168%
SEP 2022	148%	99%
OCT 2022	353%	171%

**Tabla 9.26: Comparación Error MAPE Segmento A, Series de Tiempo con Tendencia.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	15%	12%
JUN 2022	10%	21%
JUL 2022	28%	24%
AUG 2022	82%	107%
SEP 2022	85%	74%
OCT 2022	24%	48%

**Tabla 9.27: Comparación Error MAPE Segmento AA, Series de Tiempo con Estacionalidad.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	7%	7%
JUN 2022	44%	28%
JUL 2022	76%	57%
AUG 2022	28%	21%
SEP 2022	31%	6%
OCT 2022	49%	18%

**Tabla 9.28: Comparación Error MAPE Segmento A, Series de Tiempo con Estacionalidad.**

Fuente: Elaboración Propia.

	<b>INICIAL</b>	<b>FINAL</b>
MAY 2022	12%	12%
JUN 2022	13%	6%
JUL 2022	101%	72%
AUG 2022	53%	38%
SEP 2022	103%	71%
OCT 2022	108%	47%

**UNIVERSIDAD DE CONCEPCIÓN – FACULTAD DE INGENIERIA**  
**RESUMEN DE MEMORIA DE TITULO**

<b>Departamento</b>	: Departamento de Ingeniería Industrial.
<b>Carrera</b>	: Ingeniería Civil Industrial.
<b>Nombre del memorista</b>	: Isidora Carolina Morales Villalobos.
<b>Título de la memoria</b>	: Análisis y selección de métodos para pronosticar la demanda de tableros en el mercado nacional de Masisa S.A.
<b>Fecha de la presentación oral</b>	: 24 de enero 2023.
<b>Profesor(es) Guía</b>	: Hernaldo Reinoso Alarcón.
<b>Profesor(es) Revisor(es)</b>	: Alejandro Andafalt Chacur.
<b>Concepto</b>	:
<b>Calificación</b>	:

<b>Resumen</b>
<p>MASISA S.A. es una empresa dedicada a la producción y comercialización de tableros de madera, molduras, entre otros. Actualmente, los pronósticos de demanda no son los deseados, puesto que las proyecciones son poco realistas y el error MAPE que poseen es de 54%, por lo que ha surgido la necesidad de disminuirlo.</p> <p>Se busca mejorar estos ajustes de pronóstico mediante la evaluación de métodos y su validación en el sistema utilizado por la empresa IBP.</p> <p>Para ello, se realizó una segmentación de la demanda por su componente sistemática y se proponen tres modelos, con el fin de utilizarlos según el comportamiento que posea la serie de tiempo.</p> <p>Por otra parte, se observó el efecto de tres variables independientes (Índice de Precio del Productor (IPP), Índice de Precio del Consumidor (IPC) y el Precio de los productos (P)) en la demanda utilizando regresiones lineales. Se infiere que la variabilidad del IPP genera un efecto en la variabilidad de la demanda.</p>

