



**UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERIA INDUSTRIAL**

**METODOLOGÍA DE ESTIMACIÓN DE DEMANDA PARA PRODUCTOS
TECNOLÓGICOS**

**MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL
INDUSTRIAL**

CRISTIÁN ENRIQUE MORALES OLAVARRÍA

**PROFESOR GUÍA:
MANUEL REYES JARA**

**MIEMBROS DE LA COMISIÓN:
RICARDO MONTOYA MOREIRA
MIGUEL CARRASCO BRIONES**

**SANTIAGO DE CHILE
ABRIL 2009**

RESUMEN DE LA MEMORIA PARA OPTAR AL
TÍTULO DE INGENIERO CIVIL INDUSTRIAL
POR: CRISTIÁN MORALES OLAVARRÍA
FECHA: 08/05/2009
PROF. GUÍA: MANUEL REYES JARA

METODOLOGÍA DE ESTIMACIÓN DE DEMANDA PARA PRODUCTOS TECNOLÓGICOS

En un mundo en que los productos tecnológicos son cada vez más demandados, y en donde las empresas oferentes deben manejar una gran cantidad de SKUs, resulta de suma importancia la estimación de demanda para éstos. Sin embargo, se trata de un mercado de gran incertidumbre, donde los ciclos de vida se vuelven cada vez más cortos y, por consiguiente, la predicción de demanda de éstos resulta mayormente compleja.

El objetivo del presente trabajo de título es el desarrollo de una metodología de estimación de demanda para productos tecnológicos, que sea capaz de entregar pronósticos mensuales y trimestrales a nivel de SKU. Para el desarrollo, aplicación y prueba de la metodología se utilizan ventas y precios mensuales de equipos de telefonía móvil de una compañía de telecomunicaciones.

Para la determinación de un modelo de demanda, la investigación se centra en la búsqueda modelos de difusión, donde se decide finalmente utilizar el modelo de Bass, siendo necesario incorporar variables adicionales de estacionalidad y precio propio en su formulación. Para la obtención de parámetros, se opta por realizar una optimización conjunta entre equipos de un mismo segmento, los cuales son definidos internamente por la empresa, forzándolos así a compartir parámetros de estacionalidad y elasticidad precio-propia, para de esta forma disminuir el problema de falta de datos. Al validar el modelo, la estacionalidad resulta ser altamente estable, relevante y transversal para todos los equipos; respecto a la elasticidad precio-propia, ésta también resulta ser relevante, no obstante, su cálculo es altamente dependiente de unos pocos SKUs. Finalmente, se consideran elasticidades precio cruzado, sin embargo, éstas resultan no presentar una mejora significativa.

En el modelo final, un 23% de los SKUs presenta un error trimestral menor al 40%. No obstante, al evaluar sobre SKUs de mayor importancia, los cuales reportan sobre el 60% de las ventas del periodo de evaluación, estos presentan un MAPE promedio de un 63%, donde un 47% de estos equipos presenta un error menor al 40% trimestral. Por otra parte, si se evalúa el desempeño del modelo a un mes plazo, el MAPE cae drásticamente a un 29% para este mismo grupo. Al comparar con un modelo autorregresivo, se llega a niveles similares de ajuste, sin embargo, el modelo propuesto predice con un 58% menos de error respecto a éste.

Si bien existen SKUs con errores de ajuste grandes, existen también SKUs en los cuales el modelo presenta un error muy bajo, lo que sugiere que el modelo funciona bien dadas ciertas características, las que posiblemente tienen que ver con quiebres de stock y promociones. Dado lo anterior, se cree que en condiciones de monopolio o nichos de mercado, en donde los factores antes mencionados no resultan tan relevantes, el modelo se comportará considerablemente mejor y la metodología será capaz de entregar un valioso antecedente al momento de estimar demanda. De esta manera, se cree que posibles mejoras al modelo vienen dadas principalmente con la incorporación de las variables de promociones y quiebres de stock.

ÍNDICE

1. INTRODUCCIÓN	4
2. DESCRIPCIÓN Y JUSTIFICACIÓN DEL PROYECTO	5
3. OBJETIVOS	6
3.1 OBJETIVO GENERAL.....	6
3.2 OBJETIVOS ESPECÍFICOS	7
4. METODOLOGIA	7
4.1 IDENTIFICACIÓN DE DATOS Y RECURSOS DISPONIBLES.....	7
4.2 DISEÑO CONCEPTUAL DE LA METODOLOGÍA PARA CASO PRÁCTICO	7
4.3 ANÁLISIS DE RESULTADOS EN CASO PRÁCTICO.....	7
5. ALCANCES	8
6. RESULTADOS ESPERADOS	8
7. MARCO CONCEPTUAL	9
7.1 CICLO DE VIDA.....	9
7.2 MODELOS DE ESTIMACIÓN DE DEMANDA	10
7.2.1 Modelo de Bass	10
7.2.2 Modelo de Bass con estacionalidad	12
7.2.3 Modelo general de Bass modificado	13
7.2.4 Distribución Weibull	13
7.3 ESTIMACIÓN POR MÍNIMOS CUADRADOS ORDINARIOS	14
7.3.1 Estimación por Mínimos Cuadros Ordinarios Lineales (MCO)	14
7.3.2 Estimación por Mínimos Cuadros Ordinarios No Lineales (NLLS)	15
7.4 INDICADORES DE AJUSTE	15
7.4.1 RMSE	15
7.4.2 MAPE.....	16
7.4.3 MAD.....	16
7.5 SERIES DE TIEMPO.....	17
7.5.1 Modelos Autorregresivos (AR)	17
7.5.2 Medias Móviles (MA)	18

8.	<i>DISEÑO CONCEPTUAL DE LA METODOLOGÍA</i>	18
8.1	ESTUDIO DE INDUSTRIA DE EQUIPOS DE TELEFONÍA MÓVIL	18
8.1.1	Evolución Histórica y regulación	18
8.1.2	Situación Actual	19
8.2	ANÁLISIS DE DATOS DISPONIBLES	20
8.3	PROCESAMIENTO DE DATOS	22
8.3.1	Mes de lanzamiento	22
8.3.2	SKUs con ventas bajas	23
8.3.3	SKUs recientemente lanzados	23
8.3.4	Estandarización a nivel de SKU	24
8.3.5	Detección de Outliers	24
8.4	ANÁLISIS BASE DE DATOS RESULTANTE	26
8.5	FORMULACIÓN DE MODELOS DE ESTIMACIÓN DE DEMANDA	27
8.5.1	Apoyo Bibliográfico	27
8.5.2	Solución Inicial	28
8.5.3	Determinación de curva base	29
8.5.4	Incorporación de variables de precio y estacionalidad	30
8.5.4.1	Agrupamiento según segmento	30
8.5.4.2	Incorporación de variables de precio propio y estacionalidad	32
8.5.5	Formulación de modelos	34
8.5.6	Estimación de parámetros	35
8.5.7	Evaluación de modelos	37
8.5.8	Aplicación y evaluación preliminar de modelo	38
8.5.9	SKUs en sus primeras fases del ciclo	39
8.5.9.1	Solución Inicial	39
8.5.9.2	Optimización No Lineal	40
8.5.9.3	Parámetros no creíbles	40
8.5.9.4	Evaluación tratamiento para SKUs en sus primeras fases.	45
8.6	ESTIMACIÓN DE ELASTICIDADES PRECIO CRUZADO	48
8.6.1	Elasticidad intra grupo	49
8.6.2	Elasticidad entre grupo	49
8.6.3	Evaluación incorporación de elasticidades precio cruzado	51
9.	<i>APLICACIÓN Y ANÁLISIS DE LA METODOLOGÍA A CASO PRÁCTICO</i>	53
9.1	RESULTADOS GLOBALES DEL MODELO	53

9.2	COMPARACIÓN METODOLOGÍA PROPUESTA VS AR.....	54
9.3	ANÁLISIS DE SEGMENTACIÓN.....	57
9.4	VALIDACIÓN DE PARAMETROS	58
9.4.1	Elasticidad precio propia	58
9.4.2	Estacionalidad	59
9.5	ANÁLISIS POR CASOS	59
9.5.1	Análisis casos con buen nivel de predicción	59
9.5.2	Análisis casos con mal nivel de predicción	62
9.5.3	ANÁLISIS SKUS “IMPORTANTES”	65
10.	<i>RECOMENDACIONES PARA METODOLOGÍA GENERAL.....</i>	66
11.	<i>CONCLUSIONES.....</i>	68
11.1	COMENTARIOS FINALES	68
11.2	RECOMENDACIONES	70
11.3	TRABAJOS FUTUROS	71
12.	<i>BIBLIOGRAFÍA.....</i>	73
13.	<i>ANEXOS</i>	75
	ANEXO A: DERIVACIÓN ESTIMADORES MCO	75
	ANEXO B: ESTUDIO DE DEMANDA.....	76
	ANEXO C: REGISTROS INEXPLICABLES PARA BASE REDUCIDA.....	83
	ANEXO D: AJUSTE CURVA BASE A NIVEL DE SKU.....	85
	ANEXO E: APLICACIÓN PRELIMINAR MODELO 4 POR SKU	86
	ANEXO F: AJUSTE POR SKU CASO PRÁCTICO	86
	ANEXO G: ESTIMACIÓN VENTAS MENSUALES POR SKU	88
	ANEXO H: ESTIMACIÓN PARÁMETROS POR SKU	89
	ANEXO I: ANÁLISIS DE SENSIBILIDAD ELASTICIDADES PRECIO PROPIO	91
	ANEXO J: ANÁLISIS DE SENSIBILIDAD ESTACIONALIDAD	92
	ANEXO K: AJUSTE SKUS “IMPORTANTES” POR PERIODO DE CALIBRACIÓN.....	94

1. INTRODUCCIÓN

Los ciclos de vida para bienes electrónicos, que solían ser de alrededor de 10 años en los 60's, cayeron a alrededor de 5 años para los 80's y ahora son menores a los 2 años para productos como celulares o computadores. Mientras que los ciclos se vuelven más cortos, así también menos datos hay disponibles para hacer análisis de mercado o predicciones de demanda.

Como reflejo de lo anterior, productos con ciclos de vida de pocos meses hasta un máximo de 3 años son cada vez más comunes en industrias fundadas en la moda (por ejemplo juguetes y ropa) y productos de orden tecnológico (como computadores y electrónicos de consumo). Estos productos tienen ciertas características en común, como lo son la rápida sustitución de productos, comportamiento del mercado incierto y una rápida baja de los precios. Además, para muchos de estos productos, las decisiones de producción y abastecimiento tienen que ser realizadas con gran anticipación respecto al periodo de lanzamiento; incluso algunas veces, los tiempos de reposición y producción son tan grandes que las decisiones para el ciclo entero deben ser tomadas en un solo momento.

Cuando además existen marcadas estacionalidades, estos bienes son referidos en la literatura como *style goods* [1,2,3]. Un ejemplo claro de estacionalidad se da en Navidad, con un gran aumento en las ventas de este tipo de bienes, y en Enero, con una fuerte baja en la venta de los mismos. El clásico problema del vendedor de diarios asume que toda la producción ocurre en la pretemporada y todos los bienes no vendidos al final de la temporada son rematados a un precio de remate, muy debajo del precio de producción [4]. También se han tratado problemas genéricos de inventario, los cuales asumen una o más oportunidades de reabastecimiento [2,3]. En resumen, el problema de inventario de este tipo de productos se caracteriza principalmente por presentar las siguientes características.

- i. una corta, pero definida, temporada de venta,
- ii. una o más oportunidades de reabastecimiento durante la temporada después de la orden inicial,
- iii. posibles sustituciones del bien por otros productos de la línea o categoría y
- iv. estimaciones de demanda altamente inciertas.

Uno de los mayores problemas radica en el último punto ya que, aunque cierta parte de la incertidumbre de la demanda puede ser resuelta usando la data histórica de productos similares, la mayor parte prevalece debido a una serie de factores, como los cambios en los gustos de los consumidores, condiciones económicas, etc. Es por esto que resulta de suma importancia el utilizar algún tipo de modelo que permita estimar efectivamente la demanda para este tipo de productos.

Un claro representante de los productos tecnológicos son los teléfonos celulares, los cuales presentan ciclos de vida cada vez más cortos debido a la gran competencia

reinante, que fuerza a las compañías a introducir constantemente nuevos equipos, y cada vez con mayores funcionalidades. Así es como rápidamente se han ido incorporando servicios de mensajería, internet, cámara fotográfica, reproductores de música, etc.

En general el problema de *style goods* ha sido resuelto en la venta de ropa u otros ítems de temporada, sin embargo, el problema a resolver difiere en un punto muy importante, y es que el mercado de muchos productos tecnológicos presenta una oferta muy homogénea entre los distintos oferentes; por otra parte, en muchos casos los precios vienen determinados dentro de ciertos rangos por los fabricantes o distribuidores, lo cual genera precios y servicios muy similares en el mercado, a veces inclusive idénticos. Esto significa que el precio ya no resulta ser una variable de decisión, sino más bien un parámetro del mercado. Además, el típico problema de *style goods* presenta muy poca o nula flexibilidad de reabastecimiento, lo que difiere bastante del problema a resolver; de hecho muchas veces, como el caso de la ropa de tiendas por departamento, el abastecimiento completo se hace al inicio de la temporada. Estas importantes diferencias hacen necesario un acercamiento distinto.

La motivación para un acercamiento así viene dada por la necesidad de proveer un indicador mensual de ventas para el funcionamiento operacional de empresas involucradas con la venta de productos de ciclo de vida corto.

En la presente memoria se detalla en primer lugar una metodología para lograr los objetivos propuestos en este estudio. Luego, se presenta el marco conceptual, para continuar con el desarrollo del diseño de la metodología y la aplicación al caso práctico. Finalmente se detallan las conclusiones obtenidas a través de la aplicación al caso práctico y recomendaciones para la implementación y mejora de la presente metodología.

2. DESCRIPCIÓN Y JUSTIFICACIÓN DEL PROYECTO

Mediante el presente trabajo se pretende desarrollar una metodología de estimación de demanda para productos de ciclo de vida corta. La metodología debe hacerse cargo de los problemas asociados a estos productos y por ende buscar alguna forma de estimación alternativa a las comúnmente utilizadas.

Para el desarrollo y aplicación de la tecnología se tomará el caso particular de la industria de la telefonía móvil. Dicho mercado ha tenido un fuerte incremento en los últimos 5 años a nivel mundial, logrando un gran nivel de penetración en la población. El caso de Chile no es la excepción dado que hoy en día, esta industria ha alcanzado una penetración del 83,66%, teniendo un incremento en el último año de un 12,08%.

Es por esto que la industria de los teléfonos celulares cobra gran relevancia para las grandes compañías de telecomunicaciones del país, siendo su abastecimiento en cada punto de venta, clave para la venta de estos y para otorgar un mejor servicio al cliente. Además, la estimación de demanda es ortogonal a varias funcionalidades de la

empresa, siendo clave para el área de *Pricing*, así como también para la reposición de inventario.

Dadas las características de este mercado, en donde se observan ciclos de no más de 2 años, resultan poco predictivos modelos típicamente usados en problemas de estimación de demanda. Los métodos típicamente usados consisten en series de tiempo y modelos de estimación por atributo. En ambos casos, el mayor problema radica en los cortos ciclos de vida, ya que para poder calibrar estos modelos se necesita una gran cantidad de datos. Por otra parte, en los modelos por atributos, como MNL, MCL [5] o modelos de análisis conjunto, se presenta un segundo problema para su aplicación, y es que el mercado tecnológico es un mercado de muy rápido cambio en cuanto a las preferencias de los consumidores y la incorporación de nueva tecnología (responsable también de los ciclos cortos), lo que imposibilita el comparar atributos de distintos equipos en diferentes espacios de tiempo, ya que estos modelos asumen la valoración por atributo como constante a través del tiempo. Un ejemplo claro de esto es la valoración que ha cobrado en los últimos años la incorporación de cámaras integradas en los equipos celulares o el servicio WAP, los que hace 3-4 años eran atributos de menor importancia o inclusive inexistentes. Además, resulta no trivial el calibrar estos modelos al tener equipos que no coexisten en las mismas brechas de tiempo ya que no se puede simplemente asumir que las ventas de equipos que aun no han sido lanzados para un tiempo t cualquiera son iguales a 0, puesto que esto conllevaría a subvalorar los atributos pertenecientes a estos SKUs.

Bajo estas difíciles circunstancias que rodean a los productos tecnológicos, es necesario que exista una adecuada coordinación de marketing, producción e inventario. Una importante actividad que engloba estas áreas es justamente la estimación de demanda. Un buen modelo de estimación debe presentar ciertas características. Primero, por los altos tiempos y/o costos de reposición, es necesario que los pronósticos sean precisos a mediano plazo, ya sea mensual o trimestral, para así poder realizar un plan costo efectivo de reposición de inventario. Por otra parte, es esencial que se consideren los efectos estacionales.

De aquí la necesidad de buscar formas alternativas de modelamiento para un problema tan esencial como la estimación de demanda.

3. OBJETIVOS

3.1 OBJETIVO GENERAL

- Desarrollar una metodología de estimación de demanda para productos tecnológicos mediante datos transaccionales y encuestas.

3.2 OBJETIVOS ESPECÍFICOS

1. Desarrollar modelo de proyección de demanda.
2. Desarrollar metodología de estimación de elasticidades cruzadas.
3. Desarrollar una aplicación que permita la automatización de la metodología.

4. METODOLOGIA

4.1 IDENTIFICACIÓN DE DATOS Y RECURSOS DISPONIBLES

Para el desarrollo de cualquier metodología es necesario saber con qué fuentes de información se cuenta o se podría contar pues sobre estos recursos se apoyará la metodología.

Dentro de los datos disponibles se debe decidir que SKUs y/o categorías se usaran y sobre qué periodo de tiempo se realizará el estudio.

4.2 DISEÑO CONCEPTUAL DE LA METODOLOGÍA PARA CASO PRÁCTICO

Una vez identificados los datos y recursos disponibles, se procederá a desarrollar la metodología en torno a estos, apoyados en la bibliografía consultada para esta memoria. De esta manera, se construirán distintos modelos de curvas de crecimiento (ver 7.2: Modelos de estimación de demanda) evaluando su desempeño. Paralelamente se desarrollará un mecanismo para el cálculo de elasticidades.

Se utilizará una metodología similar a la metodología KDD, puesto que se incorporará un paso de Preprocesamiento de datos, seguido de un Modelamiento para llegar finalmente a una Evaluación. En el primer paso se detectarán *outliers* o datos faltantes, en el Modelamiento se utilizará apoyo bibliográfico para formular distintas opciones de modelos y donde se incorporarán los parámetros que estimen relevante y finalmente existe un paso de Evaluación que se describe en el próximo punto.

4.3 ANÁLISIS DE RESULTADOS EN CASO PRÁCTICO

Se analizará el desempeño de los modelos propuesto en base a indicadores de ajuste (ver 7.4: Indicadores de Ajuste) junto con un análisis de los resultados para determinar qué condiciones determinan un buen o un mal ajuste del modelo. Se determinara en que SKUs el modelo se comporta bien y mal y se validará el modelo para los parámetros incorporados. Este paso es esencial para lograr generalizar la metodología.

5. ALCANCES

El desarrollo de esta memoria tiene como alcance el desarrollar una metodología para la estimación de demanda para productos tecnológicos. La metodología se realizará solamente en base a datos transaccionales, sin abarcar así otro tipo de fuentes de información.

El diseño y aplicación se realizará sobre datos de una compañía de telefonía móvil de ventas y precios mensuales de 111 SKU de aparatos celulares de prepago en un periodo de ventas datando desde Abril de 2005 hasta Diciembre de 2007.

El modelo de estimación de demanda se realizará a nivel de cada SKU, pues lo que se busca es estimar la demanda desagregada. Además, para el ajuste del modelo se busca prescindir de fuentes de información ajenas a las transaccionales, puesto que los datos con los que se cuenta son netamente de esta índole y porque como parte de los requerimientos de esta memoria, se planteó el poder generar una metodología de simple aplicación, i.e. que no requiera de levantamiento adicional de información. De esta manera, se excluye información referida a promociones, publicidad, distribución, quiebres de stock, etc.

Si bien la aplicación y pronóstico se realizará sobre un producto en particular, el fin último de esta memoria es proporcionar una metodología aplicable a una amplia gama de productos tecnológicos. Es por eso que se contempla que la metodología sea utilizable sobre otro tipo de bienes que compartan similares características, principalmente en cuanto al efecto de la estacionalidad, la incidencia del precio y la extensión del ciclo de vida. Sin embargo, si se pretende extrapolar la metodología, se debe considerar cada caso individualmente, evaluando su desempeño, y realizando los ajustes necesarios, por ejemplo en la 'curva de crecimiento' utilizada.

6. RESULTADOS ESPERADOS

Los entregables que se espera proporcionar con la presente memoria son:

- **Metodología para cálculo de estimación de demanda.**

El objetivo principal de este trabajo es la obtención de una metodología que permita apoyar la función de abastecimiento mediante estimaciones de ventas mensuales a nivel de SKU para una categoría.

- **Metodología para cálculo de elasticidades**

Para el desarrollo de la metodología se contempla el incorporar como variable las elasticidades precio-propio y precio-cruzado ya que se busca incorporar la competencia dentro del modelo. Por otra parte, el contar con estos parámetros resulta de gran utilidad para las empresas, siendo muchas veces un requerimiento adicional al buscar

una metodología de estimación de demanda ya que las elasticidades resultan de particular importancia en distintas áreas de las empresas, como *Pricing* e Inventario.

- **Una programa computacional que entregue predicciones de demandas mensuales y trimestrales.**


La aplicación deberá automatizar la metodología propuesta y así entregar predicciones para cada SKU para los 3 meses siguientes, así como también, estimaciones para las elasticidades, tomando como input solamente el precio futuro de cada SKU.

7. MARCO CONCEPTUAL

7.1 CICLO DE VIDA

La demanda de un producto a través del tiempo se puede graficar como sigue.

Figura 7.1: Ciclo de vida



Fuente: Elaboración propia

- **Introducción**

Corresponde a la primera fase del ciclo la cual comienza cuando el producto se lanza al mercado. Es la fase de incertidumbre, resulta extremadamente complicado prever que pasará con el producto. Falta la información sobre el consumidor, los canales y la competencia. La dialéctica principal se establece entre el producto innovador y los sustitutos.

- **Crecimiento**

Fase explosiva en crecimiento, en la que aparecen las claves que determinarán la dinámica competitiva futura. En esta etapa se desarrolla el mercado de referencia y se cubren distintas posiciones P/M. Comienzan a entrar competidores debido a los grandes márgenes.

- **Turbulencia**

Se produce desaceleración del crecimiento como consecuencia de la saturación del mercado. Suele tomar a los desprevenidos con ampliaciones de capacidad y endeudamiento financiero. Las ventas totales crecen a tasas más bajas pero mayores aún que el promedio de la Economía

- **Madurez**

La madurez se caracteriza por la estabilidad y por ser la más larga del ciclo y en la que se encuentran la mayoría de los mercados. Los líderes de mercado empiezan a imponer su hegemonía y se instaura un relativo oligopolio que favorece mantener un “statu quo” de hecho.

- **Declive**

Se caracteriza por el descenso de la demanda, la certidumbre respecto la decadencia y la incertidumbre respecto a su duración. Es una etapa que discrimina los competidores que desinvierten, que cosechan que se especializan en mercados residuales rentables e invierten para seguir.

La evidencia señala que el ciclo de vida de los productos tiende a seguir un comportamiento ajustable a una curva tipo con forma de S que lo modela. La literatura sugiere los modelos de Weibull, Richards y Bass [6].

7.2 MODELOS DE ESTIMACIÓN DE DEMANDA

Modelos de crecimiento exponencial han sido vastamente utilizados en marketing y econometría para representar la adopción de nuevos productos y tecnologías. Una gran variedad de modelos han sido testeados con distintas estructuras. Ejemplo de estos son el Fourt and Woodlock model [7], el modelo de Gompertz [8] la función logística y el modelo de Bass [6]. Los primeros tres son modelos de dos parámetros con un punto de inflexión fijo (para una mayor discusión y detalle ver [9]), mientras que el modelo de Bass, al ser especificado por tres, es de mayor flexibilidad en cuanto al punto de inflexión de la demanda acumulada. Es por esto que el estudio se concentrará en el Modelo de Bass y sus variantes.

7.2.1 Modelo de Bass

En 1969, Bass propuso un modelo de difusión para estimar el volumen de ventas para nuevos productos. Su modelo se basa en un concepto altamente discutido en la literatura y en donde se asume que existen cinco clases de adoptadores, dependiendo de la rapidez de adopción de la nueva tecnología. Para su formulación matemática, Bass asume que existen innovadores e imitadores, donde estos últimos agrupan a los 4 grupos de más lento tiempo de adopción. Los imitadores, a diferencia de los innovadores, están influenciados en el tiempo de adopción por las decisiones de otros miembros del sistema social. La premisa básica que caracteriza la teoría de Bass se

define como sigue: “la probabilidad de que una compra inicial se haga en el tiempo t , dado que no se han realizado previas compras, es una función lineal del número de previos compradores”. Entonces,

Ecuación 7.1

$$P(t) = p + \frac{q}{m} Y(t) ,$$

donde p y q/m son constantes e $Y(t)$ representa el número de compradores previos. Como $Y(t) = 0$, la constante p es la probabilidad de una compra inicial en $t = 0$ y por lo tanto su magnitud refleja la importancia o tamaño de los innovadores en el sistema social. El resultado de q/m veces $Y(t)$ refleja la presión operando sobre los imitadores a medida que aumenta el número de compradores previos. De aquí que en la literatura se refiere a p como el coeficiente de innovación y a q como el coeficiente de imitación. Además, como se verá, m representa el mercado potencial.

De la Ecuación 7.1 se obtiene la siguiente ecuación diferencial que captura la dinámica de Bass (para mayor detalle ver [10]).

Ecuación 7.2

$$\frac{dN_t}{dt} = (p + q/m * N_t)(m - N_t); N_0 = 0 .$$

Integrando la ecuación anterior, la expresión para la demanda acumulada N_t se escribe como:

Ecuación 7.3

$$N_t = m \left[\frac{1 - \exp(-(p + q)t)}{1 + (q/p) \exp(-(p + q)t)} \right] ,$$

de donde se estima la demanda desagregada como:

Ecuación 7.4

$$n_t = N_t - N_{t-1} ,$$

y donde se aprecia que la constante m representa el mercado potencial ($N_t \xrightarrow{\infty} m$).

El modelo de difusión de Bass ha sido usado en muchas situaciones de estimación de demanda y aplicaciones en Marketing [11]. Sin embargo, la mayoría de las aplicaciones

del modelo de difusión de Bass y otros modelos de crecimiento han sido enfocadas a estimaciones de largo plazo con datos anuales de venta y para bienes de consumo durables. Es importante recalcar que el comportamiento subyacente al modelo de Bass asume una situación monopólica así como también considera sólo la primera compra de un bien, dejando de lado la restitución o recompra.

Para incorporar efectos de estacionalidad se pueden considerar multiplicativos, i.e., $d_t = T_t \times S_t + \varepsilon_t$ donde T_t es la componente de tendencia, S_t la componente de estacionalidad y ε_t el error asociado, o puede ser incorporado directamente en el modelo de Bass, como lo proponen Kurawarla y Matsuo [12] a través del modelo de crecimiento con estacionalidad.

7.2.2 Modelo de Bass con estacionalidad

Sea α_t el parámetro que denota estacionalidad en el tiempo t , donde la función presenta una periodicidad de 12 meses. El modelo es caracterizado por la siguiente modificación en la ecuación diferencial subyacente al modelo de Bass:

Ecuación 7.5

$$\frac{dN_t}{dt} = \left(p + \frac{q}{m} N_t \right) (m - N_t) \alpha_t; N_0 = 0.$$

Integrando análogamente el modelo original, la expresión para la demanda acumulada N_t se obtiene como:

Ecuación 7.6

$$N_t = m \left[\frac{1 - \exp\left(- (p + q) \int_0^t \alpha_\tau d\tau\right)}{1 + (q/p) \exp\left(- (p + q) \int_0^t \alpha_\tau d\tau\right)} \right].$$

Si $\alpha_t = 1$ para todo t , se obtiene la ecuación original de Bass para N_t , lo cual resulta evidente puesto que no habría estacionalidad. La expresión $\int_0^t \alpha_\tau d\tau$ reemplaza la variable de tiempo t en el modelo original o dicho de otra forma, re-escala el eje de tiempo en el modelo de Bass.

Muy similarmente, se han desarrollado modificaciones al modelo de Bass para incorporar variables del marketing, como las propuestas de Robinson y Lakhani, Bass y Bultez y Kalish, para finalmente llegar al Modelo general de Bass modificado o MGBM (para detalles consultar [13]).

7.2.3 Modelo general de Bass modificado

La Ecuación 7.7 describe el modelo general de Bass modificado.

Ecuación 7.7

$$N_t = m \left[\frac{1 - \exp\left(- (p + q) \int_0^t x_\tau d\tau\right)}{1 + (q/p) \exp\left(- (p + q) \int_0^t x_\tau d\tau\right)} \right],$$

donde x_t representa el esfuerzo de marketing realizado en t , que viene dado por la dinámica de las variables del marketing, como lo son el precio y la publicidad. Dado que la publicidad u otras variables del marketing son difícilmente medibles, se considera x_t como función del precio como lo describe la Ecuación 7.8,

Ecuación 7.8

$$x_t = k + \beta \frac{Pr'_t}{Pr_t},$$

donde Pr_t es el precio en t , Pr'_t es el cambio en precio en t y k es una constante positiva que refleja el impacto del precio absoluto.

7.2.4 Distribución Weibull

Aunque no tan común en la literatura, y también dentro de las curvas de crecimiento exponencial, se encuentra la distribución Weibull. Dicha curva es capaz también de representar la curva con forma de S. En Moe y Fader [14] los autores estiman demanda para un set de discos de música utilizando un método de distribución mixed-Weibull estimado vía métodos jerárquicos Bayesianos. La distribución Weibull, además, es utilizada comúnmente para caracterizar la función de tasa de falla o restitución en maquinaria [15].

La función de distribución de Weibull se escribe como sigue,

Ecuación 7.9

$$F_t = 1 - e^{-\lambda t^c},$$

donde λ y c son parámetros positivos y t representa el tiempo.

7.3 ESTIMACIÓN POR MÍNIMOS CUADRADOS ORDINARIOS

El objetivo consiste en calcular los parámetros de un modelo para que se ajusten de la mejor forma posible a los datos. Un set de datos consiste de n puntos $(x_i, y_i), i = 1, \dots, n$, donde x_i es la variable independiente e y_i es la variable dependiente. La función tiene la forma $f(x_i, \beta)$, donde los m parámetros ajustables están contenidos en el vector β . Se desea encontrar los parámetros para los cuales el modelo se ajusta mejor a la data. El método MCO define “mejor” como la suma, S , de los residuos cuadrados

Ecuación 7.10

$$S = \sum_{i=1}^n r_i^2$$

en su mínimo valor. Un residuo se define como la diferencia entre el valor empírico de la variable dependiente y su predicción, dada por el modelo. Luego,

Ecuación 7.11

$$r_i = y_i - f(x_i, \hat{\beta})$$

7.3.1 Estimación por Mínimos Cuadros Ordinarios Lineales (MCO)

Si $f(X, \beta)$ es una función lineal, entonces se puede expresar como:

Ecuación 7.12

$$f(X, \beta) = y = X\beta + \mu,$$

y como la función en general resulta no observable directamente, esta puede ser estimada a través de:

Ecuación 7.13

$$\hat{y} = X\hat{\beta} + \hat{\mu}$$

Si la cantidad de datos es suficiente y los parámetros no son demasiados, entonces X resulta ser de gran tamaño y la matriz $X^T X$ de un moderado tamaño. Si además las funciones base son independientes, $X^T X$ resulta ser no singular y luego la solución óptima para $\hat{\beta}$ se puede expresar como (ver Anexo A: Derivación estimadores MCO):

Ecuación 7.14

$$\hat{\beta} = (X^T X)^{-1} X^T y$$

7.3.2 Estimación por Mínimos Cuadros Ordinarios No Lineales (NLLS)

Los mínimos cuadrados no lineales es la forma del análisis de mínimos cuadrados que se usa para ajustar un set de m observaciones con un modelo no lineal de n parámetros desconocidos ($m > n$).

En matemáticas, la optimización no lineal (NLP) es el proceso de resolver un sistema de igualdades, desigualdades y restricciones conjuntamente impuestas, sobre un set de variables reales desconocidas, en conjunto con una función objetivo a ser minimizada o maximizada, en donde alguna de las restricciones o la función objetivo es no lineal.

Similarmente al caso lineal, lo que se busca es minimizar S .

No existe un único método de solución para un problema de NLLS. Por el contrario, un gran número de algoritmos numéricos son usados para encontrar los valores del parámetro B que minimizan la función objetivo. La mayoría de los algoritmos requieren de una solución inicial. De esta manera, los parámetros son redefinidos iterativamente como:

Ecuación 7.15

$$\hat{\beta}_j^{k+1} = \hat{\beta}_j^k + \Delta\beta_j,$$

con k el número de iteración y $\Delta\beta_j$ es el vector de incrementos. En algunos algoritmos comúnmente utilizados, en cada iteración, el modelo es linealizado por expansiones de Taylor.

7.4 INDICADORES DE AJUSTE

7.4.1 RMSE

El RMSE representa la raíz del error cuadrado medio, y resulta una medida frecuente para retratar las diferencias entre valores predichos por un modelo y los valores reales observados. RMSE sirve para agregar los residuos en un indicador de gran poder predictivo.

El RMSE se escribe como:

Ecuación 7.16

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}},$$

donde A_i representa el valor real observado y F_i el valor estimado.

7.4.2 MAPE

El MAPE se refiere al valor medio del porcentaje de error y representa una medida de ajuste de series para series de tiempo ajustadas. Generalmente expresa la precisión como porcentaje.

El MAPE promedio se escribe como:

Ecuación 7.17

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|,$$

donde A_t representa el valor real observado y F_t el valor estimado. Las diferencias entre A_t y F_t son divididas por A_t , lo que da como resultado el MAPE, y el valor absoluto de este cálculo es sumado para cada punto ajustado y luego dividido nuevamente por el número total de puntos n y así se obtiene el MAPE promedio. Esto genera un error porcentual que es comparable entre series de tiempo ajustadas que difieren en magnitud.

Aunque el MAPE es muy útil y convincente, presenta tres grandes problemas en aplicaciones prácticas.

- Si existen valores iguales a 0 en la serie (por ejemplo en series de ventas), entonces el indicador se indefine.
- Cuando existe un ajuste perfecto, el MAPE entrega un valor de 0. Sin embargo, en relación al límite superior, el MAPE no presenta una cota.
- Cuando se calcula el MAPE promedio para más de una serie puede haber un problema: un pequeño número de puntos que presenten un MAPE elevado pueden distorsionar el MAPE promedio, luego comparar el MAPE promedio de una serie de tiempo ajustada con un método comparado con el MAPE promedio de otra serie ajustada con otro método puede llevar a una conclusión errada. Para evitar este problema existen indicadores de ajuste como el sMAPE (MAPE simétrico).

7.4.3 MAD

En estadísticas, la desviación absoluta de un modelo de predicción, es simplemente la diferencia absoluta entre el set de datos y los puntos pronosticados. La desviación absoluta media (MAD) es el promedio de dichas desviaciones. Luego, el MAD se escribe como:

Ecuación 7.18

$$MAD = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| ,$$

donde A_t representa el valor real observado, F_t el valor estimado y n es el número total de datos.

En casos en que las magnitudes de las desviaciones son importantes, el MAD resulta de gran utilidad, sin embargo, en casos en que resulta mayormente importante el porcentaje de desviación es conveniente utilizar otro tipo de indicadores como del MAPE.

7.5 SERIES DE TIEMPO

Una serie de tiempo es una secuencia de puntos medidos generalmente en tiempos sucesivos y preferentemente espaciados normalmente en intervalos uniformes [16]. La predicción a través de series de tiempos es el uso de un modelo para pronosticar eventos futuros basándose en eventos pasados.

Los modelos de series de tiempo generalmente se construyen tal que cada dato está mayormente relacionado a observaciones temporalmente cercanas que a aquellas que distan mucho.

Los modelos de series de tiempo pueden tener muchas formas y pueden representar distintos procesos estocásticos, tres grandes clases de modelos destacan: los modelos autorregresivos (AR), los modelos integrados (I) y las medias móviles (MA). Combinaciones de estos modelos producen los modelos ARMA y ARIMA.

7.5.1 Modelos Autorregresivos (AR)

Un modelo AR es un tipo de proceso estocástico que es usualmente usado para predecir varios tipos de fenómenos naturales. La notación AR(p) se refiere al modelo autorregresivo de orden p. El modelo AR(p) se define como:

Ecuación 7.19

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t ,$$

donde X_t representa la serie de observaciones, $\varphi_1, \dots, \varphi_p$ son parámetros del modelo, c es una constante y ε_t representa al ruido blanco.

7.5.2 Medias Móviles (MA)

Un modelo MA es un acercamiento común para modelar series de tiempo. La notación MA(q) se refiere al orden del promedio móvil:

Ecuación 7.20

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q},$$

donde X_t representa la serie de observaciones, μ es la media de la serie, $\theta_1, \dots, \theta_q$ son los parámetros del modelo y ε_t es el ruido blanco. El valor de q representa el orden del modelo MA.

8. DISEÑO CONCEPTUAL DE LA METODOLOGÍA

8.1 ESTUDIO DE INDUSTRIA DE EQUIPOS DE TELEFONÍA MÓVIL

8.1.1 Evolución Histórica y regulación.

La telefonía móvil parte en Chile el año 1989 con CTC y CIDCOM, y desde ese entonces ha tenido un crecimiento vertiginoso impulsado por las necesidades del mercado y por decretos estatales. En Chile, el número de abonados o usuarios de telefonía móvil ha crecido de manera exponencial a partir de 1997, incrementándose la densidad del servicio desde 2,8 a 15 aparatos móviles por cada 100 habitantes entre dicho año y 1999. En este período se produjo la entrada de dos nuevos actores con el sistema PCS y se fijaron las tarifas para los cargos de acceso para los tráficos de entrada de redes móviles y fijas, regulación que permitió la efectiva implementación de la tarificación “el que llama paga” o “calling party pay” (CPP) y la introducción masiva del sistema de prepago. Actualmente el número de abonados superó los 14 millones, el mayor nivel de penetración de América Latina e incluso superior a algunos países desarrollados como Canadá y similares a los de EE.UU. y Japón, lo que refleja la importancia que el consumidor chileno le atribuye al servicio móvil y por lo tanto el valor que le asigna al servicio.

Como se puede apreciar en la siguiente tabla, la penetración que ha tenido esta industria ha sido explosiva desde el año 2000.

Tabla 8.1: Evolución de telefonía móvil

Año	Abonados a nivel nacional	Crecimiento anual	Penetración cada 100 hab.	Penetración % de hogares
2000	3.401.525		21,97	87,18%
2001	5.100.783	49,96%	32,57	129,28%
2002	6.244.310	22,42%	39,44	156,51%
2003	7.268.281	16,40%	45,41	175,97%
2004	9.261.385	27,42%	57,24	210,64%
2005	10.569.572	14,13%	64,65	250,43%
2006	12.450.801	17,80%	75,39	287,08%
2007	13.955.202	12,08%	83,66	316,70%

Fuente: SUBTEL, sobre la base de información entregada por las empresas de Telefonía Móvil.

Distinta evolución ha tenido la telefonía fija y el uso de larga distancia, que disminuyeron su incidencia en los últimos años. Mientras la telefonía fija bajó 5,6%, el servicio de larga distancia retrocedió 8,7%.

La sustitución de la telefonía fija por la móvil como única opción para la comunicación por voz en la casa también se expande. En cinco puntos aumenta la cantidad de hogares que sólo tienen teléfono celular, llegando al 41% de las casas. De esta manera la telefonía móvil gana mayor importancia por sobre la telefonía fija.

8.1.2 Situación Actual

Actualmente, existen tres grandes compañías que compiten en este mercado. La siguiente tabla muestra la cantidad de abonados de cada una de estas empresas desde el año 2000 al año 2007.


Tabla 8.2: Abonados por empresa de telecomunicaciones

Año	Movistar	Entel	Claro	Total
2000	1.863.516	1.273.977	264.032	3.401.525
2001	2.260.724	2.210.284	629.775	5.100.783
2002	2.689.481	2.568.427	986.402	6.244.310
2003	3.340.774	2.716.350	1.211.157	7.268.281
2004	4.452.149	3.270.725	1.538.511	9.261.385
2005	4.682.221	4.033.990	1.853.361	10.569.572
2006	5.305.447	4.864.081	2.281.273	12.450.801
2007	5.902.245	5.532.612	2.520.345	13.955.202

Fuente: SUBTEL, sobre la base de información entregada por las empresas de Telefonía Móvil.

El siguiente gráfico retrata la situación actual.

Figura 8.1: Market Share por compañía



Fuente: SUBTEL, sobre la base de información entregada por las empresas de Telefonía Móvil.

La sostenida inversión en tecnología ha hecho que los equipos móviles incorporen funciones cada vez más variadas, como juegos, reproducción de música MP3 y otros formatos, correo electrónico, SMS, agenda electrónica PDA, fotografía digital y video digital, videollamada, navegación por Internet y hasta Televisión digital. Las nuevas aplicaciones para el equipo móvil estarán ligadas a la Tercera Generación (3G)¹, tecnología que permitirá entregar más y mejores aplicaciones a más del 80% de la población y al 90% de los hogares chilenos.²

8.2 ANÁLISIS DE DATOS DISPONIBLES

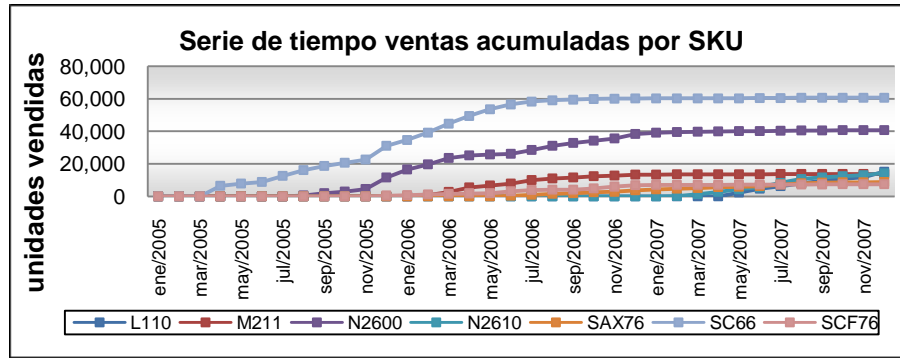
La Base de datos con la que se dispone cuenta con la información sobre ventas y precios de un grupo de equipos de telefonía móvil. Al observar las series de datos se puede hacer como punto de partida una serie de apreciaciones (ver Anexo B: estudio de demanda):

- Se observan ciclos de vida cortos y en gran parte de los casos se puede observar con claridad la forma de S, caracterizada por una etapa de introducción, seguida de un fuerte incremento en las ventas, una etapa de madurez y finalmente una etapa de declive. Un ejemplo de esto se puede apreciar en la Figura 8.2.

¹ 3G es la abreviatura para Tercera-Generación de telefonía móvil. Los servicios asociados con la tercera

² Fuente: Asociación de Telefonía Móvil (ATELMO)

Figura 8.2: Serie de tiempo ventas acumuladas



Fuente: Elaboración propia (*datos re-escalados)


- En algunos SKUs existe una marcada influencia del precio, donde se puede observar que las ventas decaen inmediatamente después de un alza en los precios. Además, los efectos del precio propio parecen ser efectivos sólo cuando la variación es por sobre o bajo la línea de decaimiento regular del precio. El decaimiento del precio mensual por SKU se presenta en la Tabla 8.3 y a modo de ejemplo de la incidencia del precio en la demanda, se presenta la Figura 8.3.

Tabla 8.3: depreciación mensual promedio por SKU

ID	sku1	sku2	sku3	sku4	sku5	sku6	sku7	sku8	sku9
depr%	-5.59%	1.53%	0.33%	1.99%	0.61%	1.98%	1.11%	0.48%	1.18%
ID	sku10	sku11	sku12	sku13	sku14	sku15	sku16	sku17	sku19
depr%	3.74%	1.95%	1.46%	3.34%	1.67%	2.00%	1.91%	1.97%	2.09%
ID	sku20	sku21	sku22	sku23	sku24	sku25	sku26	sku27	sku28
depr%	1.30%	1.18%	0.49%	3.04%	3.39%	0.62%	2.15%	2.07%	2.56%
ID	sku29	sku30	sku31	sku33	sku34	sku35	sku37	sku38	sku39
depr%	2.50%	1.39%	0.93%	1.73%	1.88%	1.67%	2.38%	2.38%	3.13%
ID	sku41	sku43	sku44	sku46	sku47	sku48	sku50	sku53	sku54
depr%	1.57%	1.90%	1.90%	2.53%	3.37%	1.23%	1.07%	1.00%	2.46%
ID	sku55	sku57	sku58	sku60	sku61	sku62	sku63	sku64	sku65
depr%	1.33%	2.22%	1.14%	1.94%	2.68%	4.86%	0.97%	1.55%	2.51%
ID	sku66	sku67	sku68	sku69	sku66	sku67	sku68	sku69	
depr%	1.94%	3.86%	2.30%	2.00%	52.28%	57.96%	53.00%	20.04%	
depr%	1.61%								

Fuente: Elaboración propia

Figura 8.3: Serie de tiempo ventas vs precio



Fuente: Elaboración propia (*datos re-escalados)


- Existe una notoria alza en las ventas en Diciembre, lo que conlleva a que muchos SKU alcancen sus *peaks* de venta en este mes. Además, se observa una fuerte caída en Enero, Febrero y Noviembre, la cual viene además acompañada por una significativa baja de precios en el primer caso. La Tabla 8.4 presenta el porcentaje de ventas por mes, donde efectivamente la mayor cantidad de ventas se da en Diciembre y que Enero, por el contrario, es el mes con menores ventas. La Figura 8.4 ejemplifica la estacionalidad de los meses señalados.

Tabla 8.4: % ventas por mes

Mes	% ventas
Enero	6.31%
Febrero	7.66%
Marzo	10.59%
Abril	10.47%
Mayo	12.28%
Junio	12.95%
Julio	11.97%
Agosto	10.73%
Septiembre	8.53%
Octubre	8.00%
Noviembre	7.51%
Diciembre	17.57%

Fuente: Elaboración propia

Figura 8.4: Serie de tiempo ventas mensuales



Fuente: Elaboración propia (*datos re-escalados)

8.3 PROCESAMIENTO DE DATOS

8.3.1 Mes de lanzamiento

Existe una gran cantidad de SKUs en los que se puede observar que en el mes de lanzamiento se dan ventas considerablemente bajas relativas a las ventas del segundo y tercer mes. Esto hace suponer que se trata de casos en que el lanzamiento fue en las últimas semanas del mes, que no existió una adecuada distribución del bien en los puntos de venta, o en que simplemente se computó mal la venta. Es por ello que se opta por eliminar el primer mes de venta en los casos en que las ventas del mes de lanzamiento sean menores al 10% del promedio de los dos meses siguientes. En la Ecuación 8.1 se define la lógica descrita.

Ecuación 8.1


$$\bar{y}_s = \begin{cases} y_s & \text{si } y_s \geq 0,1(y_{s+1} + y_{s+2})/2 \\ 0 & \sim \end{cases},$$

donde s representa el mes de lanzamiento.

8.3.2 SKUs con ventas bajas

Además, se detectó que aquellos SKUs que presentan ventas comparativamente bajas tienen una conducta distinta y poco ajustable a alguna curva con forma de S, esto probablemente debido a que al tener menores volúmenes de venta, son más susceptibles a los efectos estocásticos (ver Figura 8.5). Luego, el incluir este tipo de equipos podría sesgar el estudio, es por ello que este tipo de SKUs quedará fuera del análisis. Se establece que un producto con ventas bajas es aquel que en sus primeros 3 meses no presenta ventas superiores a las 150 unidades mensuales.

Figura 8.5: SKUs con ventas bajas



Fuente: Elaboración propia

Considerando lo anterior, se logró reducir la Base de Datos a 69 SKUs, los cuales en los últimos tres periodos del horizonte representan el 88,66% de las ventas y el 86,98% de los ingresos en el mismo periodo de tiempo.

8.3.3 SKUs recientemente lanzados

Dado que para efectos de la evaluación del desempeño del modelo se consideraran los últimos tres periodos, cualquier SKU con un ciclo de vida inferior a 4 periodos quedará fuera del estudio.

8.3.4 Estandarización a nivel de SKU

Para efectos de la formulación de modelos, se consideró el estandarizar los datos, y así hacer coexistir SKUs de distintos órdenes de magnitud, dado que al optimizar utilizando SKUs con órdenes de venta muy superiores al resto, estos se llevan el mayor peso de la optimización, luego los parámetros comunes encontrados resultarán ser principalmente reflejo de éstos, y no del conjunto, que es lo que se busca.

De esta manera, se optó por estandarizar las ventas mensuales dividiendo por el promedio de ventas mensuales del SKU, como lo describe la Ecuación 5.2.

Ecuación 8.2


$$\bar{y}_{it} = y_{it} / \hat{y}_i$$

Donde y_t representa las ventas mensuales del SKU e \hat{y}_i representa el promedio de ventas mensuales desde su lanzamiento hasta el último periodo con ventas positivas dentro del horizonte de evaluación.

8.3.5 Detección de Outliers


Para facilitar la aplicación e interpretación de cualquier modelo, es necesario tratar aquellos datos que se alejen de manera evidente del patrón normal de comportamiento. Un ejemplo de esto se presenta en la Figura 8.6 y la Figura 8.7, en donde es posible ver bajas dramáticas en las ventas que no pueden ser explicadas ni por la estacionalidad ni por el precio y dan cuenta de un posible quiebre de stock (información con la cual no se cuenta).

Figura 8.6: SKU anómalo



Fuente: Elaboración propia

Figura 8.7: SKU anómalo



Fuente: Elaboración propia

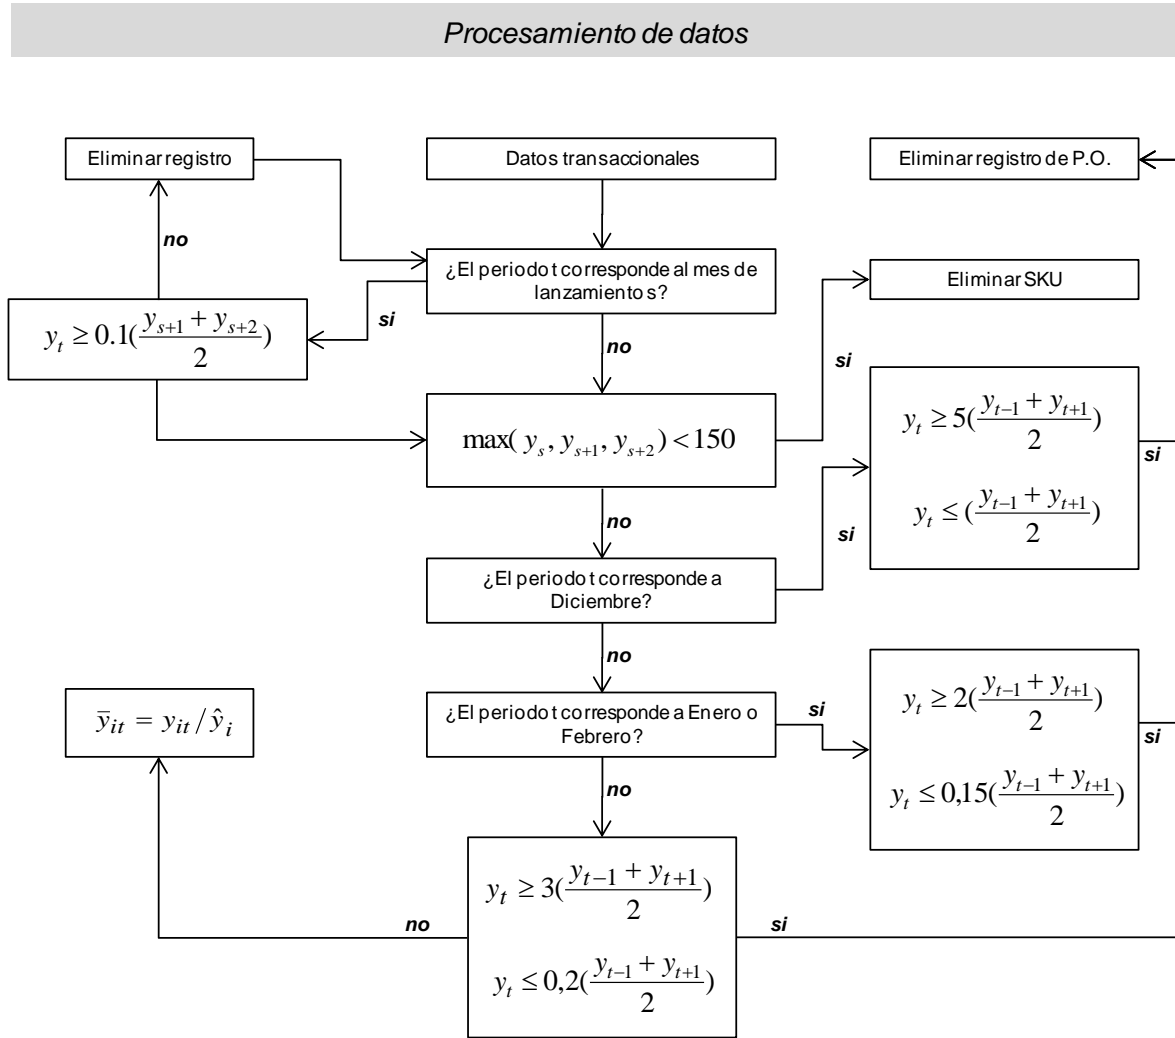
Típicamente, en series de datos, existen una serie de métodos disponibles para identificar *outliers*, sin embargo dichas reglas se basan en la media y/o en la desviación

estándar, las cuales resultan no triviales en el caso estudiado, dado que justamente el mayor problema es que el valor esperado en cada mes puede diferir mucho del mes anterior, y por lo tanto el concepto de media es no representativo, y mucho menos el concepto de desviación estándar; inclusive el mismo valor esperado resulta no trivial. El tratamiento para estos puntos no es el de reemplazarlos por valores promedios, ya que como se mencionó, no resulta trivial establecer un valor medio, por lo que se optó por simplemente excluir dichos puntos del problema de optimización a resolver. De esta forma, para establecer datos fuera de rango es necesario aplicar un criterio de manera exploratoria, el cual resulta en el siguiente set de reglas:

- Si se trata de Diciembre y las ventas del mes exceden en más de 5 veces el promedio del mes anterior y el posterior o están por bajo del promedio del mes anterior y el posterior, se excluye el dato de la optimización.
- Si se trata de Enero o Febrero y las ventas del mes están por debajo de un cuarto del promedio del mes anterior y el posterior o están por sobre el 2 veces el promedio del mes anterior y el posterior, se excluye el dato de la optimización.
- Si se trata de otro mes y las ventas del mes exceden en más de 3 veces el promedio del mes anterior y el posterior, o si las ventas del mes están por debajo de un tercio del promedio del mes anterior y el posterior, se excluye el dato de la optimización.

Estas reglas fueron establecidas graficando las series de ventas y estableciendo reglas hasta llegar a valores que detectaran *outliers* de manera razonable (ver Anexo B: estudio de demanda). Los *outliers* que se pretende detectar son aquellos debidos a efectos no considerados dentro de la información disponible, como datos erróneos, esfuerzos de marketing propios o de la competencia, quiebres de stock, etc. La Figura 8.8 resume las reglas antes descritas.

Figura 8.8: Procesamiento de datos



Fuente: Elaboración propia

Finalmente se elimina un total de 63 registros de un total de 1161 registros (5,42%).

8.4 ANÁLISIS BASE DE DATOS RESULTANTE

Al reducir la base de datos, si bien se eliminan ciertas anomalías, resulta imposible reducirlas todas, y se cree que esta no es una base idónea para trabajar, ya que aun después de la limpieza, se presenta una gran cantidad de registros con comportamiento inexplicable según los datos disponibles. En el Anexo C se presentan ejemplos de datos anómalos, donde es posible observar una serie de datos inexplicables, como peaks de ventas en los meses de Julio u Octubre, sin existir un incentivo de precios, o ventas inusualmente bajas para meses de ventas altas o inusualmente altas para meses de ventas bajas.

Es por lo anterior que no se espera obtener resultados buenos en todos los casos, ya que se parte de una base posiblemente sesgada.

8.5 FORMULACIÓN DE MODELOS DE ESTIMACIÓN DE DEMANDA

8.5.1 Apoyo Bibliográfico

Métodos tradicionales de suavización como medias móviles, suavización lineal y exponencial no están orientados para estimar demanda en productos de ciclos de vida corto [10,17]. Estos métodos aplican mejor cuando existe una tendencia estática, ya que en estos métodos, un cambio brusco en la tendencia induce a un error sistemático. Por lo tanto, al estimar demanda para productos de ciclo de vida corta que sufren rápidos cambios en el crecimiento sumado a la incidencia de factores estacionales, métodos simples de suavización no logran buenos resultados. Otros métodos más sofisticados de series de tiempo, como el Box-Jenkins ARIMA, requieren de una gran cantidad de datos para poder realizar un adecuado ajuste. En resumen, dichos métodos no sirven para estimar demanda en bienes de ciclo de vida corta.

En vez de ser fundado en datos, el modelo de predicción debe poder efectivamente usar información previa en conjunto con información de los primeros meses del ciclo de vida. Esta información puede incluir el historial de ventas de equipos similares, ya que muchas veces existe un vasto registro de ciclos completos de productos predecesores. Además, resulta lógico pensar que los productos comparten los mismos efectos estacionales, al menos estando dentro de una misma categoría. Dichos efectos pueden ser causados por factores externos del mercado así como también de factores internos de la firma.

El acercamiento común para un tipo de problema así parte de asumir a priori una función que describa la curva de crecimiento con un patrón de crecimiento con forma de S, para así después utilizar la información disponible para estimar los parámetros de dicho modelo.

Para la construcción de posibles modelos, se utilizará como referencia a Kurawarla y Matsuo [12] quienes hacen una comparación entre modelos de crecimiento de Bass con incorporación de tendencia multiplicativa, el modelo de Bass con tendencia, ARIMA y DESSN-ARIMA o ARIMA desestacionalizado para modelar series de venta para cuatro productos de una empresa manufacturera de computadores.

Estos modelos de computadores presentan ciclos de vida de entre 1 a 2 años, además de marcada estacionalidad dada por Navidad principalmente y una serie de factores anexos como gran volatilidad de los precios de los componentes o largos tiempos de reposición, los cuales calzan de manera idónea con el perfil de producto que se pretende estimar.

Dado que se tienen características similares, resulta apropiado el uso del modelo de Bass, sin embargo, del análisis de datos se considera que también es necesario el incorporar simultáneamente componentes de estacionalidad y precio, lo cual no ha sido

incorporado de manera conjunta en los modelos anteriores. Por otro lado, al incorporar la variable precio, el modelo se hace cargo en cierta medida de la competencia, tanto entre equipos, como de la industria, lo que se hace cargo a su vez de la limitación monopólica del modelo de Bass. Sumado a lo anterior, se observa que esta industria existe una alta competitividad (ver 8.1, Estudio de Industria de equipos de telefonía móvil) y en donde los precios del mismo SKU para distintas compañías en general tienden a ser los mismos. Por lo mismo anterior, tampoco se cree que las elasticidades precio cruzado sean determinantes en el modelo.

Como contraparte del modelo de Bass, se testeará el ajuste de la curva de Weibull, la cual también presenta, para su distribución acumulada, la forma de S buscada. En Moe y Fader [14] los autores estiman demanda para un conjunto de discos de música utilizando de base a la curva de Weibull, obteniendo un ajuste de la curva con errores menores al 10% mediante una combinación de la distribución mixed-Weibull y métodos jerárquicos Bayesianos.

8.5.2 Solución Inicial

Como las curvas a evaluar resultan en un problema altamente no lineal, es esperable encontrar una gran cantidad mínimos locales, por lo que una buena solución inicial resulta clave para llegar a una buena solución. La solución inicial se utilizará para el cálculo de los parámetros del modelo de Bass, es decir p , q y m . El parámetro m es compartido por el modelo de Weibull, siendo además el parámetro más determinante, por lo este procedimiento servirá también para ese modelo.

Para el cálculo de ésta parte, se utilizó una versión linealizada del modelo de Bass, y luego, mediante estimadores de mínimos cuadrados ordinarios, se llegó a la solución para dicha curva (la información para esta parte fue consultada en [6]).

El modelo básico discretizado se escribe como:

Ecuación 8.3

$$n_t = pm + (q - p)N_t - q/mN_t^2 .$$

Para estimar los parámetros p , q y m para series discretas de datos se usa el siguiente análogo:

Ecuación 8.4

$$n_t = a + bN_{t-1} + cN_{t-1}^2 , t = 2,3,\dots,T ,$$

donde n_t las ventas en t y $N_t = \sum_{\tau=1}^{t-1} n_\tau$ las ventas acumuladas hasta el periodo $t-1$. Como a estima pm , b estima, $q-p$ y c estima $-q/m$, entonces $-mc = q$, $-q/m = p$.

Luego, $q - p = -mc - a/m = b$ y $cm^2 + bm + a = 0$, o $m = (-b \pm \sqrt{b^2 - 4ca})/2c$, y de esta manera los parámetros p , q y m quedan plenamente identificados teniendo los parámetros a , b y c . Para el cálculo de estos últimos se utilizaron los estimadores MCO (para detalles ver 7.3.1).

8.5.3 Determinación de curva base

Como primera fase de la metodología, se propone el buscar la curva base, que se define como la curva ajustada a los datos solamente utilizando como variable independiente a la variable temporal, para esto, se testearon dos opciones sugeridas por la bibliografía, y que representarían la base para el modelo a construir. Para la calibración de los parámetros se considera un horizonte de tiempo desde Enero del 2005 hasta Septiembre del 2007, de esta manera se dejan los tres meses restantes para evaluar la calidad de la predicción (periodo de evaluación). Además, para la evaluación de la curva base, se descartan SKUs con ciclos de vida menores a cinco periodos ya que su optimización resulta altamente inestable (el tratamiento para dichos puntos se discute en 8.3.8). De esta manera, se contabilizan 66 SKUs. La resolución del problema se realiza en GAMS con el paquete MINOS.


La Figura 8.9 ejemplifica el ajuste logrado para ambas curvas en el SKU2 y en la Tabla 8.5 se muestra el resumen global del nivel de ajuste para ambos casos (para el desglose por equipo ver Anexo D: ajusta curva base a nivel de SKU). El índice 'e' de los últimos tres indicadores se refiere al hecho que fueron calculados sobre el periodo de evaluación y por lo tanto son indicadores del nivel de predicción.

Tabla 8.5: Tabla de Ajuste modelo Bass y Weibull

Ajuste	Bassg	Weibullg
RMSE	1620.43	2738.36
MAD	826.37	936.79
MAPE	65.09%	86.65%
RMSE _e	3774.00	3793.64
MAD _e	1076.89	1084.38
MAPE _e	136.63%	187.29%

Fuente: Elaboración propia

Figura 8.9: Serie de tiempo ventas reales vs modelos de Bass y de Weibull



Fuente: Elaboración propia (*datos re-escalados)

Como se puede apreciar, ambos modelos presentan niveles de ajuste similares, siendo levemente mejor el modelo Bass. Sin embargo, se debe considerar que existe una serie de SKUs que presentan grandes desajustes en el MAPE principalmente al final del periodo, dado que al tener ventas bajas en esta etapa, pequeños errores absolutos presentan grandes errores porcentuales. De esta forma, resulta evidente que tanto estos SKUs como aquellos que no tienen grandes ventas a lo largo de todo su ciclo son de menor relevancia. Es por esto que se definió un grupo de equipos como “importantes” (SKU_{imp}), ya que presentan ventas muy superiores al resto en los últimos tres periodos, reportando el 74.97% de las unidades vendidas y el 63.10% de los ingresos en dichos meses. La condición para ser considerado SKU_{imp} es que sus ventas en el periodo final superen las 1300 unidades.

El obtener buenos resultados en estos equipos resulta claramente de gran importancia. La Tabla 8.6 presenta un cuadro comparativo entre el ajuste para los SKU_{imp} y el ajuste global.

Tabla 8.6: Tabla comparativa ajuste global y ajuste “importantes”

Ajuste	Bassi	Bassg	Weibulli	Weibullg
RMSE	2002.67	1620.43	2713.36	2738.36
MAD	1223.44	826.37	1366.96	936.79
MAPE	33.57%	65.09%	31.20%	86.65%
RMSEe	7853.89	3774.00	8138.27	3793.64
MADe	3766.38	1076.89	3854.78	1084.38
MAPEe	75.69%	136.63%	75.24%	187.29%

Fuente: Elaboración propia

Tanto el RMSE como el MAD son mayores en todos los casos para los SKU_{imp} , lo cual resulta esperable dado que al ser indicadores absolutos y no relativos, equipos con mayores ventas evidentemente tendrán mayores valores. Sin embargo, se puede apreciar que el MAPE baja considerablemente en ambos modelos, tanto en el periodo de ajuste como en el de evaluación. Este hecho comprueba la hipótesis de que los bajos valores de este indicador se debían principalmente a grandes desviaciones porcentuales al final del ciclo de vida. Nuevamente las diferencias entre ambos modelos son mínimas pero favorables en todos los casos salvo el MAPE y MAPEe para el modelo de Bass.

Es por lo anterior que se utilizará el modelo de Bass como base para la construcción del modelo definitivo.

8.5.4 Incorporación de variables de precio y estacionalidad

8.5.4.1 Agrupamiento según segmento

Dado que existen series de ventas que presentan muy pocos cambios en el precio o inclusive ningún cambio en el caso de productos recién lanzados, resulta imposible realizar una estimación robusta para los parámetros de elasticidad precio propia. Lo mismo sucede con la estimación para los parámetros de estacionalidad, ya que estos

SKUs presentan ciclos de alrededor de 2 años, lo que significaría que inclusive con un ciclo completo se contaría vagamente con dos registros por mes.

Es por lo anterior, que se plantea dentro del modelo el forzar a que los distintos equipos compartan tanto elasticidad precio propia como estacionalidad. Para agruparlos se utilizan segmentos definidos anteriormente por la empresa en base a dos características predefinidas. Realizando todas las combinaciones posibles entre estas dos características se contabilizan en total 19 grupos, sin embargo, 7 grupos tienen menos de 3 elementos.

El problema de contar con pocos datos radica en que se da una situación en la cual existe una gran cantidad de variables para una pequeña cantidad de datos, lo cual en ciertos casos, genera grados de libertad en la optimización, y en otros casos, se logra un ajuste muy bueno pero con un muy bajo nivel predictivo, ya que más que ajustarse las variables conjuntamente a una curva, cada variable se ajusta a un punto. Es por esto que se optó por fusionar estos grupos arbitrariamente con algún grupo que compartiera una de las dos características que describe a su grupo. De aquí que se llegó a un total de 12 grupos, resumidos en la Tabla 8.7.

Tabla 8.7: Grupo de pertenencia SKU

grupo1	L110	M211	N1600	N2600	N2610	SAX76	SC66	SCF76
grupo2	N1112	DMD100	LC1300	SET290				
grupo3	A801	N6101	SEK510	MC261	MC650			
grupo4	MW220	SMX486	SMX636	SEZ300				
grupo5	A259	N6030	N6061	SMX156	SMX166			
grupo6	MV555	N6103	SMT809	SEZ520	LMG300			
grupo7	LMG220	ML6	MW375	N6131	SMC406	SM356		
grupo8	SMX656	SA31	SA71	SA76	SAL21	SEZ310	SAP75	
grupo9	SA301	SMC207	NN73	N5300	SEW810			
grupo10	LMG810	MC115	N6230	SEW300	LMG320	N5200	SEW200	
grupo11	A550	A551	MV340	MV347	MTSM2	N1108		
grupo12	N1110	N3220	SEK310	N6020	N6070	MV3	N5070	SMC516

Fuente: Elaboración Propia

De esta manera se resolverán 12 problemas análogos de optimización independientemente. Si bien no es parte de la metodología el buscar una forma de agrupamiento, si es necesario comprobar que esta cumple con ciertos requisitos, principalmente para el punto en que se plantea buscar elasticidades. Como parte de la metodología supone el agrupar según segmentos, se supone también que las elasticidades intra grupo son homogéneas, es por esto que es necesario que dentro de cada grupo los SKUs presenten precios similares: no tiene sentido que un aparato que cuesta, por ejemplo \$25.000, sea competencia para otro aparato que cuesta \$100.000. La Tabla 8.8 presenta un análisis de los precios por grupo.

Tabla 8.8: Análisis de precios por grupo

	min pi	max pi	promedio pi	desviación
grupo1	\$ 22.900,0	\$ 49.900,0	\$ 35.900,0	\$ 10.253,9
grupo2	\$ 24.900,0	\$ 59.900,0	\$ 40.650,0	\$ 14.453,9
grupo3	\$ 44.900,0	\$ 109.900,0	\$ 76.900,0	\$ 27.064,7
grupo4	\$ 39.900,0	\$ 79.900,0	\$ 59.900,0	\$ 18.257,4
grupo5	\$ 34.900,0	\$ 69.900,0	\$ 48.650,0	\$ 17.017,1
grupo6	\$ 109.900,0	\$ 199.900,0	\$ 143.233,3	\$ 44.121,0
grupo7	\$ 21.900,0	\$ 149.900,0	\$ 66.328,6	\$ 30.908,6
grupo8	\$ 36.900,0	\$ 259.900,0	\$ 155.300,0	\$ 98.009,2
grupo9	\$ 21.900,0	\$ 199.900,0	\$ 115.614,3	\$ 57.299,5
grupo10	\$ 21.900,0	\$ 59.900,0	\$ 42.233,3	\$ 13.966,6
grupo11	\$ 21.900,0	\$ 99.900,0	\$ 63.757,1	\$ 28.765,9

Fuente: Elaboración Propia

De la tabla anterior, se puede apreciar que existe una gran variabilidad de precios al interior de cada grupo, de donde se pueden ver diferencias de hasta \$128.000 pesos para el grupo 5. Lo anterior hace suponer que la metodología de estimación de precios para el cálculo de elasticidades no dará resultados coherentes. Es por esto que se busca una agrupación arbitraria que se basa principalmente en el precio. Se agrupan los SKUs primeramente según precio y luego según marca, para finalmente lograr 10 grupos con al menos 5 SKUs cada uno. La distribución queda como sigue en la Tabla 8.9:

Tabla 8.9: Grupo de pertenencia SKU, segmentación alternativa

grupo1	SEW810	NN73	MV3	SEW600	M6131	N6230		
grupo2	SEW300	SEZ520	LMG300	N6101	MV555	N6103	LMG320	SEK510
grupo3	SEK310	LMG810	N5200	N3220	SEW200	N6020		
grupo4	SMX486	MV400	SM636	SMC406	SA301			
grupo5	N6061	SEZ310	MC261	MC650	MW375	SMX656	SAL21	MV340
grupo6	SMC516	LMG220	N6030	SAP75	MV347	SEZ300		
grupo7	N6070	N2600	A801	SA76	A551	SAX76		
grupo8	SET290	SMC207	N1108	SMX156	SMX166	N1600		
grupo9	MW220	N5070	DMD100	A550	N2610	SA31	A259	
grupo10	M211	N1112	L110	SA71	MC115	MVTSM2	N1110	

Fuente: Elaboración Propia

Dado que la anterior segmentación resulta completamente arbitraria, y dado que la metodología no contempla establecer una medida de segmentación, esta sólo se utiliza llegado el punto del cálculo de elasticidades cruzadas.

8.5.4.2 Incorporación de variables de precio propio y estacionalidad


Se propone la formulación de modelos que ocupen como base el modelo de Bass pero incorporando las variables de precio y estacionalidad. Se definen como,

Ecuación 8.5

$$\frac{dN_t}{dt} = \left(p + \frac{q}{m} N_t \right) (m - N_t) h_t; N_0 = 0,$$

donde h_t es la variable que conjuga el efecto del precio con el efecto de la estacionalidad y que distingue a las distintas propuestas. Además, se considera el ocupar o no un 'precio latente', el que se define como el precio competitivo al cual se debiese vender cada SKU considerando su precio inicial y una disminución porcentual constante y mensual. Para calcular el precio latente se considera la pérdida porcentual promedio que experimentan los aparatos de un mismo grupo mes a mes, luego se asume que esta es la pérdida de precio "natural" del grupo y que por lo tanto sólo un precio por bajo y por sobre esta línea tendrá una incidencia en las ventas. La Figura 8.10 ejemplifica mediante una recta el precio latente para un SKU cualquiera.

Figura 8.10: Perdida de precio "natural"



Fuente: Elaboración Propia

Integrando la Ecuación 8.5 se obtiene la expresión para N_t :

Ecuación 8.6

$$N_t = m \left[\frac{1 - \exp\left(- (p + q) \int_0^t h_\tau d\tau\right)}{1 + (q/p) \exp\left(- (p + q) \int_0^t h_\tau d\tau\right)} \right].$$

Luego h_t viene a modificar la variable temporal del modelo de Bass simple.

La fórmula discretizada para N_t puede ser escrita según la Ecuación 8.7.

Ecuación 8.7

$$N_t = m \left[\frac{1 - \exp(-(p + q)H_{it})}{1 + (q/p) \exp(-(p + q)H_{it})} \right]$$

H_{it} queda definido dependiendo de las distintas alternativas, donde α_t es el efecto de la estacionalidad del mes t y x_t representa el efecto en t de la elasticidad precio propia β . P_{it} y P_{si} representan el precio en t y el precio inicial del SKU i respectivamente. P_{li} representa el precio latente antes definido, con γ el descenso porcentual promedio que experimenta el precio mensualmente calculado dentro de cada grupo. n_{it} representa la estimación mensual de la demanda del SKU i en el periodo t .

8.5.5 Formulación de modelos

Se proponen cuatro modelos, los cuales ocupan como base el modelo de Bass pero incorporando las variables de precio y estacionalidad, se definen como:

Figura 8.11: Modelo 1

$$H_{it} = \sum_{\tau=S_i}^t (\alpha_{\tau} + x_{\tau})$$

$$x_{it} = \beta \left(\frac{P_{it} - P_{si}}{P_{si}} \right)$$

$$n_{it} = \begin{cases} N_{it} - N_{it-1} & \text{si } N_{it} - N_{it-1} \geq 0 \\ 0 & \sim \end{cases}$$

Fuente: Elaboración Propia

Figura 8.12: Modelo 3

$$H_{it} = \sum_{\tau=S_i}^t \alpha_{\tau}$$

$$x_{it} = \beta \left(\frac{P_{it} - P_{li}}{P_{li}} \right)$$

$$P_{li} = P_{si}(1 - \gamma \cdot t)$$

$$n_{it} = \begin{cases} (N_{it} - N_{it-1}) \exp(x_{it}) & \text{si } N_{it} - N_{it-1} \geq 0 \\ 0 & \sim \end{cases}$$

Fuente: Elaboración Propia

Figura 8.13: Modelo 2

$$H_{it} = \sum_{\tau=S_i}^t (\alpha_{\tau} + x_{\tau})$$

$$x_{it} = \beta \left(\frac{P_{it} - P_{li}}{P_{li}} \right)$$

$$P_{li} = P_{si}(1 - \gamma \cdot t)$$

$$n_{it} = \begin{cases} N_{it} - N_{it-1} & \text{si } N_{it} - N_{it-1} \geq 0 \\ 0 & \sim \end{cases}$$

Fuente: Elaboración Propia

Figura 8.14: Modelo 4

$$H_{it} = \sum_{\tau=S_i}^t \alpha_{\tau}$$

$$x_{it} = \beta \left(\frac{P_{it} - P_{si}}{P_{si}} \right)$$

$$n_{it} = \begin{cases} (N_{it} - N_{it-1}) \exp(x_{it}) & \text{si } N_{it} - N_{it-1} \geq 0 \\ 0 & \sim \end{cases}$$

Fuente: Elaboración Propia

8.5.6 Estimación de parámetros

El procedimiento de estimación de parámetros será análogo al propuesto por Kurawarla y Matsuo [12], considerando además la variable precio. El problema de optimización se resuelve en la plataforma GAMS con el paquete de optimización MINOS.

El método de estimación de parámetros que se propone estima simultáneamente los parámetros de estacionalidad, comunes para el conjunto de SKUs, con los parámetros de la curva de crecimiento, individuales para cada equipo. Dado que la ecuación a resolver es no lineal ni linealizable, se utilizará un método de minimización no lineal de mínimos cuadrados ordinarios (NLLSQ). La validez y ventaja de hacer una NLLSQ simultánea se discute en Ratkowsky 1990 [18].

El procedimiento para la estimación simultánea de parámetros es la siguiente. Sea,

- n el número de productos;
- T el último mes en el horizonte; $t = 1, \dots, T$
- y_{it} las ventas por el producto i en el mes t para $i = 1, \dots, m$ y $t = 1, \dots, T$;
- P_{it} el precio para el producto i en el mes t ;
- x_{it} el efecto del precio para el producto i ;
- α_t el factor estacional para el mes t , donde $\alpha_t = \alpha_{t-12}$;
- s_i el mes de lanzamiento del producto i ;
- l_i el último mes con demanda positiva para el producto i .

La Figura 8.15 describe el problema de minimización para cada grupo.

Figura 8.15

$$\begin{aligned} \min Z &= \sum_{i=1}^n \left\{ \sum_{s_i \leq t \leq l_i} [y_{it} - n_{it}]^2 \right\} \\ &\text{s.a.} \\ &p_i > 0; q_i, m_i \geq 0 \\ 11,5 &\leq \sum_{t=s_i}^T \alpha_t \leq 12,5; \alpha_t \geq 0 \quad t = 2, \dots, T \\ \alpha_t &= \alpha_{t-12} \quad t = 13, \dots, T \end{aligned}$$

Fuente: Elaboración Propia

Se asume $N_{is-1} = 0$. La primera restricción asegura la no negatividad de los parámetros y la no indefinición de la fórmula. La segunda restricción tiene particular importancia, ya que al ser un problema altamente no lineal, existe una gran cantidad de ramas por donde optimizar, y por lo tanto es necesario encausar la optimización. Es por esto que al no existir esta restricción, son admisibles resultados en que la variable α_t puede

llegar a tomar valores tan altos como 12, que es lo que, idealmente, deberían sumar la serie completa de 12 datos. Se debe recordar que la variable α_t modifica el eje temporal del modelo de Bass, y por lo tanto para que no existiera influencia estacional cada uno de estos valores de α_t debiera ser igual a 1. Es por esto que al obtenerse valores significativamente superiores o inferiores a 12, la variable de temporalidad pasa a ser decisiva en la forma global de la curva, más allá del efecto de temporalidad. El problema de esto radica en que posteriormente no serán comparables los parámetros del modelo de Bass (p , q y m) entre SKUs de distintos grupos de optimización. Siendo esto último un punto clave dentro del problema de estimación, ya que se plantea como objetivo el encontrar relaciones entre (p , q y m), para así poder asignarle un set de parámetros a aquellos productos para los cuales no se disponga de suficiente información y para así poder encausar la optimización de mejor forma. Es por ello que al asegurar que la suma de α_t se encuentre entre 11,5 y 12,5 hace posible el poder comparar distintos sets de parámetros obtenidos. Finalmente, la última restricción hace a la serie α_t periódica con un periodo de 12.

En este punto, resulta necesario reducir el número de variables, ya que para un problema donde el principal problema es la poca cantidad de datos, el contar con muchos parámetros hace del problema un problema altamente inestable, lo que además genera grandes errores de predicción, al contar con parámetros poco robustos. Como se mencionó en el análisis de datos disponibles, los mayores efectos temporales se cree que se dan en Enero, Febrero y Diciembre; para probar esta hipótesis se probó el Modelo de Bass con estacionalidad (Ecuación 7.6) sobre el set completo de datos excluyendo solamente aquellos SKU con un ciclo menor a 5 periodos. Los parámetros encontrados se resumen en la Tabla 8.10.

Tabla 8.10: Parámetros de estacionalidad según grupo

α	gr1	gr2	gr3	gr4	gr5	gr6	gr7	gr8	gr9	gr10	gr11	gr12	prom.
Ene	0,000	0,000	0,100	0,590	0,000	0,960	0,000	0,320	0,890	0,320	0,000	0,200	0,280
Feb	0,000	0,000	0,000	0,780	0,000	1,230	0,000	1,750	1,210	0,180	0,000	0,220	0,450
Ma	1,390	0,060	0,530	1,440	0,940	1,230	0,040	0,310	1,490	0,000	0,000	0,000	0,620
Abr	1,510	1,040	1,220	1,410	0,000	1,440	0,580	0,000	0,980	4,170	0,000	0,000	1,030
May	0,000	2,380	1,900	1,950	1,550	0,960	2,910	1,040	1,030	0,000	0,000	0,510	1,190
Jun	1,720	0,300	1,660	1,710	1,940	1,090	3,900	1,190	0,900	0,000	0,000	0,600	1,250
Jul	2,000	1,140	1,340	1,450	2,930	0,800	2,180	1,070	1,130	0,000	11,720	1,970	2,310
Ago	0,820	3,620	0,930	1,120	2,170	1,790	1,090	1,930	0,580	1,570	0,000	2,180	1,480
Sep	0,010	0,110	0,000	0,620	0,000	1,120	0,190	1,020	0,410	1,230	0,000	0,740	0,450
Oct	0,310	0,000	0,830	0,250	0,000	0,520	0,550	0,570	0,630	0,850	0,000	0,530	0,420
Nov	0,530	0,000	0,920	0,200	0,000	0,320	0,100	0,270	0,660	0,220	0,000	0,870	0,340
Dic	4,190	3,860	3,070	0,990	2,970	1,040	0,960	3,030	2,540	3,100	0,000	4,700	2,540

Fuente: Elaboración Propia

De la Tabla anterior, se desprende que la optimización resulta altamente inestable para los 12 parámetros; es así como se puede apreciar que, por ejemplo, en el grupo 11, el mes de Julio se lleva todo el efecto temporal en desmedro de los otros meses. Además, se puede notar una gran variabilidad en el cálculo de los parámetros para distintos grupos, existiendo meses que pasan de meses de ventas altas a meses de ventas

bajas dependiendo del grupo de evaluación. Lo anterior da cuenta de la necesidad de reducir la cantidad de parámetros. Finalmente, se confirma la hipótesis de que los meses de Enero, Febrero y Diciembre son los que mayor influencia tienen, sin embargo, aparece Noviembre como un mes significativamente bajo en ventas.

Como consecuencia de lo anterior, para la construcción de modelos se considerará el efecto temporal solamente en los meses de Enero, Febrero, Noviembre y Diciembre, logrando así una reducción de 9 parámetros en el problema de optimización. En 9.3 se comprueba la estabilidad de estos cuatro parámetros en contraste con la inestabilidad presentada al utilizar los doce parámetros de estacionalidad. Además, se establece una última restricción para los meses de Enero y Febrero, ya que al resolver el problema de optimización muchas veces estos valores resultaban ser muy superiores a la unidad, siendo que el análisis de datos evidentemente determina que son meses de baja venta, y de esta forma se establece que ninguno de estos meses puede tener un valor superior a 1.

8.5.7 Evaluación de modelos

Para la evaluación de los modelos se prueba sobre el conjunto total de 12 grupos excluyendo aquellos SKUs con ciclos menores a los 5 periodos. La calibración se realiza sobre un periodo equivalente al horizonte completo de datos menos tres periodos, para así dejar los periodos restantes para la evaluación de las predicciones (en base al RMSEe, MADe, MAPEe).

La Tabla 8.11 muestra el ajuste global que se obtiene para cada modelo y la Tabla 8.12 muestra el ajuste obtenido sobre los SKUs “importantes”.

Tabla 8.11: Ajuste global por modelo

modelo	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
1	1657,40	830,04	69,34%	3631,68	1135,26	136,55%
2	6142,98	2387,10	129,94%	5468,43	2127,21	227,46%
3	4751,39	2034,66	81,60%	4239,34	1429,87	187,51%
4	1411,19	727,21	60,24%	3392,18	1033,87	106,31%

Fuente: Elaboración propia

Tabla 8.12: Ajuste SKUs “importantes” por modelo

modelo	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
1	1597,26	964,57	33,05%	7149,58	3238,02	90,10%
2	5675,52	3678,66	211,48%	10153,36	5913,99	197,35%
3	5614,23	3581,23	78,14%	8316,80	3953,53	76,54%
4	1718,03	1071,99	37,02%	6990,97	3453,99	84,18%

Fuente: Elaboración propia

De los resultados se desprende que el modelo 4 es el que mejores índices presenta, siendo solamente superado por el modelo 1 en los índices de ajuste para los SKUs “importantes”. No obstante, para este mismo grupo, el modelo 4 posee mejores índices de predicción (RMSEe, MADe, MAPEe). Es por lo anterior que el modelo 4 se considera

bastamente superior al resto de los modelos y será el ocupado para la metodología final.

Con los resultados de este paso además se valida el concepto de precio latente, ya que dentro de las particularidades del modelo 4 (Figura 8.13) se encuentra el uso de este concepto.

8.5.8 Aplicación y evaluación preliminar de modelo

Como se mencionó en el procesamiento de datos, resulta no trivial establecer a priori que SKU's o que registros se comportan de manera errática respecto al modelo planteado. Es por esto se plantea el realizar una aplicación preliminar del modelo, y de esta manera determinar que SKUs son *outliers* en base al nivel de ajuste que presentan, en cuyo caso serán eliminados del problema. La importancia de este paso radica en que dichos SKUs, al comportarse de manera ajena al modelo, distorsionan los parámetros comunes, y además, si es que se quiere utilizar un enfoque en que SKUs de mayor antigüedad son usados como referente para SKUs recién lanzados, entonces el error se propagará a las nuevas generaciones.

En este paso se corre el modelo para el set de 69 SKUs aislando aquellos con un ciclo inferior a cinco meses y sobre el horizonte total de ventas menos 6 periodos, para así poder evaluar los resultados predictivos sin utilizar información de los 3 periodos finales que se utilizarán para la evaluación última del modelo.

Para determinar que SKUs no presentan un ajuste ad hoc con el modelo, se analiza el ajuste para cada SKU de manera preliminar (ver Anexo E: Aplicación preliminar modelo 4 por SKU) y se analiza caso a caso donde se llega a que los siguientes SKUs presentan un comportamiento anómalo:

Tabla 8.13 Ajuste SKUs con comportamiento anómalo

	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku7	1602,99	1262,93	144,10%	63,57	44,03	31,35%
sku8	663,87	504,40	130,89%	29,87	24,79	24,86%
sku11	326,54	231,94	83,53%	102,03	91,40	96,21%
sku36	278,04	208,69	124,83%	662,66	473,04	93,92%
sku44	178,90	148,27	68,84%	55,92	45,14	183,63%
sku61	1645,21	1296,72	142,18%	369,31	330,54	105,05%

Fuente: Elaboración Propia

Donde se opta por dejar fuera del estudio a dichos equipos, que tan sólo representan el 0,31% de las ventas realizadas en los últimos tres periodos dentro del set de 69 SKUs.

Al eliminar estos SKUs se debe hacer un reagrupamiento dado que los grupos 2 y 7 quedaron con un número reducido de integrantes. De esta manera, se fusionan dichos grupos con el grupo 1 y el grupo 6 respectivamente, quedando finalmente 10 grupos.

8.5.9 SKUs en sus primeras fases del ciclo

El ocupar SKUs con pocos registros presenta una serie de problemas. Por un lado, se generan problemas en el proceso de cálculo de solución inicial, puesto que este paso requiere de al menos 3 datos (ya que se requiere estimar 3 variables). Por otra parte, para el proceso de optimización no lineal, se presenta este mismo problema pero exacerbado, ya que además de las 3 variables del modelo base, se deben calcular otras 6 variables grupales. Esto genera una gran cantidad de grados de libertad, lo que hace que el problema sea en algunos casos imposible de resolver, y en otros, de deficiente solución.

Finalmente, existe un problema de credibilidad, ya que al tener pocos datos, el set total de datos se ve mayormente afectado por la variabilidad, y por lo tanto, se generan mayores errores al estimar sus parámetros, generando un problema de confiabilidad en los parámetros obtenidos a partir de dichos registros.

Por lo anterior es que se plantea un tratamiento particular para este conjunto de equipos dependiendo de las distintas fases.

8.5.9.1 Solución Inicial

En esta etapa, se considera que un SKU con menos de 3 datos es un SKU con datos insuficientes (que se denotará de ahora en adelante como SKU_{pd}). Esto básicamente por un problema técnico, ya que a través de la Ecuación 8.4 se pretende estimar p , q y m , lo que resulta imposible con una cantidad de datos inferior a 3.

De esta manera, dichos SKU por si solos no cuentan con una solución inicial, y por lo cual se propone que estos equipos hereden los resultados de otros SKUs con una mayor trayectoria. Para establecer que SKUs serán los que donen sus puntos iniciales se establece una medida de disimilitud entre pares de equipos, la que en su mínimo valor, establecerá que SKU resulta mejor como donante (que se denotará de ahora en adelante como SKU_d),

La medida de disimilitud d_{ij} que se plantea es la suma de los datos del SKU_{pd} i menos la suma de estimación del SKU j durante el mismo periodo de su ciclo, vale decir, considerando la misma cantidad de datos desde su fecha de lanzamiento. La Ecuación 8.8 retrata esta situación.

Ecuación 8.8

$$d_{ij} = \sum_{t=s_i}^T |y_{it} - n_{it+s_j-s_i}|.$$

Donde T es el periodo total de calibración, y s_i y s_j representan el mes de lanzamiento del producto i y j respectivamente. De esta forma, se comparan los primeros meses de ventas de ambos productos.

Luego, aquel SKU que presente el menor valor para d_{ij} será el SKU_d y por lo tanto cederá su solución inicial al SKU i .

8.5.9.2 Optimización No Lineal

Para este punto, se considera que un SKU con una cantidad de datos inferior a 5 periodos es un SKU_{pd} . Experimentalmente equipos con ciclos menores a 5 periodos generan problemas en el momento de la optimización.

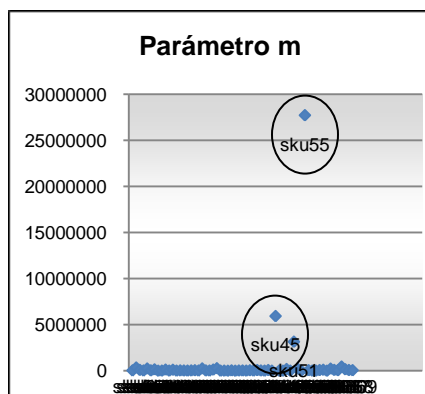
La optimización requiere que para cada equipo se estimen 3 parámetros individuales, correspondientes a los parámetros del modelo de Bass p , q y m , más los parámetros de grupo, α_t y β . De esta manera, se contabilizan 9 parámetros por SKU (3 individuales y 5 grupales). Al contar con una cantidad reducida de datos, se generan grados de libertad para el problema de optimización lo que produce que los algoritmos de optimización utilizados aborten el problema, o en algunos casos, entreguen resultados de manera poco eficiente.

Para subsanar el problema suscitado en este punto, se optó, en primer lugar, por excluir del problema conjunto de optimización a dichos SKUs, vale decir, los parámetros de estacionalidad y elasticidad serán estimados solamente con equipos con un ciclo mayor a 4 periodos.

8.5.9.3 Parámetros no creíbles

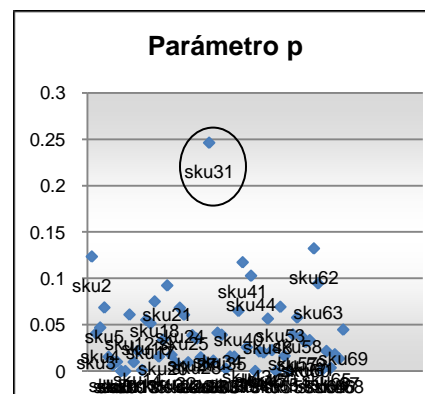
Al aplicar el modelo parcial sobre un horizonte de tiempo cualquiera, se llegan a soluciones que claramente son no creíbles. Por ejemplo, al aplicar el modelo preliminar sobre el set completo de datos hasta Junio del 2007, se pudieron observar las siguientes anomalías en los parámetros estimados:

Figura 8.16: Gráfico de dispersión para m



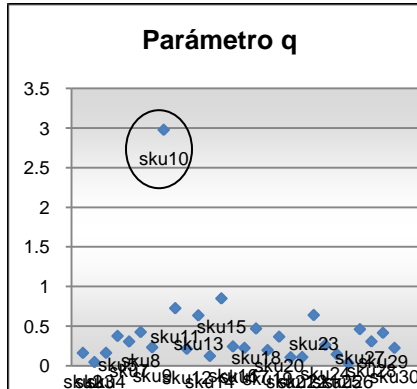
Fuente: Elaboración propia

Figura 8.17: Gráfico de dispersión para p



Fuente: Elaboración propia

Figura 8.18: Gráfico de dispersión para m



Fuente: Elaboración propia

De donde se aprecia un par de datos que claramente se escapan de la media. La Tabla 8.14 resume los parámetros para los SKUs identificados como fuera de rango. Además, para cada SKU fuera de rango se analiza el ajuste en la Tabla 8.15.

Tabla 8.14: parámetros SKU fuera de rango

parámetro	sku10	sku30	sku45	sku50	sku51
m	5.025	38.692	5.930.985	13.541	3.152.121
p	1,00E-08	9,23E-03	9,43E-05	2,25E-02	4,67E-05
q	2,97E+00	2,23E-01	2,24E-01	2,05E-01	1,54E-01
b	3,76E+00	2,18E+00	9,87E-01	2,52E+00	2,52E+00

Fuente: Elaboración Propia

Tabla 8.15: ajuste SKU fuera de rango

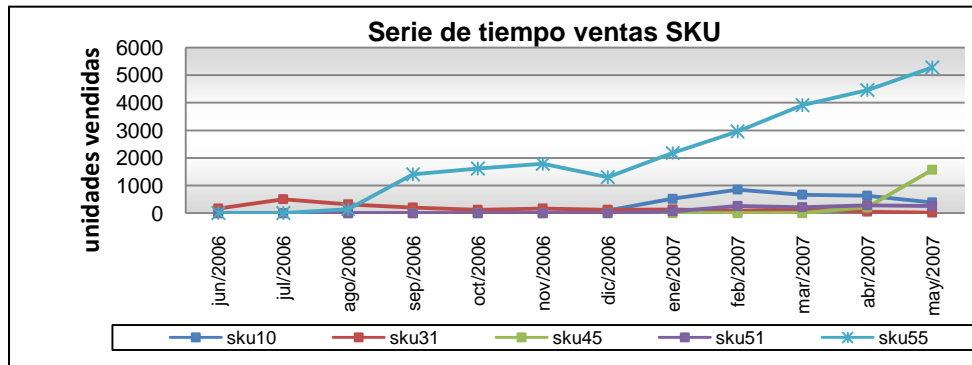
ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku10	553,56	476,13	87,38%	6869,67	5714,66	3835,34%
sku31	39,69	28,81	22,57%	5,71	5,41	52,40%
sku45	1573,00	1573,00	50,00%	2567,59	2547,33	100,00%
sku51	67,99	62,95	45,87%	38,30	37,40	3,14%
sku55	274,14	197,16	10,33%	3481,67	3240,55	69,24%

Fuente: Elaboración Propia

Es posible observar que los casos fuera de rango debidos a m presentan un nivel de ajuste dentro de rangos normales, pero sin embargo presentan un muy bajo poder predictivo, lo cual reafirma la hipótesis de que hay un problema de credibilidad en los parámetros ajustados en SKUs en primeras fases de su ciclo. Por otra parte, resulta evidente notar que los valores fuera de rango en este parámetro carecen de sentido, puesto que m representa el mercado total para cada equipo, donde se observan valores superiores a los 3.000.000, cuando de los equipos en etapas terminales, ninguno supera las 150.000 unidades vendidas. Además, ambos equipos presentan valores cercanos a 0 para el parámetro q , el que da cuenta de la velocidad de crecimiento. Es por lo anterior que estos parámetros resultan no creíbles y motivo por el cual se establece la restricción que el parámetro m no puede superar las 300.000 unidades.

La Figura 8.19 muestra la serie de ventas para estos SKUs.


Figura 8.19: Serie de tiempo ventas SKU anómalos



Fuente: Elaboración Propia (*datos re-escalados)

Se puede apreciar que en 3 de estos equipos los ciclos de vida son inferiores a los 5 meses, y que para los SKU45 y SKU51 y SKU55 resulta muy difícil establecer que forma tendrá la curva en los próximos periodos. La Figura 8.20 retrata dos opciones de cómo podría seguir las curva de crecimiento para el SKU45, una moderada y otra optimista, versus las ventas reales.


Figura 8.20: Serie de tiempo ventas SKU y posibles predicciones



Fuente: Elaboración Propia (*datos re-escalados)

La anterior figura representa la incertidumbre en que se incurre al realizar estimaciones en equipos con pocos datos, ya que ambas opciones son admitidas dentro del Modelo de Bass. Se cree que al utilizar información de SKUs similares, pero con mayor tiempo en el mercado, se pueden lograr mejores predicciones. Si se toma el ejemplo anterior, y se busca un equipo similar, el cual según la medida de disimilitud resulta ser el SKU69, se puede tener una mejor idea de la posible forma de la curva (Figura 8.21).

Figura 8.21: Serie de tiempo ventas SKU y posibles predicciones



Fuente: Elaboración Propia (*datos re-escalados y las ventas de similar ocurren en un periodo distinto)

Al analizar la curva del equipo similar, es posible clarificar en cierta medida lo que sucede en los meses venideros, así es como el símil presenta ventas muy similares al equipo en estudio para los últimos 2 meses. Además, la diferencia que existe en las ventas del tercer mes entre el SKU45 y el SKU69 es muy similar a la diferencia que presentan los mismos SKUs para el cuarto mes.

El problema antes mencionado se da principalmente en equipos que no han alcanzado su *peak* de ventas, pues este punto sirve como ancla para determinar la forma final de la curva. Por lo anterior es que se analiza el caso de los SKUs con su ciclo en fases terminales (ver Anexo B: Estudio de demanda).

Tabla 8.16: Estadísticos SKUs fases terminales

	min	max	\bar{x}
max venta	1.255	24.492	11.027
t max venta	3	14	8.214

Fuente: Elaboración Propia

En la tabla anterior se incluye información referente al *peak* de ventas en cuanto al tiempo y el monto alcanzado, donde se presenta el mínimo tiempo en el que se alcanza, el máximo tiempo en el que se alcanza, y el promedio del tiempo en el que se alcanza. Como se puede apreciar, el promedio es de 8 periodos y el máximo es de 14. Es por lo anterior que se definirá como SKU_{pd} en este punto a todo SKU con un ciclo inferior a 9 periodos. Un número mayor conduciría a reducir en demasía el número de SKUs dentro del problema de optimización conjunta y un número menor inducirá a obtención de parámetros no creíbles.

Para suplir la deficiencia de datos en los SKU_{pd} se optó por testear dos opciones, las cuales tienen 2 premisas básicas:

- la información de SKUs similares al SKU_{pd} i pero en etapas más avanzadas del ciclo de vida es más confiable que la información extraída del corto ciclo de vida de i.
- a medida que pasa el tiempo la confiabilidad de i debe crecer por sobre la del SKU donante.

Las opciones que se plantea son las siguientes:

➤ Opción 1

Para compensar la falta de datos para alcanzar el *peak* se opta por completar con la cantidad de datos faltantes para llegar a los 8 registros. Para esto, se busca un SKU_d de manera análoga al punto anterior. El SKU_d donará la cantidad de registros necesarios, ajustados por el promedio de la diferencia presentada, así como también los parámetros de estacionalidad y variabilidad de precios para dichos periodos, ya que es altamente posible que los meses pertenecientes a los datos donados no serán los mismos que los de los datos faltantes del SKU_{pd} , además de pertenecer posiblemente a distintos grupos.

Finalmente, se realizará un segundo paso de optimización, aplicado sobre los SKU_{pd} , el cual incorporará como *inputs* las variables grupales obtenidas de la optimización conjunta más los parámetros donados, y de esta forma se calculan las variables individuales para los equipos definidos como SKU_{pd} en este punto.

➤ Opción 2

La opción que se plantea es una simplificación de un típico acercamiento bayesiano, en el cual los parámetros del modelo tienen a priori una cierta distribución probabilística asociada y las cuales se van actualizando a medida que se avanza en el ciclo. Lo que se plantea es cambiar el valor de los parámetros del modelo de Bass para los 3 periodos de predicción, de manera lineal, dependiendo del largo del ciclo de vida del equipo y según la Figura 8.22:

Figura 8.22

$$\bar{m}_{it} = m_i + b_1 \left(1 - \frac{\text{ciclo}_{it}}{6} \right) (m_d - m_i)$$

$$\bar{p}_i = p_i + b_2 \left(1 - \frac{\text{ciclo}_{it}}{6} \right) p_d$$

$$\bar{q}_i = q_i + b_3 \left(1 - \frac{\text{ciclo}_{it}}{6} \right) q_d$$

Fuente: Elaboración Propia

Donde b_1, b_2 y b_3 parámetros positivos a optimizar. Se puede apreciar que cada una de las ecuaciones representa una recta. El término $(m_d - m_i)$, en el caso del parámetro \bar{m}_{it} , representa la magnitud de la diferencia entre el parámetro m del SKU_{pd} y del donante d , y de esta forma, determina el signo de la pendiente de la curva: si el parámetro del donante es mayor, entonces \bar{m}_{it} será mayor que el parámetro inicialmente calculado m_i , si el parámetro donante es menor, entonces \bar{m}_{it} será menor que m_i . Análogo es el caso de p y q .

El término $(1 - ciclo_{it}/6)$ da cuenta de la premisa de que a medida que pasa el tiempo, mayor credibilidad presentan los parámetros del SKU_{pd} y menor peso tienen los parámetros de su donante: cuando $ciclo_{it} = 1$ entonces $(1 - ciclo_{it}/8)$ alcanza su máximo, y cuando $ciclo_{it} = 8$ (el máximo valor permitido para que sea tratado como SKU_{pd} en este punto), $(1 - ciclo_{it}/8)$ alcanza su mínimo. Los parámetros b_1, b_2 y b_3 representan la magnitud de la credibilidad, a mayor valor, mayor incidencia o credibilidad tendrá el SKU donante por sobre el SKU_{pd}.

Para esta opción es necesario optimizar sobre las predicciones y no sobre el periodo de calibración, ya que básicamente lo que se plantea es que no resulta conveniente confiar plenamente en los resultados de la optimización cuando se tiene una pequeña cantidad de datos, y por lo tanto, no resultar conveniente guiarse solamente por estos. Como consecuencia de esto, hay que situarse tres periodos atrás del horizonte inicial de calibración ($th-3$), para así tener tres periodos de predicción sobre los cuales optimizar, y así poder utilizar válidamente estos resultados en th .

La Ecuación 8.9 representa el problema de optimización a resolver.

Ecuación 8.9

$$\min_b RMSEe = \sqrt{\frac{\sum_{i=1}^n \sum_{th+1 \leq t \leq te} [y_{it} - n_{it}]^2}{\sum_{i=1}^n te - th - 1}},$$

donde te representa el tiempo final que se empleará para la optimización. Los parámetros de estacionalidad, elasticidad son *inputs* del modelo, y los cuales son calculados en el paso previo. Luego, se optimizan los valores de b_1, b_2 y b_3 para lograr el menor valor de RMSEe. Con estos valores calculados, se procederá a reajustar los valores de los SKU_{pd} de 3 periodos más adelante.

8.5.9.4 Evaluación tratamiento para SKUs en sus primeras fases.

➤ Opción 1

Dentro del conjunto de SKU_{pd} de esta fase, existe un subgrupo que consta de todos aquellos equipos que tienen un ciclo superior a 5 periodos (e inferior a 9), los cuales por lo tanto, fueron optimizados también en una primera fase en la optimización

conjunta, utilizando sólo datos propios. Dado que estos SKUs presentan esta dualidad en la optimización servirán como referente para evaluar la afectividad de esta opción. A continuación se presenta el nivel de predicción de dichos SKUs en la optimización conjunta vs la opción 1.

Tabla 8.17: Ajustes optimización conjunta vs opción 1 por SKU_{pd}

	optimización conjunta previa			opción 1		
	RMSEe	MADe	MAPEe	RMSEe	MADe	MAPEe
sku13	52,86	43,35	4,86%	124,73	115,40	67,75%
sku35	973,57	932,65	46,84%	549,38	535,76	26,90%
sku45	4076,43	2945,62	47,87%	2908,74	2197,27	35,71%
sku57	22567,08	16524,95	81,02%	21856,13	15801,83	77,47%
sku58	1301,09	1162,97	17,33%	6219,08	4398,04	65,55%
sku59	1133,26	942,00	9,54%	979,52	973,79	35,23%
sku69	1543,78	1334,82	21,41%	1091,55	906,05	14,53%

Fuente: Elaboración Propia

Tabla 8.18: Ajustes optimización conjunta vs opción 1

etapa	RMSEe	MADe	MAPEe
O. conjunta	8060,74	2728,59	42,78%
opción 1	7654,31	2769,79	36,24%

Fuente: Elaboración Propia

Se puede apreciar que de los 7 SKUs en estudio, 3 presentan mejoras respecto del paso previo, mientras que otras 3 empeoran sus predicciones. No obstante, al observar el ajuste global se puede apreciar que si existe una leve mejora en los indicadores. Como no resulta claro si este paso representa una real mejora, se procede a evaluar el nivel de predicción en ambas instancias para distintos horizontes de tiempo de calibración (Tabla 8.19).

Tabla 8.19: Optimización conjunta vs opción 1 para distintos horizontes de calibración

	optimización conjunta previa			opción 1		
	RMSEe	MADe	MAPEe	RMSEe	MADe	MAPEe
T-3	7767,95	2902,72	32,64%	7632,80	2766,78	36,08%
T-4	1769,62	1064,62	50,29%	1949,58	1374,93	161,16%
T-5	2407,99	1369,88	69,13%	1583,11	1019,77	86,78%
T-6	1458,46	678,03	47,81%	1097,58	609,72	83,91%
T-7	1189,79	749,08	188,90%	5008,50	3016,54	1296,51%
T-8	1152,65	720,50	17,98%	1114,47	733,18	22,08%
T-9	2433,63	1310,48	58,93%	1644,25	1037,29	32,35%

Fuente: Elaboración Propia

Donde T representa el último periodo del cual se tienen registros (Diciembre 2007). Se puede apreciar que salvo el periodo T-7, la opción 1 presenta siempre un mejor ajuste que la optimización previa. Para evaluar se mira principalmente el RMSE y el MADe, ya que el MAPEe puede resultar grande debido a pequeños desajustes en periodos con ventas bajas.

➤ Opción 2

Para este paso, lo primero que se requiere es la obtención de los parámetros b_1 , b_2 y b_3 los cuales representan la magnitud de la credibilidad. Para esto, se calculan en múltiples periodos partiendo de T-6³. La Tabla 8.20 resume los valores encontrados.

Tabla 8.20: Parámetros de credibilidad grupo según horizonte de calibración

	b1	b2	b3
T-6	1,350	0,000	0,000
T-7	1,609	0,000	0,000
T-8	1,280	0,000	0,000
T-9	1,363	0,000	1,308
T-10	0,000	0,000	0,024
T-11	2,055	0,000	0,387
T-12	2,003	0,000	0,000

Fuente: Elaboración Propia

Se observa que los parámetros b_2 y b_3 referentes a p y q , resultan nulos para la mayoría de los horizontes de evaluación y por lo tanto se asumirán como iguales a 0. Respecto al parámetro b_1 resulta bastante estable y este se utilizará para la evaluación de modelo, utilizando los valores calculados en un t cualquiera, para el periodo $t+3$. Para evaluar la efectividad de este paso, se prueba el nivel de estimación logrado antes y después de aplicar el efecto de b_1 para los SKUs con optimización dual.

Tabla 8.21: Optimización conjunta vs opción 1 grupo según horizonte de calibración

	b1	optimización conjunta previa			opción2		
		RMSEe	MADe	MAPEe	RMSEe	MADe	MAPEe
T-3	1,350	7767,95	2902,72	32,64%	7536,10	2725,90	30,81%
T-4	1,609	2819,37	1616,87	58,88%	69679,14	22649,34	4854,89%
T-5	1,280	2474,67	1405,84	66,73%	2692,02	1482,93	148,86%
T-6	1,363	1458,46	678,03	47,81%	2985,49	1460,44	123,99%

Fuente: Elaboración Propia

Resulta evidente que esta opción es altamente inestable, donde se aprecia una leve mejora solamente en el primer periodo de evaluación, presentando un notorio empeoramiento en el resto de los periodos.

Si bien la opción 1 resulta evidentemente mejor que la opción 2, tampoco logra una mejora substancial en las estimaciones, no obstante, la mejora que presenta es relativamente estable. De esta forma, se incorpora a la metodología la opción 1 y se descarta la opción dos. Con esta paso se concluye lo que se llama el Paso 1 de la metodología.

³ puesto que los valores calculados serán utilizados para la evaluación de los 3 periodos posteriores.

8.6 ESTIMACIÓN DE ELASTICIDADES PRECIO CRUZADO

Para el cálculo de elasticidades precio cruzado, se optó por incorporarlo como un segundo paso independiente del modelo de estimación de demanda, y a la vez subdividido en dos, primero considerando las elasticidades intra grupo y luego las elasticidades entre grupo. La razón para realizar este paso de manera independiente viene dada del hecho de que, en caso contrario, i.e. incorporar dichas variables dentro del paso de optimización anterior, forzaría a calcular los parámetros para los 10 grupos y 69 SKUs en forma simultánea (debido a las elasticidades entre-grupo), contabilizando sobre 300 variables calculadas simultáneamente en un problema altamente no lineal. Esto resulta en una optimización muy cara en recursos y una enorme inestabilidad.

Se debe recordar que en esta sección se ocupa la segmentación alternativa estipulada en la Tabla 8.9.

Nuevamente, en este paso se da el problema de falta de datos, ya que existen muchos equipos que no presentan cambios en sus precios, lo que implica que para efectos prácticos es imposible calcular elasticidades cruzadas entre estos equipos, lo que no significa que ésta no exista. A su vez, una gran cantidad de equipos presentan tan sólo un par de cambios, lo que podría llevar a cálculos de elasticidades altamente sesgadas. Para contrarrestar este problema se plantea el hacer depender las elasticidades exclusivamente del grupo de dependencia. Luego, la elasticidad entre cualquier par de SKUs será homogénea dentro del grupo, existiendo heterogeneidad sólo en las elasticidades entre grupos.

La Ecuación 8.10 resume esta situación.

Ecuación 8.10

$$\mathcal{E}_{i,j} = \mathcal{E}_{gr(i),gr(j)},$$

donde $gr(i)$ y $gr(j)$ representan el grupo de pertenencia del SKU i y el SKU j respectivamente.

De esta forma, se contabiliza una mayor cantidad de datos para calcular cada elasticidad. Teóricamente, este procedimiento no debiera generar mayor pérdida de exactitud en el caso de tener una apropiada segmentación, ya que cualquier segmentación tiene como finalidad el producir segmentos heterogéneos entre si, pero homogéneos dentro de cada uno de ellos, lo que es equivalente a decir que elementos dentro de un mismo grupo se comportan de manera similar y elementos de distintos grupos se comportaran distinto. Bajo esta lógica, es de esperar que la elasticidad entre elementos similares (i.e. de un mismo grupo) sea similar, y que la elasticidad entre un elemento de un grupo A y un elemento del grupo B sea similar a la elasticidad entre otro elemento del grupo A con cualquier elemento del grupo B, por cuanto los elementos de cada grupo, por construcción, deben ser similares. Luego, asumiendo una adecuada

segmentación, es de esperar que las elasticidades entre SKUs puedan ser aproximadas por elasticidades entre grupos. En caso contrario, probablemente el resultado de este punto resulte irrelevante o perjudicial para el modelo.

8.6.1 Elasticidad intra grupo

Luego de calculados los parámetros del modelo estimación de demanda se procede a tomar como *input* las estimaciones para las ventas mensuales, n_{it} , donde se modifica la estimación de la siguiente forma:

Figura 8.23

$$\bar{n}_{it} = \begin{cases} n_{it} \exp(\bar{x}_{it}) & \text{si } N_{it} - N_{it-1} \geq 0 \\ 0 & \sim \end{cases}$$

$$\bar{x}_{it} = - \sum_{j \neq i \wedge j \in gr(i)} \beta_{intra_i} \left(\frac{P_{jt} - Pl_{jt}}{Pl_{jt}} \right)$$

Fuente: Elaboración Propia

Donde lo que básicamente se plantea es que la influencia de la elasticidad intra grupo es la resultante de la sumatoria de los cambios porcentuales de todo el grupo. El problema de minimización se escribe como,

Ecuación 8.11

$$\min Z = \sum_{i=1}^n \left\{ \sum_{s_i \leq t \leq l_i} [y_{it} - \bar{n}_{it}]^2 \right\}.$$

Fuente: Elaboración Propia

Esta etapa representa el Paso 2 de la metodología.

8.6.2 Elasticidad entre grupo

Una vez calculadas las elasticidades intra grupos se procede a un tercer paso para incorporar el efecto de la competencia entre grupos.

La estimación se modifica de la siguiente manera.

Figura 8.24

$$\bar{n}_{it} = \begin{cases} n_{it} \exp(\bar{x}_{it}) & \text{si } N_{it} - N_{it-1} \geq 0 \\ 0 & \sim \end{cases}$$

$$\bar{x}_{it} = \sum_{j \neq gr(i)} -\beta_{gr(i),gr(j)} \left(\frac{Pr_t - Pl_j}{Pl_j} \right)$$

Fuente: Elaboración Propia

Análogo al caso anterior, se plantea que la influencia de la elasticidad entre grupo es la resultante de la sumatoria de los cambios porcentuales de todos los elementos pertenecientes a otros grupos, multiplicados por las respectivas elasticidades por grupo.

Además, en este paso es necesario disminuir las variables de decisión del problema de optimización, de lo contrario el problema posiblemente será no admisible por los métodos de optimización.

Resulta lógico suponer que existen grupos que no presentan incidencia alguna sobre otros grupos, esto pues se supone que las segmentaciones producen segmentos distintos, y por lo tanto no debería existir mayor interacción entre ciertos pares de segmentos. Dado que para este paso se utiliza una segmentación en base al precio, se considera que grupos que difieren considerablemente en cuanto a precio, no tendrán incidencia el uno sobre el otro. Por lo tanto, se considera que sólo existe incidencia de aquellos grupos más próximos en cuanto a precio, vale decir, para el grupo i se considerará que existe elasticidad entre-grupo solamente con el grupo $i+1$, que representa al grupo inmediatamente siguiente en cuanto a precio promedio, y el grupo $i-1$, que representa el grupo inmediatamente anterior en cuanto a precio promedio. La anterior condición se agrega como restricción al problema de optimización, el cual se retrata en la Figura 8.25.

Figura 8.25

$$\min Z = \sum_{i=1}^n \left\{ \sum_{s_i \leq t \leq l_i} [y_{it} - \bar{n}_{it}]^2 \right\}$$

s.a.

$$\beta_{gr(i),gr(j)} = 0 \quad \text{si } gr(j) - 1 < gr(i) < gr(j) + 1$$

Fuente: Elaboración Propia

Esta etapa representa el paso 3 de la metodología.

8.6.3 Evaluación incorporación de elasticidades precio cruzado

➤ Elasticidad intra grupo

Se prueba la metodología sobre la segmentación original y la segmentación alternativa (segmentación 1 y 2). La Tabla 8.22 presenta los resultados de las elasticidades.

Tabla 8.22: Parámetros de Elasticidad intra-grupo, segmentación original

	β qr1	β qr2	β qr3	β qr4	β qr5	β qr6	β qr7	β qr8	β qr9	β qr10
1	-0.06	0.22	-0.17	0.03	0.25	-0.20	0.00	-0.08	0.00	-0.03
2	-0.02	0.18	-0.01	0.39	-0.12	-0.04	0.02	-0.01	0.04	-0.10

Fuente: Elaboración Propia

Lo primero que resalta de la tabla anterior es que las elasticidades resultan no creíbles, principalmente porque se dan muchos signos positivos, cuando debiesen ser todos negativos. No obstante, la segmentación alternativa presenta una mayor cantidad de signos negativos, por lo que aparentemente resulta una segmentación mejor. Para corroborar esta anomalía se presenta a continuación un análisis de sensibilidad para β_{intra_i} por segmentación, considerando distintos horizontes de calibración.

Tabla 8.23: Elasticidades intra-grupo según horizonte de calibración, segmentación 1

Bintra	qr1	qr2	qr3	qr4	qr5	qr6	qr7	qr8	qr9	qr10
T	-0.06	0.22	-0.17	0.03	0.25	-0.20	0.00	-0.08	0.00	-0.03
T-1	-0.11	0.09	-0.17	0.03	0.26	-0.31	0.00	0.97	0.00	0.03
T-2	-0.11	0.10	-0.17	0.03	0.34	-0.42	0.00	-0.06	0.00	0.08
T-3	-0.11	0.06	-0.17	0.02	0.25	-0.40	0.01	-0.06	0.00	0.10
T-4	-0.09	0.07	-0.14	0.04	0.25	-0.47	0.01	-0.03	0.00	0.09
T-5	-0.05	0.00	-0.13	0.06	0.18	-0.45	0.01	0.00	0.00	0.08
T-6	-0.13	-0.04	-0.09	0.07	0.25	-0.42	0.00	0.02	0.00	0.11

Fuente: Elaboración Propia

Tabla 8.24: Elasticidades intra-grupo según horizonte de calibración, segmentación 2

Bintra	qr1	qr2	qr3	qr4	qr5	qr6	qr7	qr8	qr9	qr10
T	-0.02	0.18	-0.01	0.39	-0.12	-0.04	0.02	-0.01	0.04	-0.10
T-1	-0.12	0.10	0.06	0.28	-0.05	0.02	0.02	0.03	-0.39	0.01
T-2	-0.03	0.13	0.16	0.30	-0.03	0.02	0.03	0.03	-0.40	0.01
T-3	-0.14	0.08	0.05	0.27	0.00	0.01	0.00	0.03	-0.47	0.01
T-4	-0.23	0.08	0.11	0.25	-0.04	0.01	0.02	0.04	-0.24	0.01
T-5	4.54	0.25	-11.88	1.24	0.87	1.02	-0.07	0.02	0.29	-0.43
T-6	0.08	0.21	0.13	-0.02	-0.02	0.01	0.00	0.04	-0.44	0.01

Fuente: Elaboración Propia

Se puede observar que las elasticidades resultan ser muy estables a través de los distintos horizontes de calibración, sin embargo, sus magnitudes son muy poco significativas

Finalmente se presenta el ajuste total logrado para 1 y para 2 antes y después de aplicar el paso 2 en T.

Tabla 8.25: Ajuste global antes y después de aplicar Paso 2 para segmentación 1 y 2.

	etapa	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
1	paso1	1283.48	637.80	65.58%	3827.22	1153.96	117.99%
	paso2	1286.15	647.19	66.63%	3815.65	1148.51	109.44%
2	paso1	1444.09	764.37	61.18%	3583.99	1167.73	95.86%
	paso2	1452.70	769.54	59.95%	3537.32	1141.93	94.92%

Fuente: Elaboración Propia

Al analizar el nivel de predicción (RMSEe MADe y MAPE) entre el paso 1 y el paso 2 para ambas segmentaciones, resulta claro que la incidencia es casi imperceptible. Nuevamente, al observar los indicadores en la segmentación 1 y la segmentación 2, se puede ver que la segunda presenta un ajuste de alrededor de un 15% mejor, lo que reafirma la idea de que esta segmentación es mejor.

Independiente de la segmentación, este paso resultó ser de poco aporte por lo que se descartará de la metodología.

➤ Elasticidad entre grupo

Se prueba la metodología sobre la segmentación original y la segmentación alternativa, a pesar de que para la primera no se deberían obtener resultados coherentes dada la composición dispar de los grupos. Las Tablas 8.26 y 8.27 presentan los resultados de las elasticidades entre grupos.

Tabla 8.26: Parámetros de Elasticidad entre-grupo segmentación 1

β entre	β qr1	β qr2	β qr3	β qr4	β qr5	β qr6	β qr7	β qr8	β qr9	β qr10
β qr1		0.14								
β qr2	-0.06		-0.39							
β qr3		-0.05		-0.04						
β qr4			0.36		0.23					
β qr5				0.00		0.03				
β qr6					-0.44		0.03			
β qr7						0.06		0.06		
β qr8							0.05		-0.03	
β qr9								-0.03		0.01
β qr10									-0.01	

Fuente: Elaboración Propia

Tabla 8.27: Parámetros de Elasticidad entre-grupo segmentación 2

β entre	β qr1	β qr2	β qr3	β qr4	β qr5	β qr6	β qr7	β qr8	β qr9	β qr10
β qr1		0.59								
β qr2	-0.06		0.18							
β qr3		-0.26		-0.41						
β qr4			0.02		-0.27					
β qr5				0.40		0.15				
β qr6					0.22		-0.04			
β qr7						-0.19		0.03		
β qr8							0.01		-0.28	
β qr9								-0.06		0.03
β qr10									0.09	

Fuente: Elaboración Propia

Una vez más, y dado el signo de las elasticidades, la segmentación alternativa presenta parámetros mayormente creíbles que la segmentación original. Sin embargo, los parámetros son de magnitudes pequeñas y de todas formas con la presencia de una gran cantidad de elasticidades positivas.

A continuación, se presenta el ajuste total logrado para 1 y para 2 antes y después de aplicar el paso 3:

Tabla 8.28: Ajuste global antes y después de aplicar Paso 3 para segmentación 1 y 2

	etapa	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
1	paso1	1444.09	764.37	61.18%	3583.99	1167.73	95.86%
	paso3	1456.85	775.56	59.94%	3588.91	1175.61	102.03%
2	paso1	1402.22	721.78	67.14%	3762.67	1240.04	107.36%
	paso3	1401.76	733.08	66.05%	3840.66	1280.88	111.21%

Fuente: Elaboración Propia

Se observa que el Ajuste mejora de manera casi imperceptible y que el nivel predictivo del modelo empeora considerablemente. De esta forma, se descarta la utilización de esta paso en la metodología final.

9. APLICACIÓN Y ANÁLISIS DE LA METODOLOGÍA A CASO PRÁCTICO

9.1 RESULTADOS GLOBALES DEL MODELO

Finalmente, el modelo ocupa como base el modelo de Bass, al cual se le incorpora el efecto de la estacionalidad, dada por los meses de Enero, Febrero, Diciembre y Noviembre, y las elasticidades precio propia. La forma en que se integran queda retratada por el modelo 4 (Figura 8.14). Además, se incorpora el tratamiento para SKUs en sus primeras fases del ciclo de vida, el cual queda descrito en 8.5.8.

El modelo se aplicó sobre los 10 sets finalmente conformados, contabilizando así 64 SKUs. A continuación se presenta el ajuste total logrado para la metodología, donde se presenta el ajuste global y el ajuste logrado para SKUs “importantes”. Dado que en el punto anterior se entregan indicios de la validez de la segmentación alternativa, los resultados se presentan para ambas segmentaciones.

Tabla 9.1: Ajuste global para segmentación 1 y 2

seq.	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
1	1283.48	637.80	65.58%	3827.22	1153.96	117.99%
2	1444.09	764.37	61.18%	3583.99	1167.73	95.86%

Fuente: Elaboración Propia

Tabla 9.2: Ajuste SKU_{imp} para segmentación 1 y 2

seg.	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
1	1734.93	1016.70	35.80%	6798.58	3227.68	63.66%
2	1737.87	998.37	34.86%	7267.06	3342.58	55.13%

Fuente: Elaboración Propia

Además, se debe recordar que los resultados de las predicciones son evaluadas para los tres periodos posteriores al periodo de calibración, lo que hace suponer que si es que se considera solamente un mes de predicción entonces las predicciones debieran mejorar considerablemente. Para evaluar esto, se corre el modelo en la segmentación 1 para predecir a dos meses plazo y a un mes plazo, y se obtiene el siguiente ajuste global y para SKUs “importantes”:

Tabla 9.3: Ajuste global para segmentación 1 y 2

plazo/pred	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
2 meses	1020.22	512.162	48.68%	1405.57	601.15	62.12%
1 mes	1339.22	681.58	57.53%	1107.3	511.05	64.93%

Fuente: Elaboración Propia

Tabla 9.4: Ajuste SKU_{imp} para segmentación 1 y 2

plazo/pred	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
2 meses	1874.59	1189.71	44.97%	2771.37	1811.49	43.25%
1 mes	1990.66	1286.87	43.39%	2024.83	1295.3	29.34%

Fuente: Elaboración Propia

Se aprecia una importante mejora tanto en el ajuste global como en el ajuste para el grupo “importantes”. Globalmente, la mejora para ambos plazos es de un 35-40%, y para el caso de los SKU_{imp} la mejora a 2 meses plazo y 1 mes plazo es de 20,41% y 34,32% respectivamente. Lo anterior nos indica que si es que el modelo se quiere usar para predecir a un mes plazo o incluso a 2 meses plazo, entonces este resulta de una excelente herramienta de predicción.

Las predicciones finales por SKU y ajuste por SKU se presentan el Anexo F y G respectivamente.

9.2 COMPARACIÓN METODOLOGÍA PROPUESTA VS AR

Para comparar la metodología con otro modelo se elige probar un proceso autorregresivo (AR) de orden 3 sobre los SKU_{imp} , donde el modelo es calculado mediante máxima verosimilitud exacta a través del software SPSS. No se pudo probar con un modelo más sofisticado como ARIMA ya que este procedimiento deja fuera una importante cantidad de SKUs por un requerimiento mínimo de datos, de todas formas 4 SKUs “importantes” que no pudieron ser ajustados en el proceso AR debido a falta de datos. El modelo además utiliza como variable independiente al precio.

A continuación se presentan los ajustes globales y desagregados logrados para la metodología propuesta (M.P.) en esta memoria vs los logrados por el modelo autorregresivo.

Tabla 9.5: Ajuste SKU_{imp} para Metodología propuesta vs AR

ID	Metodología propuesta						AR					
	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku1	1322,81	661,41	14,85%	925,91	534,57	16,02%	654,86	327,43	9,79%	2918,20	1684,82	22,44%
sku3	3479,67	798,29	31,90%	8839,97	5103,76	50,78%	3752,32	860,84	36,12%	8566,81	4946,05	30,46%
sku5	1097,50	388,03	41,89%	736,21	425,05	7,54%	1259,69	445,37	58,17%	1980,20	1143,27	89,22%
sku9	2006,37	536,23	38,20%	5828,81	3365,26	172,76%	3495,98	934,34	83,99%	8595,72	4962,74	310,21%
sku14	919,79	216,80	106,23%	1283,33	740,93	130,06%	1419,89	334,67	105,12%	2056,76	1187,47	219,26%
sku22	2383,97	546,92	42,48%	2961,57	1709,87	54,61%	1878,79	431,02	36,82%	4094,60	2364,02	133,24%
sku35	297,90	112,60	31,50%	949,53	548,21	46,20%	330,05	124,75	27,84%	300,40	173,44	7,55%
sku55	418,01	115,94	30,40%	1662,65	959,93	7,15%	749,86	207,97	104,19%	1804,30	1041,71	30,09%
sku57	1134,00	428,61	17,42%	22423,69	12946,32	80,98%	1646,13	622,18	31,95%	18724,36	10810,51	60,69%
sku58	406,09	181,61	17,07%	6192,53	3575,26	66,61%	599,22	267,98	30,87%	5981,23	3453,27	63,80%
sku59	345,15	130,45	69,37%	700,50	404,43	22,80%	554,27	209,50	98,97%	2105,93	1215,86	35,26%
sku66	2696,98	550,52	33,39%	830,40	479,43	54,40%	4763,22	972,29	63,95%	6585,29	3802,02	493,17%
sku67	1775,04	512,41	25,21%	5698,34	3289,94	27,69%	2568,91	741,58	40,67%	9444,34	5452,69	35,91%
sku69	2382,64	900,55	60,46%	1715,15	990,24	8,37%	1854,35	700,88	28,09%	2161,56	1247,98	28,85%

Fuente: Elaboración Propia


Tabla 9.6: Ajuste global para Metodología propuesta vs AR

	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
M.propuesta	2054,04	160,39	43,23%	7098,12	1095,26	53,28%
AR	2744,35	214,30	59,74%	7131,93	1100,48	111,44%

Fuente: Elaboración Propia


Se puede observar que el modelo AR presenta un muy buen ajuste, similar al de la metodología propuesta (MAPE sólo un 16,51% mayor), sin embargo, esta última presenta un nivel predictivo claramente superior, presentando un MAPEe un 58,16% más bajo, además, al analizar desagregadamente es claro ver que prácticamente para todos los SKUs el nivel predictivo es mejor en este modelo: de los 15 equipos analizados, en tan sólo 4 de éstos el proceso AR presenta mejores niveles predictivos. A continuación se presentan gráficos comparativos entre ambas opciones y las ventas reales para 6 SKUs en los meses de predicción.

Figura 9.1: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.2: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.3: Series ventas vs estimación



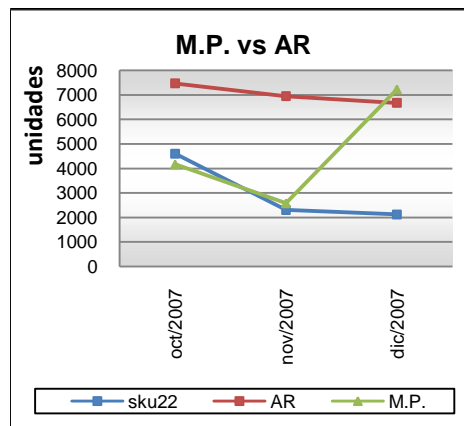
Fuente: Elaboración propia (*datos re-escalados)

Figura 9.4: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.5: Series ventas vs estimación



Fuente: Elaboración propia (*datos re-escalados)

Figura 9.6: Series ventas vs estimación



Fuente: Elaboración propia (*datos re-escalados)

9.3 ANÁLISIS DE SEGMENTACIÓN

Se observa que en la gran mayoría de los equipos no existen grandes diferencias ni en el nivel de predicción ni en los parámetros del modelo de Bass entre ambas segmentaciones (ver Anexo H: estimación parámetros por SKU). Lo anterior podría indicar que ambas segmentaciones resultan equitativamente ineficientes o que todos los SKUs tienen a comportarse de manera similar en cuanto a estacionalidad y elasticidad precio propia, y que por lo tanto no existen segmentos. Para comprobar lo anterior se realiza una tercera segmentación completamente al azar y se procede a analizar el ajuste en los SKUs “importantes”. La tabla 9.7 muestra el ajuste logrado en las 3 opciones.

Tabla 9.7: Ajuste SKU_{imp} para segmentación 1, 2 y 3

ID	segmentación original			segmentación alternativa 2			segmentación alternativa 3		
	RMSEe	MADe	MAPEe	RMSEe	MADe	MAPEe	RMSEe	MADe	MAPEe
sku1	925,91	744,64	16,02%	328,29	298,11	5,07%	2804,34	2267,86	50,19%
sku3	8839,97	8327,93	50,78%	14822,86	13478,61	82,19%	11661,63	10684,46	65,15%
sku5	736,21	718,29	7,54%	1002,15	890,95	25,08%	929,08	787,44	27,68%
sku9	5828,81	4722,07	172,76%	4255,42	3694,14	135,15%	5000,33	3871,05	141,62%
sku15	4500,13	3503,13	92,59%	4455,83	3436,16	90,82%	4554,02	3594,05	95,00%
sku18	383,38	346,70	1,61%	425,26	300,90	17,90%	437,28	302,16	21,48%
sku22	2961,57	1934,94	54,61%	2236,66	1384,16	45,95%	2249,34	1543,59	34,00%
sku28	351,54	323,81	81,09%	290,89	263,71	66,04%	568,36	550,07	137,75%
sku30	676,82	529,73	64,26%	707,84	566,09	68,67%	425,38	261,04	27,86%
sku35	949,53	919,95	46,20%	234,63	191,17	8,08%	991,46	968,40	48,63%
sku38	238,10	157,97	27,28%	257,63	188,25	27,67%	256,59	185,77	33,17%
sku57	22423,69	16518,04	80,98%	22012,33	16785,79	82,30%	23096,77	17428,16	85,45%
sku59	700,50	630,30	22,80%	758,29	557,25	20,16%	1357,65	1072,42	15,98%
sku67	5698,34	4832,30	27,69%	5208,40	3919,04	22,46%	2684,62	2050,85	8,79%
sku69	1715,15	1319,13	8,37%	3063,63	2824,33	45,30%	1339,75	1087,78	5,68%
sku72	9923,08	7821,56	58,22%	10549,51	7727,53	57,52%	11306,16	8820,02	65,65%
sku73	2080,71	1520,13	41,89%	407,45	317,63	10,66%	361,21	348,50	7,36%

Fuente: Elaboración Propia

Se observa que efectivamente las tres alternativas presentan niveles de predicción muy similares, lo que podría confirmar que no existen segmentos en cuanto a la incidencia de la estacionalidad y/o del precio. Si esto resulta efectivo, entonces los parámetros de estacionalidad y/o precio propio debiesen ser homogéneos a través de los distintos grupos. Lo anterior resulta evidente para la estacionalidad al ver la Tabla 9.8 y la Tabla 9.9, donde en la primera se puede observar la estabilidad de la estacionalidad a través de los grupos, y en la segunda, la estabilidad de la estacionalidad promedio entre las distintas segmentaciones.

Tabla 9.8: Parámetros de estacionalidad, segmentación original

α	gr1	gr2	gr3	gr4	gr5	gr6	gr7	gr8	gr9	gr10	prom
Enero	1	0,5844	0,8657	0,9764	1	0,7179	0,7273	0,8828	0,6422	0,8265	0,8223
Feb	0,7823	0,5901	0,7252	0,8025	0,7938	1	1	1	0,4939	0,9301	0,8118
Marzo	1	1	1	1	1	1	1	1	1	1	1
Abril	1	1	1	1	1	1	1	1	1	1	1
Mayo	1	1	1	1	1	1	1	1	1	1	1
Junio	1	1	1	1	1	1	1	1	1	1	1
Julio	1	1	1	1	1	1	1	1	1	1	1
Agos	1	1	1	1	1	1	1	1	1	1	1
Sept	1	1	1	1	1	1	1	1	1	1	1
Oct	1	1	1	1	1	1	1	1	1	1	1
Nov	0,5544	0,8096	0,8562	0,672	0,687	0,5818	0,6347	0,8072	0,7762	0,4791	0,6858
Dic	2,1633	1,9878	2,0529	2,0492	1,606	1,562	1,3774	1,4982	2,5877	2,2643	1,9149

Fuente: Elaboración Propia

Tabla 9.9: Estacionalidad promedio por segmentación

α prom.	1	2	3
Enero	0,822	0,837	0,877
Feb	0,812	0,869	0,848
Nov	0,686	0,681	0,657
Dic	1,915	1,87	1,946

Fuente: Elaboración Propia

Sin embargo, al analizar las elasticidades precio propio para los distintos grupos y las distintas segmentaciones, es claro ver que en ninguna segmentación este parámetro resulta homogéneo:

Tabla 9.10: Elasticidad precio propia por grupo y por segmentación

	qr1	qr2	qr3	qr4	qr5	qr6	qr7	qr8	qr9	qr10
1	0,818	3,331	1,953	2,543	3,522	1,545	2,321	1,706	0,878	2,87
2	2,915	4,417	1,665	1,270	1,071	0,795	0,001	2,898	2,811	1,102
3	2,062	2,762	1,664	1,489	3,669	1,869	2,410	1,862	3,134	0,000

Fuente: Elaboración Propia

De lo anterior, se puede concluir que probablemente todos los equipos dentro de este estudio se ven afectados de igual manera por los 4 parámetros de estacionalidad, y respecto al precio, solamente se puede suponer que efectivamente existe una importante incidencia de esta variable, pero que este efecto resulta altamente heterogéneo, y el cual finalmente, el modelo y/o la segmentación no son capaces de retratar bien. Para tener una mayor certeza de lo anterior se realiza una Validación de dichos parámetros.

9.4 VALIDACIÓN DE PARAMETROS

9.4.1 Elasticidad precio propia

Si bien de 9.2 se llega a la conclusión que la elasticidad precio propia no resulta bien retratada dentro del modelo, se procede de todas formas a realizar un análisis de sensibilidad eliminando un SKU a la vez dentro de cada grupo. El Método a utilizar es similar al propuesto en [13], la elección de este método se debe a que no sólo muestra

la estabilidad del cálculo (lo cual se puede obtener a través del Hessiano de la función objetivo) sino que además muestra la sensibilidad existente frente a cada SKU individualmente. El Anexo I presenta el resultado del análisis por grupo, donde el eje horizontal indica el SKU eliminado en cada paso.

Es posible ver que existe una gran sensibilidad a ciertos SKUs, lo cual confirma la hipótesis de la inestabilidad de este parámetro. Al ser tan sensible a SKUs individuales, dejan entrever las pocas instancias de cambios de precio que existen en el modelo, y la consiguiente gran importancia de estipular una segmentación de antemano que logre capturar este parámetro, ya que existen muchos SKUs que no presentan suficientes variaciones de precio como para estimar una elasticidad individual, por lo que la agrupación resulta imprescindible en este punto, pues un SKU con muchas variaciones podría representar a todo un grupo.

9.4.2 Estacionalidad

Análogo al punto anterior, se realiza un análisis de sensibilidad para los 4 parámetros de estacionalidad, eliminando del problema de optimización un SKU del grupo por vez. El Anexo J presenta el resultado del análisis, donde el eje horizontal indica el SKU eliminado en cada paso.

Al ver los resultados del análisis, se aprecia que en general existe muy poca variabilidad de las estimaciones al quitar un elemento del grupo. De esta manera, se valida la incorporación de este parámetro al modelo, y confirma la homogeneidad de la estacionalidad a través de los equipos.

9.5 ANÁLISIS POR CASOS

9.5.1 Análisis casos con buen nivel de predicción

Se analiza el caso de aquellos equipos que presentan un buen nivel de predicción, condición que se establece para todos aquellos SKUs que presentan un MAPEe inferior al 40%. La Tabla 9.11 presenta los indicadores de ajuste para estos SKUs junto con el indicador Xpe.

Tabla 9.11: Indicadores de ajuste y ventas periodo de evaluación para casos con buen ajuste, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	Xpe
sku1	1322.81	782.86	14.85%	925.91	744.64	16.02%	4519
sku5	1097.50	899.78	41.89%	736.21	718.29	7.54%	2056
sku16	399.44	300.52	20.69%	32.77	22.32	24.29%	91
sku18	604.28	406.57	46.94%	383.38	346.70	1.61%	1407
sku21	478.52	308.28	60.61%	34.08	33.37	25.54%	131
sku31	129.29	53.06	45.80%	1.19	1.14	6.19%	6
sku38	441.38	327.20	23.78%	238.10	157.97	27.28%	516
sku47	285.26	217.46	42.78%	45.06	39.35	21.16%	186
sku49	37.25	32.48	14.58%	277.46	199.72	36.70%	503
sku55	427.57	319.14	14.63%	1662.65	1418.11	7.15%	3221
sku59	345.15	242.50	69.37%	700.50	630.30	22.80%	2764
sku67	1775.04	1318.93	25.21%	5698.34	4832.30	27.69%	17452
sku68	1305.66	1073.07	40.99%	43.49	28.80	8.65%	244
sku69	2382.64	1555.83	60.46%	1715.15	1319.13	8.37%	6235


ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	Xpe
sku70	196.14	139.83	27.66%	317.68	290.39	30.12%	964

Fuente: Elaboración Propia

Se observa que una importante parte de los SKUs con buen nivel de predicción presentan además importantes ventas en los periodos de predicción, y que por lo tanto son parte de los SKUs mencionados como importantes. Además, sólo 6 de estos aparatos presentan ventas inferiores a las 500 unidades. Se contabilizan un total de 15 casos dentro de este grupo, los que representan un 23% de los equipos finalmente evaluados.

La Figura 9.7 presenta la serie de ventas para estos equipos, y en donde se puede apreciar que la mayoría de estos están en las primeras etapas del ciclo.


Figura 9.7: Serie de tiempo ventas SKUs con buen nivel de predicción, segmentación 1



Fuente: Elaboración Propia (*datos re-escalados)

Para confirmar la relación entre XPe y MAPEe se presenta un gráfico de dispersión entre ambas variables en la Figura 9.8, en donde se observa que efectivamente para los SKUs de mayor importancia, existe una tendencia a presentar mejores niveles de predicción.


Figura 9.8: Gráfico de dispersión MAPEe vs XPe, segmentación 1



Fuente: Elaboración Propia


A continuación se presenta la serie de ventas vs la serie de predicciones para 6 equipos pertenecientes a este grupo.

Figura 9.9: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.10: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.11: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.12: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.13: Series ventas vs estimación



Fuente: Elaboración propia (*datos re-escalados)

Figura 9.14: Series ventas vs estimación



Fuente: Elaboración propia (*datos re-escalados)

En los equipos SKU55, SKU67, SKU5 y SKU 16, se puede apreciar que el excelente nivel de predicción viene precedido con una evidente curva tipo para el modelo de Bass. Lo anterior apunta a que si se está en un periodo significativo de ventas, y las ventas pasadas se ajustan a un curva tipo de Bass, entonces la predicción será probablemente certera. Además, para el equipo 16 se observa un ajuste casi perfecto durante todo su ciclo de vida, un ajuste de este nivel difícilmente resulta de una casualidad, y sugiere que la metodología se comporta bien bajo ciertas condiciones. Es posible observar que a lo largo de su ciclo no presenta ningún comportamiento impredecible (*peaks* en meses inesperados, alzas o bajas bruscas, etc.). Esto podría implicar que bajo ciertas circunstancias es posible ajustar de manera precisa la curva y por ende, predecir adecuadamente. Dichas circunstancias probablemente se relacionan con un adecuado nivel de stock, ausencia de promociones agresivas, competencia estable, etc.

9.5.2 Análisis casos con mal nivel de predicción

Se analiza el caso de aquellos equipos que presentan un mal nivel de predicción, condición que se establece para todos aquellos SKUs que presentan un MAPEe superior al 70%. La Tabla 9.12 presenta los indicadores de ajuste para dichos SKUs junto con el indicador Xpe, que representa el promedio de ventas alcanzado durante el periodo de predicción, i.e. los últimos tres periodos del horizonte total del estudio.


Tabla 9.12: Indicadores de ajuste y ventas periodo de evaluación para casos con mal ajuste, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	Xpe
sku2	784.18	522.17	155.10%	26.57	16.93	74.70%	23
sku3	3700.40	2479.21	27.28%	14822.86	13478.61	82.19%	16399
sku6	495.25	395.54	33.22%	1410.63	1154.41	339.20%	340
sku9	2290.97	1752.36	27.44%	4255.42	3694.14	135.15%	2733
sku10	55.34	41.77	15.30%	81.28	58.67	76.86%	76
sku12	1113.91	739.74	59.05%	293.77	266.46	88.62%	301
sku13	336.74	269.02	37.36%	134.83	128.89	75.67%	170
sku14	998.89	810.47	110.66%	1191.69	1121.48	123.92%	905
sku15	389.35	326.50	30.71%	4455.83	3436.16	90.82%	3783
sku16	505.75	362.55	32.25%	141.51	139.93	154.33%	91
sku17	291.00	183.32	55.60%	115.13	107.29	87.47%	123
sku19	332.86	269.79	47.67%	124.24	120.20	290.80%	41
sku23	303.66	244.14	31.03%	107.12	103.00	89.30%	115
sku24	360.87	268.11	62.59%	1693.80	1181.54	89.81%	1316
sku26	2286.88	1979.35	592.44%	2246.90	2088.52	537.82%	388
sku27	70.03	52.68	32.78%	48.91	46.14	98.17%	47
sku33	241.73	233.67	37.18%	631.70	462.18	98.97%	467
sku41	242.94	145.47	45.62%	78.06	73.80	85.82%	86
sku43	914.55	703.47	37.27%	558.14	477.99	96.17%	497
sku46	232.17	179.83	39.36%	153.89	150.79	94.44%	160
sku48	1464.26	687.41	48.69%	182.12	175.49	86.31%	203
sku51	68.30	49.41	44.44%	1150.57	874.97	74.40%	1176
sku56	76.44	45.56	44.89%	4.23	3.90	97.60%	4
sku57	1131.18	939.84	15.79%	22012.33	16785.79	82.30%	20397
sku60	1402.23	1198.82	113.14%	495.47	452.33	142.39%	318
sku61	1671.42	1302.52	196.17%	257.36	256.32	238.81%	107
sku62	47.35	33.65	52.81%	28.56	17.96	97.98%	18
sku63	2506.79	1604.38	157.26%	101.48	99.62	71.67%	139
sku64	3381.14	1573.76	232.65%	134.07	124.86	283.76%	44
sku65	633.11	522.41	104.39%	53.74	46.58	71.66%	65
sku68	1230.76	973.39	39.59%	513.97	460.26	188.63%	244
sku71	142.93	78.52	31.13%	221.91	185.84	91.70%	203

Fuente: Elaboración Propia

Es posible observar que para casi la totalidad de los SKUs con mal nivel de predicción se tienen ventas inferiores a las 500 unidades mensuales, lo que da cuenta de la sensibilidad del MAPE en los periodos de ventas bajas. Estos equipos ascienden a un total de 31 casos, que representan un 48% de los equipos evaluados. La Figura 9.15 presenta la serie de ventas para estos SKUs donde se puede apreciar la gran mayoría está en sus últimas fases del ciclo de vida.


Figura 9.15: Serie de tiempo ventas SKUs con mal nivel de predicción, segmentación 1



Fuente: Elaboración Propia


A continuación, se presenta la serie de ventas vs la serie de predicciones para 6 SKUs pertenecientes a este grupo.

Figura 9.16: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.17: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.18: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.19: Series ventas vs estimación




Fuente: Elaboración propia (*datos re-escalados)

Figura 9.20: Series ventas vs estimación



Fuente: Elaboración propia (*datos re-escalados)

Figura 9.21: Series ventas vs estimación



Fuente: Elaboración propia (*datos re-escalados)

No obstante el mal nivel de predicción, una importante parte de estos equipos presenta un excelente ajuste a lo largo de su ciclo de vida, sin embargo, al llegar a los últimos periodos, el MAPE presenta grandes errores, esto pues errores de pocas unidades resultan en grandes errores porcentuales cuando las ventas son bajas. Dado que los errores considerables se presentan sólo cuando existen ventas bajas, se puede decir que estos malos ajuste resultan de poca importancia, y más aun, en casos como el SKU12, SKU48, SKU63 y SKU65 se puede ver que existe un excelente ajuste a lo largo del ciclo, por lo que a pesar de presentar una mala predicción, si pueden ser considerados casos exitosos. Al igual que el punto anterior, los casos en donde el ajuste resulta de tanta exactitud sugieren que la metodología tiene gran efectividad bajo ciertas condiciones. Al ver la serie de ventas para el SKU12 y el SKU65, en donde además se observan ajustes casi perfectos, no es posible observar ningún tipo de comportamiento impredecible (no existen cambios bruscos, *peaks* inusitados, etc.) lo que indicaría la presencia de condiciones idóneas. Además, ajustes de tanta precisión validan en cierta medida la metodología, ya que un ajuste así difícilmente resulta de un hecho fortuito.

Otra situación distinta a la anterior es la del SKU15 y el SKU24, que si presentan grandes errores absolutos. Respecto al primero, el SKU no se comporta de manera compatible por el modelo, ya que la metodología se basa en una situación en que existe una marcada forma de S en la curva de demanda acumulada, y en este equipo se observa una demanda muy plana previo a los 3 meses de predicción, lo que conlleva a la obtención de parámetros no creíbles en el modelo de Bass. El caso del SKU24 resulta distinto por cuanto se observa un comportamiento totalmente impredecible. El explosivo crecimiento que experimenta en Noviembre no puede ser considerado otra cosa que un *outlier*, ya que este mes resulta ser en todos los análisis un mes de ventas bajas. Luego, el gran error de predicción presentado en este caso, se asocia a un error en los datos o una anomalía en las ventas.

9.5.3 ANÁLISIS SKUS “IMPORTANTES”

La Tabla 9.13 presenta el ajuste final logrado para los SKUs “importantes”.

Tabla 9.13: Ajuste para SKUs “importantes”, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku1	1322,81	782,86	14,85%	925,91	744,64	16,02%
sku3	3479,67	2628,80	31,90%	8839,97	8327,93	50,78%
sku5	1097,50	899,78	41,89%	736,21	718,29	7,54%
sku9	2006,37	1611,12	38,20%	5828,81	4722,07	172,76%
sku15	369,98	320,21	31,17%	4500,13	3503,13	92,59%
sku18	604,28	406,57	46,94%	383,38	346,70	1,61%
sku22	2383,97	1915,30	42,48%	2961,57	1934,94	54,61%
sku28	197,58	182,53	20,75%	351,54	323,81	81,09%
sku30	183,03	151,30	42,24%	676,82	529,73	64,26%
sku35	297,90	223,67	31,50%	949,53	919,95	46,20%
sku38	441,38	327,20	23,78%	238,10	157,97	27,28%
sku57	1134,00	1000,10	17,42%	22423,69	16518,04	80,98%
sku59	345,15	242,50	69,37%	700,50	630,30	22,80%
sku67	1775,04	1318,93	25,21%	5698,34	4832,30	27,69%
sku69	2382,64	1555,83	60,46%	1715,15	1319,13	8,37%
sku72	2911,04	2148,04	57,15%	9923,08	7821,56	58,22%
sku73	143,75	138,10	15,40%	2080,71	1520,13	41,89%

Fuente: Elaboración Propia

De la tabla anterior se puede apreciar que el ajuste logrado para todos los SKUs dentro de este grupo resulta ser muy bueno, siendo el MAPE inferior al 70% en todos los casos. Si se observa el MAPEe, se puede notar que existen tan sólo 3 SKUs que son además parte del grupo de SKUs con mal ajuste, definido en 9.3. Por el contrario, una significativa porción de estos SKUs corresponde a SKUs con buen ajuste, definido en 9.4, contabilizando 7 SKUs dentro de esta categoría.

Las estadísticas anteriores resultan muy importantes ya que estos SKUs representan el 74.97% de las unidades vendidas y el 63.10% de los ingresos en los meses de predicción dentro de los SKUs incluidos en el estudio. Para validar estos resultados, se prueba para 3 horizontes de tiempo de calibración, utilizando la misma regla antes definida para establecer que SKUs caen dentro de esta categoría: las ventas del último

periodo de calibración deben superar las 1300 unidades. La tabla 9.14 resume el ajuste logrado.

Tabla 9.14: Ajuste para SKUs “importantes” según periodos de calibración, segmentación 1

	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
T-3	1734.93	1016.70	35.80%	6798.58	3227.68	63.66%
T-4	1709.34	1099.88	41.73%	2649.51	1755.72	61.03%
T-5	1609.64	1030.57	44.66%	2396.58	1646.77	72.64%
T-6	1625.68	1027.00	47.85%	2602.96	1798.35	139.41%

Fuente: Elaboración Propia

Se puede observar que para los 3 periodos de calibración se obtienen resultados similares en cuanto al ajuste para los SKU_{imp} . El periodo T-6 presenta un ajuste notoriamente superior, pero al analizar el desagregado se ve que este resultado se debe al efecto de un par de SKUs que presentan un muy mal ajuste ya que el resto presenta niveles de predicción similares a los periodos de calibración anteriores. En el Anexo K se detalla el ajuste por SKU_{imp} para los horizontes T-4 y T-5 y T-6.

10. RECOMENDACIONES PARA METODOLOGÍA GENERAL

En base a los resultados anteriores se recomiendan los siguientes pasos para la generalización de la metodología.

- **Estudio comportamiento de demanda**

En este punto, se deberán observar las series de ventas y precios para una cantidad representativa de SKUs. En primer lugar, se debe constatar que la demanda agregada efectivamente sigue una curva de crecimiento en forma de S. Luego, se debe observar que factores influyentes existen (variables independientes en la modelación), principalmente se deben observar estacionalidades, dado que en general los productos de orden tecnológicos son altamente estacionales. De esta manera, se debe determinar de qué forma afecta la estacionalidad y otros factores en el problema a resolver. Para el caso resuelto, se determinó que la estacionalidad es principalmente relevante para los meses de Enero, Febrero y Noviembre Diciembre, siendo su efecto negativo en los primeros tres, y positivo para el último. Así también, se determinó una importante influencia del precio.

- **Limpieza de base de datos**

En función del estudio de comportamiento de demanda, se deberá estipular que SKUs no se comportan según el patrón esperado, y además, se establecerá un set de reglas referidas a la estacionalidad, en caso que esta sea relevante, para así poder excluir datos que a priori se puedan declarar como *outliers*. Estos datos no aportan información relevante al problema, por el contrario, desvirtúan los parámetros compartidos. Se debe tener especial cuidado con excluir sólo casos extremos, ya que un cambio brusco en las tendencias puede deberse a la conjugación de múltiples factores, como el precio o la

misma estacionalidad. Además, en un problema en que el principal problema es la falta de datos, resulta contraproducente borrar una gran cantidad de registros.

Este paso resulta de extremada importancia, sobre todo cuando se cuenta con una gran cantidad de datos sesgados.

- **Determinación de Curva base**

Se debe determinar cuál es el mejor patrón que se ajusta a la curva de demanda observada. Se recomienda probar entre Weibull, curva de Bass u otras opciones como ARIMA si es posible. Se elegirá aquella que presente mejor índices de predicción.

- **Agrupación de SKUs**

En este paso, se deben agrupar los equipos en segmentos. La forma en que se agrupen los SKUs queda fuera de la metodología por lo que será de especial importancia la calidad de la segmentación con la que se cuente. Para esto, es esencial determinar un número prudente de equipos por grupo, ya que por un lado se necesita una cantidad suficiente como para suplir la deficiencia de datos, pero por otro lado, se debe respetar la individualidad de cada equipo. La segmentación se deberá centrar principalmente en la elasticidad precio propia, ya que como se probó en esta metodología, es probable que los parámetros de estacionalidad sean transversales a los grupos. En el caso práctico de esta memoria, se recomienda dejar un número no menor a 4 equipos por segmento y no mayor a 8.

- **Incorporación de variables de precio y estacionalidad.**

Si en el estudio de comportamiento de demanda se determinó que el precio y la estacionalidad eran relevantes, entonces estas deben ser incorporadas al modelo. Se cree que la alternativa escogida para el caso práctico es una buena opción para conjugar ambas variables, ya que, como se discutió 8.3.6, esta brinda un buen ajuste, es estable y permite la comparación de parámetros entre distintos grupos.

- **Tratamiento de SKUs en sus primeras fases.**

Se debe determinar que se considera un SKU con un ciclo inmaduro, lo cual viene dado del estudio de demanda, donde es necesario analizar el tiempo de un ciclo promedio y el tiempo promedio para llegar al *peak* de ventas. En base a esto, resulta conveniente establecer qué cantidad de datos es necesaria para poder determinar la curva del modelo y así aplicar la metodología expuesta en este trabajo de memoria. La metodología de tener SKUs donantes, que donen sus datos a SKUs con pocos registros, se presenta como una excelente alternativa para poder realizar predicciones en este tipo de SKU, los cuales en otros métodos, simplemente no califican ser calibrados.

- **Incorporación de variables de elasticidades precio cruzado**

Si es que se está en un mercado dinámico y con una fuerte competencia, se recomienda no incluir éste paso. Si se considera que ya la inclusión de la elasticidad precio propio resulta altamente inestables, luego aun más lo será el incorporar el efecto de otros SKUs, considerando la gran cantidad de potenciales SKUs competidores y empresas competidoras que puedan existir.

Si por el contrario, uno se encuentra en una situación en la cual la situación es monopólica, o con un mercado exclusivo, entonces el incorporar elasticidades precio cruzado será probablemente beneficioso, y se recomienda aplicar la metodología propuesta en 8.6.

- **Limpieza de datos en base a ajuste del modelo**

Como resulta no trivial establecer reglas para determinar *outliers*, se recomienda un segundo paso de limpieza en el cual se eliminen datos que presenten grande errores en la estimación. Estos datos no aportan al problema, sino que por el contrario, favorecen a la obtención de parámetros erráticos.

11. CONCLUSIONES

11.1 COMENTARIOS FINALES

- **Metodología de estimación de elasticidades cruzadas.**

La metodología de tres pasos probó ser solamente explicativa en el primero de ellos, llegando a mejoras insignificantes en los otros dos pasos donde se incluyen elasticidades cruzadas. Si bien en el caso práctico las elasticidades cruzadas resultan ser irrelevantes, resulta incierto saber si estas podrían resultar efectivas para otros casos; se cree que gran parte de este problema radica en la segmentación, ya que al existir muchos SKUs y pocos cambios en los precios, resulta muy dificultoso establecer que aparatos son competencia tan sólo a través de los datos transaccionales, forzando la búsqueda de formas alternativas para segmentar. Para lograr esto, resulta necesario llevar un registro con información histórica de algún tipo de investigación de mercado que permita establecer que grupos existen y han existido, ya que, si bien es posible realizar un estudio del mercado actual, este, al evaluar un mercado de rápido cambio, sólo será válido para el presente, y por lo tanto, que no podrá ser extrapolado a los equipos y/o ventas pasadas.

Por otra parte, se cree que para cada SKU se tiene tan sólo un pequeño subconjunto de SKUs que resultan ser su competencia, no tiene sentido que SKUs que difieren en grandes magnitudes en su precio presenten elasticidades precio cruzada.

- **Modelo de proyección de demanda**

Dentro de este punto, un importante resultado fue el comprobar la validez de la incorporación de la estacionalidad, la cual resultó ser extremadamente estable, y aun más, transversal a todos los equipos. Lo anterior tiene como consecuencia que, de considerar el efecto de la estacionalidad aisladamente, es posible agrupar cualquier grupo de SKUs sin importar sus características. Así también, estos resultados validan la forma en que se incorpora esta variable dentro del modelo, resultando en una variable de gran importancia.

En contraste con lo anterior, el precio resultó ser altamente sensible a unos pocos SKUs por lo que no pudo ser validado, y lo cual da cuenta de la importancia de tener una buena segmentación para este punto, ya que unos pocos SKUs dominan el cálculo de elasticidades para cada grupo.

Si bien el efecto del precio del efecto es claramente notorio, este muchas veces no forma parte de las variables operacionales de decisión, ya que el precio responde a un precio de mercado, y por lo tanto es más bien un parámetro que una variable. Además, como se está en un mercado altamente homogéneo en cuanto a oferta, se puede suponer que solamente cuando un precio se aleja del precio de mercado es cuando realmente se tiene una repercusión. Por ejemplo, si se tiene una fuerte baja del precio, pero dicho precio responde a una baja global del mercado, probablemente el efecto no será tan notorio como una baja moderada del precio, pero que se encuentra por bajo sus competidores. Este tipo de fenómenos no se pudieron captar en el modelo ya que no se contaba con información de la competencia.

Por otra parte, como se ve en 8.3, la base se presenta rica en datos fuera de rango, en donde se observan comportamientos que carecen de lógica, y que retratan una base de datos altamente sesgada, con la presencia de evidentes quiebres de stock y otras situaciones no retratadas por el modelo, que se cree que cobran gran relevancia. El problema de contar con ciertos registros errados es que estos desvirtúan toda la curva, motivo por el cual se intentó solucionar este problema al dejar fuera de la optimización registros evidentemente fuera de patrón.

El modelo resultó ser efectivo para solamente una parte de los SKUs estudiados: los SKUs establecidos como equipos con buen ajuste ($MAPE_e < 40\%$) sólo representan un 23% de los equipos finalmente evaluados; los SKUs establecidos como equipos con mal ajuste ($MAPE_e > 70\%$) representan un 48% de los equipos evaluados. No obstante, al evaluar los SKUs de mayor importancia, definidos en base a las ventas presentadas en el último periodo de calibración, estos presentan un ajuste muchísimo mejor que el promedio ($MAPE_e = 63.66\%$), siendo compuesto por una cantidad considerable de SKUs con buen ajuste. Estos SKUs representan más del 60% de las ventas totales en los últimos tres periodos y por lo tanto, el tener un buen ajuste en este grupo resulta de primordial importancia. Lo que resulta aun más interesante es evaluar el desempeño del modelo a 1 mes plazo, ya que este mejora a un 29% de MAPE para el grupo "importante", es inclusive si se expande a 2 meses plazo el error es de solamente un 43%.

Si bien el modelo falla para algunos SKUs, este representa una importante mejora respecto a un modelo AR, de donde se obtuvo que el modelo propuesto predice, en base a los mismos inputs, con un 58,16% menos de error en los SKU_{imp} y donde para 10 de 14 de estos equipos se logra una mejora. Dado que para este tipo de problemas no existe una gran cantidad de estudios, una mejora de este nivel se considera altamente exitosa, además, muchos de los métodos tradicionales, al exigir una gran cantidad de datos para su calibración, resultan inaplicables para este escenario, por lo que el sólo hecho de llegar a estimaciones razonables para SKUs con menos de 4 o 5 datos es un avance.

A su vez, al analizar los resultados por SKU, se pudo apreciar que en un número considerable de estos se presentaba un excelente ajuste durante gran parte del ciclo, lo cual avala la metodología propuesta, ya que difícilmente se pueden tener tan buenos resultados azarosamente, y lo anterior induce a pensar que existen ciertos SKUs que vivieron su ciclo bajo circunstancias idóneas (al no presentar registros fuera de lo normal), como lo pueden ser la ausencia de quiebres de stock, la ausencia de promociones y una competencia estática. Lo anterior entrega claras luces de que al incorporar dichos parámetros al modelo, o en su defecto, contar con una base aislada de dichos efectos, las estimaciones podrán ser notoriamente mejores.

- **Automatización de la metodología**

Aunque el problema resulta altamente no lineal, al lograr un adecuado número de SKUs por grupo y un acotado número de variables, se logró una aplicación altamente estable, la cual fue capaz de correr para distintos periodos de calibración, distintos grupos, y distintas configuraciones del modelo. De aquí la importancia de agrupar, ya que resulta imposible o altamente sesgado el calcular los parámetros de manera individual. Para este punto fue igualmente esencial una buena limpieza de la base de datos y un buen establecimiento de reglas de marginación.

El programa es casi totalmente modular y por lo tanto es perfectamente aplicable a otro set de SKUs pertenecientes a algún mercado similar.

11.2 RECOMENDACIONES

Si bien una parte de los objetivos de la memoria era lograr una metodología modular, es también recomendable contar con mayor información particular de cada caso a estudiar, más allá de lo netamente transaccional. Para el caso práctico analizado en este trabajo, no se tuvo acceso a información interna de la empresa, lo cual evidentemente genera un vacío de información, ya que resulta inevitable que se presenten una serie outliers inexplicables según los parámetros del modelo, debido a acciones de marketing agresivas, como promociones y publicidad, o quiebres de stock. Probablemente información referente a estos últimos no resultaría compleja de incorporar mes a mes si se implementa la metodología propuesta.

Se cree que la metodología se adapta de mejor forma a otro tipo de escenarios, como por ejemplo productos de cierta marca exclusiva, donde no exista mayor competencia o bien una situación de ardua competencia como el caso estudiado, pero donde el estudio no sea orientado a una tienda o distribuidor en particular, ya que el proceso de difusión de la tecnología se lleva a cabo dentro de la sociedad, y no dentro de una clientela en particular, por lo que es recomendable aplicar la metodología a mercados que contabilicen la totalidad de las ventas. De aplicarse la metodología a, por ejemplo, las ventas totales en el mercado chileno de los celulares, y no a una compañía en particular, es muy factible obtener datos con menor sesgo, debido a una menor sensibilidad a esfuerzos de marketing, quiebres de stock, etc., y consecuentemente, una mejor estimación en todas las etapas de la metodología. De ser empleado para ventas no totales, es recomendable ocuparlo en un mercado en donde no exista una mayor competencia, ya sea por monopolio o porque cada marca está muy bien posicionada con sus propias características. De esta manera, se disminuyen los ruidos causados por la competencia entres SKUs y se respetan las bases teóricas del modelo de Bass.

Otra información que resultaría particularmente relevante sería el tener las estimaciones de ventas totales para cada SKU realizadas por el área de venta. Teniendo esta estimación (m en el modelo) se relaja en gran medida el problema de optimización, y por otra parte, se tendría un buen punto de referencia para realizar estimaciones en SKUs con pocos datos, en los cuales se partiría estimando en base a este parámetro inicial, para luego ir actualizándolo mes a mes según el SKUs vaya avanzando en su ciclo de vida.

11.3 TRABAJOS FUTUROS

- Para problemas en los que existe un déficit de datos, los modelos Bayesianos tienen un gran desempeño. Dentro de este contexto, resulta interesante preguntarse como funcionará el modelo con un tratamiento de este estilo para aquellos SKUs en sus primeras fases del ciclo, ya que si bien se intentó aplicar una metodología especial para estos equipos, esta resultó ser poco eficiente.
- Se estima que sería de gran ayuda el incorporar un segundo paso de limpieza de datos, similar al propuesto en 8.35, el cual determine que registros son outliers pero en base a los indicadores de ajuste. El resultado de la optimización resulta muy sensible a los datos fuera de rango, y por lo tanto, el poder hacer una segunda limpieza pero en base a resultados preliminares sería probablemente un importante aporte para evitar el cálculo de parámetros poco creíbles.
- Si bien en la presente memoria se descarta el uso de modelos por atributos, resultaría interesante buscar una forma de complementar dichos modelos con el modelo propuesto o definitivamente comprobar que efectivamente estos no resultan predictivos.
- Finalmente, resultaría interesante incorporar al modelo variables mencionadas en el punto anterior, como lo son precios de la competencia, promociones, quiebres

de stock, etc., y poder además contar con estimaciones de ventas realizadas por el área de ventas de la empresa en cuestión. Probablemente resultaría en aun mejores resultados el probar la metodología en mercados nicho o monopólicos.

12. BIBLIOGRAFÍA

- [1] ŞEN A. X. ZHANG. 2008. A Style goods pricing with demand learning. *European Journal of Operational Research*.
- [2] BRADFORD J., SUGRUE P. A Bayesian Approach to the Two-period Style-goods Inventory Problem with Single Replenishment and Heterogeneous Poisson Demands. *Journal of Operational Research* 41:211-218.
- [3] PONG, MILTENBURG J., H. C. Order quantities for style goods with two order opportunities and Bayesian updating of demand. *International Journal of Production Research* 45:211-218.
- [4] CHUNG C., FLYNN J., KIRCA Ö. 2008. A multi-item newsvendor problem with preseason. *European Journal of Operational Research* 188(3):775-792.
- [5] FRITIS, N. 2005. Estimación de demanda a nivel de sku para la industria de supermercados. Memoria Ingeniería Civil Industrial. Universidad de Chile. Facultad de Cs. Físicas y Matemáticas.
- [6] BASS F.M. 1969. A New Product Growth Model for Consumer Durables. *Management Science* 15:215-227.
- [7] FOURS, L. A., WOODLOCK J. W. 1960. Early Prediction of Market Success for Grocery Products. *Journal of Marketing* 25:31-38.
- [8] HENDRY, I. The Three Parameter Approach to Long-Range Forecasting. *Long-Range Planning* 5:40-45.
- [9] TRAPPEY, C. V., WU H-Y. 2008. An evaluation of the time-varying extended logistic, simple logistic, and Gompertz. *Advance Engineering Informatics*.
- [10] MCCLAIN, J. O., THOMAS, L. J. 1973. Response Variance Tradeoffs in Adaptive Forecasting. *Operations Research* 21:554-568.
- [11] MAHAJAN, V., MULLER, E., BASS, F.M. 1990. New Product Diffusion Models in Marketing: A Review and Directions for Research. *Journal of Marketing* 54:273-295.
- [12] KURAWARLA A. A., MATSUO H. 1992. Product Growth Models for Medium-Term Forecasting of Short Life Cycle Products. IC Institute, University of Texas at Austin. Technical Report 92-09-04.
- [13] KRISHNAN V. K., BASS F. M., JAIN D. J. 1999. Optimal Pricing Strategy for New Products. *Management Science* 45:1650-1663.

- [14] MOE W. W., FADER P. 2002. Using Advance Purchase Orders to Forecast New Product Sales. *Marketing Science* 21:347-364.
- [15] JIANG R., MURTHY D. N. Mixture of Weibull distributions: Parametric characterization of failure rate function. *Stochastic Models Data Analysis* 14:1-1
- [16] NIST/SEMATECH. e-Handbook of Statistical Methods, 2003. [en línea] <http://www.itl.nist.gov/div898/handbook>. [consulta :10 noviembre 2008]
- [17] WINTERS, P.R. 1960. Forecasting Sales by Exponentially Weighted Moving Averages.
- [18] A., RATKOWSKY D. Handbook of nonlinear regression Models. Marcel Decker, New York.

13. ANEXOS

ANEXO A: DERIVACIÓN ESTIMADORES MCO

Tenemos que S se escribe como.

Ecuación 13.1

$$S = \sum_{i=1}^n r_i^2 .$$

S es minimizada cuando su gradiente con respecto a cada parámetro es igual a 0. Los elementos del vector de gradiente son las derivadas parciales de S con respecto a cada parámetro:

Ecuación 13.2

$$\frac{\partial S}{\partial B_j} = 2 \sum_{i=1}^m r_i \frac{\partial r_i}{\partial \beta_j} = 0 \quad (j = 1, 2, \dots, n).$$

Como

Ecuación 13.3

$$r_i = y_i - \sum_{j=1}^n X_{ij} \beta_j$$

entonces

Ecuación 13.4

$$\frac{\partial r_i}{\partial \beta_j} = -X_{ij} .$$

Substituyendo las expresiones de los residuos y las derivadas parciales en la ecuación del vector de gradientes da como resultado:

Ecuación 13.5

$$\frac{\partial S}{\partial B_j} = -2 \sum_{i=1}^m X_{ij} \left(y_i - \sum_{k=1}^n X_{ik} \beta_k \right) = 0 \quad (j = 1, 2, \dots, n).$$

Reordenando las ecuaciones se tiene que

Ecuación 13.6

$$\sum_{i=1}^m \sum_{k=1}^n X_{ij} X_{ik} \hat{\beta}_k = \sum_{i=1}^m X_{ij} y_i \quad (j = 1, 2, \dots, n),$$

lo que escrito matricialmente:

Ecuación 13.7

$$(X^T X) \hat{\beta} = X^T y.$$

La solución de la ecuación anterior da como resultado el vector de parámetros óptimo para $\hat{\beta}$. Si $X^T X$ es invertible, entonces la ecuación se puede reescribir como

Ecuación 13.8


$$\hat{\beta} = (X^T X)^{-1} X^T y.$$

ANEXO B: ESTUDIO DE DEMANDA

- Gráficos de demanda conjuntos


En los gráficos de demanda conjuntos es posible observar que efectivamente existe una gran estacionalidad, marcada principalmente por los meses de Diciembre, Enero y Febrero, presentando importantes alzas en el primero, y notorias caídas en los últimos dos. Además, es posible observar en la mayoría de los equipos tienen un ciclo de vida menor a los 2 años.

Figura 13.1: Serie de tiempo ventas mensuales por SKU grupo 1




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.2: Serie de tiempo ventas mensuales por SKU grupo 2




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.3: Serie de tiempo ventas mensuales por SKU grupo 3




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.4: Serie de tiempo ventas mensuales por SKU grupo 4




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.5: Serie de tiempo ventas mensuales por SKU grupo 5




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.6: Serie de tiempo ventas mensuales por SKU grupo 6



Fuente: Elaboración propia (*datos re-escalados)

Figura 13.7: Serie de tiempo ventas mensuales por SKU grupo 7




Fuente: Elaboración propia (*datos re-escalados)

- **Análisis elasticidad precio propia**


Al graficar las series de ventas vs precio resulta evidente notar la influencia del precio. No resulta correcto calcular coeficientes de correlación ya que los ciclos de vida per se presentan una forma variante en su demanda, comenzando típicamente con bajas ventas, para luego experimentar un rápido crecimiento, hasta un periodo de madurez y luego declive. De esta manera, si por ejemplo se evalúa el coeficiente en el periodo de declive, y además se toma como premisa que en este periodo el precio también tiende a bajar, y se calcula la correlación entre estos dos factores, esta será evidentemente positiva, y de esta manera se concluirá erradamente que a mayor precio mayores ventas. Es por ello que para evaluar a priori si existe una relación entre el precio y las ventas se graficaron series de tiempo de ventas vs precio.

Figura 13.14: Series ventas vs precio




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.15: Series ventas vs precio




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.16: Series ventas vs precio




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.17: Series ventas vs precio




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.18: Series ventas vs precio




Fuente: Elaboración propia (*datos re-escalados)

Figura 13.19: Series ventas vs precio



Fuente: Elaboración propia (*datos re-escalados)

Figura 13.20: Series ventas vs precio



Fuente: Elaboración propia (*datos re-escalados)

• ANÁLISIS EQUIPOS CON CICLOS DE VIDA EN ETAPAS FINALES

Tabla 13.1: Ajuste curva de Bass a nivel de SKU


	sku2	sku4	sku7	sku8	sku12	sku17	sku19	sku27	sku43	sku48	sku53	sku61	sku63	sku68
max	6.342	16.862	20.312	2.791	11.594	4.313	2.604	1.255	10.174	6.728	20.786	13.643	24.492	12.480
t max	3	5	9	12	7	10	11	5	8	4	14	7	9	11
v.inicial	1.801	1.196	15.443	1.169	3.936	1.504	244	261	1.212	3.793	10.068	1.335	24.492	689
v.total	32.939	97.761	145.643	17.772	97.164	31.629	32.099	8.642	87.592	70.757	106.866	94.531	116.391	70.647

Fuente: Elaboración propia

ANEXO C: REGISTROS INEXPLICABLES PARA BASE REDUCIDA


A continuación se presentan datos “inexplicables” al graficar la serie de ventas por SKU.

Figura 13.21: Series ventas vs estimación




Fuente: Elaboración propia(*datos re-escalados)

Figura 13.22: Series ventas vs estimación




Fuente: Elaboración propia(*datos re-escalados)

Figura 13.23: Series ventas vs estimación




Fuente: Elaboración propia(*datos re-escalados)

Figura 13.24: Series ventas vs estimación




Fuente: Elaboración propia(*datos re-escalados)

Figura 13.25: Series ventas vs estimación




Fuente: Elaboración propia(*datos re-escalados)

Figura 13.26: Series ventas vs estimación




Fuente: Elaboración propia(*datos re-escalados)

Figura 13.27: Series ventas vs estimación



Fuente: Elaboración propia(*datos re-escalados)

Figura 13.28: Series ventas vs estimación



Fuente: Elaboración propia(*datos re-escalados)

- 1- Se observa una caída anormal en los meses de Julio, Septiembre y Octubre, siendo que los dos primeros no demostraron ser meses de ventas bajas en los análisis.
- 2- Se obtiene un *peak* de ventas en Julio, el cual viene precedido de ventas muy bajas en los 2 meses anteriores y sin ser el precio un posible factor.
- 3- Se observa Septiembre como un mes de ventas anómalamente bajas.
- 4- Se observan caídas drásticas para Marzo y Mayo, se presume que es debido a quiebres de stock.
- 5- En Junio se da un *peak* inusitado, siendo q no es un mes de ventas altas, no existe cambio de precios, y viene precedido por meses de ventas bajas.
- 6- Ventas particularmente altas en el mes de Enero y sin cambios en el precio.
- 7- *Peak* en mes de Julio sin tener ventas altas en meses previos.
- 8- Ventas altas en meses de ventas bajas.

9- Ventas iniciales muy por debajo de la media.

10- Octubre como *peak* de ventas sin incentivo de precio ni meses previos de alta demanda.

ANEXO D: AJUSTE CURVA BASE A NIVEL DE SKU

Tabla 13.2: Ajuste curva de Bass a nivel de SKU

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku2	853.07	592.23	40.61%	22.78	17.50	77.21%	sku33	240.14	231.58	35.53%	631.73	461.41	98.80%
sku3	4158.71	3622.49	42.10%	9824.79	6774.53	41.31%	sku34	441.87	368.78	50.26%	545.41	539.37	35.95%
sku4	2887.55	1773.46	61.01%	76.84	60.33	39.86%	sku35	278.61	242.63	23.61%	1536.21	1472.27	73.93%
sku5	1137.48	974.54	43.76%	1292.20	950.19	22.41%	sku37	136.19	105.81	29.76%	112.76	91.31	3.02%
sku6	522.88	443.85	39.22%	981.26	975.61	286.66%	sku38	379.58	317.47	21.99%	311.42	263.51	10.61%
sku7	2592.14	1699.08	114.67%	52.51	43.63	66.46%	sku39	634.19	559.35	71.14%	716.96	712.72	2055.93%
sku8	623.68	457.85	128.27%	36.84	35.44	46.02%	sku40	333.13	278.76	14.69%	316.74	264.96	53.53%
sku9	2273.50	1523.43	21.35%	3163.86	3120.71	114.17%	sku41	165.50	136.87	34.86%	54.85	43.34	50.40%
sku10	88.23	65.74	30.88%	87.31	66.40	86.99%	sku43	1281.99	953.50	43.54%	555.38	474.91	95.56%
sku11	321.43	226.26	96.34%	106.39	87.99	99.23%	sku44	166.77	135.16	123.61%	24.36	20.38	13.44%
sku12	1980.86	1493.37	100.36%	297.60	269.07	89.49%	sku46	526.34	367.79	44.71%	156.55	153.14	95.91%
sku13	229.80	201.67	22.29%	89.61	69.91	39.61%	sku47	292.50	235.32	46.60%	75.96	62.94	23.97%
sku14	1212.07	893.58	79.36%	461.18	424.37	33.94%	sku48	1301.17	998.69	94.90%	62.82	57.64	8.52%
sku15	448.49	388.32	30.20%	4556.42	3553.75	93.93%	sku50	116.79	109.23	52.37%	1461.62	1094.73	72.69%
sku16	517.68	413.07	29.85%	113.36	99.63	109.89%	sku51	56.02	48.55	32.89%	1265.83	954.02	81.12%
sku17	626.10	389.56	79.07%	108.29	101.71	82.92%	sku53	1619.83	1297.74	106.01%	220.70	204.92	81.10%
sku18	555.11	488.60	40.58%	873.64	857.66	60.96%	sku54	163.98	135.65	36.01%	286.09	280.38	81.27%
sku19	453.93	381.43	48.67%	111.93	111.44	269.60%	sku55	365.53	306.12	14.05%	1175.79	1082.73	6.91%
sku20	788.40	565.83	72.84%	44.02	32.62	47.22%	sku57	940.41	757.72	11.77%	23733.81	17233.16	84.49%
sku21	386.61	315.71	53.39%	59.06	58.52	13.33%	sku59	173.36	145.62	5.82%	2565.09	1681.07	53.04%
sku22	2975.62	2441.65	60.75%	4039.89	3869.29	128.46%	sku60	1779.05	1459.50	129.89%	462.77	424.16	92.93%
sku23	480.05	368.59	38.27%	90.72	87.67	76.01%	sku61	2302.36	1587.39	135.51%	119.98	103.35	85.28%
sku24	394.94	300.16	52.48%	1730.88	1241.60	94.37%	sku62	121.34	69.95	79.89%	27.60	16.93	92.37%
sku25	1198.15	843.38	27.74%	547.22	383.29	59.17%	sku63	3073.04	1683.15	172.00%	73.20	69.07	49.69%
sku26	948.68	574.38	54.13%	468.09	388.25	99.98%	sku64	3921.19	2588.25	82.66%	55.79	44.00	100.00%
sku27	86.34	68.83	40.36%	49.51	46.69	99.34%	sku65	1219.04	859.67	131.28%	47.62	36.03	50.44%
sku28	355.34	317.49	35.63%	548.10	529.18	132.52%	sku66	3943.93	2925.82	63.64%	1955.03	1800.72	135.73%
sku29	30.60	24.50	25.93%	5.10	4.79	53.92%	sku67	1802.34	1417.86	29.69%	10885.66	7291.26	41.78%
sku30	274.97	200.98	31.61%	536.56	404.75	23.82%	sku68	2155.17	1382.29	51.98%	987.57	964.47	395.28%
sku31	73.89	47.24	36.40%	1.59	1.22	9.31%	sku69	1945.04	1701.11	35.73%	5109.07	4727.95	75.83%

Fuente: Elaboración propia

Tabla 13.3: Ajuste curva Weibull a nivel de SKU

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku2	853.07	592.23	40.61%	22.78	17.50	77.21%	sku33	37.00	31.26	41.48%	130.77	116.82	9.69%
sku3	4158.71	3622.49	42.10%	9824.79	6774.53	41.31%	sku34	298.77	285.48	48.36%	633.04	467.00	100.00%
sku4	2887.55	1773.46	61.01%	76.84	60.33	39.86%	sku35	431.80	356.65	46.44%	699.84	693.45	46.22%
sku5	1176.27	946.85	29.16%	1221.15	1115.39	1.04%	sku37	193.48	157.45	9.78%	1417.53	1335.28	67.05%
sku6	520.10	440.91	38.72%	948.45	942.79	277.02%	sku38	302.31	251.93	162.45%	484.80	484.41	975.33%
sku7	2659.55	1666.04	63.98%	69.75	57.98	99.96%	sku39	158.63	127.49	39.92%	268.73	265.24	35.35%
sku8	1521.99	1049.21	138.80%	197.09	196.87	255.67%	sku40	477.27	340.09	22.75%	378.59	265.57	44.91%
sku9	2300.23	1622.57	30.99%	2240.05	2058.28	75.30%	sku41	640.07	559.00	69.82%	915.08	914.79	2638.81%
sku10	59.29	44.44	18.66%	89.42	69.59	91.16%	sku43	320.79	273.56	15.72%	289.92	221.05	44.66%
sku11	333.69	247.74	119.27%	107.14	88.67	100.00%	sku44	165.36	132.81	35.89%	41.11	27.63	22.62%
sku12	2211.61	1658.41	98.05%	323.19	295.65	98.33%	sku46	1291.64	959.06	43.57%	571.06	491.45	98.88%
sku13	183.87	148.43	13.70%	80.80	58.23	24.58%	sku47	161.10	127.47	114.67%	24.05	22.78	12.63%
sku14	1177.87	796.95	48.23%	698.74	603.88	66.73%	sku48	553.09	400.47	53.12%	163.32	159.60	99.96%
sku15	490.92	421.00	33.28%	4595.40	3592.09	94.94%	sku50	297.80	249.24	53.82%	81.84	62.34	25.14%
sku16	412.89	334.13	26.66%	149.92	136.81	150.89%	sku51	1312.08	1011.47	106.39%	83.18	68.15	27.09%
sku17	654.89	431.30	85.33%	116.77	110.41	90.01%	sku53	42.96	35.26	19.46%	261.20	200.50	18.01%
sku18	437.35	405.89	30.16%	701.70	679.79	48.31%	sku54	71.57	61.80	16.79%	1387.20	985.56	65.44%
sku19	459.83	385.14	50.47%	100.82	99.91	241.73%	sku55	46.31	40.40	24.13%	1255.60	947.08	80.53%
sku20	819.68	605.99	74.08%	59.97	48.94	76.87%	sku57	1610.97	1300.18	141.05%	592.03	586.19	232.00%
sku21	331.46	288.24	48.13%	56.10	53.97	4.39%	sku59	179.14	144.95	22.05%	305.69	300.42	87.08%
sku22	2959.70	2444.73	60.38%	3837.12	3663.67	121.64%	sku60	507.09	415.70	19.20%	1859.18	1635.95	36.96%
sku23	471.80	372.97	40.55%	115.05	110.92	96.17%	sku61	80.31	58.48	67.12%	4.32	4.00	100.00%
sku24	368.93	263.11	51.97%	1726.33	1235.02	93.87%	sku62	1015.58	858.81	15.58%	22633.12	15901.20	77.96%

sku25	1104.63	803.01	30.53%	509.78	360.49	48.48%	sku63	185.32	148.59	5.65%	2352.35	1533.84	41.95%
sku26	980.46	642.05	64.79%	468.11	388.33	100.00%	sku64	1769.32	1492.76	135.87%	595.32	495.04	145.91%
sku27	657.46	319.28	109.18%	50.98	49.16	104.59%	sku65	2250.50	1524.68	134.07%	105.71	97.88	65.14%
sku28	334.13	291.96	32.07%	626.14	615.59	154.15%	sku66	126.89	74.24	93.54%	27.71	17.15	93.53%
sku29	37.15	29.06	31.94%	4.18	3.05	50.77%	sku67	2724.13	1683.65	494.66%	352.93	351.51	252.89%
sku30	304.48	227.21	25.15%	505.33	442.03	9.95%	sku68	3837.29	2609.52	84.98%	55.79	44.00	100.00%
sku31	65.54	42.01	28.47%	2.83	2.59	45.64%	sku69	1170.84	749.70	97.13%	64.44	56.46	86.86%

Fuente: Elaboración propia (*datos re-escalados)

ANEXO E: APLICACIÓN PRELIMINAR MODELO 4 POR SKU

Tabla 13.4: Análisis SKUs anómalos modelo 4

	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe		RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku2	850,15	616,65	76,35%	56,02	48,80	68,54%	sku31	146,23	65,46	44,86%	6,27	5,82	56,32%
sku3	3126,08	2160,07	29,39%	5155,99	4052,35	32,79%	sku36	278,04	208,69	124,83%	662,66	473,04	93,92%
sku4	2301,62	1726,98	95,97%	284,43	265,70	99,89%	sku37	96,88	81,02	30,02%	258,30	194,39	8,85%
sku5	392,78	302,93	39,19%	3939,48	3715,92	75,98%	sku38	508,91	419,93	30,07%	3054,16	2931,67	204,68%
sku6	379,53	253,58	25,41%	1210,51	1005,18	59,37%	sku40	366,17	314,30	11,42%	265,62	232,19	10,61%
sku7	1602,99	1262,93	144,10%	63,57	44,03	31,35%	sku41	208,95	146,35	42,85%	282,54	186,55	67,27%
sku8	663,87	504,40	130,89%	29,87	24,79	24,86%	sku43	846,75	704,15	38,09%	333,94	296,99	49,46%
sku9	1518,29	1180,81	31,62%	3648,19	2881,44	6,87%	sku44	178,90	148,27	68,84%	55,92	45,14	183,63%
sku11	326,54	231,94	83,53%	102,03	91,40	96,21%	sku46	273,11	213,34	25,01%	129,88	126,41	88,81%
sku12	1111,99	571,15	30,69%	419,86	410,61	96,46%	sku47	103,71	86,55	19,16%	700,13	553,76	85,46%
sku14	876,69	605,17	49,77%	432,55	418,49	9,11%	sku48	1290,40	628,23	40,75%	221,21	195,31	87,58%
sku15	355,42	292,19	31,14%	866,49	862,77	71,58%	sku50	34,53	30,89	19,05%	677,46	642,39	65,06%
sku16	497,59	387,70	25,46%	113,35	111,19	35,71%	sku51	77,39	49,15	58,70%	54,58	52,66	10,31%
sku17	274,27	189,54	63,89%	22,34	16,19	26,30%	sku53	1233,01	819,95	60,07%	226,24	139,00	34,59%
sku18	739,12	555,07	70,45%	610,15	549,28	22,92%	sku54	126,14	109,23	26,39%	110,96	106,96	28,60%
sku19	346,06	284,42	40,94%	153,59	126,36	2,22%	sku55	374,80	278,05	16,15%	3256,57	3041,67	64,99%
sku20	712,44	591,37	77,21%	154,46	115,68	35,62%	sku60	1325,97	1164,96	75,61%	736,74	713,15	42,55%
sku21	449,96	268,51	50,10%	416,11	349,99	62,64%	sku61	1645,21	1296,72	142,18%	369,31	330,54	105,05%
sku22	2137,50	1722,15	41,94%	4669,18	4422,91	50,92%	sku62	59,18	45,23	95,18%	5,72	5,57	15,95%
sku23	260,21	210,08	20,41%	411,16	392,65	86,74%	sku63	2298,93	1534,27	171,91%	45,77	40,32	40,87%
sku24	354,85	277,83	41,27%	38,82	26,88	27,06%	sku64	4088,29	2651,63	61,21%	24,93	24,91	66,72%
sku25	957,95	839,35	28,45%	293,69	192,50	23,52%	sku65	575,11	481,70	49,75%	44,89	36,32	53,53%
sku26	1124,18	906,00	52,37%	109,21	106,52	9,43%	sku66	2574,03	2001,88	28,63%	1121,58	976,95	10,91%
sku27	72,77	55,11	28,15%	29,19	22,93	80,92%	sku67	1468,46	1153,49	31,14%	1656,58	1643,34	3,52%
sku28	186,34	166,25	20,70%	216,33	203,25	0,94%	sku68	1279,48	1006,59	39,19%	1607,79	1487,33	59,86%
sku30	190,40	158,81	44,78%	181,36	171,94	17,94%							

Fuente: Elaboración propia

ANEXO F: AJUSTE POR SKU CASO PRÁCTICO

Tabla 13.5: Ajustes por SKU, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku1	1322,81	782,86	14,85%	925,91	744,64	16,02%	sku41	187,58	132,48	38,39%	64,29	59,68	69,39%
sku2	801,46	527,58	133,63%	21,85	15,54	40,92%	sku43	867,94	695,26	44,49%	461,48	380,28	76,52%
sku3	3479,67	2628,80	31,90%	8839,97	8327,93	50,78%	sku44	171,34	128,92	127,33%	26,17	24,25	57,63%
sku4	2278,77	1712,08	106,48%	139,35	90,18	59,59%	sku45	437,91	222,89	92,50%	3867,60	2990,23	48,60%
sku5	1097,50	899,78	41,89%	736,21	718,29	7,54%	sku46	282,87	238,85	41,93%	161,71	158,13	99,04%
sku6	501,21	400,08	35,35%	1210,91	991,50	291,33%	sku47	285,26	217,46	42,78%	45,06	39,35	21,16%
sku9	2006,37	1611,12	38,20%	5828,81	4722,07	172,76%	sku48	1217,59	605,60	47,39%	189,65	182,64	89,82%
sku10	37,85	29,55	21,16%	70,72	47,81	54,27%	sku49	37,25	32,48	14,58%	277,46	199,72	36,70%
sku12	1000,33	583,85	38,16%	324,59	297,05	98,80%	sku50	110,49	95,10	57,41%	1378,54	1044,15	69,33%
sku13	213,44	183,81	19,95%	114,51	109,82	64,47%	sku51	68,36	49,42	44,45%	1156,54	887,54	75,47%
sku14	919,79	680,04	106,23%	1283,33	1177,03	130,06%	sku52	95,79	88,37	16,55%	1136,73	933,48	122,99%
sku15	369,98	320,21	31,17%	4500,13	3503,13	92,59%	sku53	1264,30	780,24	58,06%	153,54	118,22	46,79%
sku16	399,44	300,52	20,69%	32,77	22,32	24,29%	sku54	122,72	107,42	27,63%	236,98	232,71	67,45%

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku17	315,81	213,66	71,42%	106,62	97,47	79,46%	sku55	427,57	319,14	14,63%	1662,65	1418,11	7,15%
sku18	604,28	406,57	46,94%	383,38	346,70	1,61%	sku56	81,92	57,43	54,89%	4,27	3,94	98,56%
sku19	375,58	316,58	51,13%	155,21	149,49	361,66%	sku57	1134,00	1000,10	17,42%	22423,69	16518,04	80,98%
sku20	629,76	474,46	77,05%	45,91	31,77	49,91%	sku58	406,09	335,59	17,07%	6192,53	4469,55	66,61%
sku21	478,52	308,28	60,61%	34,08	33,37	25,54%	sku59	345,15	242,50	69,37%	700,50	630,30	22,80%
sku22	2383,97	1915,30	42,48%	2961,57	1934,94	54,61%	sku60	1253,33	1103,43	87,70%	403,72	369,40	116,28%
sku23	286,37	235,26	31,11%	110,18	105,97	91,88%	sku61	1595,46	1241,52	182,73%	281,26	272,37	253,76%
sku24	319,76	234,48	42,52%	1719,74	1220,20	92,74%	sku62	50,52	34,96	82,90%	26,93	15,95	87,02%
sku25	884,47	752,40	30,64%	486,44	376,06	59,47%	sku63	2155,25	1394,87	180,72%	99,92	97,96	70,48%
sku26	927,18	626,28	56,99%	467,90	387,62	99,82%	sku64	3892,48	2401,86	64,53%	53,73	41,89	95,21%
sku27	70,72	53,66	31,64%	48,94	46,17	98,24%	sku65	448,29	348,26	43,83%	70,65	64,08	98,59%
sku28	197,58	182,53	20,75%	351,54	323,81	81,09%	sku66	2696,98	2042,99	33,39%	830,40	721,73	54,40%
sku30	183,03	151,30	42,24%	676,82	529,73	64,26%	sku67	1775,04	1318,93	25,21%	5698,34	4832,30	27,69%
sku31	129,29	53,06	45,80%	1,19	1,14	6,19%	sku68	1305,66	1073,07	40,99%	43,49	28,80	8,65%
sku33	246,43	238,64	39,47%	632,00	462,94	99,13%	sku69	2382,64	1555,83	60,46%	1715,15	1319,13	8,37%
sku35	297,90	223,67	31,50%	949,53	919,95	46,20%	sku70	196,14	139,83	27,66%	317,68	290,39	30,12%
sku37	124,46	91,26	20,31%	821,71	482,22	64,24%	sku71	191,18	88,65	33,36%	220,01	184,16	90,87%
sku38	441,38	327,20	23,78%	238,10	157,97	27,28%	sku72	2911,04	2148,04	57,15%	9923,08	7821,56	58,22%
sku40	328,61	266,89	14,11%	277,86	254,79	51,47%	sku73	143,75	138,10	15,40%	2080,71	1520,13	41,89%

Fuente: Elaboración propia

Tabla 13.6: Ajustes por SKU, segmentación 2

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe	ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku1	1392,32	1114,14	23,86%	328,29	298,11	5,07%	sku41	242,94	145,47	45,62%	78,06	73,80	85,82%
sku2	784,18	522,17	155,10%	26,57	16,93	74,70%	sku43	914,55	703,47	37,27%	558,14	477,99	96,17%
sku3	3700,40	2479,21	27,28%	14822,86	13478,61	82,19%	sku44	219,75	172,84	156,56%	20,40	20,39	23,28%
sku4	2227,03	1608,66	91,60%	90,52	71,22	18,07%	sku45	455,54	244,52	96,39%	2372,05	1732,26	28,15%
sku5	1095,71	818,75	45,88%	1002,15	890,95	25,08%	sku46	232,17	179,83	39,36%	153,89	150,79	94,44%
sku6	495,25	395,54	33,22%	1410,63	1154,41	339,20%	sku47	282,24	214,13	40,26%	28,13	25,49	10,01%
sku9	2290,97	1752,36	27,44%	4255,42	3694,14	135,15%	sku48	1464,26	687,41	48,69%	182,12	175,49	86,31%
sku10	55,34	41,77	15,30%	81,28	58,67	76,86%	sku49	55,23	42,20	16,71%	336,17	236,57	47,00%
sku12	1113,91	739,74	59,05%	293,77	266,46	88,62%	sku50	105,08	87,10	54,92%	1399,65	1049,78	69,71%
sku13	336,74	269,02	37,36%	134,83	128,89	75,67%	sku51	68,30	49,41	44,44%	1150,57	874,97	74,40%
sku14	998,89	810,47	110,66%	1191,69	1121,48	123,92%	sku52	159,03	135,62	26,06%	383,00	304,58	12,42%
sku15	389,35	326,50	30,71%	4455,83	3436,16	90,82%	sku53	1068,63	841,00	65,88%	137,52	123,02	14,72%
sku16	505,75	362,55	32,25%	141,51	139,93	154,33%	sku54	127,10	91,80	17,60%	214,49	210,07	60,89%
sku17	291,00	183,32	55,60%	115,13	107,29	87,47%	sku55	464,90	310,96	14,67%	1984,52	1640,82	13,57%
sku18	837,40	498,30	65,47%	425,26	300,90	17,90%	sku56	76,44	45,56	44,89%	4,23	3,90	97,60%
sku19	332,86	269,79	47,67%	124,24	120,20	290,80%	sku57	1131,18	939,84	15,79%	22012,33	16785,79	82,30%
sku20	670,21	528,83	71,07%	50,32	37,64	59,12%	sku58	400,31	330,98	15,84%	5971,51	4556,03	67,90%
sku21	487,02	295,08	61,94%	54,78	49,33	37,75%	sku59	262,70	212,92	51,76%	758,29	557,25	20,16%
sku22	2091,24	1729,90	37,32%	2236,66	1384,16	45,95%	sku60	1402,23	1198,82	113,14%	495,47	452,33	142,39%
sku23	303,66	244,14	31,03%	107,12	103,00	89,30%	sku61	1671,42	1302,52	196,17%	257,36	256,32	238,81%
sku24	360,87	268,11	62,59%	1693,80	1181,54	89,81%	sku62	47,35	33,65	52,81%	28,56	17,96	97,98%
sku25	943,95	824,10	35,56%	471,64	352,59	55,76%	sku63	2506,79	1604,38	157,26%	101,48	99,62	71,67%
sku26	2286,88	1979,35	592,44%	2246,90	2088,52	537,82%	sku64	3381,14	1573,76	232,65%	134,07	124,86	283,76%
sku27	70,03	52,68	32,78%	48,91	46,14	98,17%	sku65	633,11	522,41	104,39%	53,74	46,58	71,66%
sku28	193,46	163,27	17,24%	290,89	263,71	66,04%	sku66	2907,33	2280,89	40,26%	922,76	861,92	44,49%
sku30	202,67	170,68	42,80%	707,84	566,09	68,67%	sku67	1303,46	1131,95	25,40%	5208,40	3919,04	22,46%
sku31	131,26	52,93	45,62%	1,00	0,98	6,85%	sku68	1230,76	973,39	39,59%	513,97	460,26	188,63%
sku33	241,73	233,67	37,18%	631,70	462,18	98,97%	sku69	2363,23	1915,18	55,50%	3063,63	2824,33	45,30%
sku35	451,99	362,69	49,29%	234,63	191,17	8,08%	sku70	204,41	146,84	29,07%	240,52	190,73	18,51%
sku37	126,36	100,33	25,74%	635,58	446,57	57,38%	sku71	142,93	78,52	31,13%	221,91	185,84	91,70%
sku38	452,01	306,32	22,05%	257,63	188,25	27,67%	sku72	2475,32	1751,16	47,79%	10549,51	7727,53	57,52%
sku40	488,10	305,92	20,37%	98,07	85,92	5,68%	sku73	348,84	244,50	43,86%	407,45	317,63	10,66%

Fuente: Elaboración propia

ANEXO G: ESTIMACIÓN VENTAS MENSUALES POR SKU

Tabla 13.7: Estimación ventas mensuales por SKU y predicción Oct/2007-Dic/2007

ID	sku1	sku2	sku3	sku4	sku5	sku6	sku9	sku10	sku12	sku13	sku14	sku15	sku16	sku17	sku18	sku19	
Jun-2005									6907							629	
Jul-2005									7458							720	
Ago-2005				4.696					5339					1171		750	
Sep-2005				5.380					5302					1414		838	
Oct-2005				6.038					5045					1712		925	
Nov-2005				3.527					3106					1676		829	
Dic-2005				15.136					10775					4330		2120	
Ene-2006				7.247					7585					2098		1812	
Feb-2006		3564		6.367					8241					1460		1944	
Mar-2006		5009	12622	7.226					8978					2840		1968	
Abr-2006		5024	12823	6.825					9108		1794		2398	3087		2158	
May-2006		4599	15950	6.281					7068		1977		2921	2682		2094	
Jun-2006		4032	17704	5.645			1121		5395		2151		3096	2240		1987	
Jul-2006		3400	17454	4.965			1136		4063		2305		3170	1810		1843	
Ago-2006		2071	9744	4.284			1149	791	1937		2426		2783	1281		1490	
Sep-2006		1635	5287	3.637			1162	933	1420		2503	126	2640	980		1319	
Oct-2006		1261	4941	3.045			1174	1363	1033		2524	238	2416	736		1143	
Nov-2006		657	5470	1.428			641	1526	522		2577	263	2127	482		754	
Dic-2006		1508	13599	4.331			2546	9061	967		5827	1013	3949	721		1613	
Ene-2007		413	5994	1.418			1172	6261	97	300		3579	1211	1208	195	684	
Feb-2007		454	7490	1.027	1.401	1040	10063	581	451		2842	1642	808	143	2680	1178	
Mar-2007		443	8905	978	2.017	1220	15959	740	446	1197	3230	2444	1266	208	2599	968	
Abr-2007		323	16751	781	3.320	1224	19021	751	321	1459	2737	2581	1330	149	2479	788	
May-2007		235	14854	623	4.154	1228	21005	605	231	1568	2242	2384	1038	107	2325	635	
Jun-2007	3103	170	13052	495	4.672	1230	21307	400	166	1476	1777	1919	801	76	2145	507	
Jul-2007	3423	123	11370	393	4.644	1231	19807	231	119	1225	1948	1363	611	54	1947	401	
Ago-2007	3771	89	9826	311	5.525	1231	16955	123	85	914	1465	874	463	38	1741	314	
Sep-2007	2641	64	3710	246	3.161	1229	10251	62	60	630	3347	936	348	27	1534	244	
Oct-2007	2880	46	3114	194	2.233	1227	7657	31	43	411	2468	534	260	19	1333	188	
Nov-2007	2024	23	1767	88	929	664	3800	10	21	155	1424	243	171	11	684	112	
Dic-2007	7965	50	3881	254	1459	2594	7826	12	39	331	2187	264	261	16	1448	185	
ID	sku20	sku21	sku22	sku23	sku24	sku25	sku26	sku27	sku28	sku30	sku31	sku33	sku35	sku37	sku38	sku40	
Ene-2006								257				432					
Feb-2006	2086					5542		626				428					
Mar-2006	2774	2283	4737			7515		980				627					
Abr-2006	3541	2067	8817	520	1710	7584		1131				717					
May-2006	4283	1863	8944	910	1786	7427		1183				807					
Jun-2006	4848	1671	9049	1428	1802	7054		1107				891					
Jul-2006	5081	1492	9131	2115	1752	6498		923				960	662				
Ago-2006	4899	1208	4801	2647	1643	5813		692			1007	475					
Sep-2006	4346	1065	2755	3188	1487	5058		474	436	1023	339						
Oct-2006	3567	935	2706	3322	1303	4290		303	491	1002	241					183	
Nov-2006	2154	496	2418	1824	973	2434		150	630	737	138				93	213	
Dic-2006	3389	1331	5924	3878	1718	5202		181	1607	1536	209				182	923	
Ene-2007	1423	636	4926	2012	700	1855	1002	71	1251	1675	122				125	1302	2726
Feb-2007	1189	793	6246	1406	471	2219	1035	115	1058	2054	98				243	1994	2004
Mar-2007	787	690	6108	839	732	2349	1312	90	1269	2180	93	118	1292	280	2594	3730	
Abr-2007	513	597	5950	483	570	1818	2741	51	1119	1695	66	621	1476	318	2989	3458	
May-2007	359	513	8390	272	438	1395	2655	28	939	1268	46	2025	1966	679	3187	2960	
Jun-2007	230	438	8157	210	334	1062	2569	16	751	1618	32	2788	2097	762	2758	2360	
Jul-2007	146	371	7898	118	253	803	2484	9	1588	1150	22	1312	2145	843	2095	1774	
Ago-2007	93	311	7614	65	190	603	2399	5	1203	795	15	319	2101	917	1434	1273	
Sep-2007	58	258	4893	36	142	451	2315	3	1153	534	10	63	1968	979	911	882	
Oct-2007	36	211	4640	20	105	336	2231	1	828	350	7	12	1768	1023	550	595	
Nov-2007	18	103	2558	7	116	173	1435	1	470	181	4	2	1341	967	260	352	
Dic-2007	24	226	5990	10	180	331	3764	1	691	243	5	1	2382	1553	309	454	
ID	sku41	sku43	sku44	sku45	sku46	sku47	sku48	sku49	sku50	sku51	sku52	sku53	sku54	sku55	sku56	sku57	
Abr-2005							11133					9304					
May-2005							6291					4940					
Jun-2005							6427					4964					
Jul-2005							6318					4905					
Ago-2005							2604					4517					
Sep-2005							2336					4310					
Oct-2005		1812					2016					4043					
Nov-2005		1287					2726					2479					
Dic-2005		7941					5870					7499					
Ene-2006		5509					5003					5112					
Feb-2006		5917					4447					4486					
Mar-2006		7986					4657					5132					

ID	m	p	q	b	ID	m	p	q	b
sku12	113047	0.059	0.238	3.331	sku50	8383	0.020	0.568	1.706
sku13	3789	0.091	0.413	3.331	sku51	25020	0.009	0.057	1.706
sku14	104829	0.014	0.213	3.331	sku52	17875	0.016	0.438	1.706
sku15	16880	0.007	0.543	3.331	sku53	201781	0.074	0.126	1.706
sku16	35952	0.037	0.354	3.331	sku54	8835	0.019	0.383	1.706
sku17	25138	0.053	0.222	1.953	sku55	51065	0.007	0.340	1.706
sku18	32295	0.082	0.103	1.953	sku56	3090	0.000	1.000	2.321
sku19	28453	0.020	0.192	1.953	sku57	57015	0.052	0.404	1.706
sku20	55002	0.035	0.378	1.953	sku58	17814	0.035	0.533	1.706
sku21	23198	0.094	0.085	1.953	sku59	37392	0.024	0.268	0.878
sku22	509414	0.009	0.065	2.543	sku60	67886	0.031	0.225	0.878
sku23	27341	0.010	0.649	2.543	sku61	101055	0.036	0.171	0.878
sku24	19483	0.074	0.264	2.543	sku62	3392	0.130	0.426	0.878
sku25	105622	0.069	0.154	2.543	sku63	235840	0.098	0.127	0.878
sku26	10739	0.004	1.675	2.543	sku64	87790	0.002	0.543	0.878
sku27	6425	0.042	0.432	3.522	sku65	90956	0.007	0.856	2.870
sku28	12990	0.039	0.227	3.522	sku66	173817	0.006	0.180	2.870
sku30	42483	0.010	0.257	3.522	sku67	229203	0.010	0.063	2.870
sku31	3018	0.244		3.522	sku68	57026	0.013	0.298	2.870
sku33	4791	0.006	1.651	3.522	sku69	163540	0.047	0.011	2.870
sku35	15299	0.060	0.287	3.522	sku70	23539	0.033	0.077	2.321
sku37	1362020	0.000	0.156	3.522	sku71	2947	0.282		2.321
sku38	16145	0.013	0.517	1.545	sku72	114264	0.069	0.144	2.870
sku40	23598	0.068	0.505	1.545	sku73	35361	0.014	0.506	2.870

Fuente: Elaboración propia


Tabla 13.9: Parámetros por SKU, segmentación 2

ID	m	p	q	b	ID	m	p	q	b
sku1	1092057	0.003	0.118	1.102	sku41	7959	0.146	0.276	2.811
sku2	35845	0.126	0.183	1.102	sku43	83208	0.018	0.388	0.001
sku3	286386	0.043	0.107	2.898	sku44	6301	0.073	0.274	1.071
sku4	103235	0.042	0.196	0.001	sku45	43009	0.024	0.345	1.071
sku5	34549	0.032	0.478	2.811	sku46	16446	0.024	0.599	0.795
sku6	72556	0.015	0.029	0.001	sku47	6687	0.025	0.345	1.270
sku9	145587	0.004	0.416	1.102	sku48	147587	0.071	0.208	2.898
sku10	1186	0.075	0.628	2.811	sku49	3566	0.029	0.331	2.915
sku12	92232	0.070	0.219	2.898	sku50	8937	0.018	0.596	2.915
sku13	9532	0.109	0.414	0.001	sku51	168525	0.001	0.067	2.915
sku14	102848	0.016	0.215	4.417	sku52	7306	0.043	0.511	1.665
sku15	15270	0.006	0.516	4.417	sku53	153997	0.059	0.122	1.102
sku16	35116	0.064	0.204	1.071	sku54	5617	0.019	0.352	4.417
sku17	28277	0.037	0.273	1.071	sku55	73044	0.004	0.328	4.417
sku18	34530	0.077	0.101	2.811	sku56	2393	0.001	0.955	2.915
sku19	33475	0.017	0.187	1.270	sku57	59935	0.047	0.444	1.665
sku20	54330	0.032	0.377	1.270	sku58	18361	0.031	0.588	1.665
sku21	26580	0.089	0.018	0.795	sku59	7364496	0.000	0.226	2.811
sku22	383330	0.012	0.061	2.811	sku60	62205	0.034	0.186	0.001
sku23	27811	0.014	0.547	0.795	sku61	105434	0.038	0.177	1.071
sku24	19588	0.083	0.184	1.071	sku62	3412	0.078	0.667	0.795
sku25	96328	0.073	0.170	2.898	sku63	255846	0.115	0.132	1.102
sku26	6011322	0.000		2.898	sku64	56473	0.062	0.156	2.898
sku27	5819	0.043	0.433	4.417	sku65	43960	0.030	0.534	1.102
sku28	11069	0.035	0.270	4.417	sku66	165570	0.009	0.186	1.665
sku30	44307	0.010	0.267	4.417	sku67	150662	0.018	0.125	1.665
sku31	3123	0.238		4.417	sku68	62588	0.018	0.245	1.665
sku33	6760	0.007	1.644	0.795	sku69	67502	0.078	0.390	0.001
sku35	21851	0.054	0.241	1.071	sku70	20766	0.039	0.064	2.915
sku37	11202	0.008	0.211	2.915	sku71	2618	0.169	0.203	1.270
sku38	17164	0.008	0.539	1.270	sku72	95331	0.075	0.180	2.811
sku40	25529	0.137	0.273	1.071	sku73	29171	0.033	0.280	0.795

Fuente: Elaboración propia


ANEXO I: ANÁLISIS DE SENSIBILIDAD ELASTICIDADES PRECIO PROPIO

Figura 13.29: Sensibilidad precio grupo 1




Fuente: Elaboración propia

Figura 13.30: Sensibilidad precio grupo 2




Fuente: Elaboración propia

Figura 13.31: Sensibilidad precio grupo 3




Fuente: Elaboración propia

Figura 13.32: Sensibilidad precio grupo 4




Fuente: Elaboración propia

Figura 13.33: Sensibilidad precio grupo 5




Fuente: Elaboración propia

Figura 13.34: Sensibilidad precio grupo 6




Fuente: Elaboración propia

Figura 13.35: Sensibilidad precio grupo 7




Fuente: Elaboración propia

Figura 13.36: Sensibilidad precio grupo 8




Fuente: Elaboración propia

Figura 13.37: Sensibilidad precio grupo 9



Fuente: Elaboración propia


Figura 13.38: Sensibilidad precio grupo 10



Fuente: Elaboración propia


ANEXO J: ANÁLISIS DE SENSIBILIDAD ESTACIONALIDAD

Figura 13.39: Sensibilidad estacional grupo 1




Fuente: Elaboración propia

Figura 13.40: Sensibilidad estacional grupo 2




Fuente: Elaboración propia

Figura 13.41: Sensibilidad estacional grupo 3




Fuente: Elaboración propia

Figura 13.42: Sensibilidad estacional grupo 4




Fuente: Elaboración propia

Figura 13.43: Sensibilidad estacional grupo 5




Fuente: Elaboración propia

Figura 13.44: Sensibilidad estacional grupo 6




Fuente: Elaboración propia

Figura 13.45: Sensibilidad estacional grupo 7




Fuente: Elaboración propia

Figura 13.46: Sensibilidad estacional grupo 8




Fuente: Elaboración propia

Figura 13.47: Sensibilidad estacional grupo 9 Figura 13.48: Sensibilidad estacional grupo 10



Fuente: Elaboración propia



Fuente: Elaboración propia

ANEXO K: AJUSTE SKUS “IMPORTANTES” POR PERIODO DE CALIBRACIÓN

Tabla 13.10: Ajuste SKUs “importantes”, periodo de calibración T-4, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku1	1322,51	812,18	14,77%	636,15	447,56	9,29%
sku3	3292,33	2440,99	31,56%	6178,55	6175,24	49,89%
sku5	1003,98	719,10	46,55%	2121,11	1903,74	102,76%
sku6	492,98	400,90	34,92%	634,43	619,06	127,82%
sku9	1397,89	1134,31	26,78%	3700,11	2464,39	31,88%
sku14	895,42	652,19	109,04%	2352,83	2348,15	150,97%
sku18	552,67	434,98	46,79%	752,22	740,88	48,44%
sku22	2236,57	1804,07	40,59%	2927,45	2221,13	43,32%
sku28	190,29	169,27	22,39%	594,91	565,25	105,00%
sku35	590,93	532,00	38,63%	2226,45	2196,04	126,74%
sku38	456,68	352,25	25,37%	53,20	45,70	5,20%
sku45	530,30	329,10	125,64%	1290,20	973,03	27,60%
sku55	447,50	329,67	15,67%	1001,67	801,75	18,60%
sku57	2023,66	1736,93	36,09%	4017,47	3261,93	37,00%
sku58	216,30	187,90	13,23%	926,32	849,53	5,61%
sku59	323,70	219,25	71,45%	1308,78	1241,94	72,91%
sku66	2574,16	1996,98	31,08%	1029,50	1024,29	75,22%
sku67	1842,94	1416,00	28,05%	5495,69	4532,36	36,14%
sku68	1349,80	1120,79	41,27%	354,41	252,53	50,88%
sku69	2384,80	1639,85	63,36%	1562,44	1082,60	14,91%
sku72	2373,85	2366,07	53,67%	4663,11	4481,91	61,23%
sku73	263,71	198,78	39,22%	572,77	396,85	21,42%

Fuente: Elaboración propia

Tabla 13.11: Ajuste SKUs "importantes", periodo de calibración T-5, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku1	1369,62	1234,39	24,57%	1085,72	988,88	27,76%
sku3	3326,31	2325,09	31,52%	6119,32	5912,19	43,66%
sku5	1222,58	923,86	74,92%	2986,67	2414,52	75,13%
sku6	499,52	376,60	33,08%	550,60	535,47	8,89%
sku9	1420,84	1122,77	26,66%	4255,50	3355,56	29,31%
sku14	909,70	662,97	113,78%	1679,62	1488,65	56,89%
sku15	351,00	295,91	31,59%	1077,11	991,41	74,28%
sku18	530,66	417,43	46,37%	799,09	778,07	47,45%
sku22	2126,33	1728,73	40,71%	4382,60	4139,01	54,36%
sku28	189,14	170,88	21,96%	467,48	404,61	35,97%
sku35	597,40	451,76	35,62%	3608,53	3432,63	185,31%
sku38	475,22	381,92	27,70%	110,91	94,87	9,93%
sku40	415,56	324,83	13,62%	507,32	413,93	49,61%
sku45	683,81	484,54	184,97%	629,35	578,05	18,76%
sku55	461,31	357,56	16,67%	807,51	533,63	8,43%
sku57	1314,15	1098,87	21,09%	3155,42	2622,16	34,84%
sku58	567,48	443,53	55,70%	1048,71	909,95	30,82%
sku59	339,67	270,04	66,98%	1196,11	1076,21	51,04%
sku60	1287,46	1100,98	73,20%	978,62	974,56	359,62%
sku66	2545,90	1983,60	28,93%	1073,82	984,50	38,34%
sku67	1674,47	1324,68	31,88%	3223,25	3209,69	25,64%
sku68	1296,11	1058,44	39,82%	1291,49	987,46	65,25%
sku69	2527,76	1778,32	73,26%	1051,21	1049,75	5,75%

Fuente: Elaboración propia

Tabla 13.12: Ajuste SKUs "importantes", periodo de calibración T-6, segmentación 1

ID	RMSE	MAD	MAPE	RMSEe	MADe	MAPEe
sku3	3411,60	2418,40	33,04%	5331,11	4387,79	35,51%
sku5	823,28	607,31	81,41%	2708,71	2275,34	46,53%
sku9	1463,92	1152,74	30,22%	3817,52	2783,52	12,33%
sku13	640,28	575,45	51,13%	3682,56	3642,07	448,16%
sku14	927,79	685,09	119,60%	1842,70	1295,59	54,63%
sku15	322,94	264,43	33,55%	817,09	812,25	67,39%
sku18	665,03	546,88	62,63%	935,35	928,76	56,16%
sku22	2109,41	1705,57	41,34%	5144,09	4924,70	56,69%
sku30	189,02	154,50	45,37%	199,01	189,40	19,76%
sku33	84,61	82,20	9,84%	6053,73	5902,44	963,40%
sku35	230,21	181,36	33,07%	2154,18	2023,59	109,60%
sku38	488,34	403,54	30,10%	358,06	357,60	24,97%
sku40	415,08	318,22	12,32%	604,17	546,71	44,38%
sku45	670,78	563,18	223,04%	573,68	571,37	22,43%
sku55	399,62	275,01	14,77%	2169,16	2079,22	44,43%
sku57	1721,93	1669,81	38,49%	1871,96	1297,86	14,56%
sku58	299,95	259,79	34,80%	400,65	323,81	4,39%
sku59	272,39	235,66	70,03%	937,65	919,18	38,82%
sku60	1320,13	1152,74	75,70%	785,68	744,22	50,28%
sku66	2470,28	1947,47	28,58%	1228,58	1080,02	8,33%
sku67	1606,99	1240,95	32,54%	1757,98	1748,85	5,22%
sku68	1272,56	998,83	38,27%	1707,64	1588,58	63,94%
sku69	2775,23	2076,52	88,36%	1005,01	939,11	0,00%

Fuente: Elaboración propia