



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

PRONÓSTICO DE DEMANDA DESAGREGADO PARA UNA EMPRESA DE PRODUCTOS DE CONSUMO MASIVO

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL INDUSTRIAL

BEATRIZ ISABEL ZAVALA HEPP

PROFESOR GUÍA:
LUIS ABURTO LAFOURCADE

MIEMBROS DE LA COMISIÓN:
RICARDO SAN MARTÍN ZURITA
MANUEL REYES JARA

SANTIAGO DE CHILE

2015

**RESUMEN DE LA MEMORIA PARA OPTAR AL
TÍTULO DE INGENIERO CIVIL INDUSTRIAL
POR: BEATRIZ ZAVALA HEPP
FECHA: OCTUBRE 2015
PROFESOR GUÍA: LUIS ABURTO LAFOURCADE**

**PRONÓSTICO DE DEMANDA A NIVEL DESAGREGADO PARA UNA
EMPRESA DE PRODUCTOS DE CONSUMO MASIVO**

Un problema crítico al que se ven enfrentadas las empresas en la actualidad es mejorar el nivel de servicio entregado a sus clientes, ya que en mercados altamente competitivos este puede ser un factor diferenciador. Luego, es crucial contar con una estrategia óptima de gestión de inventario que permita satisfacer la demanda al mínimo costo. En este contexto, uno de los desafíos es contar con un adecuado sistema de pronóstico de demanda.

El presente trabajo se desarrollará en una empresa proveedora de productos de consumo masivo, en particular, aceites, pastas galletas y otros. Es la segunda empresa de consumo masivo más grande en la región Andina, con exportaciones a Estados Unidos y a toda Latinoamérica.

La empresa en cuestión cuenta con más de 1000 SKU's pertenecientes a distintas categorías y 41 centros propios de distribución, por lo que existe una gran cantidad de demandas distintas a nivel distribuidor-SKU. Dada la complejidad de realizar esta cantidad de pronósticos, la empresa ha optado por un sistema simple de estimación de demanda, que consiste en calcular la media móvil de las ventas de los últimos 6 meses a nivel de categoría y repartir esta estimación según la participación de cada SKU dentro de la categoría. El problema de esta estimación es que no considera estacionalidad ni otros factores externos que pudieran ayudar a precisar el modelo.

El propósito de esta memoria consiste en estimar la demanda a nivel SKU-distribuidor de los productos pertenecientes a la categoría más importante para la empresa (Aceites), creando una metodología que permita realizar estimaciones de grandes volúmenes de series de tiempo al mismo tiempo que utilice de manera inteligente la información contenida en la data transaccional utilizando técnicas de minería de datos.

Se propone la utilización de modelos ARIMA para estimar el volumen de ventas de cada distribuidor. Luego, para desagregar a nivel de SKU, se modelan las participaciones de mercado utilizando regresiones y modelos de media móvil. El beneficio del modelo anterior es que permite comprender el mercado, ya que introduce variables dependientes tales como presencia de feriados y fechas especiales, además de la detección de estacionalidad. Utilizando ARIMA se logró disminuir el WMAPE desde un 17% a un 12%, con una reducción de error de 34% en promedio y un incremento de 44 puntos porcentuales en la varianza explicada. Al desagregar a nivel de SKU, se logra una reducción de 38% del error a nivel global. El beneficio económico obtenido al contar con un pronóstico más preciso es una reducción del 42% de los costos actuales.

TABLA DE CONTENIDO

I.	ANTECEDENTES GENERALES	1
	I.I La Empresa.....	1
	I.II Canales de Distribución	1
II.	DESCRIPCIÓN DEL PROYECTO Y JUSTIFICACIÓN	4
III.	OBJETIVOS	5
	III.I Objetivo General	5
	III.II Objetivos Específicos	5
IV.	ALCANCES	6
V.	RESULTADOS ESPERADOS	6
	MARCO TEÓRICO	7
	VI.I Series de Tiempo.....	8
	VI.I.I Modelos ARIMA(p,d,q)	9
	VI.II Procedimiento de Modelación Según Box Jenkins	10
	VI.III Medidas de Error	12
VI.	DESARROLLO METODOLÓGICO	12
	VII.I Selección de la Categoría de Estudio.....	14
	VII.II Análisis Preliminar y Estadístico de Datos	15
	VII.II.I Análisis para un SKU y DEX Particular.....	18
	VII.II.II Análisis de Correlogramas.....	21
	VII.III Sistema de Pronóstico Actual	23
	VII.IV Limpieza de Datos.....	24
	VII.IV.I Detección de Outliers.....	25
	VII.V Pre-procesamiento de Datos	27
	VII.VI Descripción del Modelo de Pronóstico	27
	VII.VI.I Inclusión de la Venta de Otros DEX como Variables Explicativas	31
	VII.VI.II Desagregación a Nivel de SKU	33
VII.	RESULTADOS	34
	VIII.I Valorización Económica.....	35
VIII.	CONCLUSIONES	36
	IX.I Limitaciones.....	36
	IX.II Verificación de Cumplimiento de Objetivos	36
	IX.III Trabajo Futuro.....	37

IX.	BIBLIOGRAFÍA.....	38
X.	ANEXOS	40
	Anexo 1. Análisis Estadístico de las DEX.....	40
	Anexo 2. SKU's Seleccionados	41
	Anexo 3. Análisis Estadístico de SKU's	41
	Anexo 4. Coef. De Variación: Shares y Precios	41
	Anexo 5: Método de estimación de demanda a nivel de SKU	42
	Anexo 5.1. Aplicación Modelo de Atributos	48
	Anexo 6. Autocorrelación (ACF) y Autocorrelación Parcial (ACF parcial) por DEX.....	51
	Anexo 7. Parámetros de Modelos ARIMA	63
	Anexo 8. Métricas de Comparación Modelos ARIMA versus Actual	70
	Anexo 9. Nivel de Reducción del Error en Pronóstico de Shares	71
	Anexo 10. WMAPE Final Modelo Alicorp	72
	Anexo 11. WMAPE Final Modelo Propuesto	72
	Anexo 12. Porcentaje Reducción de Error Modelos Propuestos vs Alicorp	73
	Anexo 13. Evaluación Económica Modelo Propuesto versus Actual	73

I. ANTECEDENTES GENERALES

I.I La Empresa

Alicorp S.A es una empresa peruana cuya actividad económica consiste en la fabricación y distribución de productos de consumo masivo (aceites y grasas comestibles, fideos, harinas, galletas, jabones, detergentes, salsas, refrescos instantáneos, y productos de cuidado personal), productos industriales y nutrición animal. Cuenta con 120, 31 y 2 marcas en cada línea de negocio, respectivamente. Fue constituida el 16 de julio de 1956 e inició operaciones en agosto del mismo año en Callao, Perú.

6.800 colaboradores hacen que sea la segunda empresa de consumo masivo más grande en la región Andina, líder en todas las categorías dentro de Perú. Posee un portafolio de productos diversificado (23 categorías) con presencia en los segmentos de consumidores más importantes y en todos los niveles socioeconómicos.

Cuenta con operaciones en Argentina, Colombia, Ecuador y Chile, y con exportaciones a más de 23 países, incluyendo Estados Unidos y todo Latinoamérica. En 2013 las ventas fueron del orden de US\$1.997 millones, con un crecimiento en ventas de 30.1% con respecto al año anterior. El 67% de estas corresponden a ventas en Perú.

En cuanto a diversificación de las ventas, estas corresponden un 59% a los productos de consumo masivo, 27% a productos industriales y 14% a nutrición animal¹.

Algunos de sus principales competidores son Carozzi, P&G, Nestlé, Colgate, Unilever y Purina, dependiendo de la categoría de productos.

Misión

“Creamos marcas líderes que transforman mercados generando experiencias extraordinarias en nuestros consumidores. Estamos en constante movimiento buscando innovar para generar valor y bienestar en la sociedad.”

Visión

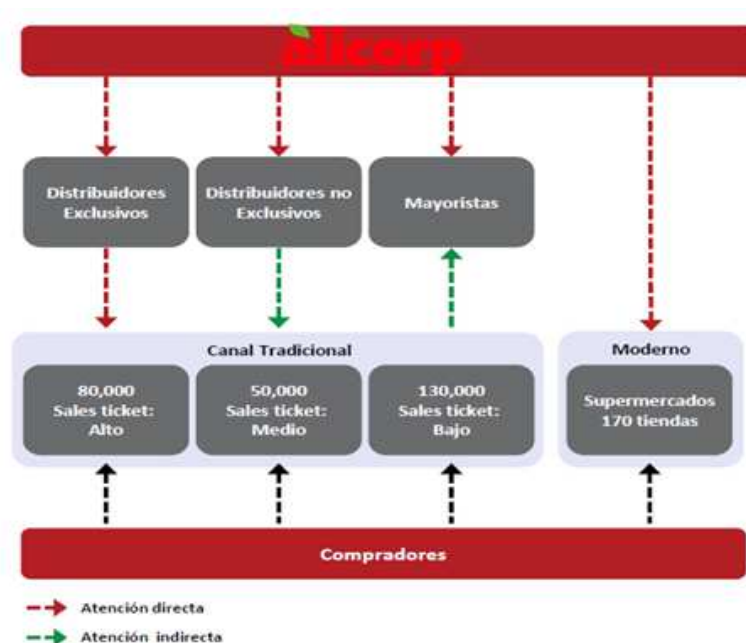
“Sorprendemos a los mercados con nuestro crecimiento agresivo e innovación. Transformamos categorías comunes en experiencias extraordinarias. Nuestro objetivo es estar entre las 250 empresas más grandes de Latinoamérica”

¹ Datos generados en el segundo trimestre de 2013.

I.II. Canales de Distribución

En Perú, Alicorp S.A cuenta con 4 principales canales de distribución, a través de los cuales atiende a más de 200.000 clientes. Estos canales se exponen en el siguiente diagrama:


Figura 1: Canales de distribución de Alicorp S.A en Perú



Fuente: Presentación Corporativa 2013 [19]

Los ingresos provienen principalmente del canal Tradicional, abarcando un 92% del total de la venta en 2013:

Figura 2: Distribución de ventas por canal en 2013



Fuente: Presentación Corporativa 2013 [19]

Dada la gran extensión de Perú, se hizo evidente la necesidad de la creación de centros de distribución, quienes estarían encargados de distribuir a los clientes minoristas. Estos centros son

llamados Distribuidores Exclusivos (DEX). Según los registros en la base de datos de la empresa, existen 41 de estos centros, los que se distribuyen en Perú según el diagrama siguiente:

Figura 3: Distribuidores Exclusivos en Perú



Fuente: Presentación Corporativa 2013 [19]

Los productos terminados son enviados desde la fábrica en Callao al Centro de Distribución Logística, desde los cuales se envían a los distintos DEX distribuidos a lo largo de todo Perú. Cada DEX tiene asignado a los clientes minoristas a los cuales debe abastecer dependiendo de la región geográfica en la que se ubican.

Figura 4: Diagrama de Flujo Fábrica-Minoristas



Fuente: Elaboración propia

II. DESCRIPCIÓN DEL PROYECTO Y JUSTIFICACIÓN

Uno de los problemas que surgen en la gestión de inventario, cuyo objetivo fundamental es calcular el nivel de existencias necesario para asegurar disponibilidad a un mínimo costo, es una adecuada estimación de demanda. Una mala estimación de demanda conlleva costos asociados a ventas perdidas, mala asignación de recursos y costo de mantenimiento de inventario innecesario.

La empresa en cuestión cuenta con más de 1.000 SKU's (Stock Keeping Unit) pertenecientes a distintas categorías, y 41 centros de distribución. Para realizar pronósticos de demanda y dada la gran envergadura del problema ($1.000 \times 41 = 410.000$ demandas distintas), se ha optado por una metodología que consiste en calcular la media móvil de las ventas de los últimos 6 meses a nivel de categoría y canal, y repartir esta estimación según la participación de cada SKU dentro de la categoría. El problema de esta estimación es que no considera estacionalidad, tendencia, ni ningún tipo de información adicional que pudiera influir en las ventas de los productos.

No es posible conocer con exactitud la cifra de los costos asociados a los malos pronósticos de demanda ya que no se tiene registro de inventario para reconstruir la demanda y contrastarlo con las ventas. Sin embargo, expertos del negocio estiman que, en promedio, un 8% de las potenciales ventas se pierden en Alicorp. Basados en este supuesto, el costo de las ventas perdidas debido a malas estimaciones de demanda ascendió a US\$173 millones en 2013.

Alicorp S.A está actualmente invirtiendo recursos en estimar del modo más preciso posible la demanda de sus productos con el objetivo de saber qué nivel de producción tener y cuánto de cada producto enviar a cada uno de los centros de distribución, de modo de maximizar su utilidad. El presente trabajo se enfocará en estimar la demanda en el canal de distribuidores exclusivos.

Este problema es bastante complejo de abordar ya que la demanda puede depender de un sinnúmero de factores a veces no fácilmente detectables, entre los que se incluyen:

- Factores climáticos
- Campañas publicitarias
- Precio de los productos
- Competencia
- Factores macroeconómicos
- Días festivos y fechas especiales
- Estacionalidad
- Ventas pasadas
- Características de los consumidores
- Etc.

Adicionalmente muchos de los factores no pueden conocerse con anticipación (por ejemplo, acciones de la competencia), por lo que no podrían incluirse en un modelo.

Se quiere testear la hipótesis de que existen ciertos distribuidores cuyo comportamiento se anticipa y representa los movimientos futuros del mercado. Por ejemplo, en cierto mes se observa que las ventas de cierto SKU en un DEX particular aumentaron en un 60%. N meses después se observa esta misma tendencia para el mismo SKU en otros DEX o a nivel agregado.

También se cree que existen SKU's cuyos movimientos son representativos de los movimientos de la categoría. Es decir, el problema debe ser abordado desde las dimensiones tiempo, producto y lugar, que de ser resuelto permitiría una estimación más precisa y con más fundamento que la estimación actual. Para utilizar esta información se debe determinar cuál o cuáles distribuidores y qué productos son los que anticipan los cambios en la demanda ya sea de las ventas totales de la categoría o de ciertos grupos de distribuidores, y con cuánta anticipación.

Para identificar una metodología que permita cumplir con estos objetivos y a modo de simplificar el problema, se trabajará con una categoría de productos en particular. Dicha metodología podrá ser entonces replicada y extendida al resto de las categorías de productos en un trabajo futuro.

III. OBJETIVOS

III.I Objetivo General

Establecer una metodología que permita pronosticar semanalmente la demanda a nivel de distribuidor-SKU de una empresa fabricante de productos de consumo masivo.

III.II Objetivos Específicos

- Identificar a ciertos distribuidores o SKU's que se anticipen a las tendencias del mercado para predecir la demanda en la categoría.
- Estudiar sustitución entre marcas, productos complementarios, efecto del precio, importancia de las variables, etc.
- Estudiar sustitución entre marcas, productos complementarios, efecto del precio, importancia de las variables, etc.
- Determinar la precisión y error de los modelos calibrados para escoger el que tenga una mejor capacidad de predicción.
- Determinar el beneficio obtenido con el modelo propuesto por sobre el modelo actual.
- Comprender de mejor manera las variables que afectan los movimientos del mercado
- Obtener un nivel de mejora de al menos un 20% en la precisión del pronóstico.

IV. ALCANCES

Para acotar el problema, la estimación de demanda se realizará en la categoría *Aceites*, con 25 SKU's a su haber. Esta elección se realizó basada en la participación de mercado de esta categoría dentro de las ventas de Alicorp, y la cantidad relativamente manejable de SKU's pertenecientes a esta categoría. La demanda se calculará semanalmente en un horizonte temporal de tres meses, por requisito del cliente.

Además, dados los miles de clientes de Alicorp, se realizará la estimación de demanda solo para las ventas realizadas mediante Distribuidores Exclusivos (Perú), a nivel de este último.

Es decir, se pretende realizar una estimación de demanda para todos los SKU de la categoría aceites, de manera semanal en un horizonte temporal de tres meses, a nivel de distribuidor exclusivo.

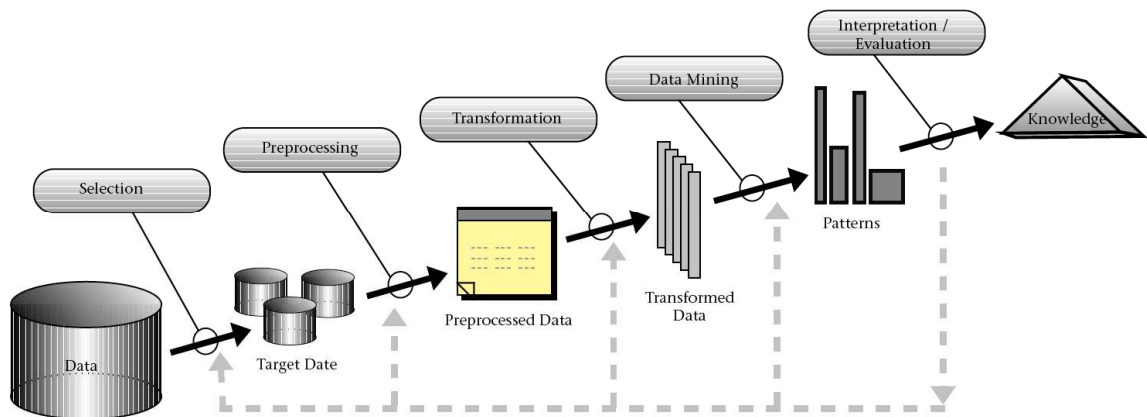
V. RESULTADOS ESPERADOS

1. Modelo de estimación de demanda a nivel de SKU para los productos de una determinada categoría.
2. Identificación de algún distribuidor/SKU que se anticipe a las tendencias del mercado para la categoría escogida.
3. Indicadores de bondad de ajuste del modelo propuesto.
4. Nivel considerable de mejora obtenido a partir del modelo propuesto versus el modelo utilizado actualmente (al menos un 20% de reducción de error en contraste con el modelo actual).

VI. MARCO TEÓRICO

El diseño metodológico que se utilizará para la resolución del problema de estimación de demanda, se basa fundamentalmente en el proceso KDD (Knowledge Discovery in Databases), que se refiere al proceso no trivial de descubrir conocimiento e información potencialmente útil a partir de una base de datos, mediante la identificación de patrones. Este proceso se divide en 5 etapas, las cuales son descritas continuación:

Figura 5: Proceso KDD



Fuente: [Fayyad et al., 1996]

- 1. Selección de datos.** En esta etapa se determinan las fuentes de datos y el tipo de información a utilizar. Se refiere tanto a la selección de variables como al muestreo de los registros disponibles. En este caso particular se seleccionarán las series de tiempo a pronosticar dependiendo de la calidad de los datos y de un largo histórico tal que sea posible una correcta modelación.
- 2. Pre-procesamiento.** Consiste en la preparación y limpieza de los datos extraídos, de forma de que dichos datos sean manejables, consistentes, confiables y útiles para la creación de modelos posteriores. Se utilizan diversas estrategias para manejar datos faltantes o en blanco, datos inconsistentes o fuera de rango. Los datos perdidos u outliers serán imputados utilizando la media móvil centrada tomando dos días similares hacia adelante y dos hacia atrás.

3. **Transformación.** Consiste en el tratamiento preliminar de los datos, transformación y generación de nuevas variables a partir de las ya existentes con una estructura de datos apropiada. Aquí se realizan operaciones de agregación, normalización transformaciones lineales, etc. Adicionalmente se añaden variables independientes que pudieran ayudar a la configuración del modelo, consolidando la base analítica lista para utilizar en la fase siguiente.
4. **Data Mining.** Es la fase de modelamiento propiamente tal, en donde métodos de minería de datos son aplicados con el objetivo de extraer patrones previamente desconocidos, válidos, nuevos, potencialmente útiles y comprensibles y que están contenidos u “ocultos” en los datos. La calibración del modelo y pronóstico se llevará a cabo en esta etapa.
5. **Interpretación y Evaluación.** Identificación de los patrones obtenidos y evaluación de los resultados de acuerdo a una serie de criterios establecidos previamente.

Dado lo expuesto en los objetivos y resultados esperados de esta memoria, hay ciertos modelos de predicción que se descartan de plano por no permitir interpretación pese a tener buena capacidad de predicción. Este es el caso, por ejemplo, de la técnica Redes Neuronales. Las herramientas basadas en series de tiempo son más simples y permiten una fácil observación de las variables que influyen, en este caso, en la demanda.

A continuación se detallan los métodos de estimación de demanda a utilizar en este trabajo.

VI.I Series de Tiempo

Se llama Series de Tiempo a un conjunto de mediciones de cierto fenómeno o experimento registradas secuencialmente en el tiempo. Estas observaciones son denotadas por $\{x(t_1), x(t_2), \dots, x(t_n)\} = \{x(t): t \in T \subseteq \mathbf{R}\}$ con $x(t_i)$ el valor de la variable x en el instante t_i .

El análisis se comienza graficando la serie para ser capaz de observar los siguientes fenómenos:

1. Outliers
2. Tendencia
3. Estacionalidad

Matemáticamente se puede decir que la serie representa variación estacional si existe un número s tal que $x(t) \cong x(t + ks), \forall t$.

En el caso de estudio en particular, se esperaría encontrar estacionalidad mensual en caso de trabajar con datos semanales y estacionalidad semanal en caso de trabajar con datos diarios.

4. Variaciones irregulares (componente aleatoria): Representa todos los tipos de movimientos de una serie de tiempo que no sean tendencia, variaciones estacionales ni fluctuaciones cíclicas.

VI.II Modelo ARIMA(p,d,q)

Box y Jenkins han desarrollado modelos estadísticos para series temporales que tienen en cuenta la dependencia existente entre los datos, esto es, cada observación en un momento dado es modelada en función de los valores anteriores. Los modelos se conocen como ARIMA (p,d,q) (Autoregressive Integrated Moving Average), que deriva de sus tres componentes AR(Autoregresivo), I (integrado), y MA (Medias Móviles). El modelo permite describir un valor como una función lineal de los datos anteriores y errores, además de incluir un componente cíclico o estacional:

$$X_t = \varepsilon_t + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

La primera componente es el modelo AR(p) y representa una suma ponderada de observaciones pasadas de la variable. El número de rezagos (p) determina el orden del modelo autorregresivo. La segunda componente corresponde a Medias Móviles, que se calcula como una suma ponderada de errores actuales y anteriores. El número de rezagos del error considerados (q) determina el orden del modelo de media móvil.

Si la serie no es estacionaria (media y la varianza constantes a través del tiempo), entonces debe ser diferenciada I veces tal que se convierta en estacionaria, lo que determina el orden del parámetro d.

Si la serie de tiempo presenta estacionalidad s , se pueden incorporar términos donde X_t dependiera de X_{t-s} , X_{t-2s} , y de los sucesivos términos. Este modelo se llama SARIMA(p,d,q)x(sp,sd,sq) donde el primer conjunto de parámetros indica lo mismo que en ARIMA, mientras que en el segundo conjunto de parámetros se tienen los similares pero respecto a la estacionalidad. El último parámetro también da cuenta de la cantidad de períodos que dura la estacionalidad.

De existir adicionalmente otros factores externos que pudieran afectar la serie, puede utilizarse el modelo SARIMAX, que permite la inclusión de esta información,

Cada uno de los parámetros usado en el modelo debe ser sometido a revisión estadística, para saber si efectivamente sirve para explicar la variable dependiente. Este análisis se realiza mediante un test-t que contrasta a cada parámetro de manera independiente contra la hipótesis nula de que el valor de ese parámetro es cero.

VI.II Procedimiento de Modelación Según Box Jenkins

Condiciones para una correcta modelación de Box Jenkins

Para modelar una serie de tiempo bajo un proceso ARIMA son necesarias dos condiciones:

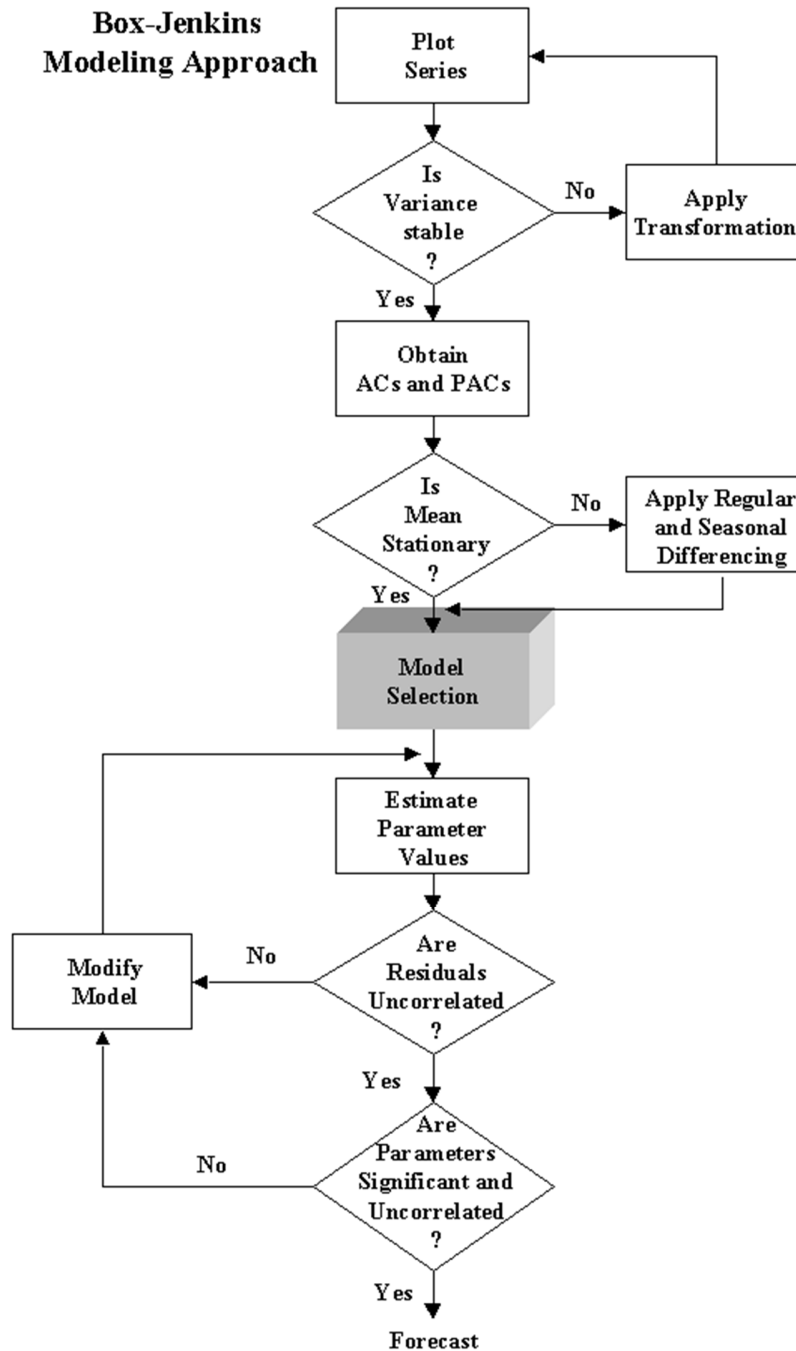
- Tener al menos 50 observaciones, de modo que la serie de tiempo sea representativa del fenómeno a estudiar.
- La serie de tiempo en estudio debe ser estacionaria.

Además se debe considerar la parsimonia del modelo como factor importante a la hora de modelar. Se debe tener la menor cantidad de parámetros posible para no sobreajustar los datos, pero permitiendo predecir de buena manera.

La metodología de Box Jenkins cuenta con una serie de pasos establecidos, descritos a continuación:

- Identificación tentativa (Visualización de la serie, gráficos de autocorrelación, autocorrelación parcial y espectograma)
- Determinación del orden del modelo (definir p, d y q)
- Estimación de coeficientes.
- Chequeo y Diagnóstico
- Volver al primer paso en caso de resultados insatisfactorios.

Figura 6: Procedimiento de modelación de Box-Jenkins



Fuente: H.Arsham [18]

Para encontrar el orden del modelo, los autores proponen estudiar la correlación existente entre los valores de la serie de tiempo. La función de autocorrelación (ACF) mide la correlación (en función de las covarianzas), entre valores de la serie con distinto número de retardos. Más formalmente, la autocorrelación con la k -ésima muestra de retardo r_k , se define:

$$r_k = \frac{\sum_{i=1}^r (X_i - \bar{X})(X_{i+k} - \bar{X})}{\sum_{i=1}^r (X_i - \bar{X})^2}$$

donde \bar{X} es el promedio de las r observaciones de la serie de tiempo.

Otro gráfico que ayuda a identificar las series de tiempo es la autocorrelación parcial (PACF), que mide la correlación entre un intervalo t y k retardos removiendo los efectos de las observaciones entre los valores originales.

Así, la autocorrelación parcial con la k -ésima muestra de retardo ϕ_{kk} es definida como

$$\phi_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \phi_{kk} r_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{kk} r_{k-j}} \quad \text{para } k = 3, \dots, r$$

$$\phi_{kj} = \phi_{k-1j} - \phi_{kk} \phi_{k-1,j-1} \quad \text{para } k = 2, j = 1, \dots, k-1$$

con

$$\phi_{22} = \frac{r_2 - r_1^2}{1 - r_1^2} \quad \text{y} \quad \phi_{11} = r_1$$

Así, comparando los correlogramas de modelos con parámetros conocidos, se obtiene información sobre cuál es el orden del modelo ARIMA que mejor se ajusta a la serie en estudio.

VI.III Medidas de Error

Para evaluar el desempeño del pronóstico (\hat{X}), se utilizarán medidas que comparan la predicción con el valor real. Estas medidas también pueden ser utilizadas para la calibración de los datos. Para una serie $(X_t)_{t=1}^n$ de media \bar{X} , se tienen las siguientes medidas de error:

1. Error Absoluto Medio (MAE): Indicador que entrega el promedio del error absoluto del pronóstico en toda la serie.

$$MAE = \frac{1}{n} \sum_{t=1}^T |X_t - \hat{X}_t|$$

2. Error porcentual absoluto medio (MAPE): Indicador que entrega en promedio el error absoluto en el pronóstico de toda la serie, como porcentaje de la serie original.

$$MAPE = \frac{1}{n} \sum_{t=1}^T \left| \frac{X_t - \hat{X}_t}{X_t} \right|$$

3. Error Porcentual Absoluto Medio Ponderado (Weighted MAPE): Equivalente a calcular un error MAPE, ponderado por el tamaño del error relativo al valor original.

El MAPE pondera cada error en el pronóstico por igual, independiente del nivel de los valores de la serie que se está pronosticando. WMAPE pondera cada error dependiendo del nivel de valores de la serie. WMAPE compensa el tamaño del error relativo al porcentaje del valor original.

$$WMAPE = \frac{\sum_{t=1}^T |X_t - \hat{X}_t| * X_t * 100}{\sum_{t=1}^T X_t}$$

Según Hyndman [14], el indicador más recomendado para comparar modelos para una misma serie es el MAE, porque es de fácil cálculo e interpretación, además de ser una medida objetiva para medir el desempeño de los modelos. Sin embargo, al ser escala-dependiente, hace que pierda el sentido si se quiere comparar modelos para diferentes series.

El MAPE tiene la ventaja de ser independiente de la escala, lo que lo hace útil para comparar modelos entre series. Sin embargo, cuando se quieren pronosticar para valores pequeños, pequeños errores arrojan un gran MAPE, ya que significan un gran porcentaje del valor real. Para corregir este problema, se utiliza el WMAPE, que pondera el error por el porcentaje que representa el valor de la serie en un punto versus el valor real. Así, grandes valores del MAPE tienen poco peso si es que el nivel del valor real es bajo.


Dado lo anterior, se utilizará el WMAPE como métrica para comparar el desempeño de los modelos.

VII. DESARROLLO METODOLÓGICO

VII.I Selección de Categoría de Estudio

Como se mencionó previamente, se seleccionará una categoría de productos en particular como objeto de estudio. Para la elección de la categoría, se considerarán la participación en ventas de cada una de estas y la cantidad de SKU's que contienen, de manera de maximizar el impacto económico de este trabajo, sujeto a la condición de que la cantidad de SKU's sea relativamente manejable, ya que la idea es generar una metodología extrapolable a otras categorías.

Figura 7: Principales Categorías de Consumo Masivo por Ventas a Junio de 2013²



Fuente: Presentación Corporativa Alicorp 2T2013

Las categorías con mayores ventas son Pastas, Aceites Domésticos y Detergentes. Para la elección de la categoría definitiva a trabajar se considerará la cantidad de SKU's que contenga cada una de ellas:

Tabla 1 SKU's por Categoría

Categoría	SKU's
Pastas	130
Aceites	25
Detergentes	99

Fuente: Elaboración propia

La categoría seleccionada para el estudio es *Aceites*.


² Promedio de últimos 12 meses al 30 de junio de 2013

VII.II Análisis Preliminar y Estadístico de Datos

La información con la que se cuenta para este trabajo consiste en data transaccional de cada SKU en cada centro de distribución. Adicionalmente se cuenta con información acerca de los atributos que describen a cada producto, como tamaño y origen del aceite, además de la serie de precios correspondiente. Sobre los centros de distribución, se tiene la ubicación geográfica. Esta información será considerada dependiendo del modelo de minería de datos a utilizar.

En la base de datos se tiene registro de las operaciones para esta categoría a partir de la semana 5 del año 2011. Sin embargo, como se expondrá en el gráfico a continuación, se observa un evidente cambio de nivel a partir del año 2012:

Gráfico 1. Litros Vendidos de Aceite

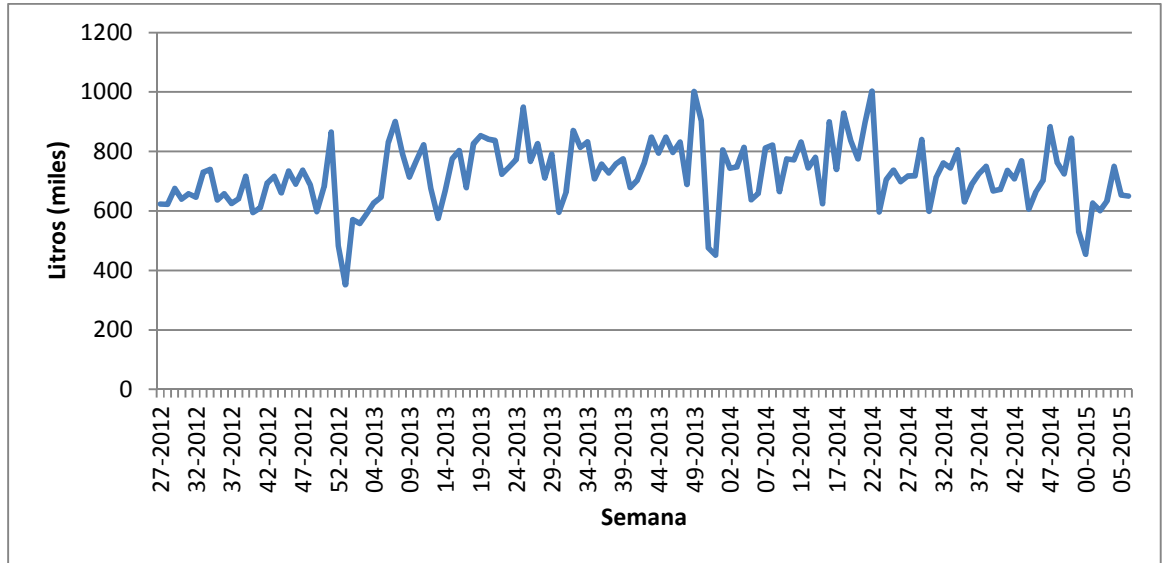


Fuente: Elaboración propia

No se tiene información acerca de qué ocasionó este cambio, sin embargo, si se utilizan los datos previos a esta fecha, se ocasionará un sesgo en la calibración del modelo. Luego, estos serán eliminados. Se trabajará entonces con 136 semanas de historia transaccional, desde la semana 27 del año 2012 hasta la semana 06 del 2015.

En el análisis expuesto a continuación se trabajará con litros vendidos y no con unidades (botellas), ya que esta información no es suficiente para observar si el consumo de aceite está aumentando o no en la población. Se podría estar consumiendo la misma cantidad de botellas pero en formato de más o menos volumen. Recordar que estas ventas corresponden solo a las realizadas por el canal minorista (distribuidores exclusivos). Así, las ventas en el periodo de estudio se ven como sigue:

Gráfico 2. Litros Vendidos de Aceite en el Periodo de Estudio




Fuente: Elaboración propia.

A priori no se observa una tendencia marcada a través del tiempo, pero sí aparentemente existe estacionalidad en la primera y última semana del año, supuesto que será testeado más adelante.

La variación del ingreso a través del tiempo se grafica a continuación:

Gráfico 3. Ingresos por Venta de Aceite en el Periodo en Estudio



Fuente: Elaboración propia

Es esperable que la curva de ingresos y ventas en litros tengan casi exactamente la misma forma, ya que los precios varían muy poco.

Se seleccionaron las series de tiempo a pronosticar utilizando los siguientes criterios de calidad:

- No se pronosticarán series sin datos de ventas en los últimos periodos (productos obsoletos).
- Según las condiciones para modelar series de tiempo según Box Jenkins [1] es necesario contar con al menos 50 registros de historia transaccional, de manera que la serie sea representativa del proceso en estudio. Se eliminarán entonces aquellas series que no cumplan con este criterio pero verificando que tengan una baja participación (inferior a 1%) en cada DEX.
- Se eliminarán aquellas series cuyos registros contengan un 25% o más de datos perdidos o inconsistentes, ya que de corregirlos, se podría introducir un sesgo importante y el resultado de la imputación podría estar muy lejos de la realidad.
- Se eliminarán aquellas series cuyos registros contengan 4 o más periodos de datos perdidos consecutivos.

Así, solo se realizará el pronóstico para 34 DEX. Las DEX seleccionadas y los estadísticos descriptivos de las ventas en cada DEX se adjuntan en el Anexo 1. Finalmente, los 6 SKUs para los cuales se crearán los modelos predictivos y el análisis estadístico se encuentran en el Anexo 3 y 4 respectivamente.

Adicionalmente se contrastó el coeficiente de variación de las participaciones de ventas los SKU contra sus respectivos precios. Como se observa en el Anexo 5, las participaciones varían mucho más porcentualmente hablando que los precios, lo que da indicios de que la participación de las ventas de los productos no está solo afectada por los precios, sino que existen otros factores relevantes que no están siendo observados. Esto resulta preocupante, ya que implica a priori implica que los pronósticos de las participaciones no serán capaces de explicar gran parte de la varianza.

En total se pronosticarán 154 series de tiempo (a nivel DEX-SKU). Con respecto a los análisis estadísticos, se destaca lo siguiente:

- Se observa que la DEX n°4 (Distribuidora Cunza S.A, Lima) es la DEX con mayor participación en las ventas, con un 6% en volumen y 5.8% en ingresos.
- Los SKU's seleccionados representan el 90% de todas las ventas efectuadas en los últimos 6 meses.
- Hay aceites que tienen un precio considerablemente superior al resto, lo que se explica porque corresponden a aceites de oliva Premium versus aceite de cocina normal (utilizado para freír).

VII.III.1 Análisis para un SKU y DEX particular


Para estudiar más en profundidad el comportamiento de la curva de demanda, se seleccionará aquel SKU con mayores ventas en litros e ingresos a modo de ejemplo y se observará el movimiento de las ventas a través del tiempo. Este mismo análisis será replicado para otros niveles de agregación de las series según sea necesario.

De la tabla anterior se sabe que el SKU con mayor volumen de ventas es el 4098, con un 18.81% de participación. Luego, el SKU seleccionado para el análisis es el 4098, que corresponde al aceite marca CIL en formato 1 litro.

Este aceite vende en promedio alrededor de 130.000 litros por semana³, mientras que el promedio de ventas semanales considerando todos los SKU es aproximadamente 30.000.

A continuación se expone la serie de ventas en litros de este aceite en el periodo en estudio:

Gráfico 4. Litros Vendidos SKU 4098



Fuente: Elaboración propia

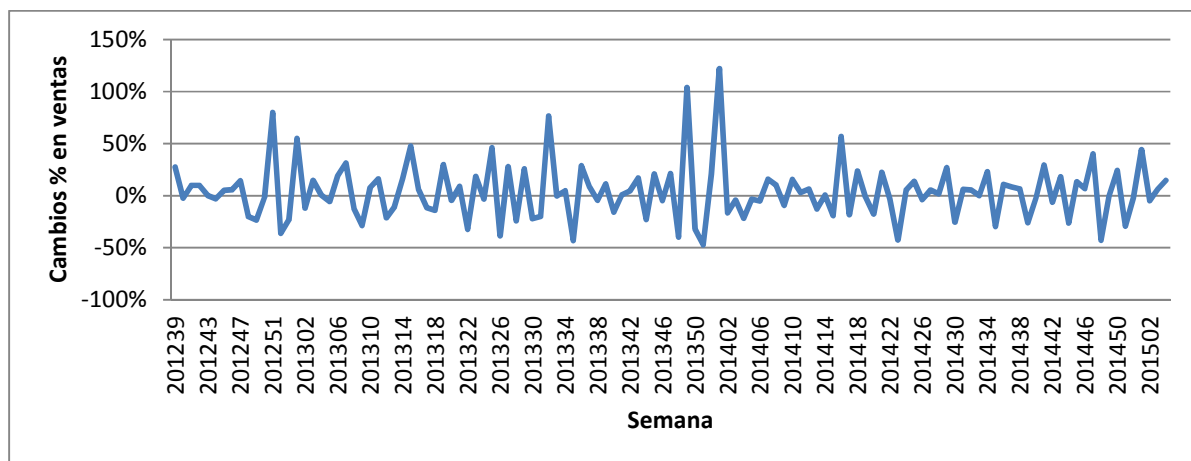
Se observa que los datos presentan una gran varianza a través del tiempo. Hay periodos en donde la venta de aceite asciende a 10 mil litros y otros en donde la venta alcanza los 20 mil. Lamentablemente, el modelo de pronóstico de media móvil no es capaz de pronosticar estas alzas y bajas, ya que simplemente promedia los últimos valores de las ventas. De ser las ventas relativamente constantes y estacionarias, el modelo de media móvil funcionaría bien, pero en este caso se observa que no es así, y que es muy probable que exista estacionalidad. La presencia de

³ Promedio calculado utilizando los datos de los últimos 7 meses de transacciones.

variables que afecten la varianza de las ventas hace de este un problema más complejo de abordar que como se hace en la actualidad.

Para estudiar el comportamiento de las ventas a través del tiempo se seleccionaron las fechas con mayores cambios porcentuales de un periodo a otro. Los cambios se grafican a continuación:

Gráfico 5 Cambios Porcentuales en Ventas SKU 4098



Fuente: Elaboración propia

Luego, estos cambios son estudiados a nivel de DEX para analizar si es posible identificar algún tipo de patrón:

- En la semana 201301 (semana n°1 del año 2013) fue posible observar un aumento generalizado a nivel de DEX. Los DEX 17 y 18 explican 35% del aumento. Ambos pertenecen a la provincia de Chincha. En 201401 el aumento también fue generalizado. Las DEX 18 (Cajamarca), 27 (Trujillo) y 44 (Trujillo) explican un 55% del aumento, todas ellas ubicadas en el norte de Perú. La DEX 17 (Huancayo) ubicada también en el norte, esta vez disminuyó sus ventas pero se explica porque tuvo un incremento significativo en el periodo anterior. También se observa un pico bastante elevado en 201401, de hecho es una de las semana que más ventas se han efectuado durante el periodo en estudio.
- En 201349 (9 al 15 de diciembre) también hubo un aumento generalizado, donde el 26% es explicado por dos DEX: la 17 ubicada en Huancayo (centro de Perú) y 18 ubicada en Cajamarca (norte), con un aumento de 123% y 250% respectivamente en relación al periodo anterior. En 201350 (16 al 22 de diciembre) se observa una caída generalizada, donde la DEX 17 ubicada en Huancayo explica 26% de la caída, lo que es lógico ya que un gran incremento en las ventas debe ser seguido por un descenso.

En 201251 (17 al 23 de diciembre) hubo un aumento generalizado, seguido de una fuerte caída. En 201351 (23 al 29 de diciembre) y 201451 (22 al 28 de diciembre) hubo una caída generalizada, pero en 2014 la DEX 45 (Cusco) duplicó sus ventas. Como se observa en el gráfico de ventas, esta caída viene después de un peak en las ventas en 201349 y 201450 (15 al 21 de diciembre) respectivamente.

- En 201448 (01/12 – 07/12) y 201348(02/12 - 08/12) se observa una caída generalizada. En 2013 el 85% Las DEX disminuyeron sus ventas y entre la DEX 18 (Cajamarca, norte), 45 (Cusco) y 42 (Chiclayo, Norte) explican un 39% de la caída. En 2014 el 80% de las DEX disminuyó sus ventas. La DEX 18 explica un 12%, la 45 explica un 18% y la DEX 56 (Junin, Centro Sur) explica un 14%.
- En 201416 el 86% de las DEX aumentaron sus ventas de manera significativa, mientras otras disminuyeron. Las DEX 27 (Trujillo) disminuyó sus ventas en un 34%, la DEX 39 ubicada en Piura disminuyó en un 42% (ambas del norte) y la DEX 5 ubicada en Lima disminuyó en un 31%.
- En 201423 se identificó una caída generalizada. En 201322 un 75% de las DEX disminuyó sus ventas. El 19% del descenso es explicado por la DEX 18 y 15% por la 45 (Cusco, Centro sur).
- Entre las DEX 17 (Huancayo, centro), 18 (Cajamarca, Norte), 40 (Arequipa, Centro Sur), 45 (Cusco, Centro Sur) y 46 (Juliaca, Centro Sur) se explica un 61% de la caída ocurrida en 201326.
- En la semana 201332 también se observa un aumento generalizado. Existen algunos pocos que disminuyeron considerablemente sus ventas, lo que se atribuye a quiebres de stock (en el periodo inmediatamente anterior hubo un notable incremento en estas DEX, y en el siguiente se vendieron una cantidad de unidades irracionalmente bajas).
- En 201435 el 79% de las DEX tuvo una caída significativa en las ventas. Entre la DEX 18 (Cajamarca, Norte) y la 47 (Chimbote, Norte) se explica un 35% de la caída. En 201335 las ventas del 75% de las DEX cayó. Entre las Dex 18, 46 (Juliaca, Centro Sur) y 35 (Chachapoyas, Norte) se explica un 35% del descenso. Estas semanas corresponden a la primera semana de septiembre, en donde no se identificó ninguna fecha especial en el calendario de festividades peruanas. Cabe recordar que la fecha 201235 no se encuentra dentro del periodo en estudio.

En conclusión, existe estacionalidad en las festividades de fin de año. Se observa un peak en las ventas en las semanas previas a navidad (una o dos semanas antes) y, como es lógico, un fuerte

descenso en la semana inmediatamente siguiente. Además se observa un incremento en las ventas durante la primera semana del año.

En la primera semana de diciembre también se observa un descenso significativo en las ventas con respecto al periodo anterior.


Se observan otras fechas con incrementos o descensos a nivel general, pero no son estacionales (no se repiten anualmente), por lo que sólo se consideran significativas las mencionadas en el párrafo anterior.

VII.II.II Análisis de Correlogramas

Análisis de Autocorrelación

A continuación se presenta el análisis de autocorrelación del SKU 4098, que entrega información sobre cuál es el orden del modelo ARIMA que mejor se ajustaría a la serie:

Figura 8 Autocorrelación SKU 4098



Fuente: Elaboración Propia

Las barras representan la correlación existente para distintos niveles de retardo. Las líneas horizontales representan los límites de confianza. Cuando las barras los superan se considera que la correlación es significativa. Se observa que el mayor nivel de autocorrelación se presenta con

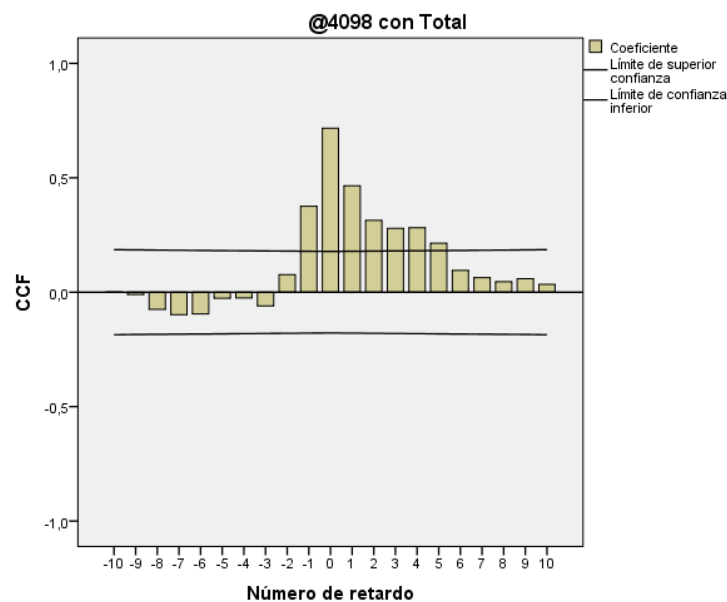
un periodo de retardo, con un 0.516 de autocorrelación parcial y un error de 0.089, lo que indica que en parte lo que se vende en un periodo depende del periodo inmediatamente anterior.

Análisis de Correlaciones Cruzadas

Anteriormente se mencionó la sospecha de que un SKU podría anticipar el comportamiento de otro (o una DEX el comportamiento de otra DEX). Para verificar esta hipótesis, y a modo de ejemplo, se realizará un análisis de correlaciones cruzadas para el SKU 4098 con el resto de los SKU y con la categoría. Existen tantas correlaciones cruzadas para el 4098 como SKU's.

A continuación se presenta la correlación cruzada del SKU 4098 con las ventas totales de la categoría aceites. Los resultados son expuestos a continuación:

Figura 9. Correlación Cruzada Entre SKU 4098 y la Categoría



Fuente: Elaboración Propia

Según los resultados de SPSS, existe una correlación cruzada de 0.72 en el retardo cero, lo que indica que lo que sucede con el SKU 4098 no es independiente de lo que sucede con la venta de la categoría a nivel general. Las correlaciones existentes entre los retardos -1 y 5 son todas significativas. Se podría decir que los movimientos del mercado están relacionados con lo que sucedió con el SKU 4098 en el periodo inmediatamente anterior (coef. de correlación cruzada=0.47). Adicionalmente se expone el resultado de las correlaciones de este SKU con algunos otros:

Tabla 2. Correlación Cruzada SKU 4098 con Otros SKU's

Par de series	Retardo	Correlación cruzada	Tip. Error
4097 con 4098	-11	0.935	0.152
4096 con 4098	-11	0.877	0.152
32 con 4098	-11	0.949	0.152

Fuente: Elaboración propia

Lo anterior se traduce en que el SKU 4098 se correlaciona con lo que ocurrirá con los SKU 32, 4096 y 4097 11 periodos después.


Con esta información se corrobora la hipótesis, lo que entrega información adicional que podría ser utilizada en la construcción del modelo en la próxima etapa.

VII.III Sistema de Pronóstico Actual

Como se mencionó anteriormente, el sistema que utiliza actualmente Alicorp para estimar la demanda es la media móvil de los últimos 6 meses (26 semanas) a nivel de categoría. Luego, para estimar a nivel de SKU, se divide este monto según el share obtenido en este mismo periodo.

Así, se replicó el modelo utilizando la función de medias móviles con un periodo de 26 semanas y pronosticando 3 meses (13 semanas) hacia el futuro. El gráfico de las ventas reales versus pronóstico en estos 13 periodos para la DEX 4, a nivel de categoría, se expone a continuación:

Gráfico 6 Venta Real versus Pronosticada



Fuente: Elaboración propia

Se observa que el pronóstico no ajusta bien a las ventas reales, ya que está bastante más suavizado. El problema del modelo actual es que no funciona bien en presencia de estacionalidad. De ser los valores siempre relativamente constante, el método de la media móvil podría considerarse adecuado para realizar los pronósticos. Este modelo tiene un MAPE de 21% y un coeficiente R2 de 2,3%. Al desagregar a nivel de SKU utilizando el promedio de los shares de los últimos 6 meses, el modelo alcanza un MAPE de 30.7%. Se utilizará esta medición como base y criterio de comparación a la hora de evaluar el nuevo modelo propuesto en la presente memoria.


VII.IV Limpieza de Datos

Se estima que la limpieza de datos es una de las etapas que requiere más tiempo del proceso KDD.

El problema de los quiebres de stock es un problema importante que debe ser solucionado previo a la etapa de modelación. Como se quiere predecir la demanda y no los quiebres de stock, se debe corregir esta información de manera que los datos reflejen de manera lo más fidedigna posible la demanda real.

La base de datos transaccional con la que se cuenta venía con valores perdidos, a modo de ejemplo se muestra la serie de tiempo de la DEX n°46:

Gráfico 7 Ventas Efectuadas en DEX 46



Fuente: Elaboración propia

Se observa que en ciertos periodos las ventas descienden a cero, lo que es muy extraño considerando que en promedio se venden sobre 6.000 litros semanales. Este fenómeno se explica

por los quiebres de stock, esto es, cuando un producto sigue siendo demandado pero está agotado en la góndola y por lo tanto no se vende.

Es por esto que esta información no representa la demanda real (solo las unidades vendidas), lo que es un grave problema para la calibración de un modelo, ya que no el problema de interés es estimar la demanda y no la venta. Lamentablemente, no se cuenta con información de inventario de los productos para conocer a ciencia cierta la función de demanda. Es por esto que se debe buscar una manera de aproximar lo mejor posible la curva de ventas a la curva de demanda.

Para corregir este problema, se revisarán los datos a nivel diario (ya que a nivel agregado es imposible observar si hubo días sin ventas) y se reemplazarán los valores nulos que no puedan ser explicados por el promedio de las ventas de días similares. Para esto se estudiará la autocorrelación parcial de cada serie de tiempo para determinar de qué días depende la demanda de uno en particular.

VII.IV.I Detección de Outliers

Al analizar los datos a nivel diario, se observaron dos fechas en el año en que no se realizaban ventas, estas son Navidad (25 de diciembre) y el primer día del año (01 de enero).

Para identificar otras variables temporales que pudiesen afectar las ventas, se obtuvieron las 20 fechas con menores y mayores ventas por año, de manera de observar estacionalidad y si aquellas fechas se celebra alguna festividad especial. Del mismo modo se seleccionaron aquellas fechas con mayor cambio porcentual con respecto al día anterior, tanto positivo como negativo. Los resultados se exponen a continuación:

Tabla 3. Fechas con Ventas más Bajas

Fecha	Característica
01 de Enero	Feriado. Ventas 0.
02-05 de Enero	Post feriado
24-27 de Enero	Sin explicación. Días sábados.
01 de Mayo	Feriado
28-29 de Julio	Feriados
01 de Noviembre	Feriado
25 de Diciembre	Feriado. Ventas 0.

Fuente: Elaboración propia

Tabla 4. Fechas con Ventas Más Altas

Fecha	Característica
11-13 de diciembre	Sin explicación
29-31 de octubre	Sin explicación

Fuente: Elaboración propia

Tabla 5. Fechas con Mayores Disminuciones Porcentuales en las Ventas con Respecto al Día Anterior

Fecha	Característica
Variable	Feriado
1 de mayo	Feriado
28 y 29 de julio	Feriado
1 de noviembre	Feriado

Fuente: Elaboración propia.

Tabla 6. Fechas con Mayores Aumentos Porcentuales en las Ventas con Respecto al Día Anterior.

Fecha	Característica
Variable ⁴	Post Semana Santa
2 de Mayo	Post feriado
30 de Julio	Post feriado
2 de Noviembre	Post feriado

Fuente: Elaboración propia.

El 8 de diciembre también corresponde a un feriado y en esta fecha en 2013 no se observan ventas, pero en 2014 solo 7 DEX cerraron y el resto sí registró ventas. En el año 2012 solo hubo dos DEX sin ventas. El 8 de octubre también es día feriado y en el año 2014 solo 6 de las DEX adscribieron a este, mientras que en 2013 9 de ellas cerraron. Situación similar ocurre el 30 de agosto, en donde solo algunas de las DEX respetan el feriado cada año. Ninguna de las fechas mencionadas anteriormente será registrada como una fecha especial, dada la aleatoriedad con que cierran algunas DEX.

Se observa que los días feriados suelen ser días en que se vende poco o disminuyen las ventas, mientras que el día siguiente las ventas se disparan porcentualmente hablando, lo cual es lógico. No es que aumenten las ventas el día que sigue a un feriado, solo se mantiene la tendencia. Existen más feriados en el calendario peruano pero no se observó alteración en las ventas a causa de esas festividades.

⁴ La fecha en que se celebra Semana Santa es variable y fijada año a año por el gobierno.

Existen dos fechas que año a año se encuentran entre los días con más ventas, pero no se encontró una causa directa de este comportamiento. Se presume que una o dos semanas antes de Navidad los clientes comienzan a preparar el stock para las ventas que acontecerán en los días venideros (recordar que el cliente es un minorista y no el consumidor final del producto). En cuanto a las altas ventas entre el 29 y 31 de octubre, no se logró identificar el motivo de esta alza.

VII.V Pre-procesamiento de Datos

Para abordar el problema de los datos perdidos, es necesario determinar el sistema mediante el cual estos datos serán imputados. Es común que se realice calculando el promedio de las ventas ocurridas en días similares. Para determinar cuáles son estos días “similares”, se debe realizar un análisis de autocorrelación. Este se realizó a nivel de categoría y para la serie con mayores ventas (SKU 4098 en DEX 4). Ambos concuerdan en que la mayor correlación se encuentra con 7 días de retardo, seguido por el día 14 y 21, y así sucesivamente. Luego, para realizar la imputación se utilizará la media móvil centrada considerando los 3 días correspondientes de las 3 últimas semanas y los 3 de las 3 semanas siguientes, mientras sean mayores a cero. Esto para no perder la componente de tendencia implícita en los datos. Se conservaron las ventas cero correspondientes a feriados y fechas especiales.

En el caso de los datos perdidos correspondientes a la serie de precio, dado que el precio se mantiene relativamente constante a través del tiempo simplemente se calculó la media móvil centrada utilizando los dos días anteriores y dos posteriores al día sin dato.

VII.VI Descripción del Modelo de Pronóstico

A continuación se describe la metodología propuesta para realizar la estimación al nivel de desagregación deseado de muchas series de tiempo distintas.

El pronóstico se realizará en dos etapas:

Etapas 1: Modelación utilizando ARIMA

Se calibrará un modelo para las ventas totales de cada DEX.


Etapas 2: Regresión Lineal

Para desagregar el pronóstico a nivel de producto, en primera instancia, se utilizó el Modelo de Atributos (cuya descripción y resultados de la aplicación se encuentran en Anexo 5), pero fue descartado debido a que no entregó los resultados esperados. Debido a esto, se optó por pronosticar las participaciones de mercado utilizando regresiones lineales en función del tiempo, para capturar la componente de tendencia que presentaban algunas series.

A modo de ejemplo, se mostrará el procedimiento utilizado en detalle para la DEX n°4. Este procedimiento es análogo para el resto de las DEX.

El primer paso consiste en realizar una exploración visual a la serie en estudio:

Gráfico 8. Ventas DEX n°4




Fuente: Elaboración Propia.

Se observa que la media y varianza son constantes a través del tiempo, por lo que la serie es estacionaria. Luego, no requiere diferenciación.

La serie exhibe muchos picos destacables los cuales parecieran estar espaciados uniformemente, sugiriendo la presencia de alguna componente periódica. Al estudiar en detalle esta peculiaridad, se observó que a fin de mes las ventas tienden a descender notablemente, a diferencia de la segunda semana del mes, que corresponden a las fechas en que los picos son destacables. Dado que no todos los meses tienen la misma cantidad de días, se definió como segunda semana del mes aquella semana que contenía el día 9 de cada mes, y la última semana aquella que contenía el día 28. De esta manera se ingresaron como variables explicativas dummies al modelo.


Luego se procede al análisis de correlogramas para obtener indicios del orden del modelo ARMA a utilizar.

Figura 8. Autocorrelación DEX 4



Fuente: Elaboración Propia.

Figura 9. Autocorrelación parcial DEX 4



Fuente: Elaboración Propia.

Se observa que la autocorrelación y autocorrelación parcial no son muy informativas con respecto al orden del modelo, ya que la autocorrelación es apenas significativa en los retardos 2 y 11. Los correlogramas correspondientes al resto de las DEX se encuentran en el Anexo 5.

Luego de ensayar distintos órdenes para el modelo ARMA, se determinó el mejor modelo entre los que tuvieran la totalidad de sus parámetros significativos (p-valor inferior a 0.05). El modelo escogido es un ARMA(1,1), cuyos parámetros se detallan a continuación:

Tabla 7 Especificación del modelo ARMA(1,1) para la DEX 4

Parámetros del modelo ARIMA				Estimación	ET	t	Sig.
@4-Modelo_1	@4	Sin transformación	Constante	18289.517	535.979	34.124	.000
			AR Retardo 1	.845	.151	5.614	.000
			MA Retardo 1	.572	.231	2.473	.017
	ventas_bajas	Sin transformación	Numerador Retardo 0	-748.743	311.734	-2.402	.020
	ventas0	Sin transformación	Numerador Retardo 0	-3909.410	1262.381	-3.097	.003
	semana2_mes	Sin transformación	Numerador Retardo 0	-950.972	429.818	-2.213	.031
	fin_mes	Sin transformación	Numerador Retardo 0	3183.627	439.775	7.239	.000


Fuente: Elaboración Propia.

Los parámetros del resto de los modelos se encuentran en Anexo 6.

Para asegurar la validez e idoneidad del modelo y la efectividad de las predicciones, los residuos estimados se deben comportar como un ruido blanco. Una de las formas en que se puede comprobar que los residuos efectivamente sean ruido blanco, es representar la FAS y la FAC de los residuos. Los valores de estas funciones deben ser no significativos a lo largo de todo el recorrido. De no ser así, se estaría observando evidencia de una mala especificación del modelo.

A continuación se presentan las FAS y FAP residuales del modelo en cuestión:

Figura 10. FAS y FAP residuales




Fuente: Elaboración Propia.

Por lo que se puede concluir que el modelo está bien especificado.

Por último, se representa gráficamente el pronóstico estimado. Además se contrasta con la demanda real y el modelo de pronóstico utilizado actualmente por Alicorp.

Gráfico 9. Ventas reales versus pronosticadas para la DEX 4



Fuente: Elaboración Propia

El pronóstico corresponde a los periodos a la derecha de la línea vertical. Se observa que el modelo propuesto ajusta muchísimo mejor que el modelo de Alicorp.

Tabla 8. Comparación Precisión Modelos

Modelo	MAE	R^2
ARMA (1,1) Calibración	1017	87%
ARMA (1,1) Pronóstico	1316	95%
Media Móvil (26) Alicorp	2879	2%

Fuente: Elaboración Propia.


Es decir, el modelo propuesto para esta DEX reduce el error actual en un 54%, y la varianza explicada aumenta en 93 puntos porcentuales.

VII.VI.I Inclusión de ventas de otras DEX como variables explicativas.

Como se mencionó al inicio, existe la sospecha de que ciertas DEX pueden anticipar los movimientos de otras, o ser una variable importante a considerar en la elaboración de

pronósticos. Para esto, se calculó la correlación cruzada entre las DEX, rescatando aquellas correlaciones con un valor fuertemente significativo. Al analizar los resultados, se observó que la DEX 1 tiene una correlación muy alta en el retardo cero con muchos DEX, lo que resultó ser bastante conveniente dado que el pronóstico del DEX 1 es bastante bueno (11% de WMAPE y R2 de 66%). Por ejemplo, la correlación cruzada del DEX 1 con el 5 es de 0,76 en el retardo cero, como se observa en la figura a continuación:

Figura 11. Correlación cruzada entre DEX 1 y DEX 5



Fuente: Elaboración Propia.

Dado este antecedente, se recalibraron los modelos anteriores introduciendo los valores de la serie del DEX1 los primeros 58 periodos y el pronóstico para los últimos 13 periodos como variable explicativa, esperando que los pronósticos del resto de los DEX aumenten su precisión.

Los resultados de aquellas DEX que presentaron una mejora significativa al introducir la correlación cruzada se adjunta a continuación:

Tabla 9. Mejora en Precisión con Correlación Cruzada

	Sin corr. cruzada	Con corr. cruzada	
Modelo DEX	WMAPE	WMAPE	% mejora
5	18%	13%	28%
11	9%	8%	11%
22	9%	5%	44%
31	10%	8%	20%
37	15%	10%	33%

Fuente: Elaboración Propia.


La tabla comparativa de las métricas de ajuste de todos los modelos ARIMA propuestos versus los actuales se encuentra en el Anexo 8.

VII.VI.II Desagregación a nivel de SKU

A continuación, se quiere desagregar este cálculo a nivel de SKU. Para esto, se utilizará una regresión lineal y una media móvil y se escogerá aquél que ajuste mejor.

Gráficamente, la evolución de los shares de los productos en la DEX 4 se ve como sigue:

Gráfico 9. Shares de los SKU's en DEX4



Fuente: Elaboración Propia.

Ambos modelos se calibrarán con 26 semanas de ventas, se testearán con las siguientes 13, a partir de lo cual se escogerá el de mejor ajuste y finalmente se calculará el error de pronóstico con las siguientes (y últimas) 13 semanas. La desventaja de estos modelos es que no permiten adquirir conocimiento acerca de la dinámica de los productos, ya que no capturan la varianza de la serie.

Una vez aplicados estos modelos a todas las series, y escogiendo el mejor para cada una, se encuentra que, en promedio, se reduce el error en los pronósticos en un 7% versus los modelos utilizados actualmente. Los resultados detallados del nivel de reducción de error por DEX y SKU se encuentran en el Anexo 9.

Integrando el pronóstico de las DEX utilizando ARIMA y las regresiones se obtiene un nivel el siguiente nivel de mejora:

Tabla 10. Porcentaje de Reducción del Error en DEX 4

SKU	30	31	32	4096	4097	4098
Reducción Error	25%	36%	35%	26%	29%	54%

Fuente: Elaboración Propia.

En promedio, se reduce el error en un 34% en este DEX.

El detalle del desempeño al integrar ambos modelos para todas las series se encuentra en el Anexo 11, mientras que el del desempeño de Alicorp se encuentra en el Anexo 10.

VIII. RESULTADOS

La metodología propuesta presenta buenos resultados sólo para cierto porcentaje de los DEX. Esto se explica porque hay ciertas series que presentan un cambio estructural en su nivel de venta, lo que puede deberse a la introducción de un nuevo producto u otros factores externos, lo que afecta la calibración del modelo. En otros casos, la varianza explicada es muy baja, cuando las series parecieran comportarse de forma aleatoria. No se tiene certeza de por qué ciertas series no presentan ningún patrón reconocible, pero es de suponer que el comportamiento de la venta se podría ver afectado al no considerar todos los productos en venta dentro de un mismo DEX.

Por el contrario, hay ciertas series con malos indicadores de ajuste, pero que gráficamente parecieran ser buenas predicciones. Esto se produce cuando hay un desfase de uno o más periodos en el comportamiento esperado de las ventas. Por alguna razón, en algunos DEX se retrasó o se adelantó el descenso esperado en las ventas de fin de año, lo que causó que las métricas de desempeño fueran muy bajas. Estos rezagos se consideran arbitrarios, por lo que igualmente se recomienda la utilización de los modelos propuestos por sobre el actual en estos casos en el futuro.

Los modelos autorregresivos funcionan entonces para 22 de los 34 DEX. La matriz con los resultados de estas DEX se encuentra en Anexo 7. Hay modelos para los cuales la mejora en WMAPE con respecto al modelo actual es pequeña, y otros para los cuales es bastante significativa. El mejor modelo es el que pronostica las ventas del DEX 4, con un WMAPE de 9% y un R^2 de 90%. El modelo con menor WMAPE es el de la DEX 29, con un WMAPE de 7% y un R^2 de 60%. En promedio, el WMAPE del modelo utilizado actualmente (MA(6)) es de un 17%, mientras que el promedio de los modelos propuestos es 12%. Además, los modelos pasan de tener en promedio un R^2 de 6% a 44%, aumentando en 38 puntos porcentuales. En promedio, se logra una reducción del error de 34% en el WMAPE mediante los modelos ARIMA, y un 7% adicional mediante la desagregación con regresiones, logrando una reducción total del error de 38% al utilizarlos en conjunto. Al sumar los errores en 3 meses para el modelo de Alicorp y el propuesto y realizar una comparación, se observa que los costos se reducen en 42%.

VIII.I Valorización Económica

Para valorizar los beneficios económicos de un mejor pronóstico de demanda, se realizaron los siguientes supuestos:

- Los productos marginan un 30% (El precio final es 1,3 veces el costo).
- El costo de sobreestock es un 25% del costo del producto en 3 meses.

Así, cuando se subestima la demanda se tiene un costo por ventas perdidas (margen), mientras que cuando se sobreestima se tiene el costo de mantener el producto en bodega (sobreestock).

Se agregaron los pronósticos semanales resultando entonces un pronóstico a tres meses. Así, las semanas con en las hubo una sobreestimación se amortiguan con las semanas en las que se subestimó la demanda.

Luego, se comparó a nivel DEX-SKU el pronóstico de demanda agregada utilizando el modelo propuesto versus el modelo actual utilizado por Alicorp. El error absoluto medio de cada serie SKU-DEX utilizando el modelo de Alicorp se encuentra en el Anexo 10 y el del modelo propuesto en el Anexo 11. Adicionalmente, en el anexo 12 se encuentra la reducción porcentual del error lograda por el modelo propuesto (integrando ARIMA y regresión) en contraste con el modelo actual, a nivel de DEX-SKU. A partir de esta tabla se calculó el beneficio económico en cada una de las series. Estos resultados se encuentran en el Anexo 13.

Pese a que el modelo propuesto siempre es más preciso que el modelo utilizado actualmente, a veces genera costos superiores, ya que el costo de las ventas perdidas es superior al costo de almacenamiento.

El modelo propuesto, debidos a errores en la estimación de demanda, genera costos S./ 240.739 (soles peruanos), en contraste con los S./ 415.420 que genera el modelo actual (media móvil de 6 meses), en 3 meses. Así, el modelo propuesto reduce en un 42% los costos asociados.

IX. CONCLUSIONES

A partir del trabajo realizado, se concluye que los modelos autorregresivos de series de tiempo son buenos pronosticadores para series con estacionalidad y mientras se observe un patrón regular en los datos. Si la serie es muy ruidosa, entonces el modelo no se desempeñará bien y si es muy plana, entonces bastará con modelos más sencillos como medias móviles o regresiones lineales para modelar. Considerando sólo aquellas series en las que el modelo propuesto funcionó, se logró reducir el error en un 30% en el WMAPE, y aumentar la varianza explicada en 38 puntos porcentuales. Además se logró una mejor comprensión del comportamiento de las ventas a nivel agregado. Se detectó, por ejemplo, que a fin de mes las ventas aumentan significativamente y que la segunda semana del mes caen abruptamente. También se detectó el impacto de los días feriados y post feriados en las ventas, entre otros.

IX.I Limitaciones

- El modelo es aplicable a series con más de 1,3 años de historia, ya que, según Box y Jenkins, se necesita de al menos 50 datos para lograr calibrar un modelo de buena calidad.
- Se requiere un análisis exhaustivo serie a serie para detectar estacionalidades inherentes a cada una, lo que complica la extrapolación de esta metodología a grandes volúmenes de series.
- El modelo es aplicable solo a series con una fuerte componente estacional. De no ser así, es más conveniente utilizar modelos más sencillos, dada la complejidad del modelo propuesto.
- Series con cambios estructurales no pueden ser calibradas con modelos autorregresivos de series de tiempo.

IX.II Verificación de Cumplimiento de Objetivos

Una vez que se tuvo más claridad con respecto a cómo resolver el problema, se descartó la idea de identificar SKU's que se anticipen a la demanda de la categoría, ya que el pronóstico se realizó a nivel de DEX. Es por esto que sí se trabajó en la identificación de ciertos DEX correlacionados entre sí. Si bien no se identificaron DEX que se anticiparan a otros, sí se identificaron correlaciones en el retardo cero con el DEX 1. Como el modelo de pronóstico de esta serie resultó ser bastante bueno, ayudó a mejorar bastante la precisión de otros modelos, pronosticando primero las ventas futuras del DEX 1 y luego introduciendo estos pronósticos como variable explicativa en los modelos de los otros DEX.

Lamentablemente, un objetivo importante que no se pudo cumplir fue comprender la interacción entre los productos de un DEX, sustitución entre marcas, elasticidades, etc., dado que el modelo que permitía estudiar estas interacciones no entregó los resultados esperados, por las razones esgrimidas en el capítulo anterior. Por otro lado, sí se logró mejor comprensión a nivel de DEX, al detectar las fechas o eventos que afectan positiva y negativamente la demanda.

Finalmente, un objetivo importante que sí se cumplió fue la reducción del error en una magnitud superior al 20%. El porcentaje de reducción alcanzado ascendió a 38%, lo que supera con creces la meta impuesta, además de lograr una reducción de 42% de los costos asociados a estimaciones imprecisas, para los DEX en los que sí funcionaron los modelos.

IX.III Trabajo Futuro

Se propone, para un trabajo futuro, recopilar información acerca del marketing mix presente en la promoción de los productos. Datos como presencia de publicidad, packs promocionales y otros pueden ser factores relevantes a la hora de vender ciertos productos. La introducción de estas variables podría generar pronósticos más precisos.

Adicionalmente, se propone recalibrar el modelo introduciendo los costos de de sobreestimar y de subestimar la venta, para generar un modelo que no solo sea más preciso, sino que efectivamente permita una reducción de costos.

Se propone además invertir el enfoque de pronóstico a nivel de DEX a uno a nivel de SKU, ya que podrían obtenerse resultados interesantes. Se detectó que sí existen correlaciones cruzadas significativas con retardos superiores a cero entre distintos SKU, por lo que se podría obtener un buen modelo pronosticando primero a nivel de SKU y luego desagregando a nivel de DEX.

X. BIBLIOGRAFÍA

- [1] G.E.P Box y G.M. Jenkins. Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco. 1976.
- [2] Bell, David R, Andre Bronfer y Pradeep K. Chintagunta (2005) “Recovering SKU-level Response Sensitivities from Market Share Models Estimated on Item Aggregates”, Journal of Marketing Research, forthcoming.
- [3] C. Olguín. “Estimación de demanda para una categoría a través de un enfoque de atributos”. Memoria para optar al título de Ingeniero Civil Industrial, U. de Chile. 2005.
- [4] N. Fritis. “Estimación de demanda a nivel de sku para la industria de supermercados”. Memoria para optar al título de Ingeniero Civil Industrial, U. de Chile. 2005.
- [5] O. Unuane. “Estudio y pronóstico de demanda a nivel de sku para la cadena regional de supermercados BRYC”. Memoria para optar al título de Ingeniero Civil Industrial, U. de Chile. 2006.
- [6] J. Jove. “Estimación de demanda a nivel de sku utilizando un enfoque basado en atributos: aplicación al caso supermercados. Memoria para optar al título de Ingeniero Civil Industrial, U. de Chile. 2005.
- [7] C. Gross. “Estimación de demanda a nivel de sku mediante un enfoque de atributos en la industria de supermercados”. Memoria para optar al título de Ingeniero Civil Industrial, U. de Chile. 2006.
- [8] F. Saavedra. “Validación de estimación de demanda a nivel de SKU utilizando un enfoque basado en atributos”. Memoria para optar al título de Ingeniero Civil Industrial, U. de Chile. 2006.
- [9] N. Wagner, Z. Michalewics, S. Schellenberg, C. Chiriac y A. Mohais. Intelligent techniques for forecasting multiple time series in real-world systems. 2011.
- [10] S. Rani, G. Sikka. Recent Techniques of Time Series Data: A Survey. Punjab, India. 2012.
- [11] V. Niennnattrakul, C.A. Ratanamahatana. Clustering Multimedia Data Using Time Series.
- [12] U. Fayyad, G. P.-Shapiro, and P. Smyth. From Data Mining to Knowledge Discovery in Databases. 1996.
- [13] M. Kumar, N. Patel, J.Woo. Clustering Seasonality Patterns in the Presence of Errors. 2002.
- [14] S. de la Fuente. Series Temporales: Modelo ARIMA. Universidad Autónoma de Madrid.
- [15] M. Quesada. Análisis de Series. Modelos Heterocedásticos.

- [16] R. Hyndman. Another Look at Forecast –Accuracy Metrics for Intermittent Demand. 2006.
- [17] R. Hyndman, A. Koehler. Another look at measures of forecast accuracy. 2005.
- [18] S. Arsham. Time-Critical Decision Making for Business Administration. Web-Enhanced Textbook, 9 edition. 2013.
- [19] Alicorp, Presentación Corporativa. http://www.alicorp.com.pe/alicorp/content/inversionistas/pdf/hechos/Alicorp_Corporate_Presentation_2Q13ESP.pdf 2013. [Online; accessed May-2015]
- [20] D. Asteriou. Notas sobre Análisis de Series de Tiempo: Estacionariedad, Integración y Cointegración. 2002.
- [21] M. Contreras. Herramientas de Software Aplicadas al Método de Regresión Lineal. 2011.
- [21] Manual IBM SPSS Forecasting 19.

XI. ANEXOS

Anexo 1. Análisis Estadístico de las DEX

Id_DEX	% Ventas	% Ingresos	Periodos	C.V.	% Perdidos
1	3.50%	3.40%	137	34%	6%
4	6.00%	5.80%	137	22%	15%
5	3.20%	3.20%	137	25%	11%
11	3.00%	3.10%	137	23%	8%
12	1.60%	1.60%	137	32%	3%
13	3.20%	3.10%	137	26%	2%
15	2.50%	2.40%	137	24%	9%
16	1.30%	1.30%	137	26%	16%
17	4.10%	4.00%	137	24%	4%
18	3.10%	3.00%	137	36%	16%
21	3.30%	3.30%	137	22%	5%
22	2.50%	2.50%	137	25%	17%
24	3.10%	3.00%	137	25%	3%
26	1.00%	1.20%	137	40%	6%
27	3.00%	3.00%	137	30%	17%
28	0.80%	0.90%	137	33%	5%
29	3.00%	3.00%	137	25%	16%
31	5.70%	5.60%	127	39%	2%
32	1.20%	1.10%	104	67%	9%
34	2.00%	2.10%	137	32%	6%
35	1.80%	2.00%	120	47%	7%
36	3.10%	3.10%	137	26%	18%
37	1.00%	1.10%	137	41%	19%
38	3.10%	2.90%	137	56%	3%
39	2.60%	2.60%	139	35%	5%
40	2.50%	2.40%	137	48%	4%
41	5.20%	5.20%	137	63%	13%
42	1.90%	1.90%	137	45%	6%
45	1.40%	1.40%	135	45%	11%
48	1.00%	1.00%	119	33%	4%
49	0.80%	0.80%	119	29%	18%
50	0.40%	0.50%	105	50%	22%
51	0.60%	0.60%	97	39%	19%
52	0.80%	0.80%	64	33%	3%
53	4.20%	4.20%	59	28%	15%
54	1.20%	1.20%	49	45%	6%
55	3.50%	3.60%	52	51%	16%
56	2.40%	2.70%	45	31%	8%
59	1.70%	1.80%	43	51%	10%

Fuente: Elaboración propia

Anexo 2. SKU's Seleccionados

prod_id	Nombre producto	Marca	Variedad
30	Aceite Soya 200cc 24 Bot	Friol	Súper Económico
31	Aceite 500cc 24 Bot	Friol	Súper Económico
32	Aceite Soya 1Lt 12 Bot	Friol	Súper Económico
4096	Nu. Aceite 200cc 24 Bot	Cil	Económico
4097	Nu. Aceite 500cc 24 Bot	Cil	Económico
4098	Nu. Aceite 1L 12 Bot	Cil	Económico

Fuente: Elaboración Propia

Anexo 3. Análisis Estadístico de SKU's

prod_id	Precio ⁵ (lt)	% Ventas ⁶	% Ingresos ⁷	Periodos ⁸	C.V. ⁹
30	4.61	4.2%	4.5%	140	33%
31	4.63	5.1%	5.3%	140	40%
32	4.27	14.6%	14.3%	140	24%
4096	4.20	3.9%	4.3%	121	33%
4097	4.54	4.8%	5%	122	35%
4098	4.14	18.8%	18.3%	129	26%

Fuente: Elaboración propia

Anexo 4. Coef. De Variación: Shares y Precios

SKU	Share	Precio
30	12%	1,8%
31	12%	1,3%
32	9%	1,7%
4096	13%	1,8%
4097	9%	1,6%
4098	9%	1,7%

Fuente: Elaboración Propia.

⁵ Precio promedio en soles por litro en 2014.

⁶ Litros vendidos por SKU como porcentaje de la venta de todos los SKUs incluidos en la tabla en los últimos 20 periodos. Se consideraron 20 periodos ya que a partir de este punto ya existían todos los SKU's presentes en la tabla.

⁷ Ingresos por SKU como porcentaje del ingreso de todos los SKUs incluidos en la tabla en los últimos 20 periodos.

⁸ Cantidad de periodos con historia transaccional por SKU.

⁹ Coeficiente de variación.

Anexo 5: Método de estimación de demanda a nivel de SKU

I. MODELO DE PARTICIPACIÓN DE MERCADOS

Los modelos de participación de mercados son modelos utilizados para entender cómo las decisiones de marketing mix (precio, promoción, atributos de productos, etc) sobre cada producto afectan las ventas. La competencia es uno de los elementos centrales en la composición de estos modelos.

Mediante la utilización de modelos Logit multinomiales (MNL) para describir la probabilidad de compra, se desarrolla un modelo de pronóstico de demanda que incorpora atributos y niveles más allá de la marca. Este modelo entrega la participación de mercado o probabilidad de compra de determinado producto dada la atracción que ella genere en los consumidores, dada la combinación de atributos que lo describan.

$$P_i = \frac{\exp(v_i)}{\sum_{i'} \exp(v_{i'})}$$

P_i = probabilidad de elección del ítem i (participación de mercado)

v_i = componente determinística de la utilidad del i – ésimo ítem

$\exp(v_i)$ atractivo de la marca i

Y v_{it} puede ser descrito como

$$v_i = \alpha_i + \sum_1^K \beta_k X_{ki} + \varepsilon_i$$

X_{ki} = valor de la k – ésima variable explicativa de la marca i

K = cantidad de variables explicativas

β_{kt} = parámetro a estimar

α_i = utilidad intrínseca de consumir la marca i

ε_i = error

Linealizando,

$$\log \frac{P_i}{\bar{P}} = v_i = \alpha_i^* + \sum_1^K \beta_k (X_{ki} - \bar{X}_{ki}) + \varepsilon_i^*$$

$$\bar{P} = \text{media geométrica}$$

$$\bar{P} \text{ y } \bar{X}_{ki} = \text{medias aritméticas}$$

$$\alpha_i^* = \alpha_i - \bar{\alpha}$$

$$\varepsilon_i^* = \varepsilon_i - \bar{\varepsilon}$$

II. MODELO DE ATRIBUTOS

Bell, Bronfer y Chintagunta (BCC) desarrollaron un nuevo modelo a nivel de atributo que permite recuperar los parámetros de preferencias a nivel de SKU desde un nivel más agregado. En particular muestra cómo la estimación del parámetro de efecto fijo para cada SKU j se encuentra relacionada con las estimaciones de efectos fijos a nivel de atributo.

BCC demuestran cómo los parámetros de los dos modelos, el agregado a nivel de atributo y desagregado a nivel de SKU, están relacionados cuando cada modelo contiene sólo efectos fijos.

El modelo se basa en crear relaciones analíticas entre los productos y los atributos que los componen, de esta manera basta estimar los parámetros del modelo solo utilizando información de atributos y a partir de cálculos se llega a los parámetros a nivel de SKU. Por otra parte, los parámetros que entrega el modelo se utilizan para recobrar elasticidades a nivel de atributos y a nivel de SKU, y además se utilizan para realizar estimaciones de demanda. Soluciona problemas como la cantidad de modelos necesarios, la cantidad de parámetros a estimar y la cantidad de información necesaria para modelar.

BCC parte del supuesto de que los consumidores no entran a una tienda en busca de un determinado producto (SKU), sino en busca de satisfacer alguna necesidad general de consumo. Solo harán la elección al observar los productos disponibles. Optarán por el SKU que posea la combinación de atributos que le entregue la mayor utilidad como cliente.

Para esto, se caracterizan los productos de la categoría en función de sus atributos y niveles. Por ejemplo, los atributos de una bebida podrían ser marca, sabor, formato y tamaño. Los niveles podrían corresponder a lata y botella dentro del atributo formato.

Supondremos que la utilidad que un producto le genera a las personas es función aditiva de la combinación de sus atributos y niveles más el efecto de otras variables de marketing como precio y promociones. A partir de esto, se busca calibrar el aporte de los distintos atributos y niveles de utilidad a la utilidad que cada SKU genera al consumidor, para luego generar una estimación de demanda para cada SKU por separado.

En general, al enfrentar la problemática de pronósticos de demanda, las cadenas utilizan enfoques agregados a nivel de categoría o nivel de marca. El problema de este enfoque es que no considera que el consumidor al enfrentar la góndola selecciona un SKU en base a un conjunto de atributos de productos los cuales tienden a ser directos y tangibles.

Los atributos seleccionados para describir la categoría deben cumplir con los siguientes criterios:

1. El atributo tiene que ser reconocible por los consumidores, es decir, debe ser fácilmente identificable ante una exploración casual por parte del consumidor.
2. El atributo y los niveles deben ser objetivos, no deben haber ambigüedades en la definición
3. Los atributos y niveles deben ser aplicables a todos los productos de la categoría, es decir, todos los SKU pueden ser descritos en forma única por una combinación de atributos y niveles.

Datos de entrada

El modelo requiere de los siguientes datos: Definición de un bien de referencia (de ahora en adelante (*outside good*), *share* de cada producto, matriz de descripciones producto – atributo y características de la góndola (precio, promociones, etc.). Cada uno de ellos debe estar referido a una unidad de tiempo específica, la cual puede ser días, semanas, meses, etc. El detalle de los datos necesarios es el siguiente:

Outside good

Representa la alternativa de no consumir (i.e. utilidad igual a 0), y se utiliza para referenciar las utilidades de los productos a su valor. Se puede estimar de dos maneras:

- Estimando el mercado potencial del producto y calculando cual es la diferencia entre las ventas reales y las potenciales en cada unidad de tiempo.
- Eligiendo algún SKU para referenciar las utilidades hacia ella. En este caso es necesario referenciar además, todas las características de la góndola con respecto al SKU escogido.

Independiente de la manera de estimar el *outside good*, nos referiremos a él con el subíndice 0.

Market shares

Representa el porcentaje de las ventas que tiene cada producto, incluido el *outside good*. Se calcula dividiendo las ventas de cada producto por las ventas totales, en cada unidad de tiempo.

Características de la góndola

Representan la presencia o ausencia de elementos que pueden influir sobre las ventas de los productos. Se utiliza entre ellas el precio de cada producto en cada unidad de tiempo y se pueden agregar otro tipo de datos como la presencia de publicidad, promociones, etc. Para efectos explicativos se trabajará solo con el precio, aunque se puede utilizar cualquier otro tipo de variable, siempre y cuando se encuentre centrado sobre la media. Además se requiere conocer qué SKUs están efectivamente disponibles en góndola en cada periodo de tiempo.

Relación productos - atributos

Describen la pertenencia (o no pertenencia) de un producto a un determinado nivel de un atributo, en otras palabras, es una manera de describir cada producto como un conjunto de atributos. La notación usual es mediante matrices producto - atributo.

Partiendo en base a un modelo MNL, se escribe la participación de mercado de un SKU_j en un periodo t (P_{jt}) en términos de la utilidad que genera cada SKU (v_{jt}). Existen dos maneras de utilizar este enfoque:

- 1. Considerando un bien de referencia ficticio creado para representar lo NO comprado por los clientes.**

$$P_{jt} = \frac{\exp(v_{jt})}{1 + \sum_k^J \exp(v_{kt})}$$

La utilidad de consumir el bien de referencia está dada por:

$$P_{0t} = \frac{1}{1 + \sum_k^J \exp(v_{kt})}$$

De ambas ecuaciones y mediante una transformación lineal se obtiene

$$\ln(P_{jt}) - \ln(P_{S_{0t}}) = v_{jt}$$

Además, la utilidad se puede escribir en función del precio del producto j en el tiempo t:

$$v_{jt} = \beta + \gamma(p_{jt} - \bar{p}_j) + \varepsilon_{jt}$$

\bar{p}_j = precio promedio del producto j

Es decir, la utilidad que un producto le reporta a un consumidor está relacionado con su precio. Mientras mayor sea el precio del producto, mayor será la utilidad que este tenga para un consumidor. A nivel de atributos se tienen las siguientes expresiones (análogas a nivel de producto o SKU):

$$\varphi_{lt}^b = \log(P_{lt}^b) - \log(P_{ot})$$

$$\varphi_{lt}^b = \alpha_l^b + \gamma^b(\bar{P}_{lt}^b - \bar{\bar{P}}_{lt}^b) + \omega_{bt} \quad (1)$$

φ_{lt}^b : utilidad del nivel l del atributo b en el tiempo t

\bar{P}_{lt}^b : participación de mercado del nivel l del atributo b en el tiempo t. Se obtiene al sumar la participación de mercado de todos los SKU que pertenecen a ese nivel.

γ^b : efecto del precio en el atributo b

$$\overline{Precio}_{lt}^b = \sum_{i=1}^{N_b} \frac{S_{it}}{S_{lt}^b} p_{it} : \text{peso del precio relativo al nivel l del atributo b}$$

$$\overline{\overline{Precio}}_l^b = \text{promedio sobre t de } \overline{Precio}_{bt}$$

Se puede demostrar que el efecto fijo β_j se puede obtener a partir del intercepto α_b que se obtiene a nivel de atributos:

$$\beta_j = \alpha_b - \frac{1}{T} \sum_{t=1}^T \log \frac{P_{jt}^b}{P_{jt}}$$

Es decir, con este enfoque basado en atributos y realizando una regresión simple (ecuación 1), se pueden obtener los parámetros necesarios para tener la utilidad de un determinado SKU, y, por ende, su participación de mercado.

A través de una segunda regresión simple, se puede recuperar el efecto del precio γ , utilizando la siguiente ecuación:

$$\mu_{jt} - \beta_j = \gamma(p_{jt} - \bar{p}_j) + \varepsilon_{jt}$$

En este caso la variable de marketing incluida es el precio, pero puede ser extendida a cualquier otra.

Dado que este modelo estima las participaciones de mercado considerando el outside good, para el cálculo de las ventas a nivel de SKU se necesita una estimación de demanda de un mercado *potencial*, es decir, incluyendo todos los clientes que entran a la sala pero que no necesariamente compran los productos de la categoría en estudio.

Así, el mercado potencial está dado por

$$\hat{M}_t = \hat{V}O_t + VT_t$$

Donde

VO_t : ventas del outside good en t

VT_t : ventas totales de la categoría en el periodo t

Las ventas pronosticadas para cada SKU están dadas entonces por:

$$\hat{V}_{jt} = \hat{P}_{jt} \cdot \hat{M}_t$$

2. **Sin la existencia de un bien de referencia:** El procedimiento es idéntico pero se calcula la participación de mercado entre los productos existentes dentro de la categoría. Así,

$$P_{jt} = \frac{\exp(v_{jt})}{\sum_k^J \exp(v_{kt})}$$

Para recuperar los parámetros a nivel de SKU es necesario estimar la demanda a nivel de categoría. Luego, las ventas por SKU se calculan como

$$\hat{V}_{jt} = \hat{P}_{jt} \cdot \hat{VT}_t$$


Donde \hat{VT}_t = venta total de la categoría. Esta estimación se realizará con algún modelo de estimación de demanda, escogido de acuerdo a diversas evaluaciones de los beneficios y costos de las diferentes opciones existentes.

Anexo 5.1. Aplicación Modelo de Atributos

A continuación, se quiere desagregar este cálculo a nivel de SKU. Para esto, se utilizará el modelo de atributos descrito en el marco conceptual.

El primer paso consiste en la exploración visual. Gráficamente, la evolución de los shares de los productos en la DEX 4 se ve como sigue:


Gráfico. Shares de los SKU's en DEX4.



Fuente: Elaboración Propia.

Adicionalmente, la evolución de los precios en el mismo periodo se expone a continuación:

Gráfico. Precio por litro por SKU



Fuente: Elaboración Propia.

Se observa que la participación varía más que lo que varían los precios (ver Anexo 5), ya que pareciera que éstos en general se mantienen relativamente constantes. Este no es un buen indicio para la utilización del modelo de atributos, ya que se concluye que existen otras variables o factores externos que pudieran afectar la demanda además del precio.

Los atributos considerados para la utilización del modelo de atributos son los siguientes:

Atributo	Niveles
Tamaño	200 cc.
	500 cc.
	1 lt.
Marca	Friol
	Cocinero
	Cil
	Capri
Variedad	Primor
	Súper Económico
	Económico
	Premium

Fuente: Elaboración Propia.

No se contaba con información del resto de los atributos de los productos. Existía el atributo origen, pero este campo no estaba especificado para todos los productos en estudio. Por este motivo fue descartado.

Así, los niveles que describen a los SKU's pertenecientes a la DEX 4 son los siguientes:


SKU	Tamaño	Marca	Variedad
30	200 cc.	Friol	Super Económico
31	500 cc.	Friol	Super Económico
32	1 lt	Friol	Super Económico
4096	200 cc.	Cil	Económico
4097	500 cc.	Cil	Económico
4098	1 lt	Cil	Económico

Fuente: Elaboración Propia.

El Modelo de Atributos fue calibrado mediante la utilización de un código en Matlab.

Los resultados obtenidos fueron los siguientes:

Gráfico. Shares Pronosticados por SKU, DEX 4.



Fuente: Elaboración Propia.

A primera vista se observa que los shares pronosticados varían muchísimo menos que los shares reales, y que tampoco captura la tendencia de los datos. A propósito de los resultados, se concluye que este modelo no es apropiado para utilizarlo en este caso específico ya que:

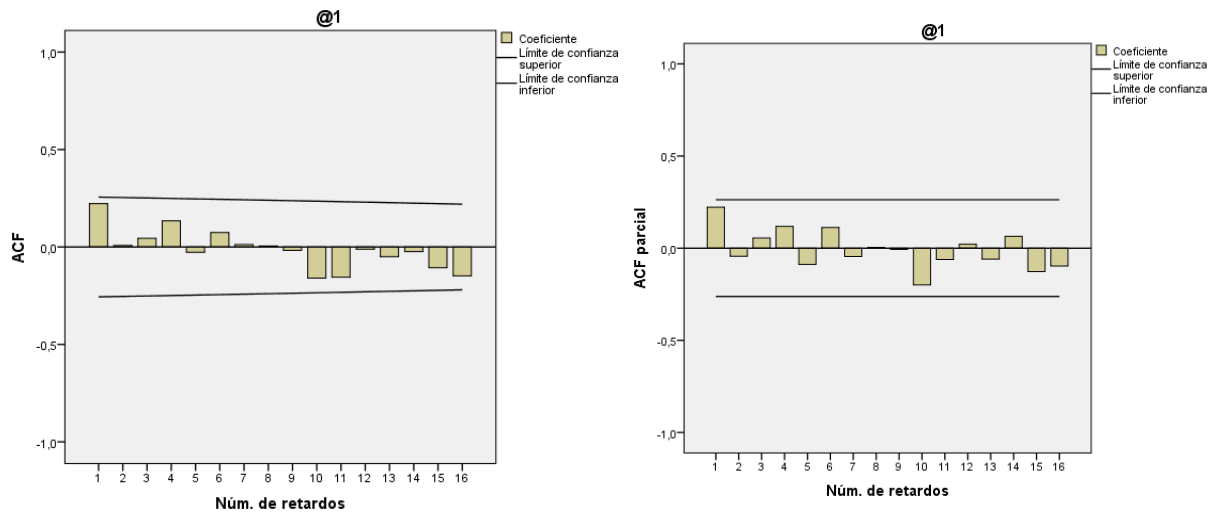
- No se están estudiando todos los SKU's que existen en realidad, lo que podría generar sesgos. Como se explicó previamente, en la etapa de limpieza de datos se filtraron aquellas series que no cumplían con ciertos criterios de calidad, i.e largo apropiado y una







cantidad de datos perdidos aceptable. Entre las situaciones que se podrían generar, por ejemplo, está que un SKU que no estuviera en estudio (SKU X) fuera sustituto de otro que sí está en estudio. Ambos SKU's aumentan su precio, pero el SKU X lo aumenta en una mayor proporción. Parte de los clientes que antes compraban el SKU X ahora comprarán el otro. Al haber eliminado al SKU X, lo único que somos capaces de observar es que un SKU en estudio aumentó su precio y aumentó su participación.







- Por construcción, el Modelo de Atributos es incapaz de capturar tendencias.
- No se tiene información acerca de factores externos que pudieran afectar la demanda, i.e marketing mix, entre otros.
- El cliente que genera las transacciones no es el consumidor final. El modelo se basa en el supuesto de que el cliente observa todas sus opciones y escoge el producto que le genere mayor utilidad. Pero en este caso, las ventas se realizan a minoristas, quienes a su vez revenderán el producto al consumidor final. Por lo tanto, este cliente no escoge la mejor elección entre las disponibles, sino que compra una variedad de productos para que los clientes finales realicen su elección. Por lo tanto, los datos transaccionales no reflejan el proceso de elección de un consumidor.





Cabe destacar que el modelo de atributos fue utilizado sobre los shares calculados sobre los litros y sobre las unidades. Ninguno de los dos modelos obtuvo buenos resultados.







Anexo 6. Autocorrelación (ACF) y Autocorrelación Parcial (ACF parcial) por DEX



































































Anexo 7. Parámetros de Modelos ARIMA

Parámetros del modelo AR(4) para DEX 1

				Estimación	ET	t	Sig.
@1		Constante		89,514	1,248	71,699	,000
		AR	Retardo 1	,025	,131	,194	,847
			Retardo 2	,090	,130	,694	,491
			Retardo 3	,170	,143	1,189	,240
			Retardo 4	,321	,150	2,140	,037
ventas0	Sin transformación	Numerador	Retardo 0	-16,284	2,993	-5,441	,000
ventas_bajas	Sin transformación	Numerador	Retardo 0	-1,695	,852	-1,988	,052

Parámetros del modelo ARIMA(1,0,1) para DEX 4

				Estimación	ET	t	Sig.
@4		Constante		135,128	1,973	68,499	,000
		AR	Retardo 1	,848	,151	5,620	,000
		MA	Retardo 1	,583	,232	2,519	,015
semana2_mes	Sin transformación	Numerador	Retardo 0	-3,690	1,597	-2,311	,025
fin_mes	Sin transformación	Numerador	Retardo 0	11,450	1,633	7,010	,000
ventas_bajas	Sin transformación	Numerador	Retardo 0	-2,893	1,157	-2,500	,016
ventas0	Sin transformación	Numerador	Retardo 0	-15,193	4,670	-3,253	,002

Parámetros del modelo AR(2) para DEX 5

				Estimación	ET	t	Sig.
@5	Sin transformación	Constante		1561,464	644,787	2,422	,019
		AR	Retardo 1	,037	,129	,287	,775
			Retardo 2	,333	,136	2,454	,017
@DEX1	Sin transformación	Numerador	Retardo 0	,609	,080	7,575	,000

Parámetros del modelo ARIMA(0,1,1) para DEX 11

				Estimación	ET	t	Sig.
@11	Sin transformación	Diferencia MA	Retardo 1	1 ,572	,114	4,997	,000
@DEX1	Sin transformación	Numerador Diferencia	Retardo 0	,716 1	,129	5,542	,000

Parámetros del modelo ARIMA(9,1,0) para DEX 12

				Estimación	ET	t	Sig.
dex12	Sin transformación	AR	Retardo 1	-,647	,142	-4,548	,000
			Retardo 2	-,507	,175	-2,900	,006
			Retardo 3	-,345	,196	-1,764	,085
			Retardo 4	,081	,204	,400	,691
			Retardo 5	,301	,201	1,496	,142
			Retardo 6	,248	,212	1,173	,247
			Retardo 7	,093	,209	,445	,659
			Retardo 8	-,022	,186	-,116	,908
			Retardo 9	-,331	,156	-2,128	,039
ventas0	Sin transformación	Diferencia	1				
		Numerador	Retardo 0	-535,582	287,759	-1,861	,049
ventas_bajas	Sin transformación	Numerador	Retardo 0	275,635	117,385	2,348	,023

Parámetros del modelo ARIMA(1,1,0) para DEX 13

				Estimación	ET	t	Sig.
dex13	Sin transformación	AR	Retardo 1	-,489	,120	-4,085	,000
		Diferencia		1			

Parámetros del modelo ARIMA(0,1,1) para DEX 15

				Estimación	ET	t	Sig.
Dex15	Sin transformación	Diferencia MA	Retardo 1	1 ,888	,075	11,819	,000
semana2_mes	Sin transformación	Numerador	Retardo 0	-820,581	326,260	-2,515	,015
fin_mes	Sin transformación	Numerador	Retardo 0	688,617	349,222	1,972	,054

Parámetros del modelo ARIMA(9,0,0) para DEX 16

				Estimación	ET	t	Sig.
@16	Sin transformación	Constante		5834,559	353,016	16,528	,000
		AR	Retardo 1	,155	,126	1,229	,225
			Retardo 2	,185	,128	1,439	,157
			Retardo 3	,094	,129	,731	,468
			Retardo 4	,081	,130	,623	,536
			Retardo 5	-,221	,128	-1,730	,090
			Retardo 6	-,062	,131	-,470	,641
			Retardo 7	,522	,132	3,943	,000
ventas0	Sin transformación	Numerador	Retardo 0	-3043,419	467,044	-6,516	,000
fin_mes	Sin transformación	Numerador	Retardo 0	490,128	190,357	2,575	,013
ventas_bajas	Sin transformación	Numerador	Retardo 0	-331,587	127,968	-2,591	,013

Parámetros del modelo ARIMA(1,0,0) para DEX17

				Estimación	ET	t	Sig.
@17	Sin transformación	Constante		20100,931	369,350	54,422	,000
		AR	Retardo 1	-,323	,129	-2,498	,016
ventas0	Sin transformación	Numerador	Retardo 0	-8887,514	1887,840	-4,708	,000

Parámetros del modelo ARIMA(2,0,0) para DEX 18

				Estimación	ET	t	Sig.
@18	Sin transformación	Constante		18608,467	1365,779	13,625	,000
		AR	Retardo 1	,285	,137	2,084	,042
			Retardo 2	,210	,137	1,529	,032
ventas0	Sin transformación	Numerador	Retardo 0	-9077,479	4015,558	-2,261	,028
ventas_bajas	Sin transformación	Numerador	Retardo 0	1096,875	1199,427	,914	,045

Parámetros del modelo ARIMA(1,0,1) para DEX 21

				Estimación	ET	t	Sig.
@21	Raíz cuadrada	Constante		130,066	3,513	37,022	,000
		AR	Retardo 1	,915	,098	9,321	,000
		MA	Retardo 1	,679	,178	3,813	,000
ventas0	Sin transformación	Numerador	Retardo 0	-14,011	5,801	-2,415	,019
ventas_bajas	Sin transformación	Numerador	Retardo 0	-4,022	1,784	-2,255	,028

Parámetros del modelo ARIMA(3,0,1) para DEX 22

				Estimación	ET	t	Sig.
@22	Sin transformación	Constante		4437,211	1736,549	2,555	,014
		AR	Retardo 1	-,868	,278	-3,117	,003
			Retardo 2	-,115	,197	-,581	,564
			Retardo 3	,142	,175	,808	,043
		MA	Retardo 1	-,785	,251	-3,133	,003
@DEX1	Sin transformación	Numerador	Retardo 0	,563	,215	2,615	,012
ventas_bajas	Sin transformación	Numerador	Retardo 0	-650,959	321,034	-2,028	,048

Parámetros del modelo ARIMA(16,0,0) para DEX 24

				Estimación	ET	t	Sig.
@24	Sin transformación	Constante		13973,109	814,642	17,152	,000
		AR	Retardo 1	-,090	,137	-,653	,517
			Retardo 2	,236	,150	1,571	,124
			Retardo 3	,213	,154	1,384	,174
			Retardo 4	-,194	,157	-1,241	,222
			Retardo 5	-,315	,165	-1,906	,064
			Retardo 6	,255	,155	1,646	,108
			Retardo 7	,315	,164	1,919	,062
			Retardo 8	,065	,159	,409	,685
			Retardo 9	-,255	,167	-1,526	,135
			Retardo 10	-,304	,160	-1,902	,065
			Retardo 11	,267	,156	1,716	,094
			Retardo 12	,177	,162	1,094	,281
			Retardo 13	-,109	,155	-,705	,485
			Retardo 14	-,120	,148	-,811	,422
			Retardo 15	,033	,149	,221	,827
			Retardo 16	,558	,133	4,203	,000

ventas0	Sin transformación	Numerador	Retardo 0	-3516,560	1575,721	-2,232	,031
ventas_bajas	Sin transformación	Numerador	Retardo 0	-1377,338	342,094	-4,026	,000

Parámetros del modelo ARIMA(2,0,0) para DEX 26

				Estimación	ET	t	Sig.
@26	Sin transformación	Constante		4151,900	160,057	25,940	,000
		AR	Retardo 1	-,030	,127	-,235	,815
			Retardo 2	,383	,128	2,998	,004
ventas0	Sin transformación	Numerador	Retardo 0	-1111,864	405,525	-2,742	,008

Parámetros del modelo ARIMA(6,0,0) para DEX 27

				Estimación	ET	t	Sig.
@27	Sin transformación	Constante		17103,773	389,870	43,871	,000
		AR	Retardo 1	,336	,140	2,401	,020
			Retardo 2	-,202	,143	-1,417	,163
			Retardo 3	-,081	,150	-,537	,594
			Retardo 4	-,051	,148	-,344	,733
			Retardo 5	,146	,143	1,018	,314
			Retardo 6	-,321	,135	-2,368	,022
ventas_bajas	Sin transformación	Numerador	Retardo 0	-965,885	435,680	-2,217	,031

Parámetros del modelo ARIMA(3,0,0) para DEX 28

				Estimación	ET	t	Sig.
@28	Sin transformación	AR	Retardo 1	,169	,131	1,291	,202
			Retardo 2	,431	,117	3,674	,001
			Retardo 3	,393	,131	2,994	,004
ventas0	Sin transformación	Numerador	Retardo 0	-884,778	630,028	-1,404	,166
ventas_bajas	Sin transformación	Numerador	Retardo 0	-351,087	177,715	-1,976	,054
ventas_altas	Sin transformación	Numerador	Retardo 0	361,402	152,395	2,371	,021

Parámetros del modelo ARIMA(9,0,0) para DEX 29

				Estimación	ET	t	Sig.
@29	Sin transformación	Constante		16154,737	237,100	68,135	,000
		AR	Retardo 1	,269	,143	1,887	,066
			Retardo 2	-,131	,149	-,880	,384
			Retardo 3	,115	,141	,811	,422
			Retardo 4	-,147	,149	-,989	,328
			Retardo 5	-,190	,149	-1,276	,209
			Retardo 6	,078	,155	,501	,619
			Retardo 7	-,227	,157	-1,448	,155
			Retardo 8	,168	,165	1,016	,315
			Retardo 9	-,293	,157	-1,867	,068
ventas0	Sin transformación	Numerador	Retardo 0	-4383,690	1043,180	-4,202	,000

Parámetros del modelo ARIMA(1,0,0) para DEX 31

				Estimación	ET	t	Sig.
@31	Sin transformación	Constante		7888,616	846,837	9,315	,000
		MA	Retardo 1	,691	,118	5,874	,000
@DEX1	Sin transformación	Numerador	Retardo 0	,844	,107	7,903	,000
ventas_altas	Sin transformación	Retardo		6			
		Numerador	Retardo 0	-557,269	93,483	-5,961	,000
			Retardo 2	562,456	169,837	3,312	,002
		Denominador	Retardo 1	1,265	,097	12,992	,000
			Retardo 2	-,647	,069	-9,437	,000

Parámetros del modelo ARIMA(4,0,0) para DEX36

				Estimación	ET	t	Sig.
@36	Sin transformación	Constante		12805,743	1020,319	12,551	,000
		AR	Retardo 1	,318	,134	2,377	,021
			Retardo 2	,245	,143	1,713	,093
			Retardo 3	-,053	,144	-,369	,713
			Retardo 4	,314	,139	2,265	,028
ventas0	Sin transformación	Numerador	Retardo 0	-2901,296	909,935	-3,188	,002

Parámetros del modelo ARIMA(1,0,1) para DEX 37

				Estimación	ET	t	Sig.
@37	Sin transformación	Constante		1541,197	779,218	1,978	,053
		AR	Retardo 1	-,886	,143	-6,191	,000
		MA	Retardo 1	-,992	,247	-4,020	,000
@DEX1	Sin transformación	Numerador	Retardo 0	,309	,097	3,193	,002
ventas_bajas	Sin transformación	Numerador	Retardo 0	-330,425	132,060	-2,502	,015

Parámetros del modelo ARIMA(1,0,0) para DEX 40

				Estimación	ET	t	Sig.
dex40	Sin transformación	Constante		8600,403	269,854	31,871	,000
		AR	Retardo 1	,288	,134	2,151	,036
ventas_bajas	Sin transformación	Numerador	Retardo 0	-729,526	319,876	-2,281	,027
ventas0	Sin transformación	Numerador	Retardo 0	-1865,175	1031,747	-1,808	,076
ventas_altas	Sin transformación	Numerador	Retardo 0	512,045	259,248	1,975	,054
semana2_mes	Sin transformación	Numerador	Retardo 0	-1245,842	388,750	-3,205	,002

Parámetros del modelo ARIMA(0,0,1) para DEX 41

				Estimación	ET	t	Sig.
dex41	Sin transformación	Constante		10425,247	135,415	76,987	,000
		MA	Retardo 1	-,303	,131	-2,315	,024
ventas_bajas	Sin transformación	Numerador	Retardo 0	-376,858	174,022	-2,166	,035
ventas0	Sin transformación	Numerador	Retardo 0	-1929,458	588,706	-3,277	,002

Parámetros del modelo ARIMA(5,0,0) para DEX 50

				Estimación	ET	t	Sig.
@50	Sin transformación	AR	Constante	134.641	5.949	22.631	,000
			Retardo 1	,002	,132	,012	,991
			Retardo 2	,512	,135	3.788	,000
			Retardo 3	,180	,150	1.207	,234
			Retardo 4	-,131	,140	-,934	,355
ventas_bajas	Sin transformación	Numerador	Retardo 5	-,407	,142	-2.873	,006
			Retardo 0	-23.003	6.052	-3.801	,000

Parámetros del modelo ARIMA(0,1,1) para DEX 51

				Estimación	ET	t	Sig.
dex51	Sin transformación	Diferencia		1			
		MA	Retardo 1	,727	,116	6,275	,000
ventas_bajas	Sin transformación	Retardo		8			
		Numerador	Retardo 0	-115,343	42,132	-2,738	,009
		Diferencia		1			
ventas0	Sin transformación	Numerador	Retardo 0	-474,039	136,784	-3,466	,001
		Diferencia		1			

Anexo 8. Métricas de Comparación Modelos ARIMA versus Actual.

DEX	ALICORP			ARIMA					NIVEL MEJORA		
	PRONÓSTICO			CALIBRACIÓN		PRONÓSTICO			PRONÓSTICO		
	WMAPE	WMAPE AGREGADO	R2	WMAPE	R2	WMAPE	WMAPE AGREGADO	R2	WMAPE	WMAPE AGREGADO	R2
1	16%	13%	0%	9%	47%	11%	9%	66%	31%	31%	66%
4	18%	14%	2%	7%	61%	9%	9%	90%	50%	36%	88%
5	22%	19%	0%	11%	60%	13%	9%	56%	41%	53%	56%
11	14%	15%	3%	7%	81%	8%	5%	70%	43%	67%	67%
12	29%	12%	24%	19%	89%	24%	5%	28%	17%	58%	4%
13	12%	10%	16%	6%	68%	9%	3%	36%	25%	70%	19%
15	17%	9%	17%	13%	25%	11%	4%	25%	35%	56%	8%
16	18%	7%	2%	18%	54%	15%	4%	31%	17%	43%	30%
17	13%	5%	1%	9%	26%	11%	1%	39%	15%	80%	38%
21	9%	4%	1%	7%	38%	8%	3%	60%	11%	25%	58%
22	10%	8%	0%	10%	32%	5%	1%	85%	50%	88%	85%
24	13%	7%	4%	14%	33%	11%	2%	48%	15%	71%	44%
27	15%	12%	0%	14%	74%	13%	10%	40%	13%	17%	40%
28	23%	11%	0%	11%	28%	15%	11%	53%	35%	0%	53%
29	10%	6%	8%	10%	71%	7%	2%	60%	30%	67%	52%

31	23%	13%	0%	5%	76%	8%	2%	71%	65%	85%	71%
36	13%	1%	17%	9%	48%	9%	1%	58%	31%	0%	41%
37	20%	15%	6%	11%	38%	10%	1%	62%	50%	93%	56%
40	16%	1%	7%	12%	35%	14%	1%	16%	13%	0%	9%
41	10%	7%	10%	23%	44%	7%	5%	74%	30%	29%	64%
50	22%	6%	27%	18%	39%	21%	2%	30%	5%	67%	3%
51	23%	15%	0%	27%	58%	16%	1%	23%	30%	93%	23%
PROMEDIO	17%	10%	7%	12%	51%	12%	4%	51%	30%	51%	44%

Fuente: Elaboración Propia.

Anexo 9. Nivel de Reducción del Error en Pronóstico de Shares

SKU's

DEX/SKU	30	31	32	4096	4097	4098
1	21%	8%	0%	0%	6%	29%
4	0%	1%	0%	0%	0%	14%
5	8%	5%	8%	9%	1%	11%
11	0%	0%	8%	0%	6%	25%
12	18%	0%	21%	7%	16%	6%
13	0%	0%	5%	2%	0%	4%
15	0%	2%	2%	1%	1%	0%
16	1%	1%	0%	0%	0%	0%
17	8%	17%	0%	8%	0%	0%
18	5%		0%	2%	35%	1%
21	0%	1%	0%	0%	6%	13%
22	32%	1%	0%	0%	9%	41%
24	0%	11%	46%	16%	0%	20%
27	0%	0%	1%	33%	0%	0%
28	2%	8%	10%	7%	1%	7%
29	27%	25%	33%	24%	0%	35%
31	11%	1%	35%	8%	0%	36%
36	4%	0%	22%	8%	12%	20%
37	0%		2%	7%	29%	21%
40			3%	9%	1%	8%
41	0%	5%	0%	0%	0%	5%
42			14%			14%
48	2%		0%	0%	0%	9%
50	0%					
51	0%	3%	23%	9%	5%	10%

Fuente: Elaboración Propia.

Anexo 10. WMAPE Final Modelo Alicorp

SKU						
DEX	30	31	32	4096	4097	4098
1	23%	24%	22%	21%	24%	14%
4	18%	17%	21%	17%	15%	13%
5	27%	25%	37%	14%	21%	19%
11	14%	19%	24%	15%	18%	14%
12	30%	29%	45%	23%	32%	38%
13	18%	17%	16%	24%	20%	13%
15	18%	19%	21%	33%	17%	17%
16	25%	20%	18%	21%	36%	26%
17	16%	17%	7%	16%	11%	14%
21	15%	15%	11%	12%	9%	11%
22	38%	22%	14%	15%	19%	10%
24	19%	26%	22%	23%	21%	12%
27	17%	22%	21%	17%	15%	17%
28	34%	34%	25%	36%	25%	24%
29	32%	22%	18%	18%	14%	11%
31	22%	22%	30%	14%	19%	16%
36	16%	22%	19%	19%	15%	21%
37	33%		66%	27%	16%	21%
40			28%	18%	15%	21%
41	23%	30%	28%	21%	25%	15%
50	21%					
51	37%	32%	43%	22%	19%	33%

Fuente: Elaboración Propia.

Anexo 11. WMAPE Final Modelo Propuesto

SKU						
DEX	30	31	32	4096	4097	4098
1	16%	17%	17%	14%	19%	11%
4	14%	11%	14%	12%	11%	6%
5	14%	14%	26%	13%	19%	12%
11	9%	14%	9%	10%	17%	8%
12	30%	28%	35%	16%	28%	32%
13	16%	12%	11%	23%	20%	15%
15	16%	18%	16%	32%	18%	12%
16	24%	22%	16%	24%	35%	22%
17	12%	20%	11%	16%	15%	17%
21	12%	13%	10%	11%	10%	11%
22	22%	15%	8%	8%	11%	7%
24	16%	18%	15%	19%	17%	12%
27	14%	19%	17%	18%	14%	18%
28	23%	23%	17%	18%	16%	19%
29	21%	16%	10%	12%	10%	7%

31	10%	12%	11%	11%	10%	10%
36	12%	22%	15%	14%	8%	13%
37	20%		44%	19%	14%	17%
40			28%	17%	17%	22%
41	23%	28%	27%	21%	24%	17%
50	21%					
51	22%	14%	16%	23%	21%	30%

Fuente: Elaboración Propia.

Anexo 12. Porcentaje Reducción de Error Modelos Propuestos vs Alicorp

SKU						
DEX	30	31	32	4096	4097	4098
1	32%	26%	23%	34%	21%	18%
4	25%	36%	35%	26%	29%	54%
5	49%	44%	32%	8%	10%	36%
11	36%	25%	64%	29%	8%	38%
12	2%	4%	23%	30%	11%	16%
13	8%	27%	32%	3%	1%	11%
15	10%	3%	24%	3%	3%	29%
16	4%	9%	15%	14%	2%	14%
17	26%	15%	62%	0%	36%	26%
21	20%	11%	9%	3%	3%	6%
22	43%	32%	43%	44%	43%	34%
24	14%	30%	33%	17%	21%	0%
27	19%	13%	20%	9%	10%	1%
28	32%	33%	33%	50%	36%	21%
29	36%	26%	42%	33%	25%	40%
31	57%	44%	65%	25%	49%	37%
36	25%	0%	20%	24%	48%	37%
37	40%		34%	32%	10%	19%
40			2%	6%	12%	6%
41	2%	7%	2%	1%	3%	10%
50	3%					
51	40%	55%	62%	5%	13%	8%

Fuente: Elaboración Propia.

Anexo 13 Evaluación Económica Modelo Propuesto versus Actual

DEX	SKU	Sobreestock Modelo Propuesto	Sobreestock Modelo Alicorp	Costo Modelo Propuesto (PEN)	Costo Modelo Alicorp (PEN)
1	1	1306	2047	2241	3513
4	4	3489	4352	5990	7470
5	5	472	2096	811	3598
11	11	514	1790	933	3251

12	12	528	201	901	343
13	13	-199	1086	261	1855
15	15	-800	535	1050	913
16	16	496	785	846	1339
17	17	-157	836	209	1446
21	21	409	483	749	884
22	22	778	1439	1419	2622
24	24	-424	315	557	538
27	27	523	824	928	1463
28	28	64	420	114	750
29	29	1944	3529	3419	6206
31	31	-162	3988	214	6854
36	36	-408	-161	572	226
37	37	186	647	324	1124
41	41	3995	3983	6864	6844
50	50	-25	141	32	238
51	51	249	603	426	1031
1	1	1042	1610	1690	2612
4	4	1647	2822	2671	4577
5	5	282	1283	457	2081
11	11	-54	1467	73	2563
12	12	-43	235	54	387
13	13	-1023	3946	1296	6495
15	15	-1352	1254	1708	2061
16	16	454	852	747	1401
17	17	990	2922	1644	4855
21	21	46	495	80	871
22	22	80	438	140	767
24	24	1926	3921	3168	6449
27	27	2142	2439	3676	4186
28	28	-51	642	67	1098
29	29	522	2682	888	4560
31	31	-130	3479	163	5649
36	36	2463	2132	4321	3740
41	41	3688	3949	5986	6410
51	51	198	715	325	1176
1	1	3230	4227	4977	6514
4	4	8759	10976	13503	16921
5	5	1995	4512	3072	6947
11	11	-1608	9443	2034	15536
12	12	798	2912	1246	4548
13	13	536	7904	838	12367
15	15	-2879	4970	3459	7762
16	16	583	1230	910	1921

17	17	-3868	18	4699	29
21	21	5450	5881	8991	9702
22	22	1564	3492	2529	5646
24	24	860	8847	1344	13825
27	27	5475	6458	8755	10327
28	28	-320	1531	394	2451
29	29	-860	7293	1048	11555
31	31	-2944	10062	3495	15528
36	36	3547	4537	5827	7454
37	37	3173	5445	5041	8650
40	40	-433	-1917	525	2323
41	41	6326	6310	9759	9734
51	51	-66	2277	80	3561
1	1	1835	2444	3213	4280
4	4	2892	3789	5064	6633
5	5	483	1209	846	2117
11	11	244	635	461	1197
12	12	101	-103	177	138
13	13	-20	378	27	668
15	15	-424	5	569	8
16	16	80	154	140	268
17	17	-965	-678	1300	913
21	21	469	540	868	999
22	22	549	1223	1036	2306
24	24	283	6	499	11
27	27	1134	-112	2062	157
28	28	345	1010	653	1913
29	29	6	-1093	10	1460
31	31	-379	2634	511	4620
36	36	-748	-1444	1062	2051
37	37	-189	209	256	369
40	40	-588	-601	835	853
41	41	3889	3876	6818	6795
51	51	-75	-10	102	14
1	1	1107	1490	1858	2501
4	4	1426	1867	2393	3134
5	5	589	1042	989	1749
11	11	411	224	734	400
12	12	-456	-604	589	780
13	13	-631	1867	825	3175
15	15	25	283	42	475
16	16	884	1025	1483	1719
17	17	-695	535	902	902
21	21	1135	764	2051	1379

22	22	238	1299	425	2321
24	24	-606	62	792	105
27	27	397	560	695	979
28	28	216	1083	387	1940
29	29	-179	417	230	697
31	31	-146	2279	189	3831
36	36	-75	-781	104	1083
37	37	-508	-300	663	392
40	40	726	574	1271	1005
41	41	2060	2054	3457	3447
51	51	-213	-46	279	60
1	1	50	-190	78	228
4	4	949	1368	1478	2129
5	5	1736	2820	2703	4390
11	11	2	687	3	1157
12	12	662	1295	1056	2066
13	13	-2429	1742	3018	2814
15	15	-644	1673	789	2666
16	16	-50	545	61	870
17	17	-5401	1472	6657	2359
21	21	4292	-1050	7045	1325
22	22	665	-25	1103	32
24	24	-2852	-1615	3541	2005
27	27	3305	3966	5388	6466
28	28	-2096	1089	2727	1842
29	29	-1661	-3010	1991	3607
31	31	-918	4103	1101	6395
36	36	-4092	-6419	5159	8092
37	37	-1750	2047	2171	3301
40	40	788	1059	1281	1722
41	41	3436	2710	5355	4223
51	51	-506	-114	628	141
		COSTO TOTAL		240739	415420