



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Implementación de un método para el pronóstico de demanda de computadores portátiles

Karen Briyith Garavito Vélez

Universidad Nacional de Colombia
Facultad de Ingeniería, Ingeniería Industrial
Bogotá, Colombia

2021

Implementación de un método para el pronóstico de demanda de computadores portátiles

Karen Briyith Garavito Vélez

Trabajo presentado como requisito parcial para optar al título de:
Magister en Ingeniería Industrial

Director (a):
Ph.D., Gustavo Alfredo Bula

Línea de Investigación:
Gestión de operaciones

Universidad Nacional de Colombia
Facultad de Ingeniería, Ingeniería Industrial
Bogotá, Colombia

2021

All models are wrong, some are useful

*George Edward Pelham Box – British
statistician*

Declaración de obra original

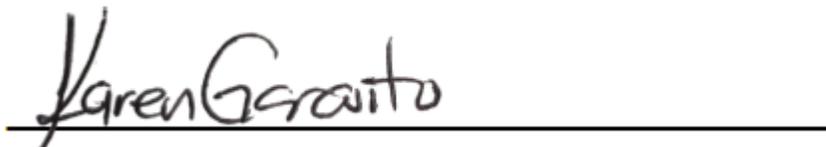
Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.

A handwritten signature in black ink that reads "Karen Garavito". The signature is written in a cursive style and is positioned above a solid horizontal line that spans the width of the signature.

Karen Garavito Vélez

Fecha 07/04/2021

Agradecimientos

Un agradecimiento especial a mi tutor y maestro Gustavo Bula quien con su conocimiento me dio visibilidad del enfoque práctico que se debe tener para generar impacto en la compañía, apoyado en la teoría pero buscando la ejecución acorde a la realidad del negocio. También un profundo agradecimiento al CEO de la compañía, Peter Arman Ostroske quien apoyó con su conocimiento de la industria y el acceso a la información para lograr un análisis detallado.

Resumen

Implementación de un método para el pronóstico de demanda de computadores portátiles.

En la búsqueda de las empresas por aumentar su rentabilidad y ofrecer un nivel de servicio adecuado se implementan herramientas para lograr ese objetivo. En este trabajo se hace uso de la implementación del modelo con enfoque jerárquico propuesto por Radim Lenort Petr Besta en el año 2013 para construir el pronóstico de la demanda de los productos de la categoría hardware línea computador portátil para una compañía comercializadora con modelo de negocio B2B (business to business/empresa a empresa). En el proceso de implementación se realiza previamente una depuración de los datos y se genera el pronóstico de la demanda agregada por subcategoría y por línea con el modelo ARIMA, luego se implementa el modelo con enfoque jerárquico para obtener desagregación del pronóstico de la demanda para la línea de computadores portátiles en función de las proporciones históricas. El trabajo se divide en dos fases. En la primera fase se lleva a cabo una revisión sistemática de la literatura para identificar los modelos que han sido usados en la construcción de predicciones de la demanda de productos similares en mercados semejantes al colombiano y en la segunda fase se implementa el modelo con los datos de la empresa en estudio y se analizan los resultados.

Al verificar las investigaciones de la industria en estudio la mayoría se enfocan en los eslabones de fabricante y mayorista, a medida que se va en la cadena de suministro aguas abajo se identifica un cambio en el comportamiento de la demanda para el eslabón distribuidor gracias a la cantidad de empresas, el tipo de cliente y el manejo del sistema de inventario *pull*. Se identifica el modelo propuesto por Lenort en la industria de moda como homóloga a la industria en estudio en su comportamiento de demanda para el eslabón distribuidor. Varios estudios en la industria moda se enfocan en redes neuronales haciendo frecuente precisión en el requerimiento de gran cantidad de datos. La industria

de alta tecnología se caracteriza por ciclos de vida cortos lo que limita la cantidad de datos históricos. Se considera que los modelos de redes neuronales son de difícil implementación en la práctica diaria por los recursos requeridos para el entrenamiento de las redes y la elección de los parámetros.

El enfoque busca tener un impacto en la facilidad de adopción y la implementación del modelo propuesto y generar eficiencia en los costos ocultos de mantenimiento de inventario, orientados a: depreciación por obsolescencia, tasas de interés por apalancamiento de capital y costos de oportunidad. Con la implementación del modelo propuesto se obtiene un ahorro de \$306 millones anuales en los costos ocultos de mantenimiento de inventario relacionados. De los \$306 millones, \$296 millones se obtienen de la limpieza de los datos y \$10 millones por el cambio en el uso del modelo promedio móvil simple al modelo ARIMA con posterior implementación del modelo con enfoque jerárquico.

Palabras clave: (pronóstico, previsión, hardware, alta tecnología, demanda, portátil).

Abstract

Model implementation for laptops forecasting.

In the search of companies to increase their profitability and offer an adequate level of service, tools are implemented to achieve this objective. In this search, the implementation of the model with a hierarchical approach proposed by Radim Lenort Petr Besta in 2013 is used to build the forecast of demand for the products of the category hardware laptop line for a retailer company with a B2B business model (business to business / business to business). In the implementation process a data refinement is previously performed and the forecast of aggregate demand is generated by subcategory and by line with the ARIMA model, then the model is implemented with a hierarchical approach to obtain a breakdown of the demand forecast for the laptop line based on historical proportions. The work is divided into two phases. In the first phase, a systematic literature review to identify the models that have been used in the construction of predictions of the demand for similar products in markets similar to Colombia, and in the second phase the model is implemented with data from the company and the results are analyzed.

When verifying the state of the art of the industry under study, most of them focus on the manufacturer and wholesaler links, as one goes in the downstream supply chain a change in the behavior of demand for the distributor link is identified by the quantity of companies, the type of client and the management of the pull inventory system. The model proposed by Lenort in the fashion industry is identified as homologous to the high-tech industry by the behavior of demand for the distributor link. Several studies in the fashion industry focus on neural networks making precision in the requirement of large amounts of data. The high-tech industry is characterized by short life cycles, which limits the amount of historical data.

Neural network models are considered as difficult to implement in daily practice due to the resources required for the training of the networks and the choice of parameters.

The approach seeks to have an impact on the ease of adoption and implementation of the proposed model and generate efficiency in the hidden costs of inventory maintenance by depreciation due to obsolescence, interest rates due to capital leverage and opportunity costs. With the implementation of the proposed model, savings of \$ 306 million per year are obtained in related hidden inventory maintenance costs. Of the \$ 306 million, \$ 296 million are by the data cleaning and \$ 10 million by the change in the use of the simple moving average model to the ARIMA model with subsequent implementation of the model with a hierarchical process.

Keywords: (Forecasting, forecast, hardware, laptop, high-tech, demand)

Este Trabajo Final de maestría fue calificado en junio de 2021 por los siguientes evaluadores:

Jair Eduardo Rocha González Msc.
Profesor Departamento de Ingeniería de Sistemas e Industrial
Facultad de Ingeniería
Universidad Nacional de Colombia

Carlos Eduardo Moreno Mantilla PhD.
Profesor Departamento de Ingeniería de Sistemas e Industrial
Facultad de Ingeniería
Universidad Nacional de Colombia

Contenido

	Pág.
1. Introducción	19
1.1 Definición del problema	19
1.2 Objetivo general y objetivos específicos	28
1.2.1 Objetivo General.....	28
1.2.2 Objetivos Específicos.....	28
2. Estado del arte.....	29
2.1 Comportamiento de la demanda en la industria de la alta tecnología	29
2.1.1 Fabricante de productos electrónicos	33
2.1.2 Mayoristas como distribuidores autorizados de los fabricantes.....	34
2.1.3 Canales como vendedores de los productos al usuario final.....	34
2.2 Modelos de pronóstico usados en la industria de alta tecnología o industrias con comportamientos de demanda análogos.	38
2.2.1 Series de tiempo.....	44
2.2.1 Medidas de desempeño para el pronóstico de la demanda	46
2.3 Selección del modelo a implementar	47
2.3.1 Modelo propuesto por Radim Lenort Petr Besta	49
2.3.2 Modelo propuesto por Kejia Hu.....	52
3. Implementación de los modelos seleccionados	55
3.1 Recopilación de los datos.....	55
3.2 Limpieza de los datos e identificación de los valores atípicos.	59
3.3 Identificación de los grupos de productos.....	64
3.4 Análisis del comportamiento de la serie de tiempo y la selección de los parámetros para la implementación del modelo ARIMA.....	66
3.5 Implementación del modelo ARIMA e implementación del modelo jerarquía propuesto por Radim Lenort Petr Besta	70
3.6 Implementación del modelo por curvas de ciclo de vida propuesto por Kejia Hu 72	72
4. Análisis de resultados	79
5. Conclusiones y recomendaciones.....	105
5.1 Conclusiones.....	105
5.2 Recomendaciones.....	107

Lista de figuras

	Pág.
Figura 1-1: Participación por categoría de ventas en pesos.	23
Figura 1-2: Participación por subcategoría H Computadores & Tablets de ventas en pesos.	23
Figura 1-3: Pronóstico de la demanda en unidades por trimestre por año con el modelo usado actualmente por la compañía, promedio móvil.	26
Figura 2-1: Clasificación de los modelos de pronóstico en el contexto industrial.	41
Figura 2-2: Serie de tiempo unidades vendidas subcategoría H Computadores & Tablets.	45
Figura 2-3: Juicio de una escala de precisión del pronóstico desarrollada por Lewis	47
Figura 2-4: Fases a desarrollar.....	51
Figura 3-1: Proceso propuesto para identificar si la venta corresponde a una licitación y el causal de las devoluciones.	58
Figura 3-2: Proceso propuesto para la creación de un stock keeping unit (SKU).....	58
Figura 3-3: Proceso realizado para la depuración de los datos	64
Figura 3-4: Función autocorrelación serie de tiempo demanda subcategoría “H Computadores & Tablets”.	67
Figura 3-5: Función autocorrelación parcial serie de tiempo demanda subcategoría “H Computadores & Tablets”.....	68
Figura 3-6: Resultado test Fuller Aumentada (ADF) serie de tiempo demanda subcategoría H Computadores & Tablets.....	69
Figura 3-7: Comportamiento de ventas en el ciclo de vida de los productos con procesador AMD	73
Figura 3-8: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel core i3.....	74
Figura 3-9: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel core i5.....	74
Figura 3-10: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel core i7.....	75
Figura 3-11: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel celeron o pentium	75
Figura 3-12: Proceso para la implementación del modelo ARIMA y modelo con enfoque jerárquico	77
Figura 4-1: Pronóstico de la demanda para la subcategoría “H Computadores & Tablets” con ARIMA (1,1,0).....	82

Figura 4-2:	Pronóstico de la demanda para la subcategoría “H Computadores & Tablets” con ARIMA (0,1,1)	83
Figura 4-3:	Pronóstico de la demanda para la subcategoría “H Computadores & Tablets” con promedio móvil.....	85
Figura 4-4:	Pronóstico de la demanda de la línea computadores portátiles con modelo ARIMA.	86
Figura 4-5:	Pronóstico de la demanda de la línea computadores portátiles con promedio móvil simple.....	87
Figura 4-6:	Serie de tiempo con datos de todas las categorías sin depuración de la base de datos de ventas.	88
Figura 4-7:	Pronóstico con datos de todas las categorías sin depuración promedio móvil simple.	97
Figura 4-8:	Pronóstico de la demanda implementando modelo con enfoque jerárquico y ARIMA con limpieza de datos a la línea computadores portátiles de la subcategoría H computadores & Tablets.....	102
Figura 4-9:	Pronóstico de la demanda implementando modelo con enfoque jerárquico y promedio móvil sin limpieza de datos a la línea computadores portátiles de la subcategoría H computadores & Tablets.....	102

Lista de tablas

	Pág.
Tabla 1-1: Pronóstico de la demanda con el modelo usado actualmente por la compañía, promedio móvil.	25
Tabla 3-1: Ejemplo de un informe con los campos requeridos en Netsuite	59
Tabla 3-2: Clúster identificados acorde a las características de los artículos para realizar el pronóstico por curvas de ciclo de vida.....	66
Tabla 3-3: Criterio Akaike serie de tiempo demanda subcategoría “H Computadores & Tablets”.....	69
Tabla 4-1: Resultados Modelo ARIMA (1,1,0).....	80
Tabla 4-2: Interpretación resultados modelo ARIMA (1,1,0).....	81
Tabla 4-3: Datos ventas versus pronóstico resultado modelo ARIMA (1,1,0).....	84
Tabla 4-4: Ventas por año de todas las categorías de la compañía con y sin limpieza de los datos.	91
Tabla 4-5: Pronóstico implementando promedio móvil simple con los datos de demanda proyectados para todas las categorías de la compañía posterior limpieza e identificación de valores atípicos.	92
Tabla 4-6: Ahorro pronóstico promedio móvil simple con y sin depuración de datos.....	93
Tabla 4-7: Diferencia en los datos de ventas para la subcategoría “H Computadores & Tablets” por la depuración de los datos.....	94
Tabla 4-8: Medidas de desempeño pronóstico ARIMA y promedio móvil simple con depuración de datos.....	95
Tabla 4-9: Ahorro implementado ARIMA con respecto a promedio móvil simple	96
Tabla 4-10: Medidas de desempeño implementando el modelo promedio móvil y el modelo con enfoque jerárquico.	99
Tabla 4-11: Pronóstico implementando el modelo ARIMA y el modelo con enfoque jerárquico.	101
Tabla 4-12: Medidas de desempeño implementando modelo con enfoque jerárquico y promedio móvil sin limpieza de datos versus ARIMA con limpieza de datos a la línea computadores portátiles de la subcategoría H computadores & Tablets.	101

1.Introducción

Las organizaciones están constantemente investigando la implementación de modelos o bien herramientas que aumenten la eficiencia operativa, comercial y financiera (V. S. Lin, 2018; Puneeth Kumar et al., 2018; Wilck IV et al., 2014). Una de las áreas de trabajo es la gestión de la cadena de suministro y dentro de esta la previsión de la demanda (Fildes et al., 2008; Srinivasan et al., 2005; Valencia-Cárdenas et al., 2015). Un correcto análisis y desempeño de esta tarea puede preparar a las empresas para afrontar cambios drásticos en el consumo de los clientes, competencia, precios del mercado y otros aspectos (Fildes et al., 2008; Srinivasan et al., 2005; Valencia-Cárdenas et al., 2015).

1.1 Definición del problema

El pronóstico se interpreta como una estimación de un evento futuro con datos pasados que se analizan para establecer tendencias subyacentes (Agostino et al., 2020; Fildes et al., 2008). El análisis de los datos históricos se encuentra entre los problemas más importantes que enfrentan los profesionales en muchos campos (Montgomery et al., 2016). Los pronósticos de la demanda forman la base para la planificación de la cadena de suministro, permite a los gerentes ser proactivos proyectando recursos financieros, técnicos, tecnológicos, humanos, capacidad y calendarios de producción, precios, promociones, capacidades de distribución, tiempos y ciclos, entre otros (Puneeth Kumar et al., 2018; Ren et al., 2020; Valencia-Cárdenas et al., 2015).

Los sistemas de producción y almacenamiento pueden clasificarse acorde a su respuesta a la demanda: anticipando la demanda del cliente, comúnmente conocido como MTS (make to stock/ hecho para almacenar) o en respuesta a la demanda del cliente, conocido como MTO (make to order/ hecho bajo orden) (Sunil Chopra, 2010). La mayor diferencia entre los sistemas MTS y MTO es que en el primero existe una planificación de la cantidad a producir o vender y en el proceso MTO no (Olhager, 2012). En el proceso MTO solamente

hay producción hasta que el cliente confirma su compra. Sin embargo, tanto en el sistema MTS como en el sistema MTO el primer paso es pronosticar cuál será la demanda del cliente. Por ejemplo, HP (Hewlett Packard) fabricante de artículos de tecnología, compra componentes de computadores con anticipación a los pedidos de los clientes pero el ensamble lo realiza en respuesta a los pedidos de los clientes, utilizando el pronóstico de la demanda para la compra de los componentes y para planificar la capacidad de su planta. Los fabricantes de procesadores y sus proveedores también requieren conocer la cantidad proyectada de venta para planificar sus recursos a pesar de trabajar la entrega de los pedidos a sus clientes bajo el sistema MTO (Tandon et al., 2013).

Los productos de alta tecnología poseen ciclos de vida cortos que generalmente oscilan entre los 3 y 24 meses (Trappey & Wu, 2008; Zhu & Thonemann, 2004), durante este periodo de tiempo se presentan diferentes etapas que requieren planificación en detalle sobre las expectativas de venta para asegurar máxima reducción en los niveles de productos obsoletos (Basallo-Triana et al., 2017). En la primera etapa denominada etapa de aceleración no se conoce con certeza cuál será el patrón del ciclo de vida (Aitken et al., 2003). Posteriormente en la segunda etapa denominada etapa de madurez, después de un lapso de tiempo de demanda lenta se da un aumento en la cantidad vendida con alta incertidumbre sobre el momento en el que el aumento ocurre (Helo, 2004). En la tercera etapa, cuando los productos van a ser reemplazados por nuevas generaciones los fabricantes planifican con antelación la salida del mercado generando una reducción en la producción antes de que se pueda observar una disminución en las ventas. La culminación en la fabricación de cada referencia trae consigo una reducción en los precios por el ingreso de la referencia sustituta, esto trae como consecuencia que algunos clientes pueden querer comprar los artículos por precios más bajos aumentando la demanda. La exigencia de planificación y control de producción durante cada etapa hace que la precisión de la estimación en la cantidad a vender disminuya cuanto más largo es el horizonte de tiempo. La cadena de valor de esta industria enfrenta altos desafíos ante esta incertidumbre en la demanda y por ello crear los pronósticos es de alta importancia.

Cada vez que se construye un pronóstico con un modelo determinado se debe medir el desempeño, si algo no se mide no es posible realizar un seguimiento del comportamiento y definir acciones de mejora, de modo que, siempre es conveniente definir métricas adecuadas y monitorearlas. Las métricas permiten determinar acorde a los parámetros

asignados por cada compañía si se tiene un buen o mal rendimiento del modelo de pronóstico usado. En los pronósticos de la demanda normalmente el resultado de la métrica del desempeño del modelo se obtiene de dos variables principales, la cantidad proyectada y la cantidad real vendida en un periodo de tiempo t . La diferencia en estas variables tiene impactos en los niveles de inventario, capacidad y tiempos de respuesta. Mantener un inventario alto, excesos de capacidad y tiempos de entrega sobreestimados proporcionan un amortiguador para reaccionar ante la variabilidad y satisfacer la demanda en cualquier momento, sin embargo puede dar lugar a un exceso de existencias. El exceso de existencias genera problemas como: capital inmovilizado, depreciación de inventario, productos obsoletos y márgenes reducidos (Basallo-Triana et al., 2017; Lu, 2014).

Si los niveles de inventario bajos son resultado de un modelo de pronóstico con mal desempeño o un sistema de control de inventario inadecuado se tienen impactos negativos en la reducción de ingresos por ventas perdidas, insatisfacción de clientes y disminución en participación de mercado, dando lugar para que las unidades de los productos pertenecientes al segmento que no fue cubierto sea satisfecho por la competencia (Cho & Daim, 2013; Donkor et al., 2012; Kaytez et al., 2015). El no tener el producto disponible en el momento que el consumidor lo requiere genera a largo plazo pérdida del cliente o un alto porcentaje de rescisión para aquellos casos en los que la competencia es capaz de surtir las órdenes a tiempo, completas, con alta calidad y buena atención al cliente (Nenni et al., 2013; Wong & Guo, 2010). Tanto los altos niveles de inventario, como los bajos, dados por un pronóstico de la demanda ineficiente son una señal de que algo no es óptimo en la cadena de suministro. Los niveles de inventario altos aumentan los costos de mantener y los niveles bajos el riesgo de no poder responder a la demanda. Por ello, vale la pena contemplar diferentes estrategias para mantener el servicio y la utilidad en un nivel adecuado.

En la industria de la alta tecnología el tener productos obsoletos es particularmente costoso debido a los precios del producto y los cortos ciclos de vida (Chanda & Aggarwal, 2014; Kurawarwala & Matsuo, 1996; Wagner, 2008). Por ejemplo, hasta el año 2005, el grupo de redes ópticas de Cisco incurrió en gastos de inventario por exceso y obsolescencia de alrededor de US \$ 13 millones por año. Al mismo tiempo, la empresa se enfrentaba a un gran error de pronóstico de la demanda (en algunos casos superó el 1,000 por ciento) y retrasos en el cumplimiento de los pedidos de los clientes (Simchi-levi, 2005).

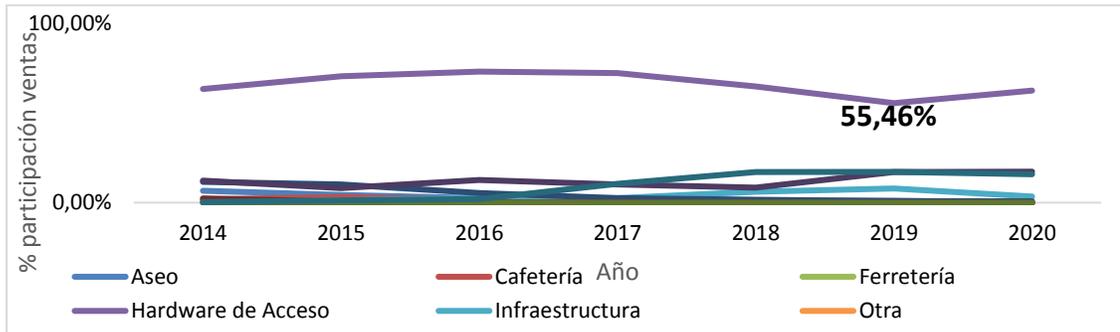
Detrás de cada innovación en todas las industrias hay una cadena de suministro que requiere una gestión de materias primas, piezas y productos terminados a través de un proceso de fabricación, abastecimiento y distribución. En la industria de la alta tecnología por la ubicación de las fábricas tanto de productores de equipos como de componentes se requiere un proceso complejo e internacional que representa desafíos para mantener el abastecimiento en los niveles adecuados en todos los países. La cadena de suministro de la industria de la alta tecnología es fundamental para la competitividad y la transformación mundial por el manejo de dispositivos como computadores, teléfonos inteligentes, tabletas o hardware en general.

La cadena de suministro de la industria de la alta tecnología se compone de cinco actores principales (Kou & Lee, 2015): 1.) los fabricantes de componentes (ejemplo: Accton o Intel), 2.) los diseñadores, desarrolladores y fabricantes de productos electrónicos (ejemplos: Hewlett Packard/Lenovo), 3.) los mayoristas como distribuidores autorizados de los fabricantes (ejemplos: Ingram Micro/Nexsys), 4.) los minoristas como vendedores de los productos al usuario final (ejemplo: OFIcomco), y 5.) las empresas como usuario final que hacen uso de los productos electrónicos para sus fines corporativos. Cada actor con ubicación y distribución o recepción en cualquier parte del mundo. Las compañías comercializadoras minoristas son el antepenúltimo eslabón de la cadena de suministro de la industria de la alta tecnología, lo que conlleva un mayor conocimiento de la demanda del usuario final y una responsabilidad de transmisión de información de consumo correcta a lo largo de los otros entes de la cadena para optimizar los procesos. El tener desviaciones en la estimación de la demanda futura en el eslabón del distribuidor minorista conlleva una variación adicional en cada participante de la cadena de suministro aguas arriba generando un “efecto látigo” que corresponde a la distorsión de la demanda transmitida por una proyección errónea en cada actor, la distorsión se va “acumulando” en cada eslabón desde el minorista hasta el fabricante de componentes exigiendo un mantenimiento de inventario extra para cubrir los cambios en la demanda (Puneeth Kumar et al., 2018).

La empresa en estudio es una compañía minorista con enfoque B2B (business to business/empresa a empresa) dedicada a la comercialización de tecnología en cinco categorías principales: hardware, software, consumibles, infraestructura y soluciones y servicios. La categoría “Hardware de Acceso” representa aproximadamente el 60% de sus

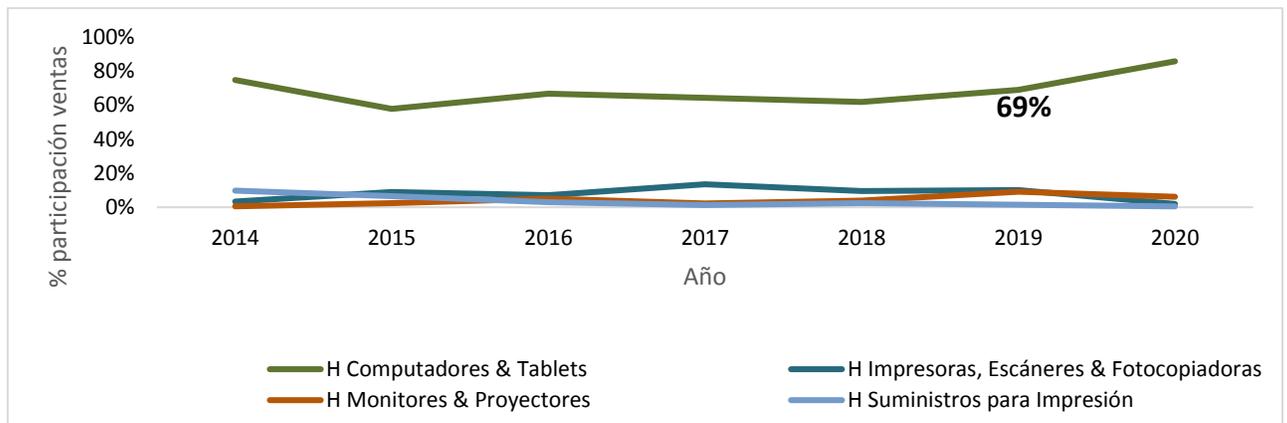
ventas en pesos colombianos (ver figura 1-1) en el que se refleja un 60% de participación de la subcategoría “H Computadores & Tablets” (ver figura 1-2). En el presente estudio nos enfocaremos únicamente en el análisis de esta subcategoría.

Figura 1-1: Participación por categoría de ventas en pesos.



Gráfica elaboración propia a partir de la base de datos de la compañía en estudio.

Figura 1-2: Participación por subcategoría H Computadores & Tablets de ventas en pesos.



Gráfica elaboración propia a partir de la base de datos de la compañía en estudio.

Cada área de la compañía cuenta con unos indicadores clave para la medición de su desempeño, ejemplo de los indicadores del área de operaciones son: rotación de inventario y exactitud de pronóstico. Este último indicador junto con los pronósticos de la demanda tanto de ventas como de operaciones y los costos proyectados por área son los parámetros de entrada para la construcción y corrección del presupuesto trimestral que realiza el departamento financiero. Con la información conjunta de la exactitud del pronóstico, los pronósticos de ventas y operaciones y los costos proyectados por área el departamento

financiero determina la necesidad de capital para los siguientes nueve meses y realiza el cronograma de trabajo con las entidades financieras. Hay que tener en cuenta que todo el capital obtenido con las entidades bancarias genera un sobrecosto adicional por tasas de interés. Para el dato de los pronósticos de la demanda se realiza la entrega de la información de manera separada por parte de las áreas de operaciones y ventas sin existir previamente una consolidación de los datos. El área financiera recibe la información de las dos partes y realiza un promedio aritmético simple. El área de ventas genera la previsión acorde a la cuota en dólares establecida por categoría por el CEO (chief executive officer/oficial ejecutivo en jefe) sin tener en cuenta factores de tendencias de mercado, estacionalidades, campañas, comportamiento histórico, etc., únicamente crecimiento esperado.

El área de operaciones, por su parte, tiene en cuenta la demanda histórica agregada de todas las categorías por periodos trimestrales implementando un modelo de pronóstico basado en series de tiempo estático promedio móvil simple. Para implementar este modelo primero se realiza una desestacionalización de la demanda y ejecución de regresiones lineales para estimar el nivel y la tendencia, posteriormente se estiman los factores estacionales y así se obtiene el pronóstico de los siguientes 4 trimestres del año. El proceso se realiza de manera anual y se hacen correcciones a medida que se tiene la demanda real de cada periodo, todo esto sin tener en cuenta la eliminación de los valores atípicos ni los factores que influyen en la demanda y su relación con la cantidad vendida.

La exactitud del pronóstico es el grado de cercanía entre el valor proyectado y el real (referencia), el cual no puede ser medido en el momento en el que se realiza el pronóstico porque la expresión se refiere al futuro, por lo tanto, se determina posterior al suceso del evento. Actualmente el indicador de desempeño del pronóstico es calculado por parte de la compañía como el promedio de las diferencias entre el pronóstico y la demanda real para el periodo t , teniendo en cuenta para cada valor pronosticado un único punto y no una serie de tiempo completa como se muestra en la tabla 1-1. Acorde a esta metodología de cálculo la compañía piensa que en este momento logra un porcentaje de exactitud de pronóstico promedio del 70%.

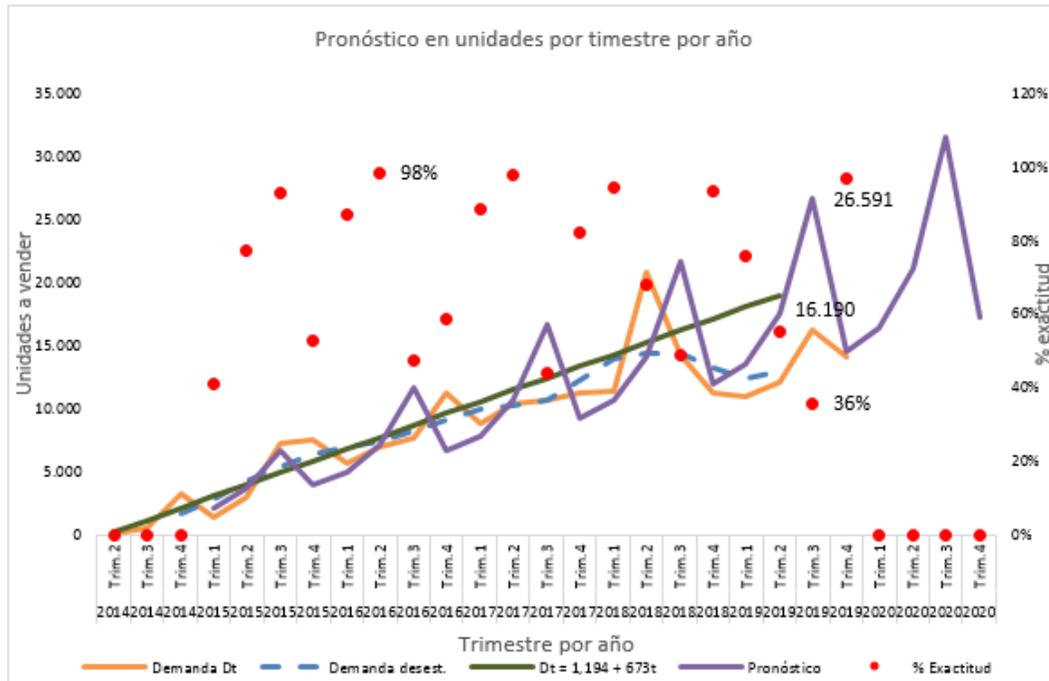
Tabla 1-1: Pronóstico de la demanda con el modelo usado actualmente por la compañía, promedio móvil.

P. t	Año	Trim	Dt	D desest.	Dt'	Factor est.	Pronó.	Nivel Lt	Error	Error abso	Error cuad.	MADt	Error %	MAP E	TSt
1	2014	Trim.2	126		200	0,63									
2	2014	Trim.3	475		1.139	0,42									
3	2014	Trim.4	3.152	1.622	2.078	1,52		1.974							
4	2015	Trim.1	1.328	2.821	3.017	0,44	2.114	3.667	786	786	618.025	786	59	59	1
5	2015	Trim.2	2.942	4.206	3.955	0,74	3.615	4.745	673	673	535.168	729	23	41	2
6	2015	Trim.3	7.245	5.293	4.894	1,48	6.715	5.842	-530	530	450.465	663	7	30	1
7	2015	Trim.4	7.464	6.347	5.833	1,28	3.917	6.852	-3.547	3.547	3.482.281	1.384	48	34	-2
8	2016	Trim.1	5.716	6.903	6.772	0,84	4.967	6.954	-749	749	2.898.001	1.257	13	30	-3
9	2016	Trim.2	6.982	7.427	7.711	0,91	7.097	7.900	115	115	2.417.213	1.067	2	25	-3
10	2016	Trim.3	7.653	8.292	8.650	0,88	11.684	8.685	4.031	4.031	4.393.113	1.490	53	29	1
11	2016	Trim.4	11.247	9.107	9.589	1,17	6.578	9.530	-4.669	4.669	6.568.660	1.887	42	31	-2
12	2017	Trim.1	8.856	9.904	10.527	0,84	7.820	10.279	-1.036	1.036	5.958.061	1.793	12	29	-3
13	2017	Trim.2	10.362	10.277	11.466	0,90	10.580	10.274	218	218	5.367.002	1.635	2	26	-3
14	2017	Trim.3	10.652	10.579	12.405	0,86	16.653	10.885	6.001	6.001	8.152.951	2.032	56	29	1
15	2017	Trim.4	11.226	12.182	13.344	0,84	9.239	13.479	-1.987	1.987	7.802.568	2.028	18	28	0
16	2018	Trim.1	11.299	13.933	14.283	0,79	10.673	14.387	-626	626	7.232.520	1.921	6	26	-1
17	2018	Trim.2	20.738	14.379	15.222	1,36	14.063	14.370	-6.675	6.675	9.898.903	2.260	32	27	-4
18	2018	Trim.3	14.284	14.318	16.161	0,88	21.622	14.267	7.338	7.338	12.828.854	2.599	51	28	0
19	2018	Trim.4	11.160	13.187	17.099	0,65	11.900	12.107	740	740	12.061.246	2.483	7	27	0
20	2019	Trim.1	10.884	12.346	18.038	0,60	13.526	12.584	2.642	2.642	11.762.322	2.492	24	27	1
21	2019	Trim.2	12.101	12.949	18.977	0,64	17.545	13.313	5.444	5.444	12.755.485	2.656	45	28	3
22	2019	Trim.3	16.190				26.591	14.123	10.401	10.401	17.778.115	3.064	64	30	6
23	2019	Trim.4	14.078				14.560	15.134	482	482	16.900.845	2.935	3	28	6
24	2020	Trim.1					16.379	14.078							
25	2020	Trim.2					21.028								
26	2020	Trim.3					31.560								
27	2020	Trim.4					17.221								

Tabla elaboración propia a partir de la base de datos de la compañía en estudio.

La figura 1-3 muestra la demanda actual y los pronósticos obtenidos durante los últimos 5 años. En algunos casos, como se visualiza para el tercer trimestre del 2019 este porcentaje es del 36% y en otros periodos tienen una exactitud que la empresa considera “mejor” acorde a su metodología de cálculo como el segundo trimestre del 2016, obteniendo un porcentaje del 98%.

Figura 1-3: Pronóstico de la demanda en unidades por trimestre por año con el modelo usado actualmente por la compañía, promedio móvil.



Gráfica elaboración propia a partir de la base de datos de la compañía en estudio.

La meta actual de la compañía según esta metodología es que en ningún trimestre el porcentaje se encuentre por debajo del 70%. Si se observa en la tabla 1-1 el primer trimestre del 2019 en el cual presentan un porcentaje de exactitud de 76% se identifica un “sobrante” de 2.642 unidades, de las cuales aún mantenían en inventario en septiembre de 2019 (6 meses después de su compra) 350 unidades y realizaron una depreciación de su valor por \$17 millones. El costo de oportunidad de mantener estas unidades por 6 meses en inventario fue de \$25 millones, se ve el efecto financiero aún en un periodo en el que la empresa considera que se obtuvo un desempeño “admisible” al estar por encima del 70%. Periodo tras periodo se acumula parte del inventario que fue adquirido adicional a la venta real en cada punto del tiempo, generando una reducción en los márgenes brutos por depreciación de activo en promedio anual por \$200 millones y por costo de oportunidad en promedio anual de \$300 millones, aquí sin tener en cuenta otros costos ocultos por mantenimiento de inventario. Adquirir en promedio 900 unidades más en los periodos en los que se sobreestima la demanda para productos que tienen un costo promedio de \$1,5

millones requiere una inversión adicional financiera y por capital inmovilizado aproximado de \$1.300 millones que afecta el flujo de efectivo y genera costos adicionales por tasas de interés en promedio anual por \$150 millones. Estos artículos son pagados al proveedor al día 30 de su adquisición y la inversión realizada en ellos se recupera aproximadamente en el día 180 o más. Actualmente la empresa no tiene cuantificado el impacto financiero que generan los costos de oportunidad y las tasas de interés por las diferencias entre el tiempo de las cuentas por pagar y el tiempo de las cuentas por cobrar. La empresa percibe de manera cualitativa un impacto en días de flujo de caja.

En la industria de la alta tecnología diferencias como las que se tienen actualmente en el pronóstico de la demanda y cambios tan rápidos en las referencias desde el fabricante por la velocidad en el desarrollo tecnológico están generando pérdidas financieras anuales para la compañía en estudio por \$650 millones en promedio. Pérdidas que deben ser analizadas recurrentemente con el objetivo de reducirlas tanto como sea posible, cualquier posibilidad de baja en valores de depreciación, costos de oportunidad y tasas de interés sería ganancia para la compañía. Dado todo lo anteriormente descrito, es fundamental verificar si con la implementación de otro modelo o modificaciones del actual se contribuye con la mejora del desempeño del pronóstico; siendo así, pregunta orientadora importante de este trabajo:

- ¿Puede el modelo a implementar o las modificaciones al modelo de pronóstico actual funcionar mejor bajo el mismo parámetro de cálculo de desempeño?

1.2 Objetivo general y objetivos específicos

1.2.1 Objetivo General

- Seleccionar e implementar un método de pronóstico de demanda para computadores portátiles aplicado a una empresa colombiana.

1.2.2 Objetivos Específicos

- Revisar el estado del arte del comportamiento de la demanda en la industria de alta tecnología en mercados emergentes como el colombiano.
- Identificar los métodos o herramientas de pronóstico que se pueden usar acorde al tipo de mercado, características y factores que afectan el comportamiento de demanda en esta industria.
- Seleccionar el método a usar acorde a la identificación realizada.
- Adecuar el método seleccionado usando el histórico de ventas de la compañía en estudio de los últimos 4 años.
- Validación de resultados con los datos de demanda de la compañía del primer y segundo semestre de 2019.

2.Estado del arte

En este capítulo se describe el comportamiento de la demanda y los modelos usados en investigaciones anteriores identificados por la revisión de la literatura tanto de la industria de la alta tecnología a nivel general como de los eslabones que componen la cadena de suministro. Después se describen las métricas usadas para cuantificar el desempeño de los modelos de pronóstico implementados acorde al comportamiento de la demanda y se define el modelo a implementar para la empresa en estudio.

2.1 Comportamiento de la demanda en la industria de la alta tecnología

Uno de los 17 objetivos de desarrollo sostenible busca construir infraestructura resiliente, promover la industrialización inclusiva y fomentar la innovación¹. El fomento de innovación se encuentra apoyado por el desarrollo tecnológico generando desafíos para la industria de la alta tecnología. Todas las innovaciones en robótica, internet de las cosas, machine learning, entre otras, tienen alta relevancia y uso en el mercado actual (Xu et al., 2018).

La industria de la alta tecnología se encuentra caracterizada por una introducción constante de nuevos artículos que deben cumplir con el requerimiento para la investigación y puesta en marcha de cada innovación (Kou & Lee, 2015; Kurawarwala & Matsuo, 1996). La característica de entrada frecuente de artículos genera alta tasa de canibalización e introducción y retirada de múltiples modelos en breves periodos de tiempo, lo que se ve

¹ Puede consultar los objetivos de desarrollo sostenible para 2030 en: <https://onu.org.gt/objetivos-de-desarrollo/>

reflejado en ciclos de vida cortos (Chanda & Aggarwal, 2014; Hu et al., 2019; Ju & Yang, 2010).

El comportamiento de ciclo de vida corto en la demanda de la industria de la alta tecnología se ha visualizado incluso desde años atrás. Goldman en el año 1982 analiza las implicaciones que tiene un patrón de ciclo de vida corto para las actividades de marketing en empresas pequeñas de alta tecnología, relacionando una etapa de declive de consumo muy pronunciada y poca o nula etapa de madurez como consecuencia del constante ingreso y retirada de referencias (Goldman & Marketing, 1982; Roberts, 1976; St. John, 1978). Al relacionar la palabra corta, Goldman hace referencia al periodo de tiempo que pasa el producto en el mercado con respecto al tiempo que se requiere desde el inicio del proyecto del nuevo producto en las fases de investigación y desarrollo hasta su lanzamiento comercial. El tiempo que pasa el producto en el mercado está compuesto por la curva del ciclo de vida y todas sus etapas: introducción, madurez y declive (Goldman & Marketing, 1982). Goldman además menciona que en algunos casos para relacionar si el ciclo de vida de un producto es corto o no, se establecen puntos de referencia relacionados con el flujo de efectivo, la rentabilidad o el periodo de recuperación.

El ciclo de vida corto en la industria de la alta tecnología marca la caída de precios como una característica que puede influenciar el comportamiento de la demanda (Wagner, 2008). La reducción de precios en las referencias se presenta siempre que se inicia la introducción de un nuevo artículo que tiene como objetivo canibalizar el producto que se encuentra actualmente en el mercado. Los actores en la industria de la alta tecnología tienen claro que la reducción en el precio es la mejor alternativa para lograr la venta total de las unidades que tienen en inventario después de tener un producto que satisface las mismas necesidades pero con mejores características (Kou & Lee, 2015). Los precios suelen tener una baja entre el 40% y 50% asegurando así un factor diferencial en la decisión de compra por parte del consumidor (Chung et al., 2011).

En la industria de la alta tecnología el cambio en el comportamiento del consumidor también puede alterar el ritmo normal de la demanda. Los cambios en las preferencias del consumidor se van dando de manera natural con el transcurrir de los años y con los avances en desarrollo y tecnología. Los cambios en los nuevos productos que servirán como sustitutos también se van dando de manera natural acorde al estudio que realizan las áreas de investigación y desarrollo de las diferentes empresas de los fabricantes sobre

las preferencias del consumidor. A medida que las áreas de innovación van detectando una predilección específica empiezan a generar estudios para lograr una identificación completa que les permita incluir características en los nuevos productos que satisfagan esos gustos y entreguen un beneficio completo a los usuarios (R. J. Lin et al., 2012).

Lograr un claro entendimiento de las necesidades del cliente y la satisfacción en el menor tiempo posible puede ser un factor determinante en el éxito o fracaso de un nuevo producto, por ello, el tiempo que transcurre entre el desarrollo y su lanzamiento debe ser lo suficiente para estudiar no sólo el comportamiento de las generaciones actuales de consumidor sino también de las generaciones futuras (Kim et al., 2021; R. J. Lin et al., 2012). Sería un supuesto en algunos casos pensar que un mejor estudio de los gustos del consumidor del futuro podría generar alguna posibilidad de existencia de etapa de madurez ya que alargaría los tiempos de entrada y retirada de productos, pero esto tendría más probabilidad de suceso si la salida de productos dependiera de un único fabricante. Actualmente la industria de la alta tecnología no es un monopolio con un único oferente, existen en el mercado empresas altamente competitivas como: lenovo, dell, toshiba, acer, apple, hp, entre otras (Kou & Lee, 2015). Teniendo en cuenta que la cantidad de fabricantes es mayor a uno se deja poca posibilidad de que la competencia no logre capturar todas aquellas características que requiere el mercado.

Se descarta la necesidad de contemplar la característica de las preferencias del consumidor en los análisis del comportamiento de la demanda en la industria de la alta tecnología dado el requisito de estudio de esta característica en las fases de investigación y desarrollo que tienen que cumplir todos los fabricantes antes del lanzamiento de un nuevo producto, siendo un factor indispensable y no diferencial por las múltiples opciones del mercado (R. J. Lin et al., 2012).

Con tantos competidores de alta calidad, el tiempo de innovación nunca se detiene y la tasa de ingreso de nuevos productos se ve impactada no sólo por un área en proceso de investigación, sino por 5 o más áreas de innovación y desarrollo (una por cada fabricante) con personas, recursos y análisis diferentes que inevitablemente hacen que la carrera por entregar productos con mejores características y en menores lapsos de tiempo no se detenga. El estudio por defecto del comportamiento del consumidor en un mercado de múltiples fabricantes elimina el supuesto de la existencia de etapas de madurez

prolongadas (Chanda & Aggarwal, 2014; Kurawarwala & Matsuo, 1996; Neelamegham & Chintagunta, 2004).

La capacidad de carga puede ser una característica que determine el comportamiento de la demanda en la industria de la alta tecnología. Una encuesta realizada por el Pew Reserach center en el 2018² muestra que la propiedad de computadores de escritorio o portátiles en estados unidos presentó una caída en las cifras en los años 2016 a 2018 de 78% a 73%. Esta cifra demuestra que en el mercado estadounidense de personas naturales no hay saturación en el consumo de computadores portátiles. Si se compara con el mercado colombiano, país en el que existe un nivel de desarrollo menor lo más probable es que se encuentra más lejos de tener saturación en el mercado. De modo que, se puede suponer que aún hay muchas décadas por delante para que la saturación en el mercado sea una característica que predomine el comportamiento de la demanda en la industria de la alta tecnología y cada uno de sus eslabones en mercados emergentes como el colombiano. A razón de la no saturación del mercado se reafirma que por ahora se sigue manteniendo con bastante fuerza la introducción constante de nuevos productos que canibalicen los existentes. Yan & Williams en el 2009 mencionaron que la computadora personal aún se encontraba en una etapa temprana de su ciclo de vida de adopción y por ende aún no se podía considerar que los ajustes estadísticos produjeran una estimación razonable de la capacidad de carga (Yang & Williams, 2009).

Con las descripciones anteriores se puede caracterizar el comportamiento de la demanda de la industria de la alta tecnología con ciclos de vida cortos, caída de precios, no saturación de mercado, canibalización de referencias e ingresos y retirada constante de productos.

Como se mencionó en el subcapítulo 1.1 la cadena de suministro de la industria de la alta tecnología tiene cinco eslabones principales: 1.) el fabricante de componentes (ejemplo: Accton o Intel), 2.) el diseñador, desarrollador y fabricante de productos electrónicos (ejemplos: Hewlett Packard/Lenovo), 3.) los mayoristas como distribuidores autorizados de los fabricantes (ejemplos: Ingram Micro/Nexsys), 4.) los minoristas como vendedores de los productos al usuario final. En la industria de la alta tecnología son denominados

² Se puede consultar el artículo en <https://www.pewresearch.org/fact-tank/2018/09/28/internet-social-media-use-and-device-ownership-in-u-s-have-plateaued-after-years-of-growth/>

“canales” (ejemplo: OFIcomco), y 5.) las empresas como usuario final que hacen uso de los productos electrónicos para sus fines corporativos.

La empresa en estudio es un canal distribuidor, es decir, se encuentra ubicada en el eslabón número cuatro. A continuación se desarrolla el comportamiento de la demanda de los eslabones fabricante, mayorista y canal. Se examinan los eslabones fabricante y mayorista porque tienen algún grado de intervención con el comportamiento de la demanda del eslabón “canal” en el que se encuentra ubicada la empresa en estudio.

2.1.1 Fabricante de productos electrónicos

En el segundo eslabón de la cadena de la industria de la alta tecnología que corresponde a los fabricantes, la inexistencia de tiempos prolongados de estabilidad y la producción y entrega en grandes lotes por pedido conlleva una variabilidad de consumo que tiende a generar comportamientos no estacionarios. Las etapas de desarrollo antes del lanzamiento y la introducción del producto tienen fechas de inicio y fin determinadas, lo que conduce a estacionalidad y alta dependencia de la variable tiempo en el comportamiento de la demanda durante el desarrollo de cada fase, teniendo así, una covarianza no constante y en algunos casos existiendo una alta relación de los valores pasados en la medida que aumenta el conocimiento del producto o se genera una salida programada (Kurawarwala & Matsuo, 1996).

Los fabricantes suelen tener una estrategia de planificación de ventas y operaciones con los mayoristas informando con antelación la referencia que va a salir al mercado, manejando una estrategia de gestión de inventario *push* que les permite asegurar la recepción de pedidos por la totalidad en producción por parte de todos los actores que se encuentren participando en el tercer eslabón de la cadena de suministro de la industria de la alta tecnología (R. J. Lin et al., 2012).

La reducción de precios que caracteriza el comportamiento de la demanda de la industria de la alta tecnología se ve marcada desde el eslabón fabricante. Se establecen acuerdos de reducciones de precios hasta del 70% con los mayoristas para las unidades que se quedan en inventario posterior a la salida de otra referencia, para esto existen unos tiempos determinados pero normalmente esto asegura la salida de aproximadamente el 90% del inventario (R. J. Lin et al., 2012). En los casos que definitivamente quedan existencias sin salida por un tiempo de 1 año desde la fecha de salida de la nueva

referencia, aún con la aplicación de descuento, el fabricante recibe la devolución de las unidades al mayorista siempre y cuando el producto se entregue en las mismas condiciones físicas en las que se recibió al momento de la compra.

2.1.2 Mayoristas como distribuidores autorizados de los fabricantes.

Los mayoristas también usan un sistema de gestión de inventarios tipo *push* con los canales, notificando lo que han puesto previamente en órdenes de compra y el tiempo estimado de llegada. En muchas ocasiones los mayoristas logran vender todas las unidades incluso antes de la llegada del producto a sus centros de distribución generando al igual que en el fabricante estacionalidad en el comportamiento de la demanda. La venta por lotes y grandes cantidades genera una fecha de salida por volumen igual a la fecha de entrega de los productos de fabricante, lo que permite que no enfoquen sus esfuerzos y recursos en salidas y mantenimientos de inventario y se tenga un comportamiento en muchas ocasiones inmediato de compraventa.

En aquellos casos que la apuesta de las unidades compradas por parte de los mayoristas no logra ser cubierta con la cantidad de pedidos recibidos por parte de los distribuidores, se inicia la reducción de precios contemplando las fechas aproximadas dadas por el anterior eslabón como lanzamiento de la siguiente referencia. Acorde a la fecha estimada de llegada de la nueva referencia los mayoristas realizan cambio en las tarifas de venta. Normalmente cuando ya ven muy próxima la llegada del sustituto se vuelve crucial el factor de precio porque saben que es una característica diferencial. Previamente desde los fabricantes tienen apoyos que les permiten manejar las estrategias de precios y transferir un porcentaje de cada descuento al canal acorde al tiempo que llevan las unidades en el inventario.

2.1.3 Canales como vendedores de los productos al usuario final.

Para el eslabón del minorista o canal como se denomina en la industria de la alta tecnología existen enfoques en dos tipos de usuario final: persona natural y empresa. La compañía en estudio se encuentra enfocada en el usuario final empresa, por esto se realiza la identificación del comportamiento de la demanda únicamente para los actores enfocados en ventas B2B.

Para los canales enfocados en empresas se empieza a percibir un cambio en el comportamiento de la demanda por media y variación constante con baja estacionalidad, esto se da por tres razones principales: 1). no tienen ventas por grandes lotes antes o en la misma fecha de la compra de los productos, 2). la etapa de desarrollo no es visible y 3). hay efectos de sustitución sin periodos determinados. A continuación se da detalle de las tres razones mencionadas:

1. No tienen ventas por grandes lotes antes o en la misma fecha de la compra de los productos: a los canales distribuidores se les imposibilita tener en la mayoría de sus negocios una estrategia de inventarios *push* debido a la alta competencia. La cantidad de fabricantes a nivel mundial ronda en 5 o 10 actores principales, en Colombia la cantidad de mayoristas ronda en 10 o 20 actores, algo limitado. Mientras que la cantidad de distribuidores está compuesta por más de 100 empresas³ (ver anexo A). Debido a la cantidad de compañías que componen el eslabón del canal distribuidor en la cadena de suministro de la alta tecnología en el mercado colombiano existe una alta competencia y responder en tiempos récord con el inventario disponible sin estar sujetos a tiempos de entrega de 30 o 45 días hábiles es un requisito y no un factor diferencial. Cuando el canal distribuidor no tiene el producto en el inventario necesita emitir la orden de compra al mayorista, si el mayorista lo tiene disponible el tiempo de entrega puede ser de 2 a 3 días hábiles, en los casos que el mayorista no lo tenga disponible se debe esperar el tiempo de entrega desde el fabricante que normalmente es de 30 a 45 días hábiles.
2. La etapa de desarrollo no es visible: mientras transcurre la fase de desarrollo para el fabricante los canales perciben las etapas de introducción, madurez y declive con lapsos de tiempo más largos para los equipos que se encuentran en el mercado. La variable de tiempo de entrega en compañías de distribución, como la empresa en estudio, hace referencia a meses y no a años, pues se contempla el tiempo de tránsito pero no el tiempo de desarrollo, generando así, una extensión

³ Se puede consultar las empresas en informa para la clasificación por actividad 4741: comercio al por menor de computadores, equipos periféricos, programas de informática y equipos de telecomunicaciones <https://directorio-empresas.einforma.co/actividad/4741-comercio-al-por-menor-de-computadores-equipos-perifericos-programas-de-informatica-y-equipos-de-telecomunicaciones-en-establecimientos-especializados/>

en los tiempos de las diferentes etapas, dando mayor espacio de planificación que puede ser utilizado en su favor con el histórico y la experiencia del mercado (Goldman & Marketing, 1982).

Para el eslabón del canal distribuidor los rápidos avances tecnológicos y la incorporación de características y funciones no siempre implica que los productos de generación actual tengan una retirada inmediata del mercado (Bayus, 1998; Chanda & Bardhan, 2008; Jaakkola et al., 1998). Chanda & Aggarwal en el 2014 toman esto como supuesto en el comportamiento de artículos de alta tecnología para determinar un modelo de inventarios, obteniendo como resultado una consistencia en la política con respecto al comportamiento real, por lo que relacionan la existencia de etapas de ciclo de vida más prolongadas en los canales distribuidores con respecto a las que perciben los fabricantes y los mayoristas (Chanda & Aggarwal, 2014).

3. Hay efectos de sustitución sin periodos determinados: a pesar de tener tiempos más prolongados en las diferentes etapas en el eslabón del canal distribuidor sigue existiendo una limitación en el ciclo de vida no sólo por la característica de avance tecnológico sino por el efecto de sustitución dada la finalización del periodo de utilidad. En el caso colombiano, el efecto de sustitución se da gracias a la norma fiscal que se impone a la técnica contable en la que se relaciona que se puede realizar la amortización de activos fijos en un periodo determinado. Por ejemplo, en el caso de los computadores portátiles se contempla una vida útil de 5 años⁴. Posterior a un periodo de 5 años desde la adquisición de un computador portátil las empresas finalizan su depreciación y consideran el artículo como “inservible”.

En consecuencia al tiempo de vida útil y el tiempo permitido de amortización, acorde a la fecha de compra, cada 5 años o menos las empresas adquieren equipos que reemplacen aquellos que se han dado de baja por finalizar su ciclo de vida generando un patrón de renovación sin periodos fijos. La asignación de activos

⁴ Se puede consultar la tabla por clasificación de tipo de activo fijo es: <https://www.gerencie.com/vida-util-de-los-activos-fijos.html>

en una empresa depende del ingreso de personal, del crecimiento de la compañía, de la implementación de nuevos procesos, entre otros. Lo anterior genera que cada empresa tenga fechas diferentes para la compra y asignación de nuevos equipos y para el cambio finalizando la vida útil, por ello es posible contemplar baja estacionalidad.

La característica de amortización de activos fijos en un periodo de 5 años posterior a su compra permite intuir que bajo el escenario de consumidor empresarial no es razonable considerar un efecto de crecimiento exponencial en el número de adoptantes hasta llegar a un punto de inflexión y posterior un aplanamiento que genere saturación de mercado. Esto se reafirma teniendo en cuenta que no es una característica por ahora que se deba contemplar en el comportamiento de la demanda de la industria de la alta tecnología como se mencionó anteriormente.

La característica de la caída de precios se mantiene en los eslabones fabricante, mayorista y canal. Para el caso del canal distribuidor cuando las unidades que se planifican en inventario dejan producto disponible posterior a la llegada de la siguiente referencia se vuelve crucial dar flexibilidad al precio para lograr salir de todas las unidades. La diferencia de precio entre el producto anterior y su sucesor normalmente puede estar entre el 40% o 50%, lo que puede prolongar la etapa de madurez respecto a la del fabricante y el mayorista dado que el proceso de caída de precios para el segundo y tercer eslabón de la cadena de suministro termina antes de la finalización en el eslabón del canal distribuidor.

Si se va a realizar un análisis del comportamiento de la demanda de un producto de la industria de la alta tecnología se recomienda el uso de datos agregados que permita una visibilidad real de la dinámica que han tenido sus antecesores en todo el ciclo de vida. La recomendación del análisis agregado se realiza dada la característica de introducción y retirada constante de nuevas referencias que se presenta en todos los eslabones.

Para no categorizar una industria completa, tipo de bien o línea de productos por un comportamiento puntual o atípico de un único artículo se recomienda enfocar el análisis en clases de productos completos y no marcas específicas o bien unitario, asegurando que cada clase contemple siempre una demanda agregada para visualizar el comportamiento completo de la familia acorde a las características técnicas o físicas. Para esto, se debe tener en cuenta que no deben existir grandes cambios en los atributos o estrategias de

marketing y ventas de los productos que componen dicha familia, en caso de ser así, será necesario conocer cuáles productos a nivel individual presentaron impactos por cambios en este tipo de estrategias y al momento de desagregar y buscar un comportamiento unitario se deben contemplar esos factores adicionales.

Teniendo en cuenta un análisis agregado es más factible la identificación de alguna correlación por la naturaleza de la demanda del consumidor y la generación de nuevos productos, encontrando así un patrón denominado “natural” que con alta probabilidad permite generalizar el mismo compartimiento de la familia a nivel de producto individual (Cox, 1967). Se debe tener en cuenta agregaciones con dimensiones coherentes con el proceso de generación de la demanda y homogeneidad, ya que cuanto más heterogénea es la demanda, más inaplicable es la ejecución del pronóstico agregado (Zotteri et al., 2005).

Finalmente se puede resumir que el comportamiento de la demanda para la industria de la alta tecnología en empresas que son canales de distribución con enfoque B2B, se encuentra caracterizada por ciclos de vida cortos, poca evidencia de saturación de mercado, series de tiempo estacionarias, baja estacionalidad y baja dependencia de los pedidos del periodo t por los resultados del periodo $t-1$ si se asegura agregación de la demanda por familias de producto.

Todas estas características reducen sustancialmente el tiempo que tienen las empresas para comunicar a los clientes potenciales, volviendo imprescindible la alta capacidad de gestión y optimización de recursos, buscando llegar a la mayor cantidad de compradores posible y asegurar una toma de decisiones adecuada y bajo gasto financiero.

2.2 Modelos de pronóstico usados en la industria de alta tecnología o industrias con comportamientos de demanda análogos.

La predicción puede entenderse como la búsqueda de información sobre el comportamiento futuro de una variable a través de un proceso racional que implica incertidumbres (Agostino et al., 2020). Bajo el contexto del presente trabajo, la predicción es un proceso metodológico en base a modelos matemáticos o subjetivos. El pronóstico

de la demanda puede ser aplicado en diferentes actividades relativas a la planificación, como lo son: planificación agregada de producción, plan maestro de producción, planificación de capacidad, planificación y control de inventarios, planificación de ventas, entre otras (Montgomery et al., 2016).

En el presente trabajo el enfoque es planificación de demanda, para obtener el pronóstico de unidades a vender de una línea de un producto informático. Como se mencionó anteriormente, este tipo de productos se caracterizan por la variedad, los rápidos cambios en las especificaciones y la rápida caída de precios, siendo así la predicción una tarea importante pero difícil (Wagner, 2008). Los problemas de pronóstico normalmente se clasifican en corto (días, semanas o meses), mediano (1 o 2 años) y largo plazo (superior a 2 años) (Montgomery et al., 2016). Los de largo plazo comúnmente usados en planificación estratégica. Los pronósticos de corto y mediano plazo se basan normalmente en la identificación, modelado y extrapolación de los patrones encontrados en los datos históricos que generalmente no presentan cambios drásticos, siendo así los modelos estadísticos muy útiles para su análisis (Montgomery et al., 2016). Teniendo en cuenta las características de la compañía y el comportamiento de la demanda, en el presente trabajo se usan previsiones a corto plazo por periodos de seis a nueve meses acorde a la planificación del presupuesto por parte del área financiera de la compañía en estudio.

Existen modelos de pronóstico de la demanda cualitativos y cuantitativos (Boylan & Syntetos, 2010; Pankratz, 2014; Stylin, 2019). Los modelos cualitativos suelen ser de naturaleza subjetiva y son empleados cuando se tiene poca o ninguna historia de datos para realizar el análisis, se requiere el juicio por parte de expertos cuando hay muchos factores que determinan el cambio del consumo; por ejemplo, factores de marketing como: eventos promocionales, descuentos especiales y eventos patrocinados con reducciones de precios que generan aumento en la demanda. O factores como desabastecimiento programado (Huang & Babri, 1998; Nenni et al., 2013; Wong & Guo, 2010) o productos sustitutos por estrategia de canibalización fija o por temporadas que por el contrario generan reducción en la demanda (Franses & Legerstee, 2009; Sanders & Ritzman, 2001). Las estrategias tanto internas como externas generan cambios en el volumen de ventas estándar (Gelper et al., 2010; Pankratz, 2014; Sunil Chopra, 2010).

Dentro de los modelos cualitativos se encuentran: Jurado de opinión ejecutiva, Método Delphi, proposición de personal comercial y estudio de mercado (Sunil Chopra, 2010).

Estos modelos se basan en el conocimiento y opiniones de personas con experiencia en el campo, como la gerencia y los expertos (Bajracharya et al., 2019; Sunil Chopra, 2010; Wong & Guo, 2010) y en ocasiones hacen uso de pruebas de marketing, encuestas a clientes potenciales y experiencia en el desempeño de otros productos.

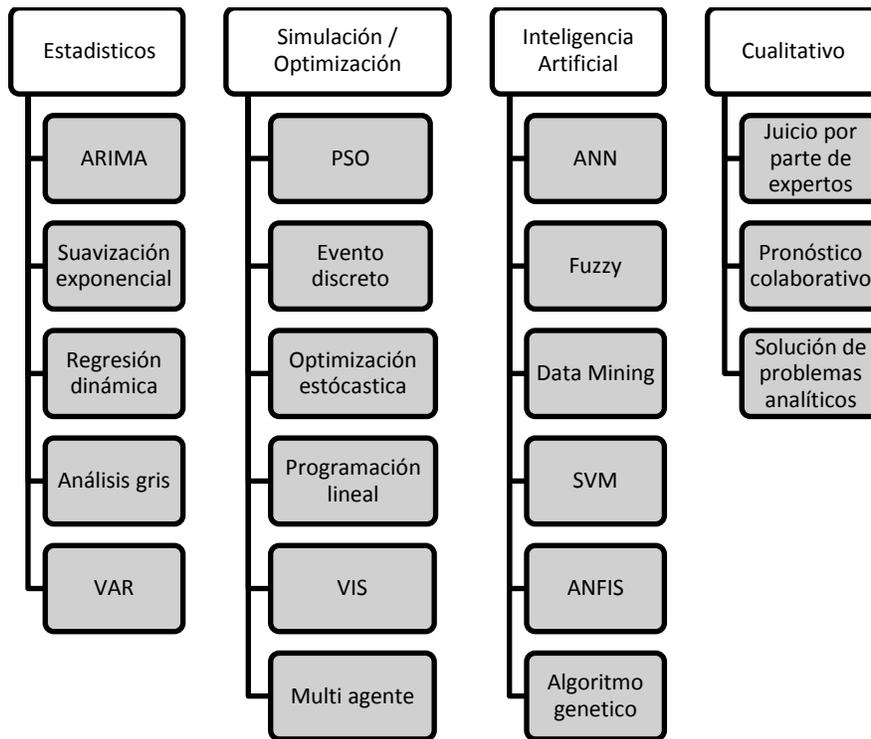
También se han propuesto diversos modelos cuantitativos, bajo este parámetro hay tres enfoques básicos para generar pronósticos: modelos basados en regresión, modelos de suavizado heurístico y modelos generales de series de tiempo (Montgomery et al., 2016). Los modelos cuantitativos suelen hacer uso formal de los datos históricos o de la identificación de patrones de la serie, expresando una relación estadística entre los valores anteriores y actuales de la variable para predecir los datos futuros. Los más utilizados son los modelos de regresión, de suavizado y de series de tiempo (Goodwin & Wright, 2010; Montgomery et al., 2016; Sunil Chopra, 2010). Ejemplo de estos son: enfoque simple, series de tiempo, media simple, media móvil, media móvil ponderada, suavización exponencial, suavización exponencial con ajuste de tendencia, análisis de regresión lineal, análisis de regresión múltiple y modelo multiplicativo (Agrawal & Schorling, 1996; Huang & Babri, 1998).

Los modelos de regresión utilizan relaciones entre la variable de interés y uno o más variables predictoras, los modelos de suavizado suelen emplear una función simple para proporcionar la predicción de la variable de interés, a menudo su justificación se da heurísticamente, los modelos de series de tiempo emplean propiedades estadísticas de los históricos para estimar los parámetros desconocidos, en la mayoría de casos por mínimos cuadrados (Montgomery et al., 2016). En investigaciones anteriores se ha sugerido la integración de modelos cualitativos y cuantitativos que logren tener en cuenta adicional al consumo recurrente, las demandas superiores o inferiores generadas por cualquier tipo de factor interno o externo (Huang & Babri, 1998; Nenni et al., 2013; Wong & Guo, 2010).

Filder en el año 2009 propone y demuestra como el uso de los modelos mixtos puede mejorar la exactitud del pronóstico acorde al contexto de la compañía, en los análisis experimentales observa que en muchos casos se realizan ajustes a los análisis estadísticos (Feng et al., 2009). Por encima del 80% de los pronósticos de la demanda son ajustados, logrando un impacto directo en el desempeño de la cadena de suministro y en el servicio (Agrawal & Schorling, 1996; Feng et al., 2009; Huang & Babri, 1998). Desde

Sanders y Manrodt en el año 1994 hasta Lapide en el año 2006 se seguía mencionando la importancia de los modelos de juicio y ad-hoc, insistiendo que debe ser un proceso correlacional a los modelos cuantitativos, existiendo así, una continua dependencia de los dos tipos de modelos en la mayoría de las empresas (Lapide, 2006; Sanders & Manrodt, 1994). Para implementar una metodología mixta se requiere establecer un procedimiento en la compañía adicional al cambio del modelo usado actualmente, por lo tanto, se propone como futura línea de investigación.

Figura 2-1: Clasificación de los modelos de pronóstico en el contexto industrial.



Clasificación realizada por (Agostino et al., 2020) paper: Forecasting models in the manufacturing processes and operations management: Systematic literature review

Agostino en el año 2020 en un proceso de revisión de literatura sobre modelos de pronóstico de la demanda realiza una clasificación identificando 4 categorías principales: estadísticos, simulación/optimización, inteligencia artificial y cualitativos, ver figura 2-1 (Agostino et al., 2020). Los modelos estadísticos se relacionaron anteriormente como modelos cuantitativos, los modelos de simulación no tienen amplia investigación en industrias del tipo en estudio, por lo tanto, se descartó su uso.

Para los modelos de inteligencia artificial, desde el año 1980 se han propuesto diferentes modelos enfocados en redes neuronales artificiales (ANN). A pesar de la existencia de una gran cantidad de literatura aplicado a predicción de ventas, la dificultad de identificar variables importantes hace que sean menos atractivos, ya que la selección de las variables afecta la precisión y son cruciales para la construcción del modelo, los ajustes generan inconvenientes de convergencia y se puede obtener malos pronósticos fuera de la muestra (Chatfield, 1993; Faraway, 1998; Nikolopoulos et al., 2007). Dado lo anterior, en los modelos de redes neuronales se vuelve vital periodos de tiempo prolongados para lograr un entrenamiento confiable sin generar sobreajuste (Chatfield, 1993). Tener demasiadas variables de pronóstico agrega complejidad al modelo, mientras que tener muy pocas variables puede resultar en un modelo ineficaz. Las variables de pronóstico importantes que tienen un impacto en los resultados son a menudo las áreas de enfoque clave o indicadores que requieren atención gerencial.

Aunque los ANN tienen gran potencial en el pronóstico de series de tiempo, en diferentes investigaciones se ha establecido que cuentan con menor error absoluto medio o equivalente a los modelos ARIMA cuando existen patrones de tendencia y estacionalidades (Alon et al., 2001). Foster y col desde el año 1992 demostraron un comportamiento superior con el suavizado exponencial respecto a las ANN en el pronóstico de datos anuales y trimestrales. Durante la década de los 80 se tenía la percepción a nivel general que los modelos ARIMA proporcionaban mejor desempeño para pronósticos inmediatos y de corto plazo, lo cual también lo reafirmó Dugan en el año 1994 mostrando que el modelo ARIMA tenía resultados de mayor precisión que el modelo Censo X-11 y los de caminata aleatoria. En el año 1990 se realiza un proceso con 111 series, de las cuales 75 mostraron un desempeño similar con modelos ARIMA respecto a modelos de redes neuronales. Posteriormente, Kang en el año en 1991 identifica un desempeño igual o superior para los modelos ARIMA en términos de MAPE en una variedad de aplicaciones. Yelland en el 2009 recalca el uso de los modelos ARIMA indicando: "*Ningún modelo en todos los tiempos ha logrado el dominio del que gozan aún los modelos de Box-Jenkins o modelos ARIMA en la predicción de series continuas*" (Yelland, 2009).

En el año 1990 fue propuesto el pronóstico de demanda por uso para aquellos productos que tienen una cantidad de consumo limitada por empresa o persona (Jeon et al., 1990), existiendo una correlación entre la penetración del producto y el número de personas por

hogar o por compañía. Para usar este tipo de técnica en la industria en estudio se requieren datos detallados y precisos como: número de trabajadores de oficina, número total de empleados, ventas por empresa, promoción de empleados, creación de nuevas vacantes o perfiles, calificación crediticia, etc; existiendo un límite para recopilar esta información, por lo cual es recomendable su uso cuando se va a estimar la demanda de empresas individuales (Yang & Williams, 2008). Para este caso de estudio se descarta el uso de esta técnica teniendo en cuenta la alta complejidad de consecución de información adicional a lo mencionado respecto a efecto de sustitución y poca evidencia actual de saturación de mercado.

Lenort en el año 2013 implementa para la industria moda su modelo con enfoque jerárquico haciendo uso del modelo ARIMA y recomendándolo por obtener mejor desempeño respecto a otros modelos adaptativos de series de tiempo implementados para ese caso de estudio con el uso del software statgraphic plus 5.0, sin embargo; en la línea de investigación futura propone el uso de ANNs (Lenort & Besta, 2013). Hyndman en el año 2011 también propone uso de ARIMA en la implementación del pronóstico de la demanda con enfoque jerárquico para la industria turística (Hyndman et al., 2011). Por otro lado, para la industria de alta tecnología las investigaciones son limitadas, existen investigaciones más amplias por tasas de obsolescencia, considerando una capacidad límite de adopción a futuro (Yang & Williams, 2008). Existen otras investigaciones relacionadas por demanda con el uso de modelos por curvas de ciclo de vida (Basallo-Triana et al., 2017), para este tipo hay dos investigaciones a detalle, una para el fabricante Dell (Hu et al., 2019), y otra para el fabricante HP (Burruss, 2002). Otra relacionada con la demanda por uso (Moon et al., 2015) y una investigación de implementación del modelo ARIMA propuesto por Lu en el año 2014 combinado con el uso de vectores de regresión y su enfoque es únicamente en 5 productos (Lu, 2014).

La mayoría de las investigaciones relacionadas anteriormente están enfocadas en el actor fabricante o mayorista, el cual acorde a su estrategia de inventario *push* genera cambio en el comportamiento de la demanda con respecto al actor del canal distribuidor minorista B2B. La investigación realizada por Yang con enfoque exclusivamente B2B, se descarta por el tipo de información requerida por empresa. El análisis del comportamiento de la serie de tiempo del modelo en estudio y la visibilidad de estacionariedad permite deducir que ARIMA tendría un comportamiento adecuado.

Finalmente, teniendo en cuenta la base de datos de la compañía en estudio y el comportamiento de la demanda para la industria de la alta tecnología en el eslabón de distribuidor, se vuelve de vital importancia la implementación de un modelo que no requiera un volumen de datos histórico superior a 3 años acorde al ciclo de vida promedio de los artículos y que sea de moderado nivel de complejidad para su adopción, implementación y puesta de marcha; buscando escalabilidad y no generar alto grado de resistencia al cambio. Por lo tanto, acorde a lo antes mencionado y la visibilidad de estacionariedad en el análisis de la serie de tiempo, se propone la selección del modelo ARIMA acorde a los beneficios en implementación y desempeño antes mencionados con respecto a otros modelos en combinación con el modelo con enfoque jerárquico implementado en una investigación anterior en la industria análoga “moda”.

2.2.1 Series de tiempo

Una serie de tiempo es un conjunto de datos sobre una variable de interés en el que las observaciones se toman de acuerdo con el orden en el tiempo (Montgomery et al., 2016; Wei, 2013). En el caso de estudio la variable corresponde a las unidades vendidas agregadas a nivel trimestral de la categoría hardware y subcategoría computadores & tablets de la compañía en estudio. Cuando se muestra en forma gráfica uno de los ejes representa la unidad de tiempo, normalmente el eje x, y en el eje y se relaciona la variable medida. Los puntos de datos se trazan y generalmente se conectan con líneas rectas, permitiendo así el análisis del gráfico. La característica fundamental de una serie de tiempo es que sus observaciones están correlacionadas (Wei, 2013), gracias a esto se pueden observar patrones como: tendencias, aleatorios, ciclos, cambios de nivel o atípicos. La figura 2-2 muestra un ejemplo de gráfico de series de tiempo con los datos de la variable de interés de este estudio desde el año 2015 al año 2019 por periodos trimestrales.

Las variaciones mensuales que se perciben en los gráficos pueden atribuirse a causas internas o externas, en aquellas internas se pueden presentar estrategias de marketing, ventas, financieras u otras, que busquen una estimulación o reducción en las cantidades acorde a los objetivos. Aunque parezca evidente que siempre se espera un aumento, más aún cuando la variable es consumo, hay ciertos casos que buscan el efecto contrario, como aquellos en los que se va a realizar el lanzamiento de un nuevo producto y su enfoque principal es canibalizar la demanda del producto antecesor, en esos casos se da un efecto de decrecimiento acorde a la etapa de declive.

Figura 2-2: Serie de tiempo unidades vendidas subcategoría H Computadores & Tablets.



Gráfica elaboración propia a partir de la base de datos de la compañía en estudio.

Las causas externas son atribuidas normalmente a factores que no son controlables por la compañía, por ejemplo: recesiones económicas, estrategias de la competencia, políticas gubernamentales, etc., Los factores externos tienen un efecto en el consumo que en algunos casos puede ser contrarrestado con estrategias internas, pero en otros dependiendo de su impacto se puede volver incontrolable y tener un reflejo claro en el resultado final de demanda. Los cambios generados por los factores internos y externos se identifican como valores atípicos y deben ser eliminados de la serie para tener información más precisa del consumo.

Una característica que también marca el comportamiento de la demanda son las variaciones del tipo estacional, se da una repetición para cada ciclo en el mismo periodo. Por ejemplo, hay fechas o climas durante el año que estimulan o reducen por sí solos el efecto de consumo, para esos casos se dice que la serie de tiempo subyacente atraviesa una variación cíclica predecible dependiendo de la época del año. Las estacionalidades se consideran como uno de los patrones estadísticos más utilizados para mejorar la precisión de los pronósticos de la demanda.

Otra característica clave de los comportamientos en las series de tiempo es la estacionariedad, se denomina estrictamente estacionario si su distribución de probabilidad conjunta es invariante con respecto a un cambio de origen temporal (Wei, 2013), una serie

de tiempo estacionaria exhibe un "comportamiento estadístico" similar en el tiempo y esto a menudo se caracteriza como una distribución de probabilidad constante (Montgomery et al., 2016), si el nivel medio no puede considerarse constante, se dice que una serie no es estacionaria (Box et al., 2016; Brockwell & Davis, 2016). No se debe confundir estacionariedad con estacionalidad, son dos características diferentes. Normalmente las series de tiempo con tendencias, o con estacionalidad, no son estacionarias, ya que esos dos parámetros pueden afectar el valor de la serie en tiempos diferentes, en aquellos casos en los que los ciclos son aperiódicos la serie sí es estacionaria (Montgomery et al., 2016).

2.2.1 Medidas de desempeño para el pronóstico de la demanda

Una de las etapas del proceso de pronósticos de la demanda es la evaluación, por este motivo, suele ser una buena práctica acompañar la medición con una estimación de la magnitud del error de pronóstico que se puede experimentar (Montgomery et al., 2016). Los componentes del error son la inconsistencia y el sesgo, variables que se busca minimizar si se quiere mejorar el pronóstico (J. Scott Armstrong, 2002). La mayoría de las investigaciones realizan comparaciones entre dos modelos evaluando el desempeño del pronóstico de la demanda mediante 3 medidas principales (Ren et al., 2020) :

- Error absoluto medio (MAE)
- Error porcentual absoluto medio (MAPE)
- Error cuadrático medio (MSE)

Cuanto más pequeño son los valores MAE y MSE se considera un modelo más preciso, siempre y cuando se realice la evaluación sobre los mismos datos puesto que no toman en cuenta la magnitud de los valores reales, en lugar de estos, la medida MAPE considera el valor real al medir el error porcentualmente, por esto, suele ser una medida ampliamente usada (Klimberg et al., 2010).

Lewis en el año 1982 desarrolló una escala para categorizar la precisión del pronóstico con la medida MAPE como se muestra en la figura 2-3, recomienda adicional a esto, validar si en el conjunto de datos hay una tendencia significativa o componente estacional que puede subestimar o sobreestimar la precisión.

Figura 2-3: Juicio de una escala de precisión del pronóstico desarrollada por Lewis

MAPE	Juicio de precisión pronóstico
Menor que 10%	Alta precisión
11% a 20%	Buen pronóstico
21% a 50%	Pronóstico razonable
51% o más	Pronóstico impreciso

Información tomada de (Klimberg et al., 2010)

Aun así, no sólo las medidas cuantitativas son parámetro de decisión para la selección de un modelo, los profesionales encargados de gestión de la demanda suelen incluir en sus valoraciones: velocidad, requisitos de suficiencia de datos, facilidad de uso e implementación y estabilidad (Ren et al., 2017)

Conforme a lo anterior, se determina realizar la evaluación y análisis de resultados acorde a las tres medidas usadas comúnmente MAE, MSE y MAPE. Se toma como referencia la medida MAPE para comparar los modelos implementados con y sin la depuración de datos.

2.3 Selección del modelo a implementar

Con la revisión de literatura se identifican tres tipos de investigaciones para la selección del modelo a implementar: 1) aquellas que han sido evaluadas en grupos estratégicos que pertenecen a la industria de artículos electrónicos de alta tecnología, 2) aquellas en las que el ciclo de vida del producto tiene etapas definidas por su corta duración (Kurawarwala & Matsuo, 1996) y 3) estudios realizados en la industria de moda como homóloga en el comportamiento de la demanda a la industria de la alta tecnología.

Para el caso de la industria moda, se contempla con comportamiento de demanda similar al tener temporadas de planificación, lanzamiento y puesta en marcha acorde a la evolución de las tendencias en vestuario. Actualmente cuenta con diferentes investigaciones enfocadas en inteligencia artificial y redes neuronales, estos modelos fueron descartados ya que a pesar de tener investigaciones en una industria que comparte características similares en el compartimiento de consumo, el cambio de los estándares

de moda no lleva consigo un “atraso” en los avances de desarrollo o productividad como sí se presenta en la industria que nos compete, por ende, en la industria moda se puede agregar los consumos de productos de años ilimitados, en cambio, en la industria de alta tecnología, pasada 1 década hay cambios drásticos en características físicas y técnicas de los productos respecto a los antecesores.

El avance de la tecnología se da a razón de las necesidad de automatización y optimización, generando así mejores equipos, con mayores capacidades y menores precios en lapsos de tiempo muy cortos, lo que se traduce en homologaciones por canibalización en un número bajo de décadas (Lu, 2014; Tandon et al., 2013; Wagner, 2008). Quizá a razón de lo mencionado anteriormente, se reducen notablemente las probabilidades de tener un índice alto de precisión si se comparan los computadores del año 1990 al año 2000, es decir, aquí se tiene poca data respecto a la cantidad requerida para la implementación de los modelos de redes neuronales.

Por otro lado, los recursos requeridos para el entrenamiento de las redes neuronales y la elección de parámetros vuelve inviable y complejo el entendimiento y la implementación en la práctica diaria por parte de las áreas de planificación de las diferentes compañías (Agostino et al., 2020; Ben Taieb & Koo, 2019; Rivera-Castro et al., 2019).

A pesar de que el tipo y la calidad de los datos es un factor importante para la implementación de modelos de pronósticos basados en históricos (Shankaranarayanan & Cai, 2006), en el presente trabajo no se tendrá en cuenta porque se busca identificar modelos que puedan mejorar los resultados que obtiene actualmente la compañía mediante la implementación del modelo “promedio móvil simple” con su base de datos actual, independiente de la calidad de esta. Dado lo anterior, la calidad de los datos se analizará durante la fase de limpieza y depuración para dar recomendaciones según se requiera, pero no se tiene en cuenta como un factor para la elección del modelo puesto que cualquiera que se implemente se trabajaría con la misma base de datos. El uso de modelos cualitativos requiere un proceso de gestión del cambio a largo plazo, por lo cual no se hace uso de estos para la ejecución del presente trabajo pero sí se incluye en las recomendaciones.

A partir de lo anterior se seleccionan los modelos implementados previamente por Radim Lenort Petr Besta en el año 2013 en su publicación titulada “Hierarchical Sales forecasting system for apparel companies”, y el implementado por Kejia Hu en el año 2019 en su

publicación titulada “Forecasting New product life cycle curves: Practical approach and empirical análisis” (Hu et al., 2019).

2.3.1 Modelo propuesto por Radim Lenort Petr Besta

Por parte de Lenort en el año 2013 se propone el manejo de niveles de agregación con el fin de crear un pronóstico con enfoque jerárquico del tipo “top-down/arriba-abajo” para generar un pronóstico de la demanda agregado por familia de productos y posteriormente realizar una desagregación en función de las proporciones históricas (Lenort & Besta, 2013). Para la ejecución de las proporciones históricas se realiza una asignación acorde a la relación en volumen de unidades entre el producto desagregado y la familia que lo compone, como proceso anterior se debe ejecutar el pronóstico de la demanda directo por producto (ver ecuación 3.1)

$$r_i = \frac{DCF_i}{\sum_{i=1}^n DCF_i} \quad (2.1)$$

Donde

i - proporción del producto $i - th$

DCF_i - pronóstico directo del producto $i - th$

n - número de productos que componen la línea.

$i = 1, 2, \dots, n.$

Para obtener la desagregación final se procede con la multiplicación del pronóstico de la demanda de la familia por la relación obtenida de cada producto según la ecuación 2.2 (ver ecuación 3.2)

$$FCF_i = FPF * r_i \quad (2.2)$$

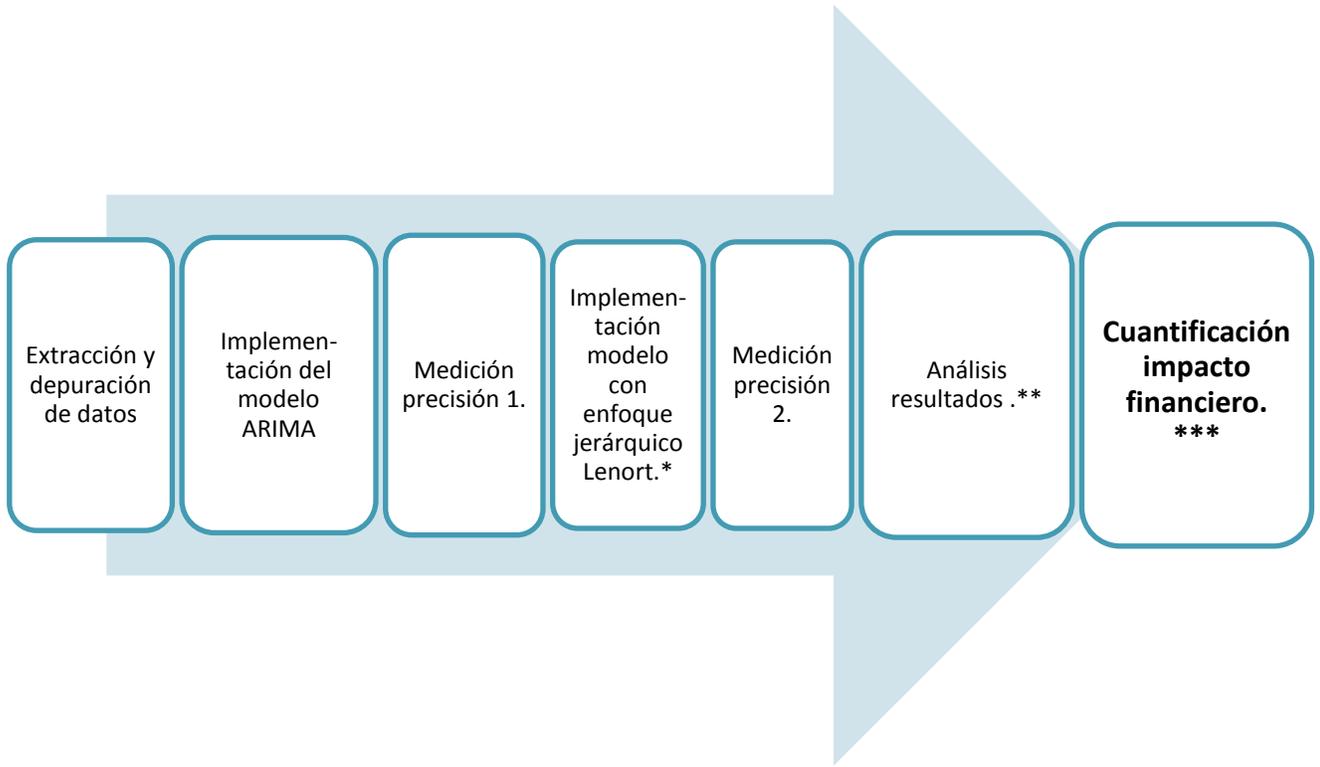
Donde

FCF_i = pronóstico final del producto i

FPF = pronóstico de la familia

Para la generación de los pronósticos de la demanda directos por línea y categoría de productos, Lenort realiza el uso del análisis de series de tiempo en el software estadístico "statgraphic 5.0" identificando existencia de componentes estacionales y de tendencia. Acorde a esto ejecutan los modelos adaptativo y Box Jenkis. Al medir la precisión con las medidas de desempeño RMSE, MAE, MAPE, ME y MPE, Lenort relaciona que los modelos con mayor exactitud en términos de minimizar error de pronóstico, son los modelos Box-Jenkins.

Con la revisión de literatura del comportamiento de la demanda, los modelos implementados en investigaciones anteriores y las medidas de precisión recomendada, se realiza la selección de los modelos a usar. A continuación, se describen las fases a desarrollar en todo el proceso de ejecución (ver figura 2-4), las cuales serán descritas en los capítulos posteriores.

Figura 2-4: Fases a desarrollar.

Gráfica elaboración propia.

(*) Para la implementación del modelo propuesto por Lenort, se debe asegurar la ejecución del pronóstico de la demanda agregado para la subcategoría de productos y posteriormente se asegura el pronóstico directo por cada línea. De allí, implementando el modelo con enfoque jerárquico se obtiene la desagregación de las unidades por línea.

(**) El análisis de resultados se realizará con enfoque en el proceso de gestión y planificación de demanda.

(***) El objetivo de implementación de todas las fases buscará la reducción de gastos financieros que pueden ser cuantificados a través de los costos ocultos de mantenimiento de inventario, enfocados en costo de oportunidad, tasas de interés de apalancamiento financiero y depreciación anual.

2.3.2 Modelo propuesto por Kejia Hu

Por parte de Hu en el año 2019 se propone desarrollar un enfoque que pueda implementarse para generar pronósticos de la demanda de productos nuevos similar a productos anteriores, en este caso se enfocan en el estudio en la compañía Dell como eslabón fabricante en la línea de computadores personales que como lo mencionan tienen una gran dependencia del ingreso de productos nuevos y ciclos de vida cortos (Agrawal & Schorling, 1996). Acorde a esto, caracterizaron el ciclo de vida en las etapas de introducción, crecimiento, madurez y declive, identificando así, una etapa de fuerte declive y una falta de etapa de madurez como lo había relacionado Goldman en el año 1982. El 50% de los productos analizados por Kejia Hu tenían una etapa de madurez de menos del 13% del ciclo de vida. Según esta identificación determinan diferentes curvas de ciclo de vida y concluyen que las de mejor ajuste corresponden a las compuestas por métodos simples como las curvas lineales por partes relacionadas a curvas triangulares y trapezoidales, que adicional a su ajuste son atractivas para implementar en la práctica al ser fácilmente cuantificables.

Kejia Hu y Jason Acimovic en su investigación realizan el estudio tanto para Dell como para un fabricante minorista de accesorios de computadores obteniendo también resultados consistentes. La metodología de implementación se presenta a continuación:

1. Uso de información histórica de un mismo clúster de productos con características similares para ajustar una curva de ciclo de vida.
2. Preparación y normalización de los datos
3. Ajuste de varias familias de curvas a los datos normalizados
4. Identificación de curvas con mejor ajuste y ejecución de pronóstico acorde a las curvas identificadas.

Con el fin de asegurar heterogeneidad entre los productos del mismo clúster, proponen el uso de los datos del ciclo de vida del producto normalizado con agrupamiento para operacionalizar la similitud entre los productos. Se realiza normalización tanto del volumen como de la longitud de la curva. La agrupación se propone acorde a la jerarquía de los productos o las especificaciones técnicas.

Como conclusión obtienen que su enfoque logra reducir los errores absolutos de pronóstico fuera de la muestra en aproximadamente el 3% con respecto a los pronósticos de Dell y más del 1% en las pruebas de robustez (Hu et al., 2019).

Finalmente, con la revisión del estado del arte se identifican los modelos usados para el pronóstico de la demanda tanto de la industria de la alta tecnología como de los eslabones que componen la cadena de suministro. Se selecciona el modelo ARIMA dada la relación por diferentes autores como un modelo que proporciona mejor desempeño o un desempeño igual al realizar la comparación con otros modelos y la facilidad de adopción e implementación respecto a los modelos de redes neuronales. Posterior al modelo ARIMA se propone la implementación del modelo con enfoque jerárquico para obtener el pronóstico desagregado para la línea computadores portátiles. El modelo con enfoque jerárquico se propone dado el uso en una investigación para la industria moda como homóloga en el comportamiento de la demanda a la industria de la alta tecnología. Adicionalmente, se propone la implementación del modelo por curvas de ciclo de vida dada la implementación en el eslabón fabricante para la misma industria que la compañía en estudio.

Se determina como métrica de desempeño principal para evaluar los pronósticos de la demanda la medida MAPE por considerar el error en términos porcentuales absolutos y con ello permitir la comparación de los modelos implementados independiente de la base de datos.

3. Implementación de los modelos seleccionados

La implementación de los dos modelos seleccionados se hace en 6 fases: la recopilación de los datos, la limpieza de los datos e identificación de los valores atípicos, la identificación de los grupos de productos, el análisis del comportamiento de la serie de tiempo y la selección de los parámetros para la implementación del modelo ARIMA, la implementación del modelo ARIMA e implementación del modelo con enfoque jerárquico y por último la implementación del modelo por curvas de ciclo de vida.

A continuación se describe el desarrollo de cada una de las fases para la implementación de los modelos.

3.1 Recopilación de los datos

En la ejecución de la primera fase se toma la base de datos de la empresa en estudio que se encuentra almacenada en el sistema de información de Oracle "Netsuite". La compañía lleva en este sistema de planificación de recursos empresariales (ERP) los módulos de ventas, contenido, finanzas, compras, alistamiento y despachos.

El módulo de ventas del sistema de información Netsuite cuenta con un submódulo para la administración de relaciones con el cliente (CRM) que permite el registro en el ERP de todo el proceso completo de la gestión de ventas y la ejecución de todas las actividades en la cadena de suministro. Este proceso está compuesto por cuatro etapas principales: registro de oportunidad y recepción de solicitud del cliente, compra y recibo de mercancía, alistamiento y embalaje de mercancía, despacho y entrega de mercancía y por último soporte postventa. Para seguir las cuatro etapas principales en el orden mencionado con anterioridad a nivel de sistema de información, en Netsuite se generan los siguientes documentos que son denominados "transacciones": oportunidad (OPO), cotización (COT),

orden de venta (ODVCO), orden de compra (ODCCO), recibo del artículo (RTO), remisión (EOC), factura (FACCO), autorización de devolución (DEVCO) y nota crédito (NCRCO).

Las transacciones orden de compra y recibo del artículo no se ejecutan en el 100% de las solicitudes de los clientes, únicamente se llevan a cabo en dos situaciones: 1) cuando el inventario disponible no es suficiente para surtir las órdenes de venta y 2) cuando es un producto con características especiales que se procesa ante el mayorista como “backorder/en lista de espera”.

Netsuite como plataforma de Oracle cuenta con alto grado de flexibilidad para acceder a la información registrada, permite a cualquier usuario diseñar y personalizar sus propios reportes acorde a su necesidad, no es esencial que una persona del equipo de tecnología realice un desarrollo para lograr acceso a un informe con cierto tipo de campos y características. Por ejemplo, el líder del área de finanzas puede crear su vista de reporte o “búsqueda guardada” como lo denomina Netsuite seleccionando como llave principal las cuentas contables y de allí acceder a todas las posibles transacciones que hayan impactado esa cuenta específica. Por otro lado, el líder del área de operaciones puede crear el mismo informe que creó el líder del área de finanzas con una llave principal diferente, puede usar el cliente, el proveedor o el artículo, y con esto acceder a la información de todas las transacciones asociadas a esa llave principal. Una visual para análisis completamente diferente a la obtenida por el líder del área de finanzas.

Netsuite también cuenta con la opción de programar con cierta frecuencia el envío de los reportes previamente personalizados. Por ejemplo, si un usuario necesita que a su correo llegue el reporte de inventario de manera diaria a las 12:00 pm para visualizar el monto de cierre por día y el costo de oportunidad, esto es posible.

Gracias a las características de personalización, programación en envío de información e integridad de los módulos del sistema ERP para todas las áreas de la compañía, la empresa no requiere ni usa otro sistema de información adicional para lograr la gestión y administración de las bases de datos. La arquitectura del sistema permite que los datos tengan una estructura dinámica contando con el atributo de compatibilidad, relevancia, información oportuna y orientación al usuario. Para lograr calidad en las bases datos que permita una correcta recopilación de la información, adicional a los atributos de compatibilidad, relevancia, información oportuna y orientación al usuario, los datos deben estar completos y permitir una facilidad en su uso. Para la compañía en estudio durante la

implementación de la fase de recopilación de los datos se identifica ausencia de datos completos generando dificultad en el uso y el análisis. Dado lo anterior se evidencian oportunidades de mejora a pesar de tener un sistema de información robusto, en este caso, debe existir una mejora en el usuario con un proceso diseñado a prueba de errores y no en el sistema. Actualmente no se asegura un registro completo de todos los campos disponibles en las diferentes transacciones ni en los maestros de artículos, de proveedores y de clientes. Esto conlleva pérdida de información y por ende dificultad en el uso de las bases de datos.

Con el objetivo de tener los atributos de datos completos y facilidad de uso en las bases de información de la compañía en estudio se recomienda asegurar un correcto registro en:

1. La creación de los artículos que componen el maestro de productos de la compañía: se debe asegurar el registro de toda la información relacionada con características técnicas y físicas. Esto con el objetivo de realizar una correcta agrupación e identificación de clústeres para reconocer un único comportamiento en diferentes referencias que probablemente satisfacen el mismo tipo de necesidad.
2. Los perfiles de cliente o identificación en la transacción ODV: se recomienda tener un campo en el formulario del cliente o en la transacción de la orden de venta para identificar si la venta corresponde o no a una licitación y por ende se categoriza como dato atípico. Ver figura 3-1
3. Las autorizaciones de devoluciones: cada vez que se genera una devolución de algún cliente se debe relacionar el causal en un campo de la transacción. Estas pueden ser de 3 tipos posibles: garantía, error interno o error cliente. Con ello sería posible identificar cuáles transacciones se perdieron por errores internos que llevaron al cliente a tomar la decisión de desistir de la compra y categorizar la venta como dato de demanda por venta perdida. Ver figura 3-1

Para el caso de gestión de demanda, con estas 3 acciones se cumpliría con los atributos de facilidad de uso e información completa, así sería posible considerar una buena calidad en las bases de datos. En este trabajo en la fase de limpieza de datos e identificación de los valores atípicos se realiza este proceso de manera manual y se relaciona la metodología usada para esa actividad.

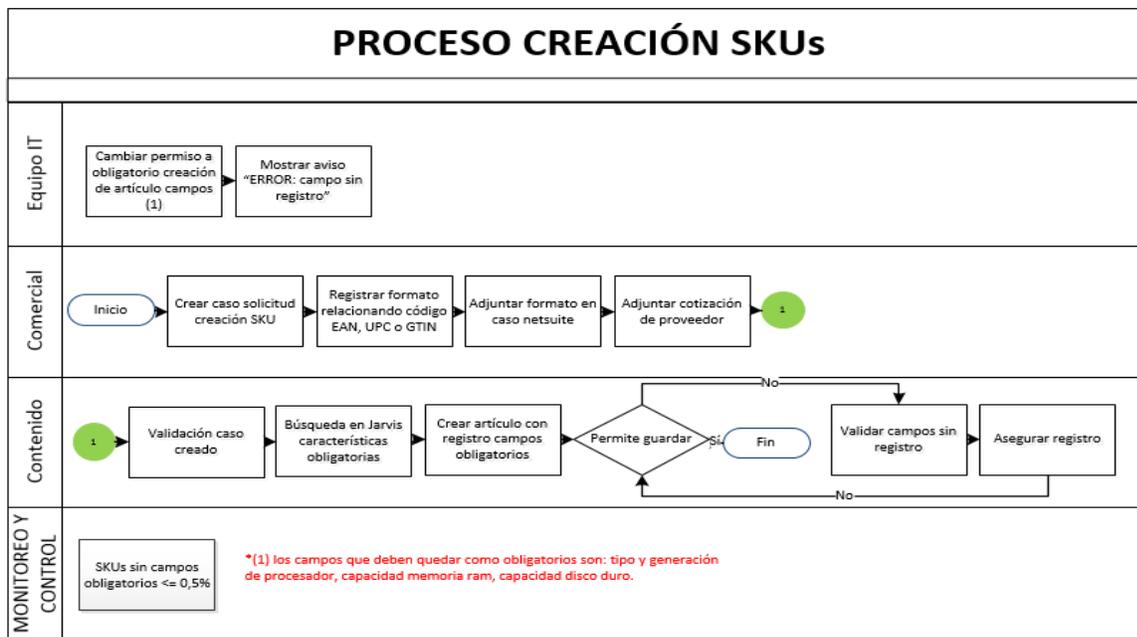
En la figura 3-2 se puede observar la propuesta planteada para la creación de los artículos con el objetivo de asegurar un correcto registro a futuro.

Figura 3-1: Proceso propuesto para identificar si la venta corresponde a una licitación y el causal de las devoluciones.



Gráfica elaboración propia a partir del proceso propuesto.

Figura 3-2: Proceso propuesto para la creación de un stock keeping unit (SKU).



Gráfica elaboración propia a partir del proceso propuesto.

El informe creado en netsuite para la extracción de los datos de demanda debe ser creado con los campos relacionados en la tabla 3-1 para las transacciones: cotización, orden de venta, factura, autorización de devolución y nota crédito.

Tabla 3-1: Ejemplo de un informe con los campos requeridos en Netsuite

Fecha de creación	Número de documento	Nombre	Artículo	Cantidad	OFI Categoría de Compras	OFI SubCategoría de compras	Código UPC	Fabricante	Marca	Familia	Procesador	Memoria RAM	Disco Duro	OFI NOTAS INTERNAS	Creado desde	Nota (principal)
18/11/2014 09:48:00 a. m.	FAC000902	CLI046537 C&M Consultores SA	32469 Computador Lenovo Thinkcentre M73	20	Hardware de Acceso	H Computadores & Tablets		HP Inc		Probook					ODV001116	

Tabla informe Netsuite

3.2 Limpieza de los datos e identificación de los valores atípicos.

En la ejecución de la segunda fase posterior a la recopilación de los datos se identifica cuáles transacciones se incluyen en los datos de la demanda y la fecha de registro correcta. La fecha de registro de la venta debe coincidir con la fecha de la solicitud del cliente.

En la revisión de las transacciones se identifica que existen diferencias en el mes de registro de la solicitud del cliente y el despacho de la mercancía respecto al mes de la ejecución de la factura debido a dos causas principales:

1. No se cuenta con todos los documentos para que el cliente acepte la radicación de la factura: en la mayoría de los casos los documentos corresponden a parafiscales, orden de compra del cliente y valor de la orden de compra coincidente con el valor de la factura.
2. El cliente ya ha cerrado el periodo de facturación del mes en el que se hace efectiva la entrega: los clientes suelen realizar cierre contable mensual y para ello determinan un día límite de recepción de facturas por parte de los proveedores, con esto aseguran cumplimiento en la entrega del estado de resultados mes a mes. Los días de cierre para la mayoría de los clientes son entre el día 20 y 25 de cada mes, pasado este día hasta el día 30 o 31 según corresponda, únicamente reciben mercancía con remisión como documento soporte.

Gracias al CRM el área de ventas puede hacer el registro con la fecha correcta desde que se recibe la primera solicitud del cliente hasta que se convierte en una venta confirmada sin importar el canal de recepción de la solicitud. Si el canal de contacto es la página web,

el call center o el KAM (Key account manager/ gerente de cuenta) siempre proceden con el registro en el sistema ERP de la oportunidad con el tercero asociado. Si la oportunidad pasa a la segunda etapa se genera una segunda transacción que queda como registro de cotización. Si la cotización se convierte en una orden de compra enviada por el cliente inmediato se crea una orden de venta en el sistema Netsuite, transacción que es procesada por las áreas de operaciones y finanzas para la entrega del producto o servicio al cliente. A razón de las diferencias entre las fechas de solicitud real del cliente respecto a las fechas de factura, se toma como fecha de venta la que corresponde a la creación de la transacción orden de venta (ODV). Se realiza el cambio en todas las fechas de las facturas por las fechas de la orden de venta.

En la verificación de las transacciones que se deben incluir en los datos de demanda se identifican ODVs que no son creadas por las áreas de ventas, corresponden a documentos realizados por el área de finanzas para generar una “re-facturación” o para legalizar alguna cuenta por cobrar pendiente a un tercero. Las re-facturaciones se generan por diferentes causales como: errores en los datos del tercero, la falta de inclusión de los comentarios solicitados previamente por el cliente (número de orden de compra, departamento que solicitó el servicio, centro de costos, etc.,) o diferencias en los valores aceptados por el cliente con respecto a los valores estipulados en la factura.

Para hacer la re-facturación el área de finanzas genera una nota crédito (NCR) directamente desde la factura que se quiere anular. Al realizar la transacción directamente desde la factura se genera un cargue de las unidades al inventario y una anulación de la cuenta por cobrar. Posterior a la ejecución de la nota crédito el área financiera realiza una nueva orden de venta para dar salida a las unidades que se cargaron en el inventario y para generar la nueva factura con los datos correctos. El proceso mencionado anteriormente también genera diferencias entre el mes de la fecha real de la solicitud del cliente respecto al mes de la fecha de la nueva factura. En la mayoría de los casos la diferencia es hasta de dos meses o más porque el error se detecta cuando el cliente lo manifiesta. En algunos casos en el mismo momento de la entrega y radicación de la factura el cliente procede con el rechazo del documento por falta de algún criterio como los especificados anteriormente, en otros casos el cliente no realiza el rechazo en el mismo momento de la radicación de la factura sino mucho tiempo después, quizá cuando ya han pasado los 30 o 60 días de crédito y debe proceder con el pago.

Infortunadamente hay clientes que aprovechan la falta de información o error en las facturas para postergar el pago y hasta el momento del vencimiento informan que la factura no puede ser pagada porque tienen algún error, o informan la ausencia de registro por pérdida del documento. Para este último caso mencionan no tener un registro efectivo en su sistema. Aunque esto es de interés de estudio no nos compete en el desarrollo de este trabajo, se propone como recomendación en futuras investigaciones.

La nota crédito no solo se genera cuando se requiere hacer una re-facturación sino también cuando el cliente decide hacer una devolución del producto o servicio entregado. Se hace uso del documento autorización de devolución (DEVCO) para diferenciar las transacciones que corresponden a una devolución real de mercancía con respecto a anulaciones por error en los datos. Cada vez que el cliente realiza un contacto para solicitar algún tipo de devolución se realiza en el sistema la creación de un caso del tipo “novedad postventa”. El área de novedades postventa asegura el contacto con el cliente y genera en el sistema la transacción DEVCO en los casos que se puede aceptar la devolución acorde a la política de devoluciones y retracto. La transacción DEVCO certifica que la devolución del producto o servicio está autorizada para seguir el proceso de revisión y aceptación. Únicamente el área de novedades postventa tiene el permiso a nivel de rol en el sistema para generar el documento DEVCO. El área de novedades postventa lleva a cabo el proceso en Netsuite de forma simultánea a la realización del proceso físico, es decir, no completan la transacción DEVCO hasta no tener el artículo en la bodega o certificada la recepción por parte del proveedor. Esto confirma lo anteriormente explicado sobre la diferenciación de las notas crédito por devolución real de mercancía respecto a las notas crédito por error en datos por medio del documento de autorización de devolución. Gracias a la diferenciación de las notas crédito no se toma como transacción de venta las facturas que corresponden a ODVs creadas por el área financiera ni las notas crédito que no cuentan con una DEVCO, únicamente se incluyen en los datos de demanda las notas crédito realizadas por devolución de la mercancía o el servicio.

Por otro lado, a pesar de tener un registro efectivo de todas las oportunidades y cotizaciones presentadas no existe una etiqueta para identificar la causal de aquellas oportunidades que no tuvieron una conversión positiva a orden de venta. Se relaciona que existe un registro efectivo de las oportunidades porque la compañía mide con base a este dato todo lo que se clasifica como “backlog/trabajo pendiente” y con ello se miden los indicadores del área de ventas. Existe baja probabilidad de que se reciba una solicitud sin

tener un registro en el sistema, así lo expresa el director del área comercial. Al no tener una etiqueta que categorice la causal de pérdida de la cotización no fue posible medir la venta perdida que tiene la empresa por causa de una falta de inventario y considerar este como un dato de demanda.

Las devoluciones reales generadas por los clientes también deben tener una identificación de la causal para clasificarlas como dato de demanda por venta perdida cuando así corresponda. Como se mencionó anteriormente, es posible identificar cuáles notas crédito corresponden a devolución de la mercancía o servicio por parte del cliente gracias al documento DEVCO. Aunque existe el documento que certifica la aceptación no existe ninguna etiqueta o campo en la transacción en la que el área de novedades postventa registre la causal de la devolución. Si el cliente desiste de la compra posterior a la devolución por un error interno de la compañía esta venta no se incluye como dato de demanda.

Los errores a nivel interno que son causal de no conversión de una orden de venta en factura son: traducción errónea de la solicitud del cliente a los números de parte relacionados en el maestro de productos de la empresa, entendimiento erróneo de la necesidad del cliente, registro erróneo de cantidades solicitadas por el cliente versus cantidades registradas en ODV y comunicación errónea al cliente del precio real del producto. Todos estos errores pueden causar algún grado de inconformismo en el cliente y que decida desistir de la compra en lugar de recibir cambio por el producto que sí había solicitado o aceptar el cambio en el precio. Allí indudablemente se da una venta perdida que sí debería hacer parte del dato de demanda. Dado lo anterior, no se tiene en cuenta en los datos de la demanda la venta perdida por conversión positiva de cotización pero que no se refleja en factura por algún error a nivel interno.

A pesar de no poder contar con este dato, se indagó con el área de novedades postventa las posibles causales de devolución y cuáles se presentaban con mayor frecuencia acorde a su percepción, con el objetivo de identificar si se tiene riesgo de tener alta desviación por este causal y por ende dar una recomendación asociada.

La empresa cuenta con canal de licitaciones que presentan las entidades del estado mediante la plataforma “Colombia compra eficiente” a lo largo del año, estas son negociaciones puntuales que tienen un proceso de presentación de propuestas mediante RFPs (Request for Quotation /petición de cotización) y RFQs (Request for proposal) y

tienen un proceso de protección por parte del fabricante. Estas licitaciones son surtidas mediante el modelo MTO (make to order/ hecho bajo orden) ya que tienen unas características y precios puntuales dando un tiempo específico para el cumplimiento del contrato. Por otro lado, estas ventas no tienen un impacto representativo a nivel de asignación de capital ya que para este tipo de proyectos finanzas realiza una cesión de contrato a las entidades bancarias con el objetivo de tener un apalancamiento que no emplea los cupos de créditos destinados para la función del negocio diaria, por ello, las licitaciones no se contemplan dentro de los datos a ser analizados en este trabajo.

No fue posible realizar una identificación de las órdenes de venta que corresponden a licitaciones por medio de la transacción ni por medio de los datos del cliente. Actualmente la empresa no tiene una etiqueta ni en la transacción ODV ni en el formulario del perfil del cliente para una rápida tipificación. En algunos documentos de cotización se identificaron notas con la palabra “licitación” pero esto no se presentaba de manera estándar en el 100% de los casos. Para identificar las ventas que corresponden a licitación fue necesario validar la razón social del tercero y de manera cualitativa identificar las empresas que posiblemente pertenecían o no a empresas del estado. Después de hacer esa identificación se realizó la validación por medio de la cámara de comercio o RUT. La verificación por la razón social junto con el cruce de los comentarios en la cotización fue la validación para exclusión de las transacciones correspondientes a licitaciones.

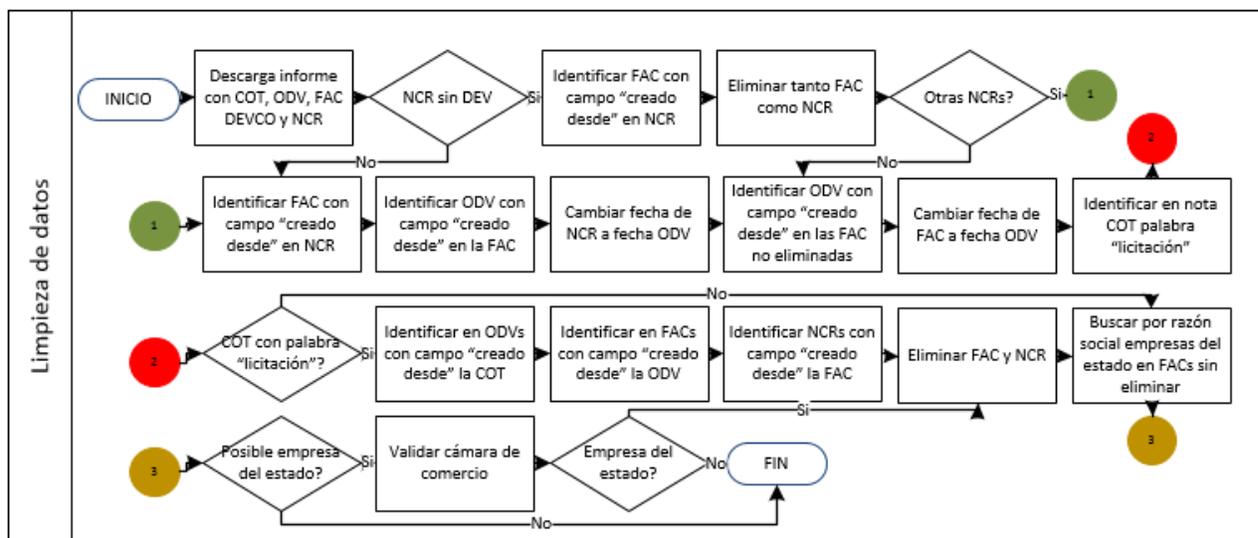
Como resultado final del proceso de análisis de los datos para la identificación de las transacciones que se deben tener en cuenta en los datos de la demanda y las fechas que corresponden a la solicitud del cliente se puede concluir:

- Únicamente se tomaron como dato de demanda las transacciones de ODV que tenían efectiva alguna factura, asignando como fecha de la transacción la fecha de la orden de venta.
- Para el 100% de las notas crédito existe un campo en la transacción denominado “creado desde” en el cual se puede identificar si son creadas desde una FACCO o desde una DEVCO, este mismo campo también se puede visualizar en todas las transacciones registradas en Netsuite. Dado lo anterior, a las transacciones de notas crédito se les asignó la fecha de la ODV como documento inicial. También se anularon las NCRs que no correspondían a una devolución real sino a un error en los datos y a su vez la factura creada para anular esa NCR.

- Se anulaban las facturas asociadas con terceros que correspondían a licitaciones.

En la figura 3-3 se puede visualizar el flujograma con la descripción de pasos a seguir para ejecutar el proceso de depuración de datos descrito anteriormente.

Figura 3-3: Proceso realizado para la depuración de los datos



Gráfica elaboración propia a partir del proceso realizado.

3.3 Identificación de los grupos de productos

Para la implementación del modelo propuesto por Kejia Hu en el año 2019, en su publicación "Forecasting New product life cycle curves: Practical approach and empirical análisis" (Hu et al., 2019) por curvas de ciclo de vida, fue necesario identificar las características que se tendrían en cuenta para la definición de los clústeres, para ello se indagó con el área de compras de la compañía dado el conocimiento que tienen sobre la industria de la alta tecnología. Se identificaron tres características principales que se tienen en cuenta en la compra de computadores portátiles: el tipo y generación de procesador, la capacidad de disco duro y la capacidad de memoria RAM. A pesar de que los procesos efectuados por el área de contenido para la creación y el mantenimiento del maestro de productos también son gestionados mediante el ERP, al descargar la información de las 347 referencias que componen la subcategoría "H Computadores & Tablets", únicamente el 27% tenían registro de capacidad de memoria, el 26% registro de capacidad de disco duro y el 20% registro del tipo y generación del procesador. Debido a esta ausencia de

datos, para aquellas referencias que no tenían alguno de los campos registrados se realizó la identificación mediante la página ICECAT⁵ con el número de parte. Para las referencias que no se podía obtener con la base gratuita de icecat, se genera la búsqueda en la página de los fabricantes mediante alguno de los seriales que tiene la transacción en el sistema. Se categorizan las 3 características así:

- Tipo y generación de procesador: AMD, Intel Pentium o Celeron, Intel Core i3, Intel Core i5 e Intel Core i7
- Capacidad de disco duro: $x \leq 4$ GB, 4 GB $< x \leq 16$ GB, siendo x la capacidad del disco duro.
- Capacidad de memoria RAM: $x \leq 256$ GB, 256 GB $< x \leq 500$ GB y $x > 500$ GB, siendo x la capacidad de memoria RAM.

De allí, se identifican 30 grupos como se relaciona en la tabla 3-2

⁵ se puede consultar catálogo abierto <https://icecat.biz/es>

Tabla 3-2: Clúster identificados acorde a las características de los artículos para realizar el pronóstico por curvas de ciclo de vida.

Tipo procesador	Capacidad memoria Ram (x)	Capacidad Disco duro (x)
AMD	$x \leq 4$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
	$4 \text{ GB} < x \leq 16$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
Intel Pentium o Celeron	$x \leq 4$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
	$4 \text{ GB} < x \leq 16$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
Intel Core i3	$x \leq 4$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
	$4 \text{ GB} < x \leq 16$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
Intel Core i5	$x \leq 4$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
	$4 \text{ GB} < x \leq 16$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
Intel Core i7	$x \leq 4$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB
	$4 \text{ GB} < x \leq 16$ GB	$x \leq 256$ GB
		$256 \text{ GB} < x \leq 500$ GB
		$x > 500$ GB

Tabla elaboración propia

3.4 Análisis del comportamiento de la serie de tiempo y la selección de los parámetros para la implementación del modelo ARIMA

Como se mencionó en el capítulo anterior, para la implementación del modelo con enfoque jerárquico propuesto por Lenort primero se debe realizar los pronósticos agregados y para esto se seleccionó el modelo ARIMA. Para la ejecución del modelo ARIMA se usó código Python en Google Colaboratory.

Con el objetivo de seleccionar los parámetros del modelo ARIMA se realiza la validación del componente de media móvil y el componente autorregresivo. Para el componente de media móvil se observa en la figura 3-4 que el coeficiente de autocorrelación en ningún caso supera el $\pm 25\%$. La línea intermitente en el gráfico representa el rango de $\pm 25\%$ y la serie azul representa el porcentaje de autocorrelación que tiene cada uno de los periodos: $t-1$, $t-2$, $t-3$ y $t-4$ respecto al periodo t . Dado el porcentaje de correlación por debajo de $\pm 25\%$ se establece que los valores que toman la variable en el tiempo son independientes entre sí, existiendo un comportamiento sin dependencia o correlación de las observaciones anteriores, por lo tanto, se puede establecer tentativamente un valor de 0 para el proceso de media móvil.

Figura 3-4: Función autocorrelación serie de tiempo demanda subcategoría “H Computadores & Tablets”.

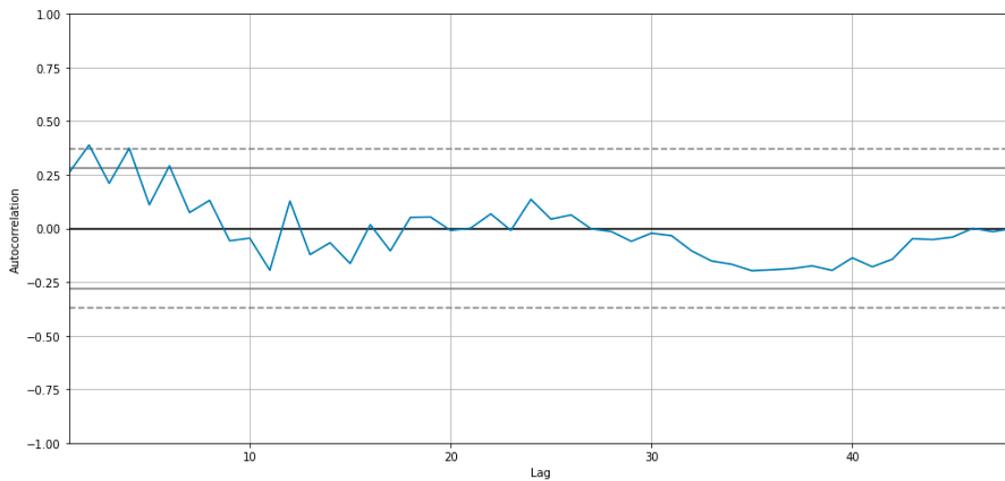
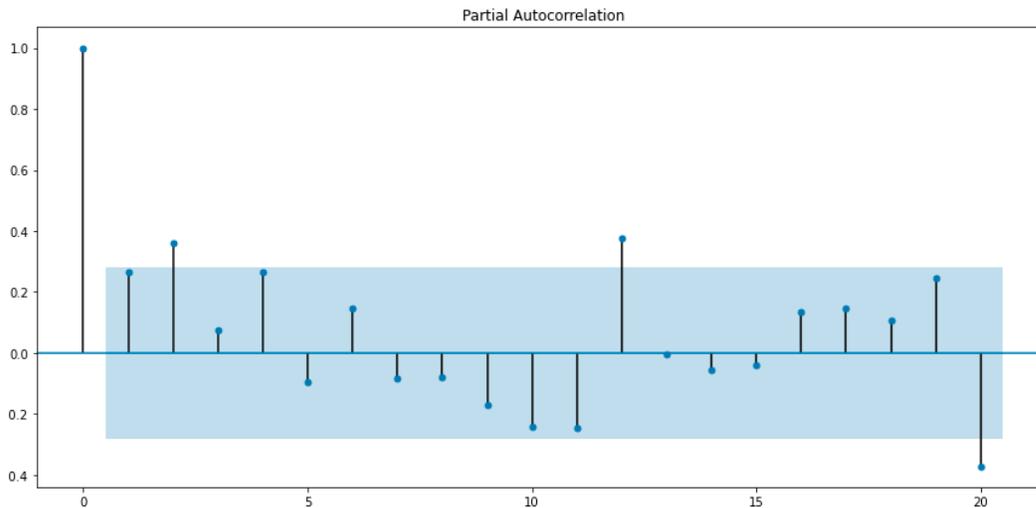


Figura 3-5: Función autocorrelación parcial serie de tiempo demanda subcategoría “H Computadores & Tablets”.



Para el caso del proceso autorregresivo, se realiza validación de la función de autocorrelación parcial con la intención de verificar si existe alguna correlación sin considerar la dependencia creada por los retardos intermedios existentes, en la figura 3-5 se puede ver la existencia de correlación en 4 de los puntos (2, 12 y 20), por lo que probablemente tomando un único rezago se estaría teniendo en cuenta esta característica en el comportamiento del pronóstico de la demanda.

Adicional, como se observa en la figura 3-6 se realiza la validación con la prueba de Dickey Fuller Aumentada (ADF) con el objetivo de identificar la existencia de raíces unitarias y verificar estacionariedad, obteniendo un valor de 0,03. La prueba de hipótesis en el test Fuller indica que siempre que el p-value de rezagos sea mayor a 0,05 la serie no es estacionaria. Un p-value de 0,03 indica que hay evidencia significativa para rechazar la hipótesis nula que los datos no son estacionarios. Los datos de la demanda de la subcategoría “H Computadores & Tablets” de la compañía en estudio presentan un comportamiento estacionario.

Figura 3-6: Resultado test Fuller Aumentada (ADF) serie de tiempo demanda subcategoría H Computadores & Tablets.

```

ADF Test Statistic : -2,9794405555387407
p-value : 0,03685951371988469
#Lags Used : 1
Number of Observations : 35
strong evidence against the null hypothesis(Ho), reject the null
hypothesis. Data is stationary

```

Gráfica google colab

Tabla 3-3: Criterio Akaike serie de tiempo demanda subcategoría “H Computadores & Tablets”.

```

ARIMA(2,1,2) (0,0,0) [0] intercept : AIC=inf, Time=0.32 sec
ARIMA(0,1,0) (0,0,0) [0] intercept : AIC=709.586, Time=0.01 sec
ARIMA(1,1,0) (0,0,0) [0] intercept : AIC=691.206, Time=0.09 sec
ARIMA(0,1,1) (0,0,0) [0] intercept : AIC=inf, Time=0.06 sec
ARIMA(0,1,0) (0,0,0) [0] : AIC=707.640, Time=0.01 sec
ARIMA(2,1,0) (0,0,0) [0] intercept : AIC=691.271, Time=0.03 sec
ARIMA(1,1,1) (0,0,0) [0] intercept : AIC=inf, Time=0.13 sec
ARIMA(2,1,1) (0,0,0) [0] intercept : AIC=inf, Time=0.21 sec
ARIMA(1,1,0) (0,0,0) [0] : AIC=689.333, Time=0.03 sec
ARIMA(2,1,0) (0,0,0) [0] : AIC=689.440, Time=0.02 sec
ARIMA(1,1,1) (0,0,0) [0] : AIC=684.521, Time=0.06 sec
ARIMA(0,1,1) (0,0,0) [0] : AIC=683.423, Time=0.03 sec
ARIMA(0,1,2) (0,0,0) [0] : AIC=684.642, Time=0.06 sec
ARIMA(1,1,2) (0,0,0) [0] : AIC=682.966, Time=0.13 sec
ARIMA(2,1,2) (0,0,0) [0] : AIC=684.896, Time=0.16 sec
ARIMA(1,1,3) (0,0,0) [0] : AIC=684.872, Time=0.13 sec
ARIMA(0,1,3) (0,0,0) [0] : AIC=686.539, Time=0.10 sec
ARIMA(2,1,1) (0,0,0) [0] : AIC=686.292, Time=0.10 sec
ARIMA(2,1,3) (0,0,0) [0] : AIC=685.695, Time=0.28 sec
ARIMA(1,1,2) (0,0,0) [0] intercept : AIC=inf, Time=0.21 sec

```

Best model: ARIMA(1,1,2) (0,0,0) [0]

Total fit time: 2.216 seconds

Para validar con otra opción los parámetros del modelo se hace uso del criterio de información Akaike como método matemático para evaluar qué tan bien se ajusta el modelo a los datos. Se comparan diferentes combinaciones en los parámetros autorregresivo, integrado y media móvil de los modelos ARIMA y el criterio determina cuál es el que mejor se ajusta a los datos. El modelo de mejor ajuste según el criterio Akaike es el que adopta la mayor cantidad de variaciones utilizando la menor cantidad de variables independientes posibles. El criterio Akaike describe la relación entre el sesgo y la varianza, por lo tanto, se reduce cuando aumenta la bondad de ajuste y el de menor resultado es el mejor modelo. Al implementar el criterio al modelo ARIMA con los datos de la empresa en estudio se obtienen los resultados relacionados en la tabla 3-3.

La combinación de parámetros autorregresivo, integrado y media móvil que arroja menor valor para el criterio akaike es (1,1,2), razón por la que se relaciona como el mejor modelo en el resumen de la corrida del código akaike en Python (ver tabla 3-3). Al correr el modelo ARIMA con los parámetros (1,1,2) en google colabory con código python se presenta problema de no invertibilidad. Debido a esto, se corren los modelos con las posibles opciones que no presentan problema de no-estacionariedad, no convergencia y no invertibilidad, obteniendo como combinación de parámetros con menor error MSE y menor criterio akaike el (1,1,0). Con esto es posible tomar la relación que se detectó en la gráfica de autocorrelación parcial y contemplar como viable el factor de rezago de 1 en el componente autorregresivo. Como el uso de 2 rezagos en el componente móvil genera no invertibilidad, se puede determinar que el supuesto tomado con la validación de la función de autocorrelación en la cual no se evidencia un requerimiento de inclusión de algún factor para el componente de media móvil es correcto, por lo tanto, se relaciona el parámetro 0 que se había identificado en la validación de la función de autocorrelación.

3.5 Implementación del modelo ARIMA e implementación del modelo jerarquía propuesto por Radim Lenort Petr Besta

Para la implementación del modelo “Hierarchical sales forecasting system” propuesto por Radim Lenort Petr Besta en el año 2013 se implementa previamente el modelo ARIMA para obtener los pronósticos de la demanda para la Subcategoría H Computadores & Tablets y la línea computadores portátiles. Después de la implementación del modelo ARIMA se implementa el modelo con enfoque jerárquico como se mencionó en el capítulo 2.3.1.

Para la implementación del modelo ARIMA se hace uso de Google Colaboratory con la biblioteca statsmodels y el código Python statsmodels.tsa.arima_model. El código Python mencionado ejecuta el modelo autorregresivo integrado de promedio móvil ARIMA utilizando variaciones y regresiones de los datos estadísticos y encuentra patrones para la predicción de los datos futuros. La combinación de parámetros autorregresivo, integrado y de media móvil usados para correr el modelo son (1,1,0) acorde a la identificación realizada en el capítulo 3.4. En el anexo B se puede observar el código completo Python usado para correr el modelo.

Para la implementación del modelo “Hierarchical sales forecasting system” se realiza la identificación de las líneas que componen la subcategoría H Computadores & Tablets. La subcategoría se encuentra compuesta por tres líneas principales: portátiles, servidores, tablets & todo en uno & PCs. El modelo ARIMA se implementa de manera agregada para la subcategoría H computadores & Tablets y también se implementa de manera individual para cada una de las 3 líneas que componen la subcategoría.

El modelo con enfoque jerárquico como lo propone Lenort se realiza del tipo “top-down/arriba-abajo”. Con los datos de predicción del modelo ARIMA a nivel de línea se determina la proporción histórica que tiene cada línea en el total de las unidades de la sumatoria de los pronósticos individuales, como se relaciona en la ecuación 3.1:

$$r_i = \frac{DCF_i}{\sum_{i=1}^n DCF_i} \quad (3.1)$$

Donde

i = proporción de la línea $i - th$

DCF_i = pronóstico directo de la línea $i - th$

n = número de líneas que componen la subcategoría H Computadores & Tablets.

$i = 1,2,3$.

Siendo

1 = *Portátiles*

2 = *Servidores*

3 = *Tablets & todo en uno & PCs*

Para obtener la desagregación final se procede con la multiplicación del pronóstico de la demanda de la subcategoría H computadores & Tablets por la relación obtenida de cada línea según la ecuación 3.1 (ver ecuación 3.2)

$$FCF_i = FPF * r_i \quad (3.2)$$

Donde

FCF_i = pronóstico final de la línea $i - th$

FPF = pronóstico de la subcategoría H Computadores & Tablets.

3.6 Implementación del modelo por curvas de ciclo de vida propuesto por Kejia Hu

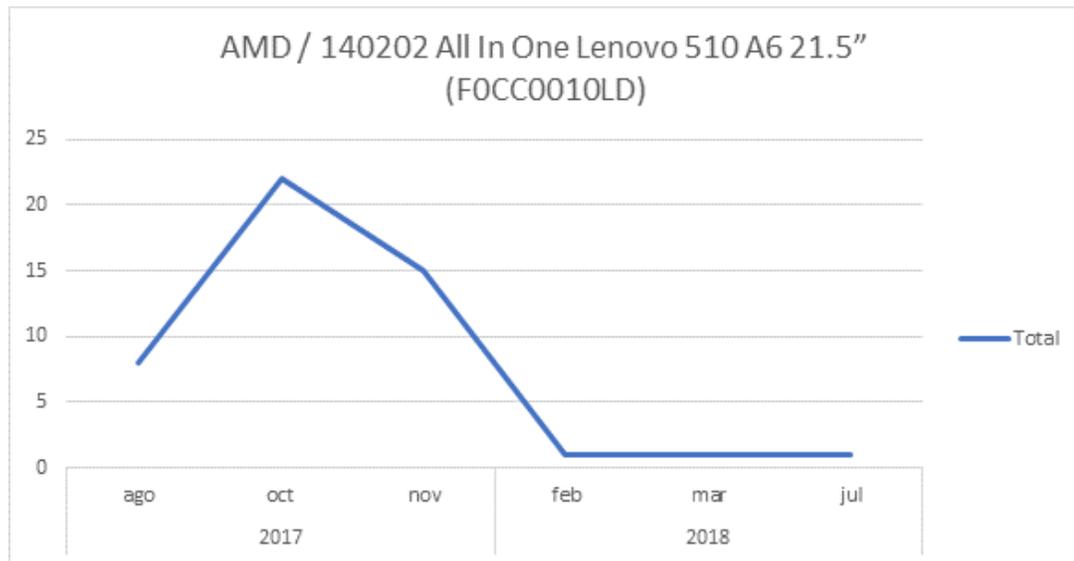
Una vez realizadas las anteriores etapas se cuenta con los clústeres compuestos por los artículos que cumplen las mismas características en términos de procesador, capacidad de memoria RAM y capacidad de disco duro. Se realiza la gráfica para el artículo de mayor venta y frecuencia para los 30 grupos identificados. Al realizar la gráfica se observa que a nivel del eslabón de distribuidor no hay una identificación clara de ciclos de vida. No es posible identificar las etapas de introducción, desarrollo y declive. El eslabón minorista distribuidor no cuenta con los datos del 100% de las ventas de los artículos fabricados por cada referencia. El fabricante tiene los datos de venta agregados por cada referencia que sale al mercado, cada distribuidor tiene una proporción en participación de la venta de cada artículo respecto a la producción total. La desagregación que tiene el minorista hace que los artículos no tengan un ciclo de vida claro desde su perspectiva de demanda.

Para descartar que no se diera la visualización por una única cantidad de artículos en un mismo grupo se realizó agregación solamente a nivel de tipo de procesador, a pesar de

ello sigue sin existir una visualización en las etapas del ciclo de vida como se menciona en la investigación de Kejia Hu.

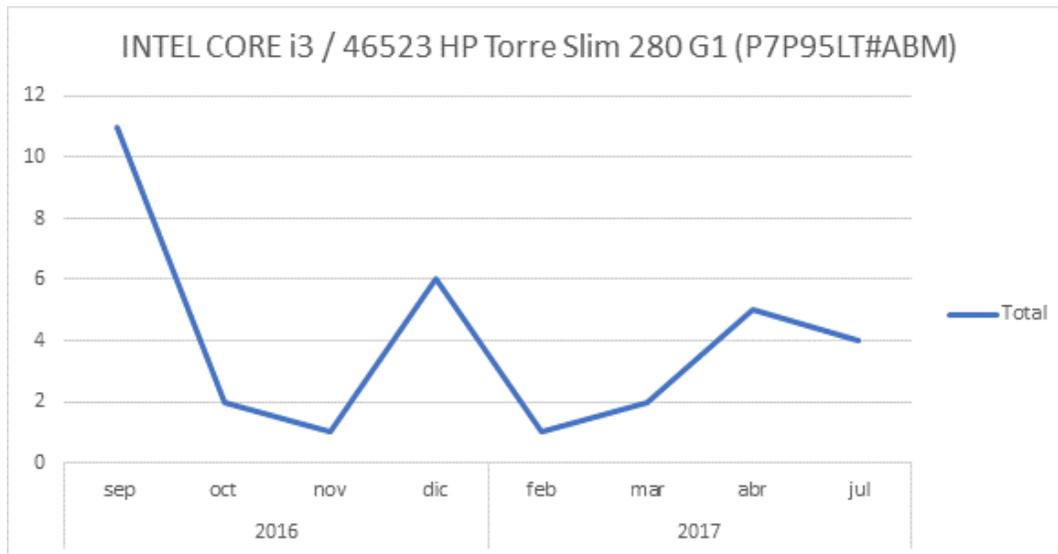
El comportamiento para el artículo de mayor cantidad de meses con registro de venta para cada categoría de procesador: AMD, Intel Core i3, Intel core i5, Intel core i7 e Intel Pentium o celeron se puede visualizar en las figuras 3-7, 3-8, 3-9, 3-10 y 3-11 respectivamente. En las figuras se puede validar que no hay existencia de ciclos de vida claros. Dado la no visibilidad de las etapas del ciclo de vida en el comportamiento de la demanda con los datos de la empresa en estudio, se descarta la recomendación del uso de este modelo y no se generan análisis en los capítulos siguientes.

Figura 3-7: Comportamiento de ventas en el ciclo de vida de los productos con procesador AMD



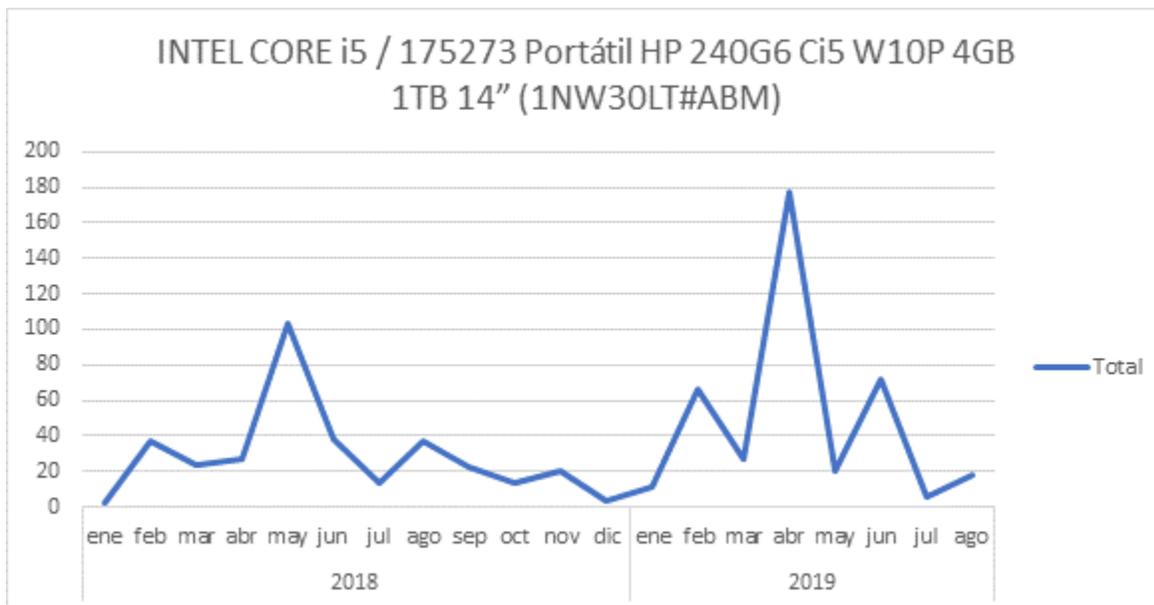
Gráfica elaboración propia a partir de la base de datos de la compañía en estudio

Figura 3-8: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel core i3



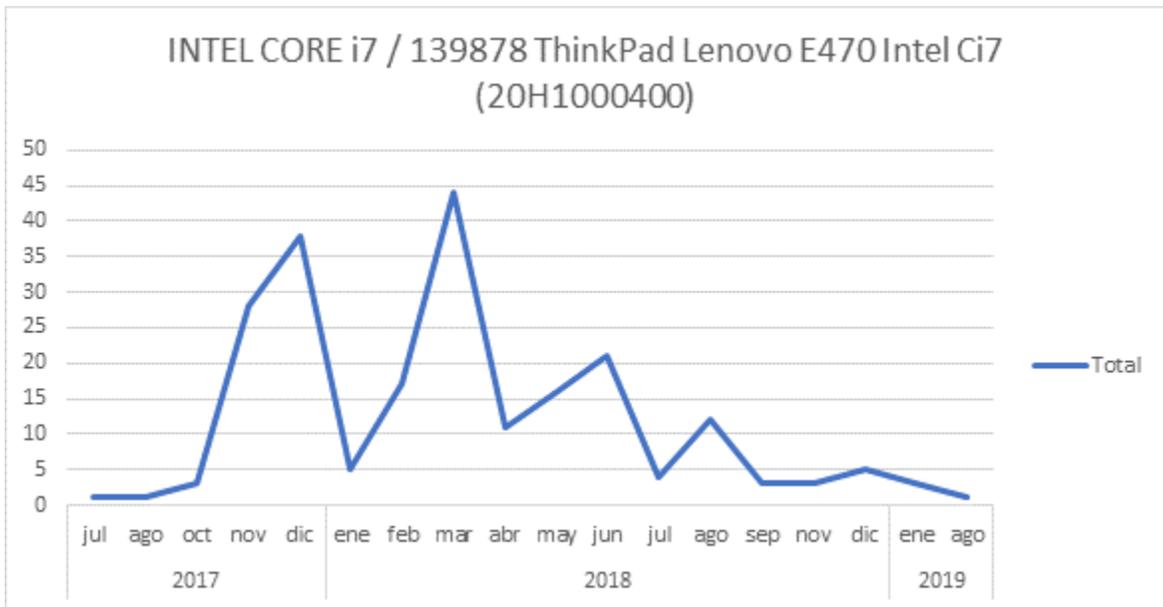
Gráfica elaboración propia a partir de la base de datos de la compañía en estudio

Figura 3-9: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel core i5



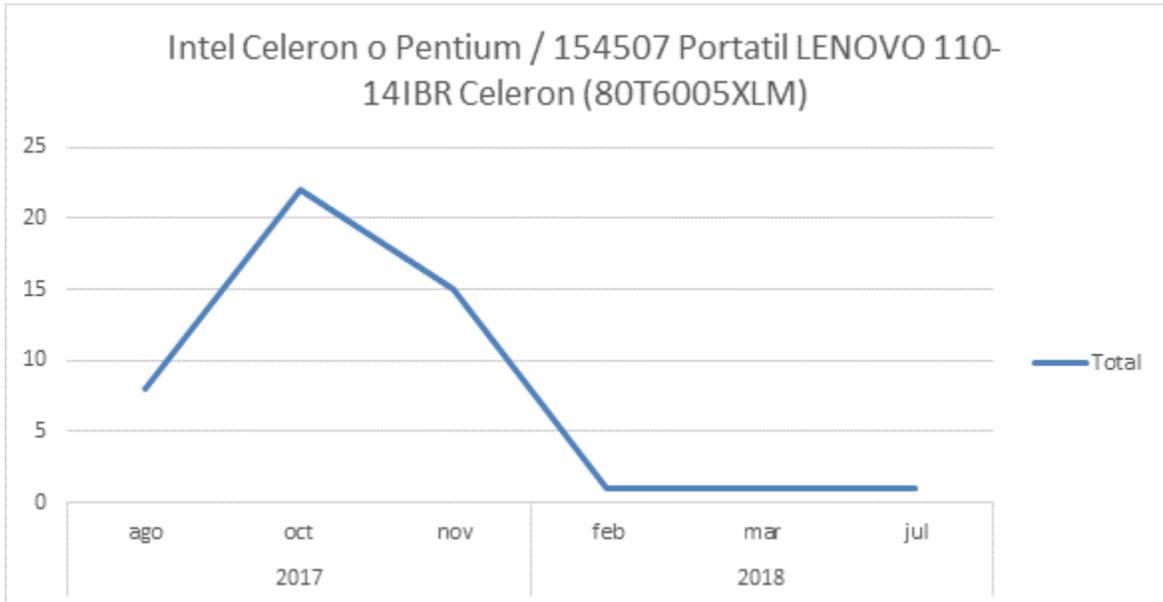
Gráfica elaboración propia a partir de la base de datos de la compañía en estudio

Figura 3-10: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel core i7



Gráfica elaboración propia a partir de la base de datos de la compañía en estudio

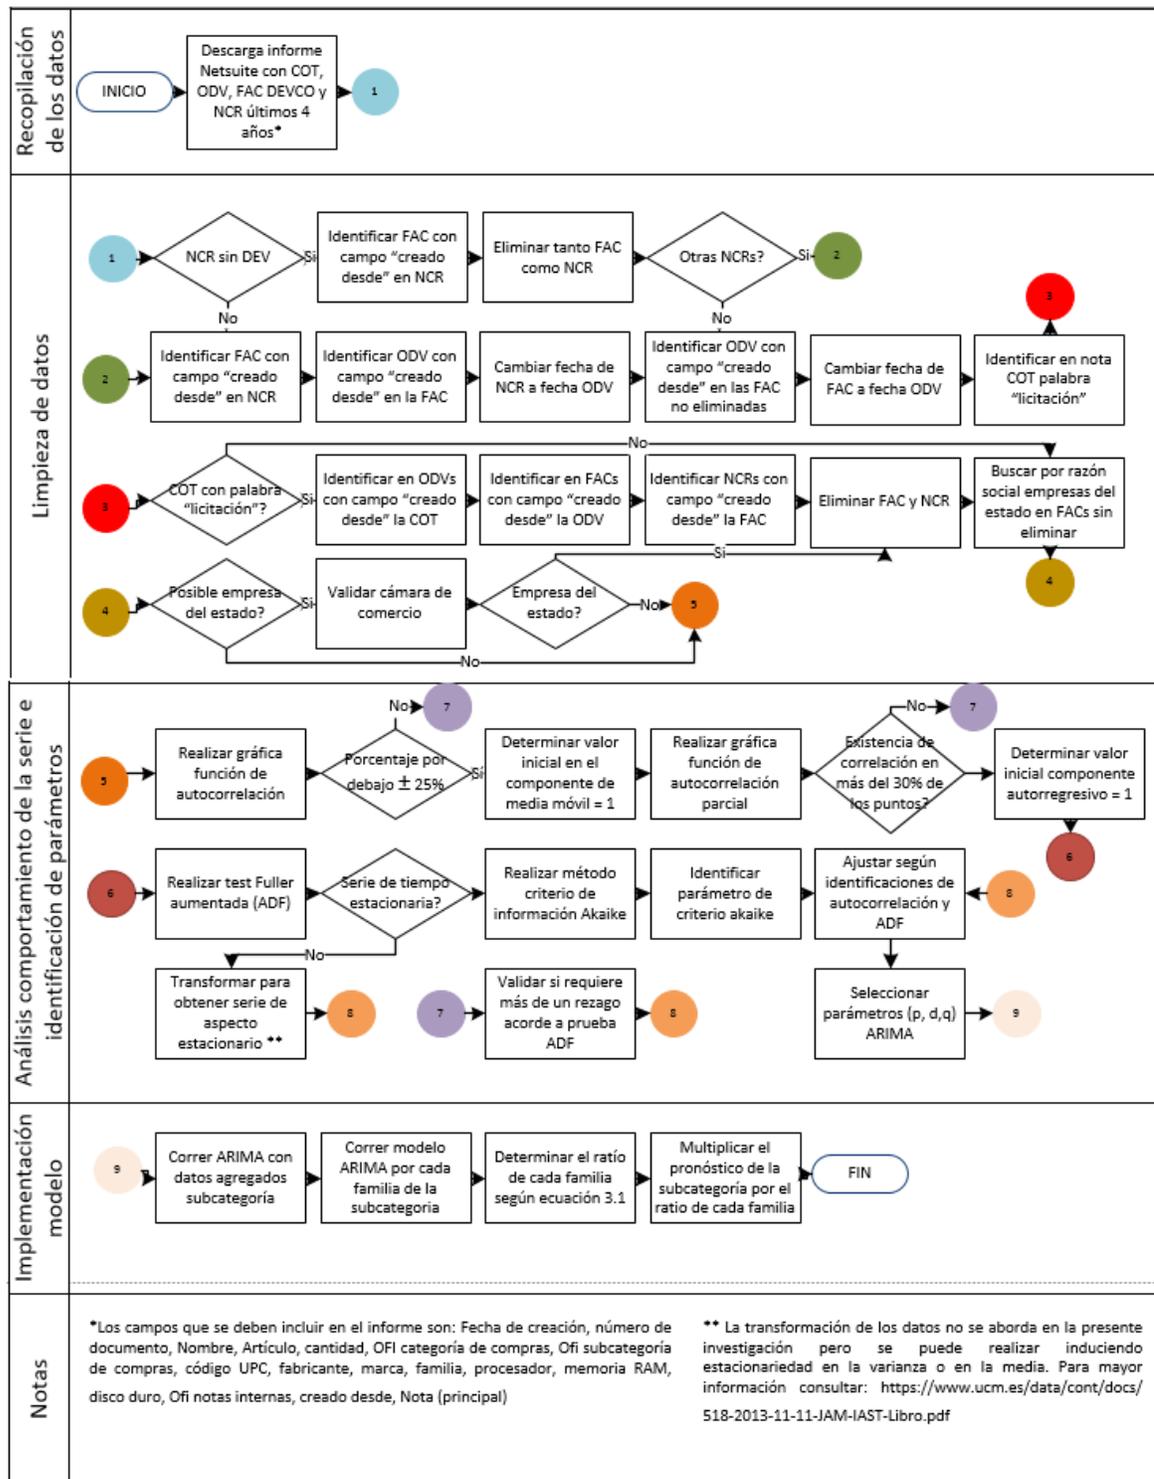
Figura 3-11: Comportamiento de ventas en el ciclo de vida de los productos con procesador Intel celeron o pentium



Gráfica elaboración propia a partir de la base de datos de la compañía en estudio

Finalmente, como conclusión se puede determinar que con el proceso de recopilación de datos se identifica la necesidad de asegurar el registro de la información completa para tener calidad en los datos y aprovechar las ventajas que brinda el sistema de información usado actualmente por la empresa. La limpieza de los datos e identificación de los valores atípicos permite tener una demanda no estacionaria y tener la visibilidad de las unidades reales que se deben contemplar como unidades de demanda. El análisis del comportamiento de la serie por medio de las funciones de autocorrelación, autocorrelación parcial y el criterio de información Akaike permite identificar los parámetros a usar para el modelo ARIMA. Dado el comportamiento de la demanda en el eslabón distribuidor minorista se descarta el uso del modelo por curvas de ciclo de vida y únicamente se termina el desarrollo del presente trabajo con los resultados y análisis del modelo con enfoque jerárquico. En la gráfica 3-12 se relaciona el resumen de los pasos a seguir para la implementación del modelo ARIMA y posterior implementación del modelo con enfoque jerárquico propuesto por Radim Lenort Petr Besta.

Figura 3-12: Proceso para la implementación del modelo ARIMA y modelo con enfoque jerárquico



Gráfica elaboración propia.

4. Análisis de resultados

En esta sección se muestran los resultados y el análisis de la implementación del modelo ARIMA y el modelo “Hierarchical Sales forecasting system for apparel companies” a la serie de datos de la empresa en estudio; posterior a la limpieza de los datos e identificación de los valores atípicos, el análisis del comportamiento de la serie de tiempo de la demanda y la definición de los parámetros como se relacionó en el capítulo anterior. El análisis de los resultados se lleva a cabo a través de una comparación entre el modelo usado actualmente por la compañía y el modelo propuesto. Dado que la compañía actualmente realiza el pronóstico de la demanda agregado para todas las categorías de venta y a fin de hacer comparables los resultados, adicional a la implementación del modelo propuesto también se realiza el pronóstico de la demanda con el modelo usado actualmente por la empresa con los datos depurados para la subcategoría H computadores & Tablets y la línea computadores portátiles.

En la tabla 4-1 se muestran los resultados obtenidos al implementar el modelo ARIMA con la serie de tiempo de la demanda de la subcategoría H Computadores & Tablets para los años 2016 a 2019. Se usan como datos de entrenamiento para el modelo la demanda de los periodos 2016 a 2018 y como datos de validación el periodo del año 2019. Al realizar el análisis del comportamiento de la serie de tiempo con el uso del criterio de información Akaike se obtienen 8 posibles combinaciones de parámetros que arrojan un número menor comparado con el resultado obtenido para los parámetros seleccionados (1,1,0). Las combinaciones que arrojan menor valor de desviación estándar, estimación de máxima verosimilitud y criterio de información Akaike son los modelos de mejor ajuste siempre que se conserve la invertibilidad en los datos como relacionó en el capítulo anterior. Todas las combinaciones que usan más de un rezago para el número de medias móviles hacen que la serie de tiempo no presente invertibilidad, lo que indica que al realizar la transformación la serie ya no cumple con la condición de que el presente dependa de forma convergente de su propio pasado. Dada la no invertibilidad se descarta el uso de los parámetros (1,1,1),

(0,1,2), (1,1,2), (1,1,3), (0,1,3) y (2,1,3). El parámetro (1,1,1) a pesar de tener un único rezago para el número de media móviles también presenta no invertibilidad por los rezagos que se realizan adicionales en los componentes autorregresivo e integrado. Posteriormente se relaciona la causal para descartar el uso de los parámetros (0,1,1) y (2,1,1)

Tabla 4-1: Resultados Modelo ARIMA (1,1,0)

Dep. Variable:	D. Sales		No. Observaciones	35	
Modelo:	ARIMA (1,1,0)		Estimación de máxima verosimilitud	-342,627	
Método:	css-mle		Desviación estándar de los términos de error	352,998	
Fecha:	Wed, 03 Feb 2021		AIC	691,254	
Hora:	03:50:01		BIC	696,804	
Muestra:	02-01-2016 - 12-01-2018		HQIC	693,343	
	coef	std err	z	P> z 	[0.025 0.975]
const	11,4959	32,663	0,352	0,727	-52,52 75,51
ar.L1.D.Sales	-0,5891	0,115	-0,115	0,000	-0,81 -0,36
Raíces					
	Real	Imaginario	Módulo	Frecuencia	
AR.1	-1,6974	+0,0000j	1,6974	0,5000	

De los resultados obtenidos en la tabla 4-1 se identifica que la desviación estándar de 353 unidades dada por las diferencias del valor real comparado con el valor pronosticado es menor al error que se obtiene con las otras combinaciones de parámetros posibles arrojadas por el criterio de uso de información Akaike que sí mantienen la invertibilidad en

la serie. La desviación estándar, la estimación de máxima verosimilitud con menor valor y el criterio Akaike confirma que los parámetros (1,1,0) para el número de autorregresivos, el número de diferencias y el número de medias móviles respectivamente son los de mejor ajuste para la serie de tiempo en estudio.

Tabla 4-2: Interpretación resultados modelo ARIMA (1,1,0)

Tipo	Comentario
No. Observaciones	Corresponde al número de datos usados como histórico y como entrenamiento para correr el modelo ARIMA.
Método	El método “css-mle” maximiza la probabilidad de suma condicional de cuadrados.
Estimación de máxima verosimilitud	Estimación de máxima verosimilitud: -342,627 corresponde al valor que maximiza la probabilidad de obtener los datos que el modelo ha observado, corresponde a las estimaciones de mínimos cuadrados que se obtienen minimizando.
Desviación estándar de los términos de error	desviación estándar de los términos de error. El modelo arroja una desviación estándar por las diferencias del valor real comparado con el valor pronosticado de 353 unidades.
AIC	un valor de criterio akaike para los parámetros 1,1,0 en los componentes autorregresivo, integrado y media móvil respectivamente de 691, 25 como se mostró también en la tabla 3-3
BIC	al igual que el criterio akaike, el criterio de información bayesiano (BIC) es un criterio para selección del mejor modelo acorde a la bondad de ajuste y la función de verosimilitud. El BIC tiene un término de penalización mayor que AIC. Los parámetros 1,1,0 arrojan un BIC de 696,8, muy cercano al akaike.

Tabla elaboración propia

En la tabla 4-2 se relaciona la interpretación que se puede dar a las variables principales arrojadas en los resultados obtenidos en la tabla 4-1 al correr el modelo ARIMA (1,1,0) para el número de autorregresivos, número de diferencias y número de medias móviles respectivamente. Para el caso de los parámetros (0,1,1) se conserva la invertibilidad en la

serie de tiempo y se obtiene una desviación de 306 unidades, una desviación menor respecto a las 352 unidades de desviación del modelo (1,1,0) pero un mayor error cuadrático medio (419 vs 418). El modelo ARIMA con parámetros (0,1,1) tiene un valor de probabilidad $P > |z|$ de 0 lo que rechaza la hipótesis nula de normalidad indicando que no es normal el residual.

En la figura 4-1 se muestran los pronósticos de la demanda arrojados para el primer trimestre del año 2020 con un intervalo de confianza del 95% para la demanda agregada de la subcategoría “H Computadores & Tablets”. Con los parámetros (1,1,0) se obtiene un mejor ajuste en el pronóstico con respecto a los parámetros (0,1,1) como se muestra en la figura 4-2. En la figura 4-2 el pronóstico de la demanda únicamente arroja una serie creciente lineal sin tener en cuenta el comportamiento de crecimiento o decrecimiento que tiene la serie de tiempo en los diferentes momentos. El pronóstico de la demanda para los parámetros (1,1,0) mantiene la estacionariedad que caracteriza la serie de tiempo presentando una media constante y manteniendo el comportamiento de la varianza, lo que no sucede con el pronóstico para los parámetros (0,1,1). A pesar de tener un menor error en la desviación estándar con los parámetros (0,1,1) la serie presenta un error cuadrático mayor y esto se puede evidenciar en las dos figuras. Dada las condiciones del comportamiento de la serie de pronóstico de la demanda y el error cuadrático medio se descarta el uso de los parámetros (0,1,1)

Figura 4-1: Pronóstico de la demanda para la subcategoría “H Computadores & Tablets” con ARIMA (1,1,0)

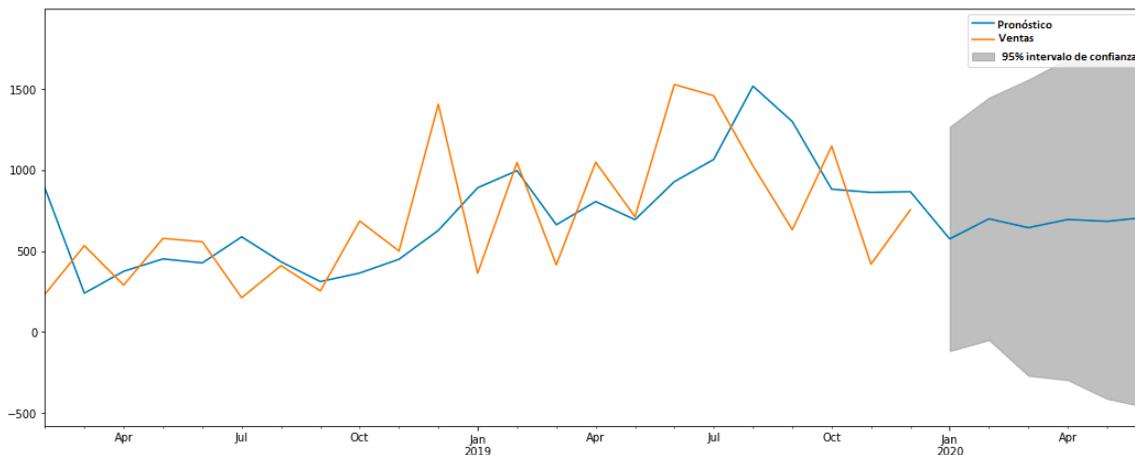
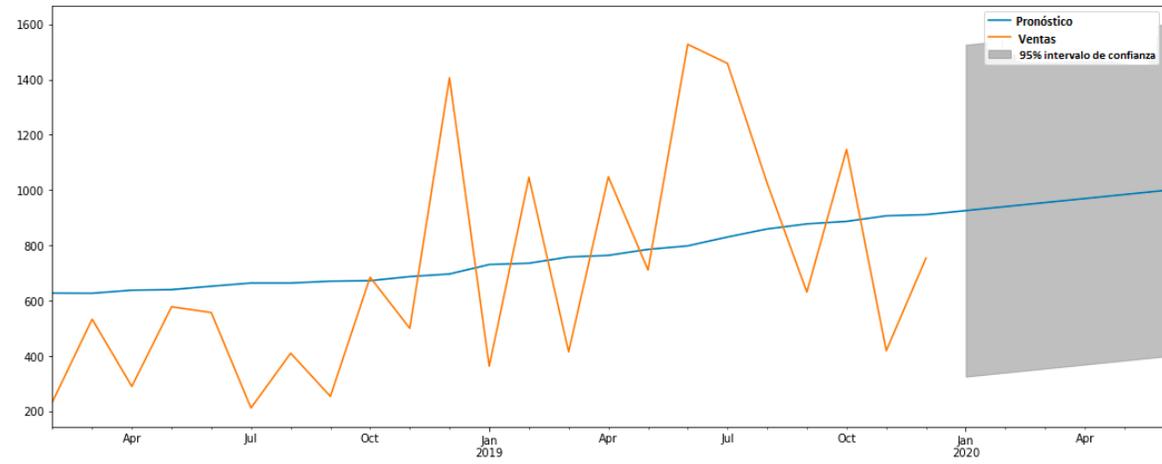


Figura 4-2: Pronóstico de la demanda para la subcategoría “H Computadores & Tablets” con ARIMA (0,1,1)



Sucede lo mismo para los parámetros (2,1,1) que para los parámetros (0,1,1) pero en este caso el error cuadrático medio tiene mayor diferencia con respecto al obtenido con los parámetros (1,1,0). El modelo arroja un error cuadrático medio de 445 y 418 para los parámetros (2,1,1) y (1,1,0) respectivamente. La diferencia de 27 puntos hace que los parámetros (2,1,1) no sean los de mejor ajuste para la implementación del modelo ARIMA. Teniendo en cuenta que se descartan las 8 posibles combinaciones de parámetros con menor valor para el criterio de información Akaike se rectifica el uso de la combinación (1,1,0) como modelo de mejor ajuste.

En la tabla 4-3 se relacionan los valores arrojados por el modelo ARIMA (1,1,0) para el periodo de agosto de 2018 a diciembre de 2019. Corresponde a los datos que están como gráfica en la figura 4-1 teniendo en cuenta que el pronóstico ARIMA con mejor ajuste corresponde al modelo de parámetros (1,1,0) manteniendo las características de la serie de tiempo de la demanda. En adelante únicamente se hace relación al modelo ARIMA (1,1,0).

Tabla 4-3: Datos ventas versus pronóstico resultado modelo ARIMA (1,1,0)

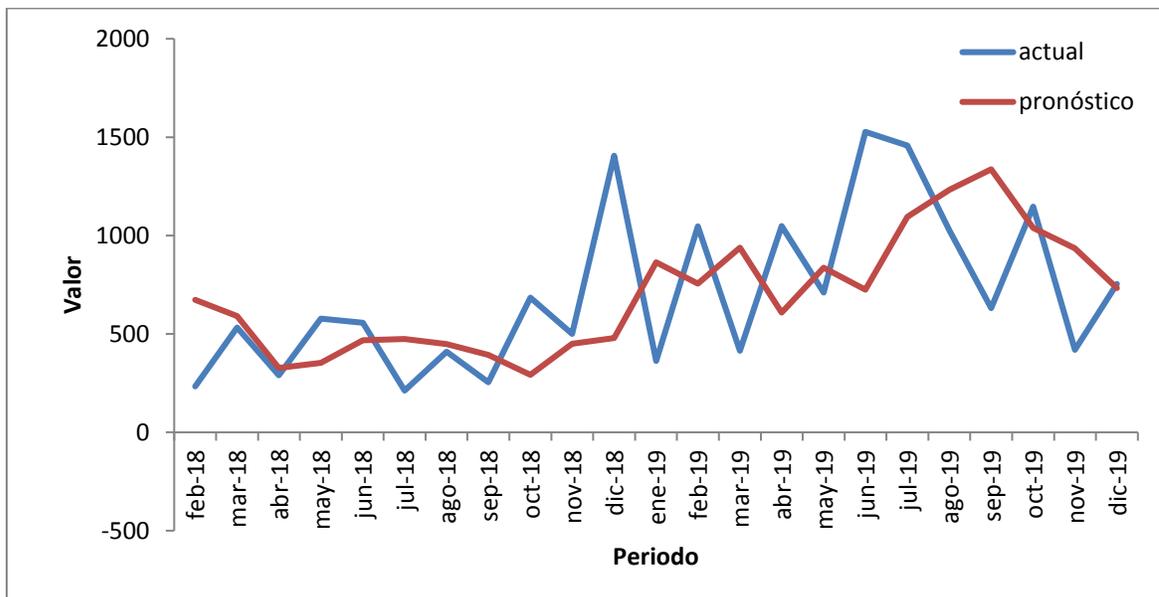
Mes	Venta	Pronóstico	Diferencia
2018-08	410	350	60
2018-09	254	348	-94
2018-10	685	323	362
2018-11	500	534	-34
2018-12	1406	594	812
2019-01	363	1053	-690
2019-02	1046	974	72
2019-03	415	686	-271
2019-04	1048	816	232
2019-05	711	685	26
2019-06	1527	950	577
2019-07	1458	1047	411
2019-08	1025	1554	-529
2019-09	631	1325	-694
2019-10	1147	876	271
2019-11	419	882	-463
2019-12	754	875	-121

Tabla elaboración propia resultados obtenidos modelo

Para tener una base de comparación entre los valores obtenidos con el modelo propuesto y los valores obtenidos con el modelo usado actualmente por la empresa se realiza el pronóstico de la demanda con los datos depurados y el modelo promedio móvil simple, que corresponde al usado actualmente por la compañía. En la figura 4-2 se puede visualizar el pronóstico de la demanda obtenido con el modelo usado actualmente por la empresa. El pronóstico de la demanda con el promedio móvil simple sigue manteniendo la media constante y el comportamiento de la varianza que caracteriza la serie de tiempo. Bajo estos parámetros tanto el pronóstico de la demanda obtenido con el modelo propuesto ARIMA (1,1,0) como el modelo usado actualmente por la compañía se ajustan a la serie de tiempo de la demanda de la categoría H computadores & Tablets para los años 2016 a 2019. Si comparamos lo que se visualiza en la figura 4-1 respecto a la figura 4-2, a vista

se puede decir que se tiene un mejor ajuste con el modelo ARIMA ya que en 5 de los puntos de todos los periodos el pronóstico es el mismo que la demanda real, en cambio para el promedio móvil se obtiene aparente igualdad únicamente en dos de los puntos. Esta comparación es muy cualitativa, por lo tanto, se mantiene únicamente como hipótesis. Como la visualización de la serie de tiempo de pronóstico de la demanda para los dos modelos muestra un ajuste adecuado al mantener las características de la serie de tiempo estacionaria, posteriormente se determina el mejor modelo con las medidas de desempeño que se relacionaron en el capítulo 2.2.1.

Figura 4-3: Pronóstico de la demanda para la subcategoría “H Computadores & Tablets” con promedio móvil.

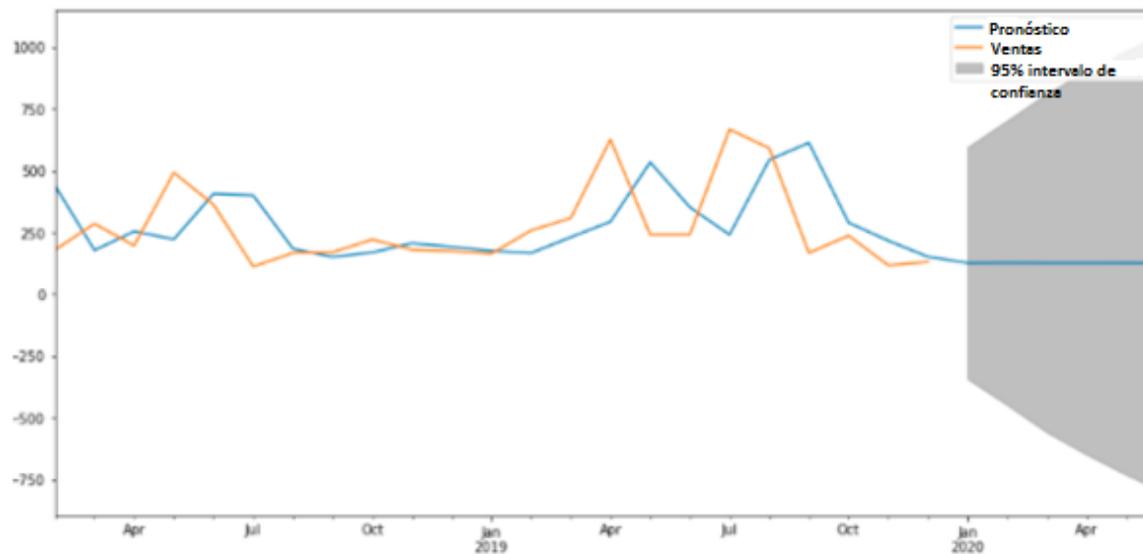


Gráfica elaboración propia

En la figura 4-3 se visualiza el pronóstico de la demanda implementando el modelo ARIMA únicamente para la línea computadores portátiles, que junto con las líneas Servidores y Desktop and All in One and Tablets componen la subcategoría H computadores & Tablets. El pronóstico de la demanda para la línea computadores portátiles con el modelo ARIMA y los parámetros (1,1,0) para el número de autorregresivos, el número de diferencias y el número de medias móviles respectivamente sigue manteniendo la característica de media constante y el comportamiento de varianza que caracteriza a la serie de tiempo de la demanda de los datos agregados para la subcategoría H computadores & Tablets. Teniendo en cuenta que la línea computadores portátiles representa el 56% de la demanda

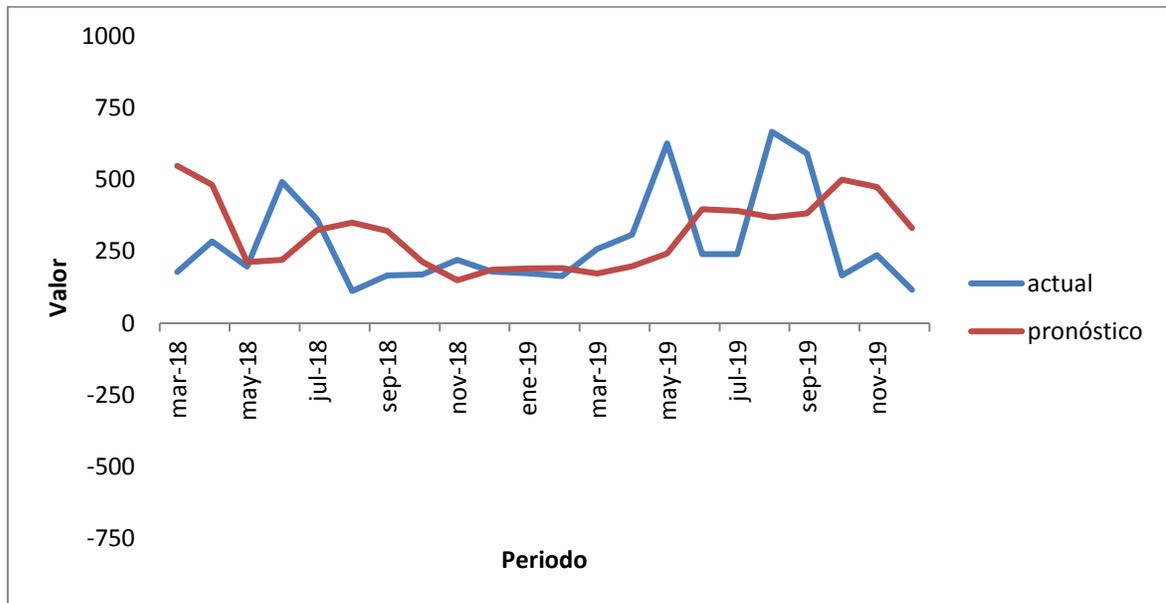
de la subcategoría total se esperaba que el pronóstico directo de la línea conservara el mismo comportamiento de la subcategoría, esto se confirma y se puede evidenciar comparando la figura 4-3 con la figura 4-1. Con la visualización se puede observar mayor exactitud para los datos desagregados de la línea computadores portátiles respecto a lo que se visualiza para la subcategoría H Computadores & Tablets. Posteriormente se hace el análisis con las medidas de desempeño para aprobar o no esta hipótesis.

Figura 4-4: Pronóstico de la demanda de la línea computadores portátiles con modelo ARIMA.



Igualmente, con el objetivo de tener una comparación del pronóstico de la demanda de la línea computadores portátiles obtenido con el modelo propuesto respecto al pronóstico de la demanda obtenido con el modelo usado actualmente por la compañía, se realiza el proceso con los datos depurados implementando el modelo promedio móvil simple para la línea computadores portátiles. El resultado se puede observar en la figura 4-4. El pronóstico de la demanda obtenido con el modelo promedio móvil simple sigue manteniendo la característica de la serie de tiempo de la demanda conservando una media constante y manteniendo el comportamiento de varianza.

Figura 4-5: Pronóstico de la demanda de la línea computadores portátiles con promedio móvil simple



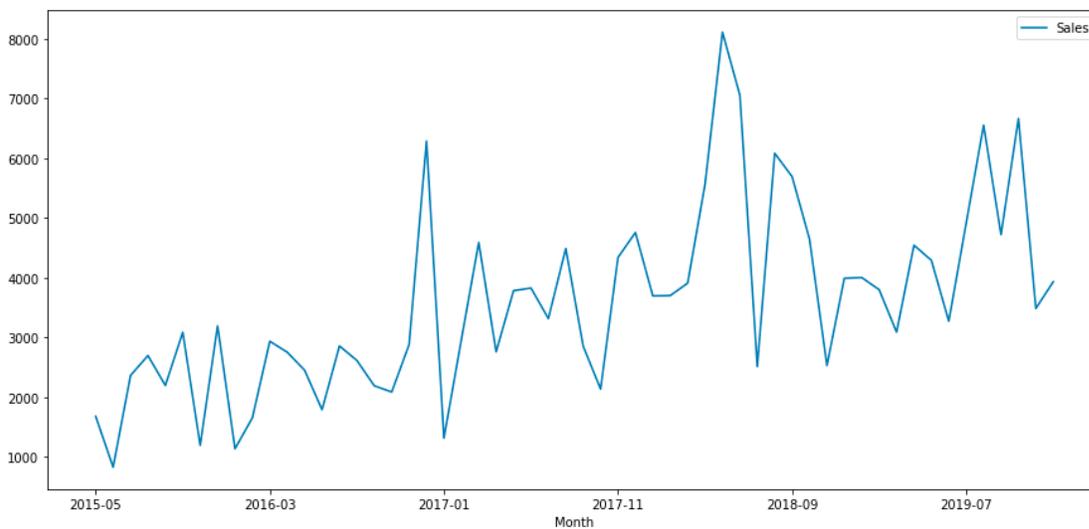
Gráfica elaboración propia

Si se compara únicamente en términos de visualización las figuras 4-3 y 4-4 que corresponden al modelo ARIMA (1,1,0) y al modelo promedio móvil simple respectivamente para la línea computadores portátiles se observa menor ajuste para el modelo promedio móvil. Se puede ver que el pronóstico de la demanda con modelo promedio móvil no toma un ajuste cuando hay puntos con demanda muy superior al promedio como el caso de mayo del 2019 en el que las unidades duplican el promedio con un valor de 667 unidades con respecto al promedio de 332 unidades. El modelo promedio móvil toma el aumento un periodo después únicamente en un 20% respecto al promedio con 398 unidades para junio de 2019, periodo en el que el dato de demanda baja del promedio a 241 unidades.

La serie de tiempo de los datos de demanda agregada para la subcategoría H Computadores & Tablets para los años 2016 a 2019 tiene un comportamiento estacionario, lo que permite la implementación del modelo ARIMA sin ninguna transformación en los datos ni descomposición acorde al factor aleatorio, de tendencia y de estacionalidad. Actualmente el pronóstico de la compañía se realiza de manera agregada para todas las categorías, como consecuencia el comportamiento de la serie no es estacionaria por media no constante como se puede visualizar en la figura 4-6 y también lo muestra la prueba

estadística de Dickey Fuller Aumentada en la que se confirma la existencia de una raíz unitaria (ver anexo C). Hay algunos productos de la compañía que se han ido incorporando a lo largo de los años con apuestas en marketing y enfoque en estrategia de servicios, generando así, un aumento representativo en las ventas con el transcurrir del tiempo. Como la línea computadores portátiles ha estado desde el nacimiento de la compañía no se tiene de manera representativa un cambio en las ventas que genere una variación en la media.

Figura 4-6: Serie de tiempo con datos de todas las categorías sin depuración de la base de datos de ventas.



Tener una serie de tiempo no estacionaria requiere generar cambios en la serie de manera logarítmica, de tendencia o por patrones, como resultado a estos cambios se puede generar mayores márgenes de error en el resultado de la implementación de los modelos ARIMA. Bajo el parámetro de estacionariedad no se recomendaría implementar el modelo de pronóstico de la demanda de manera agregada para todas las categorías de la compañía. Esta hipótesis se evalúa posteriormente con las métricas de desempeño y únicamente con la implementación del modelo usado actualmente por la compañía ya que la depuración de los datos solo se realizó para la subcategoría H Computadores & Tablets. Acorde a la evaluación de la hipótesis se puede o no recomendar como futura investigación la implementación del modelo ARIMA con la demanda agregada para todas las categorías de la compañía realizando el ajuste necesario a la serie de tiempo y después la implementación del modelo con enfoque jerárquico para la desagregación del pronóstico de la demanda para cada subcategoría y cada línea.

El paso de la limpieza de los datos e identificación de los valores atípicos es esencial antes de la implementación de cualquier modelo como se mencionó en el capítulo 3. El tener notas crédito en periodos diferentes al periodo de la solicitud del cliente genera duplicidad en las ventas. En los datos que toma la compañía actualmente para la implementación del pronóstico de la demanda se tiene en cuenta los datos duplicados por nota crédito y también se toma como dato de demanda las ventas por licitaciones que corresponden a valores atípicos. Tener en cuenta como demanda para la serie de tiempo los datos mencionados anteriormente también genera que la serie de tiempo no sea estacionaria cambiando de manera representativa la media de las ventas a lo largo del tiempo y mostrando estacionalidad en los periodos que las empresas públicas suelen aumentar el número de licitaciones para gastar todo el presupuesto asignado de cada año.

El nivel de ingresos por ventas en el estado de resultados mensual no se ve afectado por la duplicidad que generan las transacciones de nota crédito puesto que el área financiera de manera mensual realiza el ajuste. Para realizar el ajuste generan un diario con la provisión de las ventas que se ejecutaron en cada mes pero que no se generó una factura. En el periodo que se ejecuta la factura se reversa el ingreso con otra transacción de diario. Sin embargo, los cambios que realiza el área financiera para tener un dato correcto de los ingresos mes a mes no tienen ningún impacto en el registro de las transacciones en el ERP a nivel de unidades. El contemplar los datos de notas crédito y licitaciones para realizar el pronóstico de la demanda conlleva de por sí errores independiente del modelo que se use. Para asegurar una facilidad en el proceso de limpieza de los datos e identificación de valores atípicos a largo plazo es necesario comunicar a las partes involucradas y hacer el seguimiento correspondiente para llevar a cabo los procesos relacionados en el capítulo 3.1 realizando los cambios directamente en el sistema y a futuro no sea necesario realizar grandes cambios en las bases de datos obtenidas directamente desde el sistema de información Netsuite.

Teniendo en cuenta que se realizó la limpieza de los datos e identificación de los valores atípicos únicamente para la subcategoría H Computadores & Tablets y a fin de tener los valores comparables para los datos de la demanda de las categorías totales, se realiza la proyección del total de unidades de demanda de todas las categorías con los datos obtenidos para la subcategoría H Computadores y Tablets. Se realiza el proceso de proyección teniendo en cuenta que la subcategoría H Computadores & Tablets representa el 69% de la categoría Hardware de acceso y que a su vez esta categoría representa el

56% de las ventas de todas las categorías de la compañía. Para hacer la proyección se realiza la división por cada periodo de las unidades de demanda depuradas para la subcategoría H Computadores y tablets y se divide en 0,28 (% de participación de la subcategoría en el total de ventas de la compañía).

Para validar los resultados obtenidos posterior al proceso de proyección para las ventas totales de todas las categorías y la limpieza de los datos e identificación de los valores atípicos se compara el monto de ventas que se obtendrían con las unidades depuradas con respecto al promedio de ventas mensual que tiene el área financiera registrada en el estado de resultados. Para ello se contempla un valor promedio de venta por unidad de \$1,5 millones (ver anexo D). Por ejemplo, para el año 2019 la empresa tenía ventas promedio mensuales de \$5.700 millones (ver anexo E), si se tiene en cuenta las unidades depuradas y proyectadas por el valor promedio de venta por unidad se tendrían ventas para los trimestres 1, 2, 3 y 4 del año 2019 de \$9.700 millones, \$17.600 millones, \$16.600 millones y \$12.400 millones respectivamente. Lo anterior sumado a los proyectos por licitaciones que mensual representan alrededor de \$1.000 millones corresponde aproximadamente a las ventas totales (ver tabla 4-4). Considerando los valores de ventas por trimestre y el valor que se obtiene de la depuración de las unidades multiplicado por el promedio de venta por unidad se muestra que los datos de proyección son correctos posterior a la limpieza e identificación de los valores atípicos y están acorde a las cantidades según las ventas mensuales de la compañía.

Si se realiza la comparación de las unidades de la demanda de todas las categorías de la compañía con la proyección de datos posterior a la limpieza e identificación de los valores atípicos con respecto a los datos que se obtienen directamente desde el sistema de información sin ninguna modificación hay una diferencia en los datos de las unidades vendidas del 47% como se muestra en la tabla 4-4. Se tiene una cantidad sobreestimada aproximada del 47% en los datos que se obtienen directamente desde el sistema de información sin ninguna modificación por todas las razones mencionadas anteriormente y las mencionadas también en el capítulo 3.2. La diferencia es significativa, razón por la cual cobra aún mayor importancia el proceso de la limpieza de los datos e identificación de los valores atípicos para la implementación de cualquier modelo para el pronóstico de la demanda. Las unidades sin ningún tipo de modificación son las que contempla actualmente la compañía para la generación del pronóstico de la demanda con el modelo del promedio móvil simple, generando así un error inicial.

Tabla 4-4: Ventas por año de todas las categorías de la compañía con y sin limpieza de los datos.

Año	Trimestre	Cantidad sin limpieza de los datos	Cantidad con limpieza de los datos	Dif	Sin contratos puntuales	Unidades sobre- estimadas
2016	Trim.1	5.716	2.565	3.151	\$ 3.847.500.000	1.050
2016	Trim.2	6.982	2.223	4.759	\$ 3.334.500.000	1.586
2016	Trim.3	7.653	2.987	4.666	\$ 4.480.500.000	1.555
2016	Trim.4	11.247	5.859	5.388	\$ 8.788.500.000	1.796
2017	Trim.1	8.856	4.741	4.115	\$ 7.111.500.000	1.372
2017	Trim.2	10.362	6.105	4.257	\$ 9.157.500.000	1.419
2017	Trim.3	10.652	6.484	4.168	\$ 9.726.000.000	1.389
2017	Trim.4	11.226	7.394	3.832	\$ 11.091.000.000	1.277
2018	Trim.1	11.299	3.501	7.798	\$ 5.251.500.000	2.599
2018	Trim.2	20.738	5.091	15.647	\$ 7.636.500.000	5.216
2018	Trim.3	14.284	3.131	11.153	\$ 4.696.500.000	3.718
2018	Trim.4	11.160	9.255	1.905	\$ 13.882.500.000	635
2019	Trim.1	10.884	6.516	4.368	\$ 9.774.000.000	1.456
2019	Trim.2	12.101	11.737	364	\$ 17.605.500.000	121
2019	Trim.3	16.190	11.123	5.067	\$ 16.684.500.000	1.689
2019	Trim.4	14.078	8.287	5.791	\$ 12.430.500.000	1.930
Total general		183.428	96.999	47%	\$ 56.494.500.000	1.801

Tabla elaboración propia a partir de la base de datos de la compañía en estudio.

Inicialmente, si se implementa el modelo promedio móvil simple que usa actualmente la compañía para las categorías totales pero realizando previamente la limpieza de los datos y la identificación de los valores atípicos, se daría de por sí un ahorro de \$296 millones anuales que corresponden a la sobreestimación promedio trimestral de 1.800 unidades como se relaciona en la tabla 4-4.

Tabla 4-5: Pronóstico implementando promedio móvil simple con los datos de demanda proyectados para todas las categorías de la compañía posterior limpieza e identificación de valores atípicos.

Periodo t	Años	Trim	Dt	Demanda desest.	Dt = -438 + 424t	Factor estacional	Pronóstico	Nivel Lt	Error	Error abso	Error cuadrático	MADt	Error %	MAPEt	TSt
1	2014	Trim.2	56		-13	-4,21949222									
2	2014	Trim.3	212		412	0,515039922									
3	2014	Trim.4	1.412	727	837	1,687967709		885							
4	2015	Trim.1	595	1.264	1.261	0,471698409	1.170	1.644	575	575	330.387	575	97	97	1
5	2015	Trim.2	1.319	1.886	1.686	0,782190709	2.672	2.128	1.353	1.353	1.080.334	964	103	100	2
6	2015	Trim.3	3.250	2.375	2.111	1,539423566	1.563	2.621	-1.687	1.687	1.668.570	1.205	52	84	0
7	2015	Trim.4	3.349	2.734	2.536	1,320547063	2.178	2.847	-1.171	1.171	1.593.999	1.196	35	72	-1
8	2016	Trim.1	2.565	2.814	2.961	0,866272962	2.778	2.781	213	213	1.284.252	1.000	8	59	-1
9	2016	Trim.2	2.223	3.095	3.386	0,656555808	5.160	3.409	2.937	2.937	2.507.785	1.322	132	71	2
10	2016	Trim.3	2.987	3.681	3.811	0,783837032	2.898	3.953	-89	89	2.150.672	1.146	3	61	2
11	2016	Trim.4	5.859	4.438	4.236	1,383264835	3.674	4.923	-2.185	2.185	2.478.840	1.276	37	58	0
12	2017	Trim.1	4.741	5.360	4.661	1,01726808	4.386	5.797	-355	355	2.217.440	1.174	7	53	0
13	2017	Trim.2	6.105	5.989	5.085	1,20049269	7.648	6.181	1.543	1.543	2.233.763	1.211	25	50	1
14	2017	Trim.3	6.484	6.026	5.510	1,176704936	4.232	5.871	-2.252	2.252	2.491.798	1.305	35	49	-1
15	2017	Trim.4	7.394	5.744	5.935	1,245789377	5.169	5.618	-2.225	2.225	2.696.784	1.382	30	47	-2
16	2018	Trim.1	3.501	5.198	6.360	0,550464514	5.994	4.779	2.493	2.493	2.967.289	1.468	71	49	-1
17	2018	Trim.2	5.091	5.012	6.785	0,750334564	10.136	5.245	5.045	5.045	4.573.326	1.723	99	52	2
18	2018	Trim.3	3.131	5.621	7.210	0,434266188	5.566	5.998	2.435	2.435	4.663.767	1.771	78	54	4
19	2018	Trim.4	9.255	6.829	7.635	1,212219812	6.664	7.660	-2.591	2.591	4.791.876	1.822	28	53	2
20	2019	Trim.1	6.516	8.659	8.060	0,808472407	7.602	9.658	1.086	1.086	4.579.328	1.779	17	50	3
21	2019	Trim.2	11.737	9.537	8.485	1,383340463	12.624	9.416	887	887	4.368.631	1.729	8	48	3
22	2019	Trim.3	11.123				6.900	10.382	-4.223	4.223	5.077.125	1.860	38	48	1
23	2019	Trim.4	8.287				8.159	9.705	-128	128	4.824.086	1.774	2	45	1
24	2020	Trim.1					9.210	8.287							
25	2020	Trim.2					15.112								
26	2020	Trim.3					8.235								
27	2020	Trim.4					9.654								

Tabla elaboración propia a partir de la base de datos de la compañía en estudio.

Para el primer trimestre del 2019 según la medición de error de pronóstico de la demanda por parte de la empresa se tenía un porcentaje de exactitud de 76% y existía un excedente de 2.642 unidades de las cuales aún mantenían en inventario en septiembre de 2019 (6 meses después de su compra) 350 unidades, realizaron una depreciación de su valor por \$17 millones. Si se ejecuta el pronóstico de la demanda bajo los mismos parámetros pero con la depuración correspondiente, el valor obtenido para el primer trimestre del 2019 es de 7.600 unidades con un exceso únicamente de 1.086 unidades (ver tabla 4-6), un 59% de diferencia, de las cuales mantendrían en inventario en septiembre de 2019 tan solo 143 unidades para una depreciación de su valor por \$7 millones, un valor promedio anual de

\$84 millones respecto a \$200 millones sin la depuración de los datos, un ahorro de \$116 millones anuales únicamente para la variable de costo por depreciación.

El promedio mensual del valor del inventario de la compañía es de \$3.500 millones (ver anexo F). Si se contempla un valor promedio de \$1,5 millones por unidad corresponde a un promedio de unidades de 2.400 por mes en inventario. Con el valor promedio de 2.400 unidades de inventario se rectifica que la compañía mantiene un aproximado a las 2.642 unidades que se relacionan como exceso para el primer trimestre del año 2019. Además, se propone como línea de investigación el estudio de los márgenes que se usan para lograr salir del inventario que queda como exceso mes por mes. Posiblemente los márgenes son sustancialmente menores causando también un impacto financiero para la compañía en la utilidad bruta.

Dado el escenario mostrado para el primer trimestre del 2019 en el que la cantidad en exceso se reduce un 60% a 1.086 unidades con la limpieza de los datos e identificación de los valores atípicos y estimando una tasa efectiva anual de 9% y un promedio por unidad de \$1,5 millones el costo de oportunidad por mantener las unidades de inventario promedio mensual pasaría de \$25 millones a \$10 millones, lo que arrojaría unos ahorros anuales de \$180 millones (ver tabla 4-7). El ahorro anual que se obtiene por el costo de depreciación y el costo de oportunidad es de \$296 millones si se asegura una limpieza de los datos y la identificación de los valores atípicos antes de la implementación de cualquier modelo de pronóstico de la demanda.

Tabla 4-6: Ahorro pronóstico promedio móvil simple con y sin depuración de datos.

Tipo (cifras en millones COP anuales)	Valor data inicial	Valor limpieza data	Ahorro
Costo de oportunidad	300	120	180
Costo de depreciación	200	84	116
TOTAL	500	204	296

Tabla elaboración propia.

También se comparan los datos de demanda para la subcategoría H Computadores & Tablets posterior a la limpieza e identificación de los valores atípicos con respecto a los datos obtenidos directamente del sistema de información sin ninguna modificación para los años 2016 a 2019 que corresponden a los periodos usados para el análisis.

Tabla 4-7: Diferencia en los datos de ventas para la subcategoría “H Computadores & Tablets” por la depuración de los datos.

Artículo: OFI Subcategoría de compras		H Computadores & Tablets		
Artículo: OFI Grupo de Subcategoría		(Varios elementos)		
Año	Trimestre	Cantidad	Dato análisis	% dif
2014	Trim.2	66		
2014	Trim.3	128		
2014	Trim.4	2.412		
2015	Trim.1	784		
2015	Trim.2	530		
2015	Trim.3	466		
2015	Trim.4	382		
2016	Trim.1	922	718	22%
2016	Trim.2	870	622	29%
2016	Trim.3	1.093	836	24%
2016	Trim.4	2.000	1.640	18%
2017	Trim.1	1.719	1.327	23%
2017	Trim.2	2.080	1.709	18%
2017	Trim.3	2.094	1.815	13%
2017	Trim.4	2.123	2.070	2%
2018	Trim.1	1.406	980	30%
2018	Trim.2	1.823	1.425	22%
2018	Trim.3	1.608	876	46%
2018	Trim.4	3.730	2.591	31%
2019	Trim.1	2.565	1.824	29%
2019	Trim.2	3.117	3.286	-5%
2019	Trim.3	3.630	3.114	14%
2019	Trim.4	2.239	2.320	-4%
		33.019	27.153	18%

Tabla elaboración propia a partir de la base de datos de la compañía en estudio.

Al realizar la comparación mencionada anteriormente se obtiene una diferencia en las unidades de la demanda del 18% como se muestra en la tabla 4-5. Lo que rectifica el error aproximado del 47% que se puede obtener al contemplar todas las categorías de la compañía. Estas diferencias llevan consigo mayores costos de mantenimiento de inventario como se relacionó en la tabla 4-7.

Para hacer la comparación entre el modelo usado actualmente por la compañía con respecto al modelo propuesto para la implementación del pronóstico de la demanda, se hace la ejecución del modelo promedio móvil simple con los datos depurados que se analizaron con frecuencia mensual. Posteriormente se ejecuta con los mismos datos el modelo ARIMA teniendo como datos de entrenamiento los periodos 2016 a 2018 y como datos de prueba el periodo de 2019. El resultado obtenido arroja un mejor desempeño con el modelo propuesto ARIMA para las tres medidas analizadas: error cuadrático medio (MSE), error absoluto medio (MAE) y error porcentual absoluto medio (MAPE). La diferencia de los valores obtenidos para el modelo ARIMA respecto al modelo promedio móvil simple como se muestran en la tabla 4-8 son de 27.570, 25,37 y 3,46% respectivamente.

Teniendo en cuenta que el MSE corresponde al promedio de las diferencias al cuadrado, si se toma la raíz de 27.570 se obtiene un promedio de diferencia de 166 unidades que se estarían sobreestimando si se implementa el promedio móvil simple con los datos depurados en lugar de implementar el modelo ARIMA. Estimando una tasa efectiva anual de 9% y un promedio por unidad de \$1,5 millones el costo de oportunidad por mantener las 166 unidades de inventario sería de \$24 millones anuales y requieren una inversión adicional de \$249 millones.

Tabla 4-8: Medidas de desempeño pronóstico ARIMA y promedio móvil simple con depuración de datos.

Modelo	MAE	MSE	MAPE
Promedio Movil simple	362	202.805	52,57%
ARIMA	336	175.234	49,11%
Diferencia	25	27.570	3,46%

Tabla elaboración propia a partir de los resultados de los modelos implementados.

Dado que el resultado de la métrica MAE para el modelo del promedio móvil simple arroja un error promedio de 362 unidades por mes, se tendría un costo de oportunidad anual de \$51,4 millones, un costo por depreciación de \$27,9 millones para 48 unidades en promedio por mes que superarían los 6 meses en inventario y un costo anual por tasas de interés por capital inmovilizado de \$59 millones. Lo anterior representa un costo total anual de \$139 millones con respecto al costo total anual de \$129 millones que se tendría con la implementación del modelo ARIMA. Como se muestra en la tabla 4-9 se obtiene un ahorro de \$10 millones anuales adicionales a los \$296 millones anuales que únicamente requieren la depuración de los datos y la identificación de los valores atípicos.

Tabla 4-9: Ahorro implementado ARIMA con respecto a promedio móvil simple

Tipo (cifras en millones COP anuales)	Promedio móvil simple	Arima	Ahorro
Costo de oportunidad	51,48	47,78	3,70
Costo de depreciación	27,95	25,94	2,01
tasa interés	59,73	55,44	4,29
TOTAL	139,16	129,16	9,99

Tabla elaboración propia a partir de los resultados de los modelos implementados.

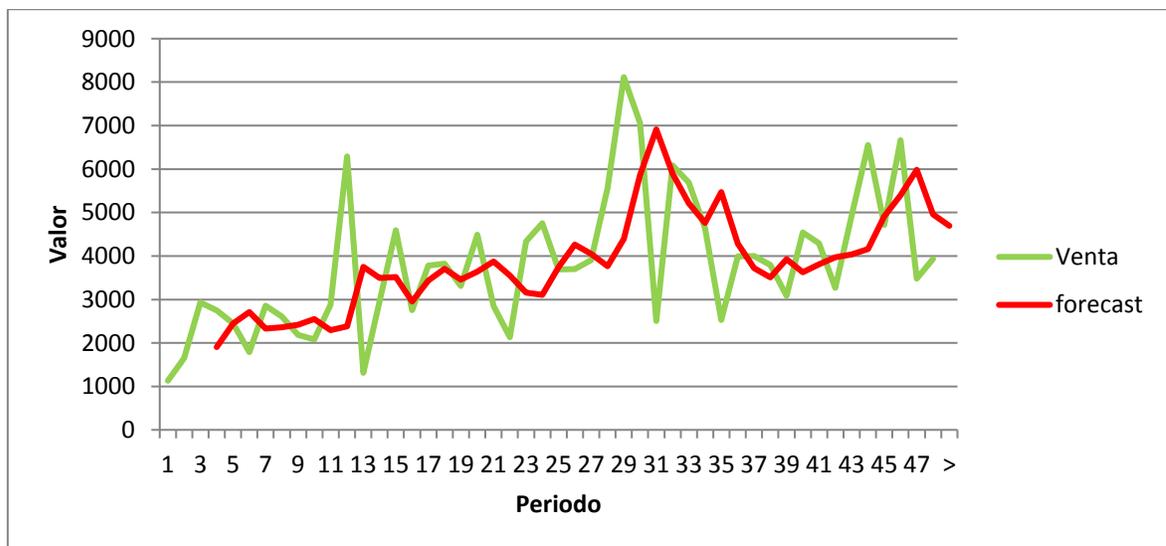
Al determinar la medida de desempeño MAPE del pronóstico de la demanda obtenido con el modelo promedio móvil simple sin la depuración de los datos y con la demanda agregada de todas las categorías de la compañía usando la serie de tiempo completa y no un único punto, la compañía tiene un error porcentual de 24,03% (ver figura 4-6). El error de 24,03% es menor que el error de 49,11% obtenido con el modelo ARIMA para los datos desagregados de la subcategoría H Computadores & Tablets. Dado lo anterior, como lo relaciona Lewis en el año 1982, con un 49,11% de error MAPE tendríamos un juicio de precisión de pronóstico “razonable” al estar en el rango de 21% a 50% pero se recomienda implementar el modelo con los datos agregados para tener un mejor desempeño y de ser posible lograr un “buen pronóstico” al obtener un MAPE en el rango de 11% a 20%. Teniendo en cuenta que en el presente estudio únicamente se realiza la depuración de los

datos para la categoría “H Computadores & Tablets” no es posible implementar el modelo ARIMA con la serie de tiempo de los datos de demanda agregada para todas las categorías de la compañía, esto se recomienda para futuros estudios.

Considerando que para la medida de desempeño MAPE se tiene menor error con los datos agregados para todas las categorías comparado al obtenido con los datos desagregados para la subcategoría H Computadores & Tablets con la implementación de los modelos promedio móvil simple y ARIMA respectivamente, se rechaza la hipótesis mencionada anteriormente en la que no se recomienda implementar el modelo ARIMA para el pronóstico de la demanda agregada de todas las categorías por no ser una serie de tiempo estacionaria. Se recomienda para futuros estudios realizar el ajuste necesario a la serie de tiempo e implementar el modelo ARIMA para comparar los resultados del pronóstico de la demanda para los datos de la subcategoría y los datos agregados de las categorías.

Con el objetivo de validar si la implementación del modelo “Hierarchical Sales forecasting system for apparel companies” mejora el desempeño del pronóstico promedio móvil simple bajo la medida de desempeño MAPE se implementa el modelo con enfoque jerárquico con los datos de demanda depurados de la subcategoría H computadores & Tablets.

Figura 4-7: Pronóstico con datos de todas las categorías sin depuración promedio móvil simple.



Gráfica elaboración propia a partir de resultados modelo.

Para implementar el modelo con enfoque jerárquico para la demanda agregada de todas las categorías y obtener el pronóstico de la demanda de la subcategoría H Computadores & Tablets se realiza el pronóstico directo tanto para la demanda agregada de todas las categorías como para la demanda de la subcategoría con el modelo promedio móvil simple. Para los pronósticos directos y a fin de hacer comparables los resultados se hace uso de los datos sin ninguna depuración, como los usa actualmente la compañía.

Posterior a la ejecución de los pronósticos de la demanda directos se implementa el modelo con enfoque jerárquico para obtener el pronóstico de la demanda final para la subcategoría H Computadores & tablets. Se hace la evaluación del desempeño del pronóstico de la demanda para la subcategoría H Computadores & Tablets con la medida MAPE para los resultados obtenidos con el modelo de enfoque jerárquico, el modelo implementando únicamente promedio móvil simple para la subcategoría H Computadores & Tablets y el resultado efectuando el porcentaje de participación de las ventas de la subcategoría H computadores & Tablets sobre el resultado del promedio móvil simple directo del pronóstico de la demanda de las categorías totales. Los resultados de la evaluación de desempeño con la medida MAPE para los tres escenarios mencionados se muestra en la tabla 4-10.

La implementación del modelo con enfoque jerárquico arroja un mejor resultado para la medida de desempeño MAPE del pronóstico de la demanda de la subcategoría H Computadores & Tablets con 8,72 errores porcentuales por debajo con respecto al resultado obtenido implementando el promedio móvil directo a la subcategoría. Dado que el modelo con enfoque jerárquico asegura la desagregación en función de las proporciones históricas también se tiene un mejor desempeño (39,74% versus 47,35%) implementando ese enfoque con respecto a la asignación directa con el porcentaje de participación de la subcategoría sobre las ventas totales como se visualiza en la tabla 4-10.

Tabla 4-10: Medidas de desempeño implementando el modelo promedio móvil y el modelo con enfoque jerárquico.

Modelo	MAE	MSE	MAPE
Promedio móvil directo para subcategoría	347	219.435	48,46%
Promedio móvil con % participación	408	237.738	47,35%
Promedio móvil con enfoque jerárquico	367	248.578	39,74%

Tabla elaboración propia a partir de los resultados de los modelos implementados.

A continuación se relaciona el detalle al que corresponde cada uno de los escenarios que se evaluaron con la implementación del modelo promedio móvil simple para obtener el pronóstico de la demanda de la subcategoría H Computadores & Tablets relacionados en la tabla 4-10:

- **Promedio móvil directo para subcategoría:** corresponde a la implementación del modelo “promedio móvil simple” únicamente con las unidades de la demanda que corresponden a la subcategoría “H Computadores & Tablets”.
- **Promedio móvil con % participación:** primero se realiza la implementación del modelo “promedio móvil simple” con la demanda agregada de todas las categorías, posteriormente para obtener el pronóstico de la demanda para la subcategoría H Computadores & Tablets se multiplica el valor obtenido para todas las categorías por el porcentaje de participación en ventas en unidades de la subcategoría H Computadores & Tablets del total de unidades vendidas de todas las categorías de la compañía.
- **Promedio móvil con enfoque jerárquico:** corresponde a la implementación del modelo “promedio móvil simple” y la implementación del modelo con enfoque jerárquico que tiene en cuenta la distribución para la subcategoría H Computadores & tablets acorde a las proporciones históricas.

Adicional a recomendar la implementación del modelo ARIMA con la demanda agregada de todas las categorías previa la limpieza de los datos y la identificación de los valores atípicos, posterior a la ejecución de los pronósticos directos también se recomienda implementar el modelo con enfoque jerárquico para obtener la desagregación del pronóstico de la demanda de la subcategoría H Computadores & Tablets dado el desempeño para la medida MAPE mostrando una mejor exactitud porcentual en 9 puntos en términos absolutos de pronóstico al realizar el pronóstico implementando el enfoque jerárquico con respecto al pronóstico implementando ARIMA para la subcategoría sin ningún proceso adicional.

Una vez validada la mejora que aporta la implementación del modelo con enfoque jerárquico se procede a hacer la implementación también para los pronósticos de la demanda directos de la subcategoría H Computadores & Tablets y la línea computadores portátiles obtenidos con el modelo ARIMA. Para la implementación de los modelos ARIMA se realiza siempre con los datos depurados.

La implementación del modelo con enfoque jerárquico también se realiza con los datos del promedio móvil simple sin la previa depuración hasta la desagregación para el pronóstico de la línea computadores portátiles a fin de hacer comparables los resultados con la implementación del modelo ARIMA y el enfoque jerárquico para el pronóstico de la demanda de la línea computadores portátiles.

Puesto que para el modelo promedio móvil simple se usan los datos sin depuración y para el modelo ARIMA se usan los datos con depuración, únicamente se emplea como métrica principal de desempeño para los análisis la medida MAPE que tiene en cuenta el error porcentual absoluto. El MAPE con el modelo ARIMA para la línea computadores portátiles es de 56,2% como se muestra en la tabla 4-11, este valor es menor con respecto al MAPE arrojado con el modelo promedio móvil simple en 9,21 puntos porcentuales como se muestra en la tabla 4-12. El resultado de la implementación del modelo con enfoque jerárquico para el modelo promedio móvil simple se puede evidenciar en el anexo G y la figura 4-8.

Tabla 4-11: Pronóstico implementando el modelo ARIMA y el modelo con enfoque jerárquico.

Familia	H Computadores & Tablet
	Línea 94 Portátiles
Líneas	Línea 94 Servidores
	Línea 94 Todo en Uno_PCs

Fecha	Línea 94 Portátiles	Línea 94 Servidores	Línea 94 Todo en Uno_PCs	Familia	Línea 94 Portátiles	Línea 94 Servidores	Línea 94 Todo en Uno_PCs	FCFportá	FCFserv	FCFallone	Real observado port	Dif port
2018-12	196	0	405	594	32,61%	0,00%	67,39%	194	0	400	174	20
2019-01	178	0	685	1053	20,63%	0,00%	79,37%	217	0	836	164	53
2019-02	169	0	1082	974	13,51%	0,00%	86,49%	132	0	842	258	-126
2019-03	233	0	364	686	39,03%	0,00%	60,97%	268	0	418	308	-40
2019-04	300	0	649	816	31,61%	0,00%	68,39%	258	0	558	626	-368
2019-05	548	0	188	685	74,46%	0,00%	25,54%	510	0	175	241	269
2019-06	385	0	444	950	46,44%	0,00%	53,56%	441	0	509	241	200
2019-07	245	0	737	1047	24,95%	0,00%	75,05%	261	0	786	667	-406
2019-08	546	0	1170	1554	31,82%	0,00%	68,18%	494	0	1060	591	-97
2019-09	633	0	670	1325	48,58%	0,00%	51,42%	644	0	681	167	477
2019-10	298	0	454	876	39,63%	0,00%	60,37%	347	0	529	237	110
2019-11	220	0	658	882	25,06%	0,00%	74,94%	221	0	661	117	104
2019-12	152	3	698	875	17,82%	0,35%	81,83%	156	3	716	131	25
										MAE	MSE	MAPE
										176,53	53.347,01	56,2%

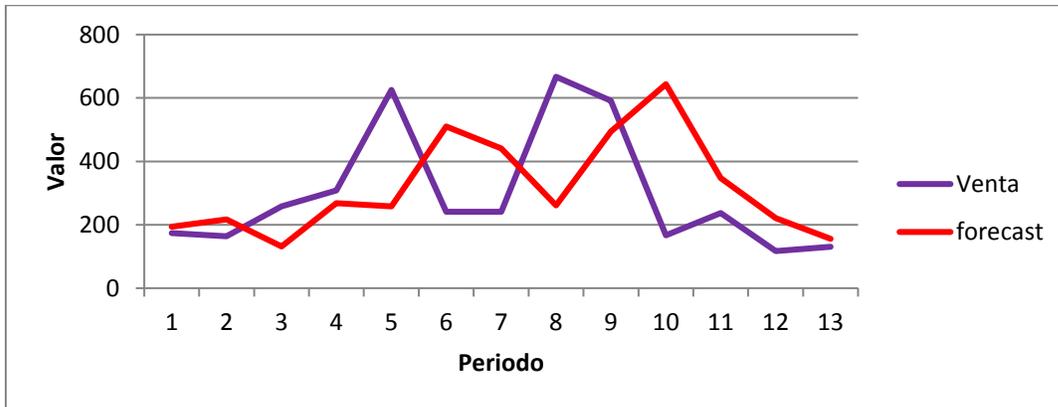
Tabla elaboración propia a partir de los resultados de los modelos implementados.

Tabla 4-12: Medidas de desempeño implementando modelo con enfoque jerárquico y promedio móvil sin limpieza de datos versus ARIMA con limpieza de datos a la línea computadores portátiles de la subcategoría H computadores & Tablets.

Modelo	MAE	MSE	MAPE
Implementación enfoque jerárquico promedio móvil simple	197	48.434	65,39%
Implementación enfoque jerárquico ARIMA	177	53.347	56,18%
Diferencia	20	-4.913	9,21%

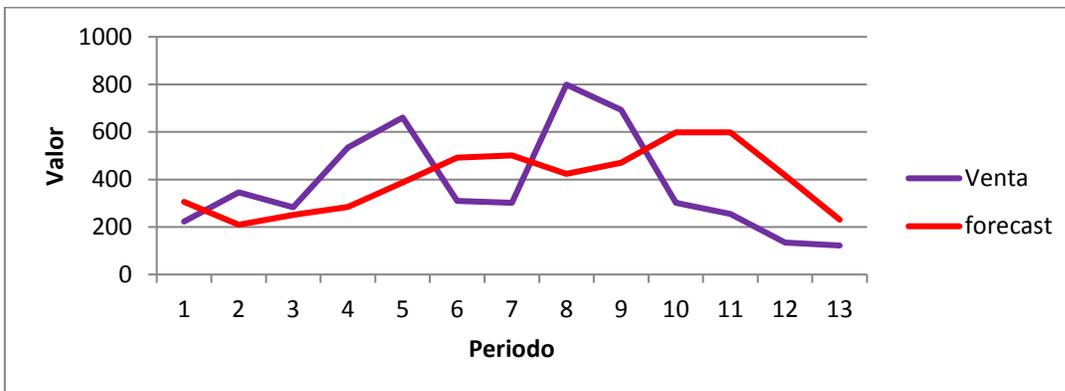
Tabla elaboración propia a partir de los resultados de los modelos implementados.

Figura 4-8: Pronóstico de la demanda implementando modelo con enfoque jerárquico y ARIMA con limpieza de datos a la línea computadores portátiles de la subcategoría H computadores & Tablets



Gráfica elaboración propia a partir de resultados modelo

Figura 4-9: Pronóstico de la demanda implementando modelo con enfoque jerárquico y promedio móvil sin limpieza de datos a la línea computadores portátiles de la subcategoría H computadores & Tablets



Gráfica elaboración propia a partir de resultados modelo

Si comparamos las gráficas 4-8 y 4-9 se percibe mejor ajuste del pronóstico de la demanda para la línea computadores portátiles con el modelo ARIMA y se confirma cuantitativamente con la medida MAPE teniendo error de pronóstico de la demanda de 56,18% y de 65,39% para los modelos ARIMA y promedio móvil simple respectivamente. Dado esto aceptamos la hipótesis relacionada anteriormente en la que se mencionaba mejor ajuste del pronóstico de la demanda para la línea computadores portátiles obtenido

con el modelo ARIMA con respecto al modelo promedio móvil simple por la visualización de las figuras 4-3 y 4-4 sin la implementación del modelo con enfoque jerárquico.

Finalmente, como conclusión del análisis de resultados se determina que la implementación del modelo ARIMA y posterior la implementación del modelo con enfoque jerárquico para realizar el pronóstico de la demanda arroja mejor desempeño que el modelo usado actualmente por la compañía. La limpieza de los datos e identificación de los valores atípicos permite un ahorro de \$296 millones anuales y la implementación del modelo ARIMA con enfoque jerárquico respecto al modelo promedio móvil simple permite un ahorro de \$10 millones anuales. La compañía obtiene un ahorro de \$306 millones anuales posterior a la implementación de lo propuesto en el presente trabajo.

El desempeño del pronóstico bajo la medida MAPE mejora si se realiza con la demanda agregada para todas las categorías y de allí se realiza la desagregación con el modelo del enfoque jerárquico. Por lo tanto, se recomienda realizar la depuración de los datos de la demanda para todas las categorías de la compañía e implementar el pronóstico de la demanda con el modelo ARIMA y el modelo con enfoque jerárquico hasta el nivel de desagregación que la compañía quiera obtener para lograr mayor nivel de ahorro anual respecto a los \$306 millones relacionados.

5. Conclusiones y recomendaciones

5.1 Conclusiones

- El proceso de limpieza de los datos y depuración de los valores atípicos genera un ahorro de \$296 millones anuales independiente del modelo de pronóstico usado. La implementación del modelo ARIMA y el modelo con enfoque jerárquico permite un ahorro adicional de \$10 millones anuales. La selección e implementación de los modelos para el pronóstico de la demanda de la línea computadores portátiles de la empresa en estudio permite un ahorro anual de \$306 millones de pesos cuantificados en costos ocultos de inventario asociados a costos de oportunidad, depreciación y tasas de interés por apalancamiento financiero. Existen costos asociados a flujos de caja, almacenamiento y mantenimiento de inventario que no se contemplan en el análisis actual y se recomienda su cuantificación a mediano plazo.
- La revisión del estado del arte del comportamiento de la demanda de la industria de la alta tecnología en mercados emergentes como el colombiano permite determinar que se encuentra caracterizada por ciclos de vida cortos con ingreso y retirada constante de productos, poca evidencia de saturación del mercado y demanda elástica. La característica de estacionariedad en la serie de tiempo cambia acorde al eslabón de la cadena de suministro dado el sistema de inventario manejado por cada uno.
- Dada la característica de ingreso y retirada constante de productos en la industria de la alta tecnología se recomienda el uso de la demanda agregada para los diferentes análisis. Acorde al comportamiento de la demanda de la industria de la alta tecnología se determina como análoga la industria moda. Para la industria de la alta tecnología la mayoría de las investigaciones se enfocan en el eslabón fabricante implementado modelos por curvas de ciclo de vida, modelos por uso y

modelos por capacidad de carga a razón de tasas de obsolescencia. Para la industria moda hay mayor cantidad de investigaciones con uso de modelos estadísticos y redes neuronales. En diferentes investigaciones se establece que el modelo ARIMA tiene igual o mejor desempeño que las redes neuronales, adicional a tener mayor facilidad en el proceso de implementación, adopción y uso.

- Dadas las diferentes revisiones de literatura se determina el uso del modelo ARIMA como adecuado acorde al comportamiento de la demanda del eslabón distribuidor con enfoque B2B para la industria de la alta tecnología. Como se recomienda analizar los datos de manera agregada, con el fin de obtener el pronóstico de la demanda de la línea computadores portátiles, se selecciona un modelo con enfoque jerárquico que es implementado en una investigación para la industria moda.
- Para la implementación de los modelos seleccionados es crucial la limpieza de los datos e identificación de los valores atípicos. Posterior a la depuración de los datos se puede realizar un análisis correcto de la serie de tiempo. El análisis de la serie de tiempo con las diferentes pruebas y lectura de los correlogramas permite determinar como valores adecuados para el modelo ARIMA los parámetros (1,1,0) para el número de autorregresivos, número de diferencias y número de medias móviles respectivamente. Posterior a la implementación del modelo ARIMA para la subcategoría H Computadores & Tablets y la línea computadores portátiles se obtienen las proporciones históricas y se determina el pronóstico final para la línea computadores portátiles mediando la implementación del modelo con enfoque jerárquico. Se descarta el uso del modelo por curvas de ciclo de vida al no tener un comportamiento visible de etapas de introducción, madurez y declive en las series de tiempo de la demanda del eslabón distribuidor.
- Para la validación de los resultados y comparación entre los modelos propuestos y el modelo usado actualmente por la compañía se hace uso principalmente de la medida de desempeño MAPE. La implementación del modelo ARIMA mejora en 3,46% el desempeño del pronóstico respecto al modelo promedio móvil simple para el pronóstico de la demanda de la subcategoría H Computadores & Tablets. La ejecución de pronósticos de la demanda con el modelo promedio móvil simple arroja mejores resultados a nivel de desempeño en términos de error porcentual absoluto MAPE si se realiza con la demanda agregada para todas las categorías de la compañía, obteniendo un 24,03% versus un 52,57% ejecutando el modelo

con los datos depurados para la subcategoría H Computadores & Tablets. Esto nos permite concluir que para este caso en específico el desempeño cambia significativamente en función del nivel de agregación adoptado. Aquí se debe tener en cuenta siempre que las agregaciones deben ser con dimensiones coherentes con el proceso de generación de demanda y homogeneidad, ya que cuanto más heterogénea es la demanda, más inaplicable puede ser la ejecución del pronóstico de la demanda agregada.

- La industria de la alta tecnología requiere una conexión adicional con el eslabón distribuidor, actualmente existe una coordinación entre los eslabones fabricante y mayorista para asegurar la salida total de las referencias antes del lanzamiento de otro producto con fines de canibalización pero esto no ve 100% reflejado en el eslabón distribuidor, en muchos casos los mayoristas aprovechan los descuentos u oportunidades de devolución de inventario al fabricante sin trasladarlo siempre al distribuidor. Se deja como línea en futuras investigaciones el análisis en la metodología de coordinación con el eslabón distribuidor y con ello proponer opciones de implementación.

5.2 Recomendaciones

- Se recomienda en investigaciones posteriores verificar el proceso usado actualmente para las refacturaciones y el canal que permite la aceptación de devolución de alguna factura teniendo en cuenta la afectación que esto representa en la calidad de los datos por ser documentos ejecutados en fechas diferentes a la venta.
- Se debe realizar identificación tanto de las ventas perdidas por no conversión de una oportunidad como las generadas por devoluciones de los clientes por errores internos. El no cuantificar estas causales no sólo afecta la calidad del pronóstico al no tener en cuenta la demanda completa, sino que también afecta la mejora continua en la compañía.
- Al indagar con el área de novedades las causales de devolución, según la percepción del rol actual del cargo, indica que aproximadamente un 20% de las devoluciones corresponden a errores internos, se recomienda asegurar la medición a futuro para no perder ingresos y mejorar la calidad de los datos.

- En capítulos anteriores se presenta una recomendación sobre el proceso que se debería llevar a cabo en la creación de artículos, teniendo en cuenta que la información incompleta con un sistema de información robusto afecta en gran medida la calidad de la base de datos.
- Algunas de las limitaciones del modelo sugerido se dan al no contemplar factores externos, como eventos de marketing, promociones, etc. Por lo que se recomienda realizar una combinación del modelo propuesto con modelos cualitativos para contemplar variables ajenas al histórico.
- La implementación del modelo requiere identificación de parámetros para su ejecución, por lo que se recomienda tener mayor profundización en el uso de herramientas del tipo Google colab para identificar estas variables de manera rápida gracias a las bibliotecas existentes de modelos estadísticos en código Python.
- Dado que la compañía actualmente cuenta con un área de planificación de demanda y un ERP robusto, se recomienda que el área mencionada anteriormente sustituya el uso del modelo promedio móvil simple por el uso del modelo ARIMA. Así pues, la compañía tendría únicamente como función adicional el entrenamiento y uso del modelo ARIMA mediante la herramienta gratuita de Google colab. Dada la facilidad de aplicación del modelo se recomienda incluirlo en las tareas para que los \$10M anuales de ahorro sean justificables sin una alta inversión de recursos.
- El proceso de identificación de las ventas que corresponden a licitaciones se realizó con un proceso 100% manual por lo que posiblemente se tiene algún grado de error en estos datos. Se recomienda asegurar el cambio en el registro de la información para prevenir este error a futuro.

A. Anexo: Empresas inscritas en informa actividad 4741

directorio-empresas.einforma.co/actividad/4741-comercio-al-por-menor-de-computadores-equipos-perifericos-programas-de-informatica-y-equipos-de-telecomunic..

por menor de computadores equipos perifericos programas de informatica y equipos de telecomunicaciones en establecimientos especializados.

1 2 3 4 5 ... 53 54 ... 155 »

Empresa	Ciudad	Departamento
Dell colombia inc	Bogota	Bogota
I shop colombia s a s	Bogota	Bogota
Mac center colombia sociedad por acciones simplificada	Bogota	Bogota
Colsof s a s	Cota	Cundinamarca
Singular comunicaciones s a singularcom s a	Bogota	Bogota
Compunet s a	Cali	Valle
Redes y sistemas integrados s a s	Barranquilla	Atlantico
Oficomco sas	Bogota	Bogota
Nueva era soluciones sas	Cota	Cundinamarca

B. Anexo: Código Google Colaboratory modelo ARIMA (1,1,0)

```
from pandas import read_csv
from pandas import datetime
from matplotlib import pyplot
import pandas as pd
from pandas.plotting import autocorrelation_plot
import numpy as np
import matplotlib.pyplot as plt
%matplotlib inline
from sklearn.metrics import mean_squared_error
from math import sqrt
from pandas import DataFrame

df=pd.read_csv('ventas_mes_2016_2019_mod datos fechas NCRs y CLIs licitacion SIN TABLETS SIN CODERE PUNTUAL.csv')
df.head()

# Updating the header
df.columns=["Month","Sales"]
df.head()
df.describe()
df.set_index('Month',inplace=True)

from pylab import rcParams
rcParams['figure.figsize'] = 15, 7
df.plot()
```

```
import pandas as pd
import numpy as np

# Reading the data
df = pd.read_csv("ventas_mes_2016_2019_mod datos fechas NCRs y CLIs licitacion SIN TABLETS SIN CODERE PUNTUAL.csv")
print(df.shape)
print(df.info())
```

```
(48, 3)
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 48 entries, 0 to 47
Data columns (total 3 columns):
 #   Column  Non-Null Count  Dtype
---  -
 0   Date    48 non-null      object
 1   Sales   48 non-null      int64
 2   Class   48 non-null      object
dtypes: int64(1), object(2)
memory usage: 1.2+ KB
None
```

```
[2] train = df[df["Class"] == "Train"]
test = df[df["Class"] == "Test"]
print(train.shape)
print(test.shape)
```

```
(36, 3)
(12, 3)
```

```
[3] train_array = train["Sales"]
print(train_array.shape)

test_array = test["Sales"]
print(test_array.shape)
```

```
(36,)
(12,)
```

```
!pip install pmdarima
from pmdarima.arima import auto_arima
stepwise_fit = auto_arima(df['Sales'], trace=True,
suppress_warnings=True)
```

```
from statsmodels.tsa.arima_model import ARIMA
model=ARIMA((train_array),order=(1,1,0))
model_fit=model.fit()
model_fit.summary()
```

C. Anexo: Test Fuller

```
def adfuller_test(sales):  
    result = adfuller(sales)  
    labels = ['ADF Test Statistic','p-value','#Lags Used','Number of Observations']  
    for value,label in zip(result,labels):  
        print(label+' : '+str(value) )  
  
    if result[1] <= 0.05:  
        print("strong evidence against the null hypothesis(Ho), reject the null hypothesis. Data is stationary")  
    else:  
        print("weak evidence against null hypothesis,indicating it is non-stationary ")  
  
adfuller_test(df['Sales'])
```

```
ADF Test Statistic : -2.319778322244248  
p-value : 0.1656683885477866  
#Lags Used : 2  
Number of Observations : 53  
weak evidence against null hypothesis,indicating it is non-stationary
```

D. Anexo: Valor promedio por unidad

Tipo de art	Ubicación	ID interno	Artículo	In.	OFI Categ	Valor de fact	Por de fact	Disponil	Stock acti	Costo unida
Artículo de inv	CO Principal	211829	211829 Portatil Acer 14" 1TB 4GB TMP2410-G2-	No	Hardware de	\$1.914.258,45	0,13%	1,00	1,00	\$1.914.258,45
Artículo de inv	CO Principal	213537	213537 Monitor Dell 18.5" (E1916HV)	No	Hardware de	\$2.195.944,84	0,15%	13,00	13,00	\$168.918,83
Artículo de inv	CO Principal	213575	213575 Macbook AIR 13.3" 128GB (MQD32E/A)	No	Hardware de	\$2.996.544,00	0,20%	1,00	1,00	\$2.996.544,00
Artículo de inv	CO Principal	213576	213576 PC HP 400 8GB 3.8 GHz, 6 MB i5 7500 (No	Hardware de	\$3.587.388,00	0,24%	2,00	2,00	\$1.793.694,00
Artículo de inv	CO Principal	213606	213606 HP Prodesk 400 G4 CPU/Monitor V190 (No	Hardware de	\$9.038.148,00	0,61%	4,00	4,00	\$2.259.537,00
Artículo de inv	CO Principal	213610	213610 Monitor HP EliteDisplay 21,5" (1FH45AA	No	Hardware de	\$2.046.998,25	0,14%	3,00	3,00	\$682.332,75
Artículo de inv	CO Principal	213612	213612 Computador HP ProDes 400G5 SFFi53.0	No	Hardware de	\$0,00	0,00%	1,00	1,00	\$0,00
Artículo de inv	CO Principal	213638	213638 Monitor 18,5" HP (2NK17AA#ABM)	No	Hardware de	\$690.764,00	0,05%	2,00	2,00	\$345.382,00
Artículo de inv	CO Principal	213641	213641 PC Dell Optiplex Ci5 8G 4GB W10P (9PK	No	Hardware de	\$14.643.429,84	1,00%	8,00	8,00	\$1.830.428,73
Artículo de inv	CO Principal	213642	213642 PC 280 4GB Monitor 18,5"HP(3WU20LT#	No	Hardware de	\$2.176.830,88	0,15%	1,00	1,00	\$2.176.830,88
Artículo de inv	CO Principal	213654	213654 PC HP 280 G3 i5-8500 4GB 1TB W10P (No	Hardware de	\$3.858.865,59	0,26%	2,00	2,00	\$1.929.432,80
Artículo de inv	CO Principal	213717	213717 Monitor Samsung Curvo 24" Gaming (LC	No	Hardware de	\$675.000,00	0,05%	1,00	1,00	\$675.000,00
Artículo de inv	CO Principal	213745	213745 Laptop DELL Vostro 14 5481 Intel Core i	No	Hardware de	\$2.436.858,12	0,17%	1,00	1,00	\$2.436.858,12
Artículo de inv	CO Principal	213758	213758 Monitor DELL 21.5" (E2220H)	No	Hardware de	\$585.744,34	0,04%	2,00	2,00	\$292.872,17
Artículo de inv	CO Principal	213789	213789 PC HP 400G5PD DM i79700T 8GB/1TB P	No	Hardware de	\$12.495.000,00	0,85%	5,00	5,00	\$2.499.000,00
Artículo de inv	CO Principal	213902	213902 AIO Compaq 18-4200LA AMD E1, 2GB,	No	Hardware de	\$945.000,00	0,06%	1,00	1,00	\$945.000,00
Artículo de inv	CO Principal	213906	213906 Thinkvision Lenovo E2054 (60DFAAR1U	No	Hardware de	\$307.874,52	0,02%	1,00	1,00	\$307.874,52
Artículo de inv	CO Principal	213951	213951 Monitor HP EliteDisplay E222 21.5" (M1N	No	Hardware de	\$477.223,44	0,03%	1,00	1,00	\$477.223,44
Artículo de inv	CO Principal	213966	213966 ProDesk SFF HP 600 G2 Corei5 (L1Q39	No	Hardware de	\$1.772.159,06	0,12%	1,00	1,00	\$1.772.159,06
Artículo de inv	CO Principal	213967	213967 Monitor HP VH22 21.5" (V9E67AA#ABA	No	Hardware de	\$2.429.729,90	0,17%	5,00	5,00	\$485.945,98
Artículo de inv	CO Principal	214003	214003 HP P204v Monitor 19,5" (5RD66AA)	No	Hardware de	\$1.700.000,00	0,12%	5,00	5,00	\$340.000,00
Artículo de inv	CO Principal	218966	218966 Monitor Dell Serie Entry (E2216HV)	No	Hardware de	\$14.876.063,28	1,01%	46,00	46,00	\$323.392,68
Artículo de inv	CO Principal	219097	219097 HP 280 G3 SFF Core i3 RAM 4GB DD 1T	No	Hardware de	\$3.157.086,54	0,21%	2,00	2,00	\$1.578.543,27
Artículo de inv	CO Principal	219168	219168 HP ProDesk 400 G6 SF Intel Core i7-970	No	Hardware de	\$2.530.000,00	0,17%	1,00	1,00	\$2.530.000,00
Artículo de inv	CO Principal	219525	219525 Monitor Dell 18.5" (E1916H_G)	No	Hardware de	\$12.420.000,00	0,84%	46,00	46,00	\$270.000,00
Artículo de inv	CO Principal	223366	223366LS CTO Portátil Latitude 3400 i5-8265U C	No	Hardware de	\$7.441.968,34	0,51%	3,00	3,00	\$2.480.656,11
Artículo de inv	CO Principal	223502	223502LS CTO Optiplex 3070 MFF Mini/Micro (C	No	Hardware de	\$4.499.365,75	0,31%	2,00	2,00	\$2.249.682,88
Artículo de inv	CO Principal	223503	223503LS Monitor DELL 21.5" (E2220H)	No	Hardware de	\$576.647,21	0,04%	2,00	2,00	\$288.323,61
Artículo de inv	CO Principal	223727	223727 PC Micro OptiPlex 3060 MSFF XCTO Inte	No	Hardware de	\$85.450.875,12	5,81%	46,00	46,00	\$1.857.627,72
										\$1.307.155,83

E. Anexo: Estado financiero ventas año 2018 y 2019

Oficomco SAS

Estado de Resultado Integral

Del 1 de Enero al 31 de Diciembre de 2019

(Cifras Expresadas en Pesos Colombianos)

Descripción	Nota	2.019 ACUMULADO	2.018 ACUMULADO
<u>Ingresos</u>			
Ingresos de actividades ordinarias	14	68.454.105.503	49.339.917.503
Devolucion en Ventas	14	(363.397.477)	(437.515.763)
Ingresos Netos		68.090.708.025	48.902.401.740
Costo de Ventas	15	55.194.665.883	37.583.084.991
Utilidad Bruta		12.896.042.142	11.319.316.749
<u>Gastos de Operacion</u>			
Gastos De Administración		0	1.085.112.678
Gastos De Ventas	16	12.762.070.729	8.789.620.658
Utilidad Operacional		133.971.414	1.444.583.413
Otros Ingresos	17	6.404.359.785	339.892.959
Gastos Financieros	18	1.135.859.060	441.045.333
Otros Gastos	19	4.461.345.107	530.253.566
Utilidad Antes de Impuestos		941.127.031	813.177.473
Provisión por Impuesto de Renta	11	326.772.260	407.654.000
Impuesto Diferido	11	319.203.110	
Utilidad del Ejercicio		295.151.662	405.523.473

Las notas adjuntas hacen parte integral del Estado de Situación Financiera



Peter Arman Ostroske
Representante Legal
Oficomco SAS



Adriana Carolina Salamanca
Contador
TP N. 113812-T



Nestor Guillermo Guerrero Piñeros
Revisor Fiscal
TP N. 57191-T
Business an Business Auditores LTDA

F. Anexo: Valor promedio inventario

Oficomco SAS

Estado de Situación Financiera Comparativo
a 31 de Diciembre de de 2019
(Cifras Expresadas en Pesos Colombianos)

ACTIVO	Nota	Diciembre 2019	Diciembre 2018
ACTIVOS			
Activos Corriente			
Efectivo y equivalentes de efectivo	1	1.488.315.935	630.335.609
Cuentas por Cobrar Comerciales y otras cuentas por cobrar	2	28.446.310.131	17.624.341.725
Inventarios	3	3.608.128.834	3.992.971.572
Activos por Impuestos Corrientes	4	2.679.213.133	3.132.021.920
Total Activos Corrientes		36.221.968.033	25.379.670.826
Activos no Corrientes			
Inversiones (Medidas costo amortizado)		0	38.365.243
Propiedades, planta y equipo	5	10.058.401.822	2.645.572.506
Activos intangibles diferentes a plusvalía	6	5.459.689	196.399.426
Impuesto Diferido		0	0
Total Activos no Corrientes		10.063.861.511	2.880.337.175
Total Activos		46.285.829.545	28.260.008.001

PASIVO		Diciembre 2019	Diciembre 2018
PASIVO			
Pasivo Corriente			
Obligaciones Financieras	7	4.587.349.438	4.207.421.887
Cuentas por Pagar Comerciales y Otras Cuentas por Pagar	8	9.734.990.663	8.294.263.504
Beneficio Empleados	9	776.738.952	455.519.020
Otros Pasivos No Financieros Corrientes	10	390.931.630	2.055.534.446
Total Pasivos Corrientes		15.490.010.683	15.012.738.857
Pasivos no Corrientes			
Obligaciones financieras	7	11.322.485.912	2.647.221.749
Provisiones		7.163.708.290	587.304.102
Pasivos por impuesto diferido	11	62.424.016	0

G. Anexo: Pronóstico con enfoque jerárquico y promedio móvil simple

Línea 94 Portátiles	Línea 94 Servidores	Línea 94 Todo en Uno_PCs	Línea Almacenamiento	Línea Impresoras	Monitores y proyectores	Línea Otras	Línea otras línea 94	Línea 94 Portátiles	Línea 94 Servidores	Línea 94 Todo en Uno_PCs	Línea Almac enamiento	Línea Impresoras	Monitores y proyectores	Línea Otras	Línea otras línea 94	Familia	Real observado port	FCF portátiles
342	1	245	333	407	221	3498	846	6%	0%	4%	6%	7%	4%	59%	14%	5893	243	342
258	1	163	278	149	95	3044	1228	5%	0%	3%	5%	3%	2%	58%	24%	5216	512	258
289	0	246	412	232	230	2462	889	6%	0%	5%	9%	5%	5%	52%	19%	4761	222	289
326	0	760	372	272	263	2455	1025	6%	0%	14%	7%	5%	5%	45%	19%	5473	183	326
306	0	805	361	260	259	1892	404	7%	0%	19%	8%	6%	6%	44%	9%	4287	223	306
209	0	1034	265	146	176	1595	294	6%	0%	28%	7%	4%	5%	43%	8%	3720	346	209
251	0	690	330	129	210	1855	40	7%	0%	20%	9%	4%	6%	53%	1%	3505	283	251
284	0	765	482	125	248	1970	55	7%	0%	19%	12%	3%	6%	50%	1%	3929	534	284
388	0	467	476	157	196	1889	56	11%	0%	13%	13%	4%	5%	52%	2%	3628	660	388
492	0	424	469	123	381	1845	74	13%	0%	11%	12%	3%	10%	48%	2%	3809	309	492
501	0	454	424	179	481	1866	68	13%	0%	11%	11%	4%	12%	47%	2%	3973	302	501
424	0	615	443	241	532	1678	101	11%	0%	15%	11%	6%	13%	42%	3%	4034	799	424
470	0	717	434	414	341	1623	158	11%	0%	17%	10%	10%	8%	39%	4%	4158	693	470
598	0	699	494	412	233	2337	139	12%	0%	14%	10%	8%	5%	48%	3%	4913	302	598
598	2	610	683	431	264	2681	127	11%	0%	11%	13%	8%	5%	50%	2%	5397	255	598
417	2	652	797	358	516	3179	59	7%	0%	11%	13%	6%	9%	53%	1%	5980	134	417
230	4	567	732	297	594	2473	58	5%	0%	11%	15%	6%	12%	50%	1%	4956	122	230
																MAE	MSE	MAPE
																196,96	48.434,14	65,39%

Bibliografía

- Agostino, I. R. S., da Silva, W. V., Pereira da Veiga, C., & Souza, A. M. (2020). Forecasting models in the manufacturing processes and operations management: Systematic literature review. *Journal of Forecasting*, *October 2019*, 1–14. <https://doi.org/10.1002/for.2674>
- Agrawal, D., & Schorling, C. (1996). Market share forecasting: An empirical comparison of artificial neural networks and multinomial logit model. *Journal of Retailing*, *72(4)*, 383–407.
- Aitken, J., Childerhouse, P., & Towill, D. (2003). The impact of product life cycle on supply chain strategy. *International Journal of Production Economics*, *85(2)*, 127–140. [https://doi.org/10.1016/S0925-5273\(03\)00105-1](https://doi.org/10.1016/S0925-5273(03)00105-1)
- Alon, I., Qi, M., & Sadowski, R. J. (2001). Forecasting aggregate retail sales: A comparison of artificial neural networks and traditional methods. *Journal of Retailing and Consumer Services*, *8(3)*, 147–156. [https://doi.org/10.1016/S0969-6989\(00\)00011-4](https://doi.org/10.1016/S0969-6989(00)00011-4)
- Bajracharya, A., Khan, M. R. A., Michael, S., & Tonkoski, R. (2019). Forecasting Data Center Load Using Hidden Markov Model. *2018 North American Power Symposium, NAPS 2018*. <https://doi.org/10.1109/NAPS.2018.8600677>
- Basallo-Triana, M. J., Rodríguez-Sarasty, J. A., & Benitez-Restrepo, H. D. (2017). Analogue-based demand forecasting of short life-cycle products: a regression approach and a comprehensive assessment. *International Journal of Production Research*, *55(8)*, 2336–2350. <https://doi.org/10.1080/00207543.2016.1241443>
- Bayus, B. L. (1998). An analysis of product lifetimes in a technologically dynamic industry. *Management Science*, *44(6)*, 763–775. <https://doi.org/10.1287/mnsc.44.6.763>
- Ben Taieb, S., & Koo, B. (2019). Regularized regression for hierarchical forecasting without unbiasedness conditions. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1337–1347. <https://doi.org/10.1145/3292500.3330976>
- Box, G. E. ., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis*

Forecasting and Control.

- Boylan, J. E., & Syntetos, A. A. (2010). Spare parts management: A review of forecasting research and extensions. *IMA Journal of Management Mathematics*, 21(3), 227–237. <https://doi.org/10.1093/imaman/dpp016>
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*.
- Burruss, J. (2002). *Forecasting for Short-Lived Products*.
- Chanda, U., & Aggarwal, R. (2014). Journal of High Technology Management Research Optimal inventory policies for successive generations of a high technology product. *Journal of High Technology Management Research*, 25(2), 148–162. <https://doi.org/10.1016/j.hitech.2014.07.004>
- Chanda, U., & Bardhan, A. K. (2008). Modelling innovation and imitation sales of products with multiple technological generations. *Journal of High Technology Management Research*, 18(2), 173–190. <https://doi.org/10.1016/j.hitech.2007.12.004>
- Chatfield, C. (1993). Neural networks: Forecasting breakthrough or passing fad? *International Journal of Forecasting*, 9(1), 1–3. <https://econpapers.repec.org/RePEc:eee:intfor:v:9:y:1993:i:1:p:1-3>
- Cho, Y., & Daim, T. (2013). *Technology Forecasting Methods* (pp. 67–112). https://www.researchgate.net/publication/262725442_Technology_Forecasting_Methods_in_Research_and_Technology_Management_in_the_Electricity_Industry_Methods_Tools_and_Case_Studies
- Chung, W., Talluri, S., & Narasimhan, R. (2011). Price markdown scheme in a multi-echelon supply chain in a high-tech industry. *European Journal of Operational Research*, 215(3), 581–589. <https://doi.org/10.1016/j.ejor.2011.07.002>
- Cox, W. E. (1967). Product Life Cycles as Marketing Models. *The Journal of Business*, 40(4), 375–384. <http://www.jstor.org/stable/2351620>
- Donkor, E. A., Mazzuchi, T. A., Soyer, R., & Alan Roberson, J. (2012). Urban Water Demand Forecasting: Review of Methods and Models. *Journal of Water Resources Planning and Management*, 140(2), 146–159. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0000314](https://doi.org/10.1061/(asce)wr.1943-5452.0000314)
- Faraway, J. J. (1998). *Time series forecasting with neural networks : a comparative study using the airline data*.
- Feng, G., Huang, G., Lin, Q., & Gay, R. (2009). *of Hidden Nodes and Incremental Learning*. 20(8), 1352–1357.
- Fildes, R., Nikolopoulos, K., Crone, S. F., & Syntetos, A. A. (2008). Forecasting and

- operational research: A review. *Journal of the Operational Research Society*, 59(9), 1150–1172. <https://doi.org/10.1057/palgrave.jors.2602597>
- Franses, P. H., & Legerstee, R. (2009). Properties of expert adjustments on model-based SKU-level forecasts. *International Journal of Forecasting*, 25(1), 35–47. <https://doi.org/10.1016/j.ijforecast.2008.11.009>
- Gelper, S., Fried, R., & Croux, C. (2010). Robust forecasting with exponential and holt-winters smoothing. *Journal of Forecasting*, 29(3), 285–300. <https://doi.org/10.1002/for.1125>
- Goldman, A., & Marketing, A. (1982). Short product life cycles: implications for the marketing activities of small high-technology companies *. *R & D Management*, 1&2, 81–89.
- Goodwin, P., & Wright, G. (2010). The limits of forecasting methods in anticipating rare events. *Technological Forecasting and Social Change*, 77(3), 355–368.
- Helo, P. (2004). Managing agility and productivity in the electronics industry. *Industrial Management and Data Systems*, 104(7), 567–577. <https://doi.org/10.1108/02635570410550232>
- Hu, K., Acimovic, J., Erize, F., Thomas, D. J., Mieghem, J. A. Van, Hu, K., Acimovic, J., Erize, F., Thomas, D. J., & Mieghem, A. Van. (2019). *Manufacturing & Service Operations Management Forecasting New Product Life Cycle Curves: Practical Approach and Empirical Analysis Forecasting New Product Life Cycle Curves: Practical Approach and Empirical Analysis*. May.
- Huang, G. Bin, & Babri, H. A. (1998). Comments on “approximation capability in $C(\mathbb{R}^n)$ by multilayer feedforward networks and related problems.” *IEEE Transactions on Neural Networks*, 9(4), 714–715. <https://doi.org/10.1109/72.701184>
- Hyndman, R. J., Ahmed, R. A., Athanasopoulos, G., & Shang, H. L. (2011). Optimal combination forecasts for hierarchical time series. *Computational Statistics and Data Analysis*, 55(9), 2579–2589. <https://doi.org/10.1016/j.csda.2011.03.006>
- J. Scott Armstrong. (2002). *PRINCIPLES OF FORECASTING: A Handbook for Researchers and Practitioners*. <https://doi.org/10.1007/978-0-306-47630-3>
- Jaakkola, H., Gabbouj, M., & Neuvo, Y. (1998). Fundamentals of technology diffusion and mobile phone case study. *Circuits, Systems, and Signal Processing*, 17, 421–448. <https://doi.org/10.1007/BF01202301>
- Ju, M., & Yang, Y. A. N. (2010). *Forecasting Global Generation of Obsolete Personal*

Computers. 44(9), 3232–3237.

- Kaytez, F., Taplamacioglu, M. C., Cam, E., & Hardalac, F. (2015). Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. *International Journal of Electrical Power and Energy Systems*, 67, 431–438. <https://doi.org/10.1016/j.ijepes.2014.12.036>
- Kim, H. J., Jee, S. J., & Sohn, S. Y. (2021). Cost–benefit model for multi-generational high-technology products to compare sequential innovation strategy with quality strategy. *PLoS ONE*, 16(4 April), 1–17. <https://doi.org/10.1371/journal.pone.0249124>
- Klimberg, R. K., Sillup, G. P., Boyle, K. J., & Tavva, V. (2010). Forecasting performance measures - What are their practical meaning? In *Advances in Business and Management Forecasting* (Vol. 7). Elsevier. [https://doi.org/10.1108/S1477-4070\(2010\)0000007012](https://doi.org/10.1108/S1477-4070(2010)0000007012)
- Kou, T. C., & Lee, B. C. Y. (2015). The influence of supply chain architecture on new product launch and performance in the high-tech industry. *Journal of Business and Industrial Marketing*, 30(5), 677–687. <https://doi.org/10.1108/JBIM-08-2013-0176>
- Kurawarwala, A. A., & Matsuo, H. (1996). Forecasting and Inventory Management of Short Life-Cycle Products. *Operations Research*, 44(1), 131–150. <http://www.jstor.org/stable/171910>
- Lapide, L. (2006). Evolution of the forecasting function. *Journal of Business Forecasting*, 25(1), 22–28.
- Lenort, R., & Besta, P. (2013). Hierarchical sales forecasting system for apparel companies and supply chains. *Fibres and Textiles in Eastern Europe*, 21(6), 7–11.
- Lin, R. J., Che, R. H., & Ting, C. Y. (2012). Turning knowledge management into innovation in the high-tech industry. *Industrial Management and Data Systems*, 112(1), 42–63. <https://doi.org/10.1108/02635571211193635>
- Lin, V. S. (2018). Judgmental adjustments in tourism forecasting practice: How good are they? In *Tourism Economics*. <https://doi.org/10.1177/1354816618806727>
- Lu, C. J. (2014). Sales forecasting of computer products based on variable selection scheme and support vector regression. *Neurocomputing*, 128, 491–499. <https://doi.org/10.1016/j.neucom.2013.08.012>
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2016). *Introduction Time Series Analysis and Forecasting*. 671.
- Moon, J., Chang, N., & Cho, W. (2015). Demand Forecasting for B2B Electronic Products : The Case of Personal Computer Market. *Journal of the Korea Society of IT Services*,

- 14, 185–197. <https://doi.org/10.9716/KITS.2015.14.4.185>
- Neelamegham, R., & Chintagunta, P. K. (2004). *Modeling and Forecasting the Sales of Technology Products*. 195–232.
- Nenni, M. E., Giustiniano, L., & Pirolo, L. (2013). Demand forecasting in the fashion industry: A review. *International Journal of Engineering Business Management*, 5(SPL.ISSUE). <https://doi.org/10.5772/56840>
- Nikolopoulos, K., Goodwin, P., Patelis, A., & Assimakopoulos, V. (2007). Forecasting with cue information: A comparison of multiple regression with alternative forecasting approaches. *European Journal of Operational Research*, 180(1), 354–368. <https://doi.org/10.1016/j.ejor.2006.03.047>
- Olhager, J. (2012). The role of decoupling points in value chain management. *Contributions to Management Science*, 37–47. https://doi.org/10.1007/978-3-7908-2747-7_2
- Pankratz, A. (2014). Forecasting With Dynamic Regression Models. *Journal of the American Statistical Association*, 88(422), 705–706.
- Puneeth Kumar, K., Manjunath, T. N., & Hegadi, R. S. (2018). Literature Review on Big Data Analytics and Demand Modeling in Supply Chain. *3rd International Conference on Electrical, Electronics, Communication, Computer Technologies and Optimization Techniques, ICEECCOT 2018, December*, 1246–1252. <https://doi.org/10.1109/ICEECCOT43722.2018.9001513>
- Ren, S., Chan, H.-L., & Ram, P. (2017). A Comparative Study on Fashion Demand Forecasting Models with Multiple Sources of Uncertainty. *Annals of Operations Research*, 257(1), 335–355. <https://doi.org/10.1007/s10479-016-2204-6>
- Ren, S., Chan, H. L., & Siqin, T. (2020). Demand forecasting in retail operations for fashionable products: methods, practices, and real case study. *Annals of Operations Research*, 291(1–2), 761–777. <https://doi.org/10.1007/s10479-019-03148-8>
- Rivera-Castro, R., Nazarov, I., Xiang, Y., Maksimov, I., Pletnev, A., & Burnaev, E. (2019). An industry case of large-scale demand forecasting of hierarchical components. *Proceedings - 18th IEEE International Conference on Machine Learning and Applications, ICMLA 2019*, 134–139. <https://doi.org/10.1109/ICMLA.2019.00029>
- Roberts, E. B. (1976). Technology Strategy for the Medium-Size Company. *Res Manage*, 19(4), 29–32. <https://doi.org/10.1080/00345334.1976.11756363>
- Sanders, N. R., & Manrodt, K. B. (1994). Forecasting Practices in US Corporations: Survey Results. *Interfaces*, 24(2), 92–100. <https://doi.org/10.1287/inte.24.2.92>

- Sanders, N. R., & Ritzman, L. P. (2001). JUDGMENTAL ADJUSTMENT OF STATISTICAL FORECASTS. *Springer Science+Business Media*.
- Shankaranarayanan, G., & Cai, Y. (2006). Supporting data quality management in decision-making. *Decision Support Systems*, 42(1), 302–317. <https://doi.org/10.1016/j.dss.2004.12.006>
- Simchi-levi, D. (2005). *Supply Chain Architecture in a High Demand Variability Environment* by. 1999.
- Srinivasan, S. R., Ramakrishnan, S., & Grasman, S. E. (2005). Incorporating cannibalization models into demand forecasting. *Marketing Intelligence and Planning*, 23(5), 470–485. <https://doi.org/10.1108/02634500510612645>
- St. John, H. M. (1978). The Energy Market for High-Technology Companies. *Journal of Marketing*, 42(4), 46–53. <https://doi.org/10.2307/1250085>
- Styrin, K. (2019). Forecasting Inflation in Russia Using Dynamic Model Averaging. *Russian Journal of Money and Finance*, 78(1), 03–18. <https://doi.org/10.31477/rjmf.201901.03>
- Sunil Chopra. (2010). *Administracion de Cadena de Suministro*. <https://doi.org/10.1017/CBO9781107415324.004>
- Tandon, R., Chakraborty, A., Srinivasan, G., Shroff, M., Abdullah, A., Shamasundar, B., Sinha, R., Subramanian, S., Hill, D., & Dhore, P. (2013). Hewlett Packard: Delivering profitable growth for HPDirect.com using operations research. *Interfaces*, 43(1), 48–61. <https://doi.org/10.1287/inte.1120.0661>
- Trappey, C. V., & Wu, H. Y. (2008). An evaluation of the time-varying extended logistic, simple logistic, and Gompertz models for forecasting short product lifecycles. *Advanced Engineering Informatics*, 22(4), 421–430. <https://doi.org/10.1016/j.aei.2008.05.007>
- Valencia-Cárdenas, M., Díaz-Serna, F. J., & Correa-Morales, J. C. (2015). Planeación de inventarios con demanda dinámica. Una revisión del estado del arte. *DYNA (Colombia)*, 82(190), 182–191. <https://doi.org/10.15446/dyna.v82n190.42828>
- Wagner, D. (2008). Lecture Notes in Computer Science: Preface. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 5157 LNCS*.
- Wei, W. W. S. (2013). *Oxford Handbooks Online Time Series Analysis* (Vol. 2, Issue April 2018). <https://doi.org/10.1093/oxfordhb/9780199934898.013.0022>
- Wilck IV, J. H., Pope, J., & Kauffmann, P. J. (2014). Literature review for forecasting traffic counts for high tourism areas. *IIE Annual Conference and Expo 2014*, 1272–1281.

- <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84910029456&partnerID=40&md5=32563cd1ae613706f3bba2f7b58e68e0>
- Wong, W. K., & Guo, Z. X. (2010). A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. *International Journal of Production Economics*, 128(2), 614–624.
- Xu, L. Da, Xu, E. L., & Li, L. (2018). Industry 4.0: State of the art and future trends. *International Journal of Production Research*, 56(8), 2941–2962. <https://doi.org/10.1080/00207543.2018.1444806>
- Yang, Y., & Williams, E. (2008). *Forecasting Sales and Generation of Obsolete Computers in the U . S .*
- Yang, Y., & Williams, E. (2009). Technological Forecasting & Social Change Logistic model-based forecast of sales and generation of obsolete computers in the U . S . *Technological Forecasting & Social Change*, 76(8), 1105–1114. <https://doi.org/10.1016/j.techfore.2009.03.004>
- Yelland, P. M. (2009). Bayesian forecasting for low-count time series using state-space models: An empirical evaluation for inventory management. *International Journal of Production Economics*, 118(1), 95–103. <https://doi.org/10.1016/j.ijpe.2008.08.027>
- Zhu, K., & Thonemann, U. W. (2004). An adaptive forecasting algorithm and inventory policy for products with short life cycles. *Naval Research Logistics*, 51(5), 633–653. <https://doi.org/10.1002/nav.10124>
- Zotteri, G., Kalchschmidt, M., & Caniato, F. (2005). *The impact of aggregation level on forecasting performance*. 94, 479–491. <https://doi.org/10.1016/j.ijpe.2004.06.044>