

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL



**FACULTAD DE CIENCIAS NATURALES Y MATEMÁTICAS
UNIDAD DE INVESTIGACIÓN Y POSTGRADO**

**PROYECTO DE TITULACIÓN
PREVIO A LA OBTENCIÓN DEL TÍTULO DE:
“MAGÍSTER EN LOGÍSTICA Y TRANSPORTE CON MENCIÓN
MODELOS DE OPTIMIZACIÓN”**

**TEMA:
DISEÑO DE UN MODELO DE PRONÓSTICO DE DEMANDA PARA
MEJORAR EL STOCK DE UNA EMPRESA IMPORTADORA DE
PRODUCTOS PARA LABORATORIO CLÍNICO**

**AUTOR:
AVENDAÑO FIGUEROA KAREN ALEXANDRA**

Guayaquil - Ecuador

2020

RESUMEN

En el presente trabajo de investigación se buscó encontrar la mejor metodología de pronóstico de demanda para lograr una mejora en el abastecimiento de productos de una marca de reactivos de química clínica de una empresa importadora de Guayaquil, de esta forma se logrará reducir el índice de producto caducado en la empresa y que no exista desabastecimiento para el mercado. Para lograrlo, se realizó una vasta observación de las ventas reales de los últimos 5 años, se establecieron ítems Pareto para obtener los que representan el 80% de las ventas y se analizaron varios modelos de pronóstico entre los que se encuentran la Suavización Exponencial y los métodos de ARIMA, escogiendo por cada ítem el modelo que más se ajuste a la venta real. También se realizó un análisis por perfil de producto, ya que al ser reactivos para laboratorio clínico, tienen la peculiaridad que deben ser realizados de manera conjunta para un mejor diagnóstico clínico. Seguidamente, se logró llegar a un resultado óptimo para cada ítem y se demuestra que se logró disminuir el porcentaje de producto caducado anual. Finalmente se llegan a varias conclusiones del estudio y se realizan diversas recomendaciones a la empresa para optimizar el abastecimiento y la venta.

ABSTRACT

Through this research work, the main objective was found the best methodology for Demand Forecasting in order to achieve an improvement in the supply of products from a brand of clinical chemistry reagents from an importing company in Guayaquil, so it could help to reduce the index of expired products in the company and the purpose to not have any shortage for the market. To achieve this, the author made a vast observation of the real sales of the last 5 years, and she established the Pareto items with the intention to obtain those that represent 80% of sales. Also, various forecast models were analyzed, including Exponential Smoothing and ARIMA methods, choosing for each item the model that best fits the real sales. An analysis by product profile was also carried out, due to the products are reagents for clinical laboratories they have the peculiarity that they must be carried out together for a better clinical diagnosis. Subsequently, an optimal result was achieved for each item and it is shown that the percentage of annual expired product was reduced. Finally, several conclusions of the study are reached and various recommendations are made to the company to optimize supply and sales.

DEDICATORIA

Dedico el presente trabajo, en primer lugar a mis padres Julio y Alexandra, y mi abuelita Bélgica que siempre han sido, son y serán un constante apoyo en mi vida desde el inicio de mis estudios colegiales cuando era niña, luego con mis estudios universitarios y ahora finalmente con mis estudios de postgrado, también se lo dedico a mi hermana Jocelyne, que ha estado muy pendiente del desarrollo de este trabajo de investigación y a quien considero mi inspiración, ya que tomó la decisión de estudiar una carrera bastante pesada como medicina y que muy pronto logrará culminarla con el mayor de los éxitos. Finalmente, pero no menos importante una dedicatoria especial a mi esposo Hugo que ha sido una compañía constante y un gran soporte dentro de todo el trayecto recorrido para lograr culminar con la mayor de las satisfacciones esta tesis.

AGRADECIMIENTO

En primer lugar, quiero agradecer a Dios por permitirme culminar con éxito el presente trabajo de investigación, a pesar de las adversidades que se han presentado en las últimas semanas.

Así mismo quiero agradecer a mi tutor que siempre ha estado pendiente del desarrollo y avance de la presente tesis y motivando constantemente para lograr culminarlo a tiempo.

También un gran reconocimiento a la empresa en donde laboro, quienes confiaron en mi conocimiento y capacidad para el desarrollo de este estudio, además fueron quienes lograron facilitar la información respectiva para culminar exitosamente este estudio y que así mismo logró mejorar la eficiencia de la empresa.

Finalmente, un agradecimiento especial a la Escuela Superior Politécnica del Litoral por permitirnos a los profesionales en logística obtener más conocimientos técnicos y ponerlos en práctica dentro de nuestro ámbito profesional.

DECLARACIÓN EXPRESA

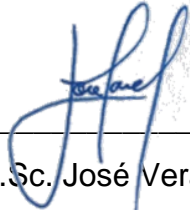
La responsabilidad por los hechos y doctrinas expuestas en este Proyecto de Titulación, me corresponde exclusivamente y ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría. El patrimonio intelectual del mismo, corresponde exclusivamente a la ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

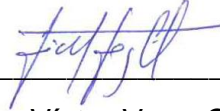


Karen Alexandra Avendaño Figueroa

TRIBUNAL DE GRADUACIÓN



M.Sc. José Vera Aray
PRESIDENTE



M.Sc. Víctor Vega Chica
DIRECTOR



Omar Ruiz Barzola Ph.D.
VOCAL 1



M.Sc. Pedro Ramos de Santis
VOCAL 2

ABREVIATURAS O SIGLAS

- AES: Additive Exponential Smoothing, Suavización Exponencial Adaptativa.
- Análisis Pareto: Distribución 80/20, el 80% de las ganancias está establecido en el 20% de los productos.
- Cadena de Suministro: son los procesos establecidos dentro de las empresas de forma directa o indirecta que incluye a proveedores, líneas de producción, almacenes, medios de distribución, canales mayoristas y minoristas hasta llegar al cliente final.
- DES: Double Exponential Smoothing, Doble Suavización Exponencial.
- Efecto Látigo: se refiere a la tendencia de cambios que se tienen en el inventario en respuesta a los requerimientos de la demanda. La variación de la demanda del mercado hace que cada eslabón en la cadena de suministro contribuye con una mayor cantidad de stock para responder, entre más se aleje de la demanda, mayor es su variación.
- Know-how: “saber cómo”, hace referencia a como las empresas tienen el conocimiento teórico y práctico para ejecutar sus actividades de manera eficaz, eficiente y efectiva.
- MRP: Material Requirements Planning, Planeación de Requerimiento de Materiales.
- SKU: Stock Keeping Unit, Unidad de Mantenimiento en Almacén.
- Stock: en español conocido como inventario, es la cantidad de productos que tiene la organización destinado para varios fines.

TABLA DE CONTENIDO

RESUMEN.....	II
ABSTRACT.....	III
DEDICATORIA	IV
AGRADECIMIENTO	V
DECLARACIÓN EXPRESA	VI
TRIBUNAL DE GRADUACIÓN	VII
ABREVIATURAS O SIGLAS.....	VIII
TABLA DE CONTENIDO	IX
LISTADO DE FIGURAS.....	XII
LISTADO DE GRÁFICOS.....	XII
LISTADO DE TABLAS.....	XIII
CAPÍTULO 1	1
1. INTRODUCCIÓN.....	1
1.1. Antecedentes.....	1
1.2. Descripción y justificación del problema.....	2
1.3. Objetivos.....	3
1.3.1. Objetivo General.....	3
1.3.2. Objetivos Específicos	3
1.4. Hipótesis	3
1.5. Alcance	3
1.6. Metodología	4
CAPÍTULO 2.....	5
2. MARCO TEÓRICO	5
2.1. Demanda	5
2.1.1. Características de la Demanda.....	6

2.1.2.	Clasificación de la Demanda	7
2.2.	Pronóstico.....	9
2.2.1.	Importancia del Pronóstico	10
2.2.2.	Características de los pronósticos	11
2.2.3.	Factores relacionados con el pronóstico de la demanda	11
2.2.4.	Papel del pronóstico de la demanda en la cadena de abastecimiento .	12
2.3.	Procedimiento para pronosticar la demanda	12
2.3.1.	Entender el objetivo del pronóstico	12
2.3.2.	Integrar la planeación y el pronóstico de la demanda en la cadena de suministro.....	12
2.3.3.	Entender e identificar los segmentos de clientes	13
2.3.4.	Identificar los principales factores que influyen en el pronóstico de la demanda	13
2.3.5.	Determinar la técnica apropiada de pronóstico	13
2.3.6.	Establecer medidas de desempeño y error para el pronóstico.....	13
2.4.	Tipos de Pronóstico	14
2.4.1.	Cualitativos	14
2.4.2.	Series de Tiempo.....	15
2.4.3.	Causal	19
2.4.4.	Simulación	20
2.5.	Análisis de Series temporales	21
2.5.1.	Modelos AR, MA y Mixtos.....	21
2.6.	Cálculo de Errores de pronóstico	23
2.7.	Método de pronóstico apropiado.....	23
2.8.	Pronósticos en el Sector de la Salud.....	25
CAPÍTULO 3.....		26
3.	METODOLOGÍA	26

3.1. Marco Metodológico.....	26
3.2. Análisis de los datos	28
3.2.1. Análisis general de las ventas	28
3.2.2. Análisis por grupo	31
3.2.3. Análisis por producto	32
3.2.4. Análisis de productos por perfil	35
3.2.5. Análisis de Tendencia y Estacionalidad	40
3.3. Diseño de Modelos de Pronóstico.....	41
3.4. Análisis de Sensibilidad y Error	54
3.4.1. Sensibilidad del modelo de pronóstico	54
3.4.2. Error del modelo de pronóstico	56
CAPÍTULO 4.....	65
4. RESULTADOS	65
4.1. Resultados preliminares.....	65
4.2. Resultados finales acumulados.....	73
CAPÍTULO 5.....	74
5. Conclusiones y Recomendaciones	74
6. Próximas Líneas de Investigación.....	76
7. Referencias.....	78
8. Apéndices y anexos	79
8.1. Anexo A: Cronograma de la Tesis	79
8.2. Apéndice A: Modelos de los Pareto B	81
8.3. Apéndice A: Modelos de los Pareto C.....	83

LISTADO DE FIGURAS

Ilustración 1 – Flujo del Proyecto de Investigación.....	4
Ilustración 2 – Demanda Estocástica o Aleatoria	8
Ilustración 3 – Demanda con Tendencia Creciente	8
Ilustración 4 – Demanda con Tendencia Decreciente	8
Ilustración 5 – Demanda Estacional Envolvente	9
Ilustración 6 – Demanda Estacional Escalón	9

LISTADO DE GRÁFICOS

Gráfico 1 – Ventas vs Caducado 2018.....	2
Gráfico 2 – Participación de Ventas	29
Gráfico 3 – Pareto de Marcas	30
Gráfico 4 – Tendencia de Ventas.....	41
Gráfico 5 – Comparación de Pronósticos vs Real Ácido Úrico	56
Gráfico 6 – Comparación de Pronósticos vs Real Colesterol	57
Gráfico 7 – Comparación de Pronósticos vs Real Creatinina	58
Gráfico 8 – Comparación de Pronósticos vs Real Glucosa	58
Gráfico 9 – Comparación de Pronósticos vs Real HDL Colesterol	59
Gráfico 10 - – Comparación de Pronósticos vs Real LDL Colesterol.....	60
Gráfico 11 – Comparación de Pronósticos vs Real Lipasa.....	60
Gráfico 12 – Comparación de Pronósticos vs Real TGO Cinético.....	61
Gráfico 13 – Comparación de Pronósticos vs Real TGP Cinético	62
Gráfico 14 – Comparación de Pronósticos vs Real Triglicéridos	62
Gráfico 15 – Comparación de Pronósticos vs Real Urea Color	63
Gráfico 16 – Comparación de Pronósticos vs Real Urea Cinética.....	64
Gráfico 17 – Pronóstico Ventas 2019.....	65
Gráfico 18 – Relación Ventas vs Pronóstico Ácido Úrico	66
Gráfico 19 – Relación Ventas vs Pronóstico Colesterol	67
Gráfico 20 – Relación Ventas vs Pronóstico Creatinina	67
Gráfico 21 – Relación Ventas vs Pronóstico Glucosa	68

Gráfico 22 – Relación Ventas vs Pronóstico HDL Colesterol	69
Gráfico 23 – Relación Ventas vs Pronóstico LDL Colesterol	69
Gráfico 24 – Relación Ventas vs Pronóstico Lipasa	70
Gráfico 25 – Relación Ventas vs Pronóstico TGO Cinético	70
Gráfico 26 – Relación Ventas vs Pronóstico TGP Cinético	71
Gráfico 27 – Relación Ventas vs Pronóstico Triglicéridos	71
Gráfico 28 – Relación Ventas vs Pronóstico Urea Color	72
Gráfico 29 – Relación Ventas vs Pronóstico Urea Cinética	73
Gráfico 30 – Ventas vs Caducado 2019.....	73

LISTADO DE TABLAS

Tabla 1 – Componentes de las Series de Tiempo.....	15
Tabla 2 – Errores de Pronóstico.....	23
Tabla 3 – Resumen Métodos de Pronóstico	24
Tabla 4 – Análisis de Ventas.....	28
Tabla 5 – Crecimiento en Ventas	28
Tabla 6 – Pareto de Marcas.....	29
Tabla 7 – Análisis de Perfil de producto.....	31
Tabla 8 – Análisis Pareto en Dólares	33
Tabla 9 - Análisis Pareto en Unidades	34
Tabla 10 – Análisis Pareto Final.....	35
Tabla 11 – Sensibilidad por Modelo de Pronóstico 1	54
Tabla 12 – Sensibilidad por Modelo de Pronóstico 2	55
Tabla 13 – Resultados del Pronóstico.....	65

CAPÍTULO 1

1. INTRODUCCIÓN

1.1. Antecedentes

El segmento de laboratorio clínico alrededor del mundo está en constante crecimiento y Ecuador no es la excepción. Existen cada vez más empresas que se dedican a la importación y distribución de reactivos e instrumentos para laboratorios públicos y privados, por lo que se ha escogido a una empresa en particular de este sector, de la cual se detectó que cuenta con inconvenientes en su abastecimiento de producto, el mismo que tiene problemas con la caducidad de algunos otros productos, por lo que se necesita encontrar un punto medio en donde la demanda no se quede desabastecida y se minimice la pérdida por producto caducado.

La empresa en estudio representa alrededor de 40 marcas para el mercado ecuatoriano; siendo de éstas, 7 marcas que representan el 80% de las ventas. El estudio se basará en la marca número 1. Esta marca tiene varias líneas de producto que maneja para distintas áreas de laboratorio, entonces el objetivo planteado será centrarse en la principal, ya que su representación en ventas se traduce en un 48.17% (ventas 2014 al 2018).

Así mismo esta empresa tiene un alto potencial de crecimiento, además de un ambicioso proyecto de fabricación local de esta misma línea de reactivos con el aval y el know-how de la empresa internacional que actualmente le supe de estos productos, he aquí la importancia principal de establecer un correcto modelo de pronóstico de demanda, el mismo que pueda servir posteriormente de base para establecer el MRP (Planificación de Requerimiento de Materiales) para cuando se inicie el proceso de fabricación nacional, el cual está previsto iniciar en dos años aproximadamente.

1.2. Descripción y justificación del problema

La empresa que se ha tomado como caso de estudio, tiene una alta complejidad al momento de desarrollar los pronósticos de venta de sus productos, ya que los clientes finales a los que atienden en su gran mayoría pertenecen al sector estatal del país, por tanto, en su mayoría de veces no cuentan con los recursos económicos suficientes para establecer compras periódicas y estables a lo largo del año fiscal. Es así, que la compañía busca siempre mantenerse provista de todo su portafolio de productos y de esta forma lograr abastecer a todos los laboratorios, clínicas, hospitales y centros de salud gubernamentales que soliciten estos productos.

Como no se tiene una metodología tecnificada para pronosticar qué y cuándo se requerirán los productos, gran parte de estos terminan caducándose dentro de la compañía, por lo que la pérdida que obtiene la empresa anualmente es bastante alta.

Como ejemplo podemos tomar el año fiscal 2018, en donde la pérdida total de la empresa ascendió a \$ 485,898 sobre una venta de \$12'588,481, en porcentaje la media representa el 4.08% de las ventas, pero al compararse con su competencia el porcentaje se reduce a penas al 2% (datos no publicados).




Gráfico 1 – Ventas vs Caducado 2018

Por tanto, se ha decidido realizar un análisis a fondo de los datos históricos con los que encuentra la empresa de la principal marca de ventas y de esta forma obtener un modelo de pronóstico adecuado para la línea de producto en general o para cada tipo de producto de manera particular.

1.3. Objetivos

1.3.1. Objetivo General

Desarrollar un modelo de pronóstico de venta para los siguientes periodos para mejorar la gestión actual del proceso de importaciones y que sirva de base para establecer un MRP para la fabricación de reactivos de manera local.

1.3.2. Objetivos Específicos

- Analizar los datos históricos de ventas, eliminando los picos y bajas de venta.
- Determinar varios modelos de pronóstico que se ajusten a los datos analizados.
- Comparar los resultados obtenidos por cada modelo y definir el que mejor se adapte a la necesidad del mercado.
- Mejorar la gestión de importaciones mediante la optimización del stock y la reducción de producto caducado.

1.4. Hipótesis

Es posible disminuir la cantidad de producto caducado de la empresa si se realiza un modelo de pronóstico de demanda adecuado para cada producto.

1.5. Alcance

El presente proyecto será realizado en una empresa Importadora de reactivos e insumos para laboratorio clínico ubicada en Guayaquil, de la misma se seleccionarán 1 marca y de esta 1 línea del Pareto de ventas más importantes para la empresa; dentro del horizonte de 6 a 12 meses a partir de la información obtenida.

1.6. Metodología

Para la realización del presente trabajo de estudio se iniciará con el análisis de los datos de ventas históricas de todas las líneas de productos proporcionados por la empresa, para entender la tendencia que podrían tener estos datos (estacionales o estacionarios), luego se realizaría el ajuste del modelo de pronóstico más conveniente de acuerdo con la información previamente obtenida de los datos. A continuación, se procederá a realizar la comparación entre varios modelos para adaptar el más conveniente a cada una de las líneas de los productos y finalmente, luego de determinado el modelo, se procedería a revisar los pronósticos respectivos versus las ventas reales.

De esta forma, y una vez obtenida la información del pronóstico con el error minimizado, se establecerá el mejor modelo de optimización para realizar las órdenes de pedidos, indicando los mínimos y máximos de stock por cada uno de los ítems.

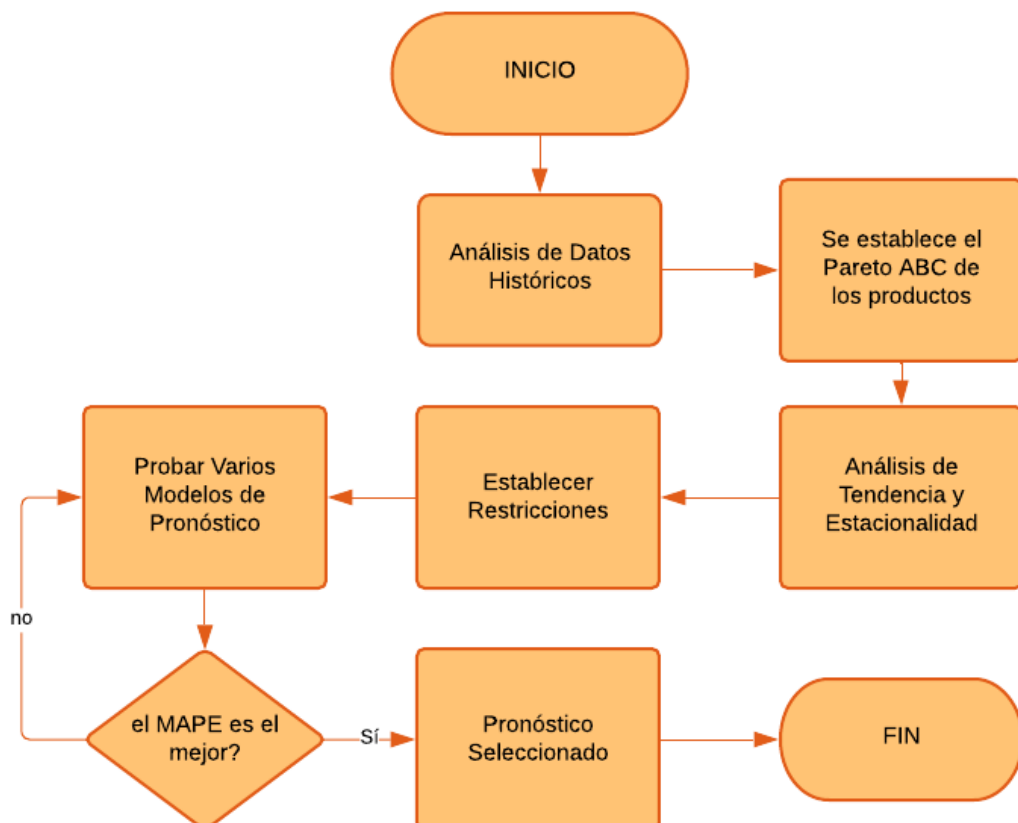


Ilustración 1 – Flujo del Proyecto de Investigación

CAPÍTULO 2

2. MARCO TEÓRICO

Para el análisis y desarrollo del presente proyecto se describirá primero el significado de demanda, su importancia, características y clasificación, luego se detallará el concepto de pronóstico y su papel dentro de la cadena de abastecimiento, finalmente se explicarán los diferentes modelos de pronóstico que existen, de tal forma que al final del capítulo se pueda determinar cuál o cuáles serían los mejores que se ajusten a la situación actual de la demanda de la empresa y finalmente escoger el que mejor se adapte para cada uno de los productos seleccionados.

Se abarcarán conceptos desde los más simples y sencillos hasta lo más complejos, ya que este análisis permitirá tener un mayor rango de elección y una mejor conclusión del modelo más óptimo.

2.1. Demanda

Existen varios conceptos de demanda según varios autores y expertos en economía y mercadotecnia.

En su libro “Dirección del Marketing” Phillip Kotler y Kevin Keller describen a la demanda como: *“El Deseo de productos específicos que están respaldados por una capacidad de pago”*. (Kotler & Keller, 2006)

Por otro lado, Carlos Rodríguez en su libro “Diccionario de Economía” conceptualiza a la demanda como: *“Las cantidades de determinado bien o servicio que los compradores están dispuestos a adquirir a cada nivel de precios. Implica entonces no solamente la intención de adquirir el bien en cuestión sino adicionalmente la disposición de los medios económicos para su realización”*. (Rodríguez, 2009).

También Rafael Pampillón en su propio significado la define de la siguiente forma: *“La demanda, como concepto económico, no se equipara simplemente con el deseo o necesidad que exista por un bien, sino que requiere además que los*

consumidores, o demandantes, tengan el deseo y la capacidad efectiva de pagar por dicho bien". (Pampillón, 2008)

Finalmente, la demanda se puede definir como la necesidad que tiene una persona, familia, empresa o cualquier consumidor en general de un producto o servicio determinado, está influenciada por un gran número de elementos que determinarán la cantidad de producto que se requiere. Algunos de estos elementos están relacionados con las preferencias del consumidor, hábitos o información que éste posea sobre el bien o servicio en el cual está interesado, así mismo como la capacidad económica que posea para adquirirlo.

2.1.1. Características de la Demanda

La demanda tiene varias características, esta puede ser:

- Continua o Discreta
 - Demanda continua: Se prevé como una función continua del tiempo
 - Demanda discreta: La que se efectúa por periodos de tiempo. Puede ser un solo periodo o múltiples periodos.

- Dependiente o independiente.
 - Demanda dependiente: Se refiere a aquellos componentes, submontajes o productos cuya cantidad es el resultado de la petición de otros productos.
 - Demanda independiente: Está limitada a las decisiones de los clientes y no puede ser anticipada.

- Diferida o Perdida
 - La demanda es diferida, si no se satisface la demanda (ruptura de stocks), por ende, será posible diferir la entrega.
 - La demanda es perdida, cuando no se satisface la demanda y no se puede esperar por la entrega, venta perdida.

2.1.2. Clasificación de la Demanda

Clasificar adecuadamente la demanda es una herramienta de mucha ayuda dentro del pronóstico de demanda establecido dentro de cada empresa, ya que cada artículo se identifica por su código, descripción y por sus propias características individuales, por tanto, sería muy complicado proyectar un modelo de diferente para cada artículo.

Por tanto, es necesario clasificar los artículos en grupos que sean relevantes para el sistema de gestión. Los cuales podemos clasificar en dos grandes grupos:

- **Demanda Determinística o Predecible:** Se dice que un producto tiene una demanda predecible cuando la cantidad y el tiempo en que han de ser entregado están confirmados. Tienen demanda predecible:
 - Artículos que deben proveerse para una campaña o promoción específica que culminará con la venta de la cantidad inicial, no generándose otro requerimiento subsiguiente.
 - Artículos suministrados previamente al lanzamiento de nueva mercancía o de una campaña o promoción de ventas. Estos productos pueden comportarse posteriormente como productos de demanda aleatoria.

- **Demanda Estocástica o Aleatoria:** Como su nombre lo indica la demanda aleatoria obedece a factores que no son controlables. Hay tres grupos:
 - **Demanda Estable:** Es aquella en la que, aunque el valor de la demanda varía, lo hace alrededor de una cifra constante a lo largo del tiempo. Por lo tanto, no hay evidencia de ninguna tendencia creciente o decreciente.

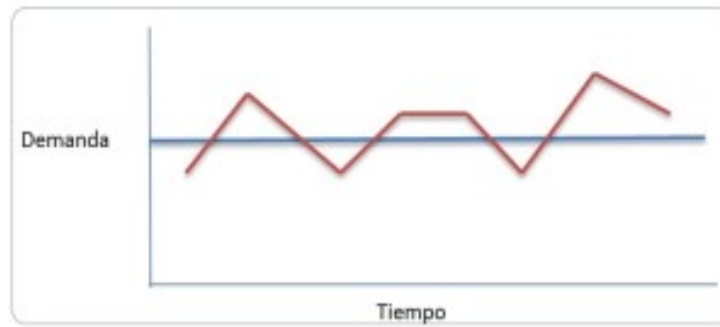


Ilustración 2 – Demanda Estocástica o Aleatoria

○ Demanda con Tendencia:

- Creciente: Es aquella en la que el valor medio de la demanda varía con el tiempo, mostrando una tendencia creciente.



Ilustración 3 – Demanda con Tendencia Creciente

- Decreciente: Es aquella en la que el valor medio de la demanda varía con el tiempo, mostrando una tendencia decreciente.




Ilustración 4 – Demanda con Tendencia Decreciente

- Demanda Estacional

- **Envolvente:** Es aquella que muestra una variación en la demanda media en diferentes puntos del ciclo de planificación, y esta variación puede relacionarse con determinados factores del mercado que tienen influencia en el comportamiento de la demanda.




Ilustración 5 – Demanda Estacional Envolvente

- **Modelo Escalón:** Los periodos de estacionalidad pueden variar desde periodos pequeños de 1 o 2 semanas, a periodos grandes de tiempo que pueden cubrir varios meses.




Ilustración 6 – Demanda Estacional Escalón

2.2. Pronóstico

Philip Kotler define al Pronóstico de ventas como: “*La estimación o nivel esperado de ventas de una empresa, línea de productos o marca de producto, que abarca un periodo de tiempo determinado y un mercado específico*”. (Kotler & Keller, 2006)

Para Stanton, Etzel y Walker, *“El pronóstico de ventas se prepara mediante un presupuesto y un programa de marketing específico. Sin embargo, cuando se ha preparado el pronóstico de ventas, atañe a todos los departamentos de la compañía. Con base en las ventas anticipadas se planea la cantidad necesaria de capital de trabajo, la utilización de la planta y las instalaciones de almacenaje. También dependen de estos pronósticos el calendario de producción, la contratación de operarios fabriles y la compra de materias primas.”* (Stanton, Etzel, & Walker, 2004)

Para resumir, el pronóstico de ventas es la proyección o estimación de las ventas de un producto o servicio durante un período de tiempo determinado. Los pronósticos determinan qué productos o servicios pueden venderse tomando en consideración la realidad y su objetivo principal es de ser el input de los planes operativos dentro de la compañía y así prever la necesidad de capital de trabajo, utilización de la planta y almacenaje y compra de materias primas.

2.2.1. Importancia del Pronóstico

Los pronósticos son esenciales para toda compañía, así como para cualquier decisión importante de la directiva, ya que es la base de la planeación corporativa a largo plazo.

Es de suma importancia en varios de los ejes principales de una organización, es así que, en las áreas funcionales de finanzas y contabilidad, los pronósticos proporcionan el fundamento para la planeación de presupuestos y el control de costos. Por otro lado, en el departamento de marketing el pronóstico de ventas sirve para planear productos nuevos, compensar al personal de ventas y tomar otras decisiones clave. Así mismo el personal de producción y operaciones utiliza los pronósticos para tomar decisiones continuas acerca de la planeación de la producción, la programación y el inventario.

Es de utilidad resaltar que, por lo regular, un pronóstico perfecto es imposible, en cuando en un ambiente de negocios hay demasiados factores que no se pueden prever con certeza, por lo tanto, en lugar de buscar el pronóstico perfecto, es mucho

más importante establecer la práctica de una revisión continua de los pronósticos y aprender a vivir con pronósticos imprecisos. Esto no quiere decir que no se trate de mejorar continuamente el modelo o la metodología de pronosticar, pero lo que se debe hacer es tratar de encontrar y usar el mejor método de pronóstico disponible, dentro de lo razonable.

2.2.2. Características de los pronósticos

- Regularmente, los pronósticos no son perfectos y casi siempre están errados, como consecuencia deben contar tanto con el valor esperado del pronóstico como un dato que indique el error de medición del mismo.
- Cuando se pronostica a largo plazo, la precisión desciende, al contrario, cuando se pronostica a corto plazo, la precisión aumenta; esto se debe a que en promedio los segundos tienen una desviación estándar menor en relación a la media de los primeros.
- Es siempre mucho mejor trabajar con pronósticos agregados que con pronósticos desagregados, ya que la precisión de los primeros es mucho más certera, dado que la desviación estándar de su error en relación a la media es menor.
- En todo pronóstico existe el efecto látigo, que es un fenómeno observado dentro de la cadena de abastecimiento en donde se ve claramente una tendencia de distorsión del inventario cuando más lejos se está del consumidor final.

2.2.3. Factores relacionados con el pronóstico de la demanda

- Demanda pasada
- Tiempo de entrega del producto
- Publicidad planeada o campañas de marketing
- Estado de la economía
- Descuentos de precio planeados
- Acciones que los competidores han tomado

2.2.4. Papel del pronóstico de la demanda en la cadena de abastecimiento

La base de toda la planeación de la cadena de suministros es el pronóstico de la demanda y siguiendo esta línea existen enfoques de proceso PULL/HALE y PUSH/EMPUJE.

- Con los procesos PULL: la ejecución se inicia en respuesta al pedido de un cliente, por tanto, en el momento de la ejecución de un proceso PULL, se conoce con certidumbre la demanda del cliente. Para los procesos de HALE la gerencia debe planificar la capacidad disponible y el inventario, pero no la cantidad exacta que se ejecutará. Finalmente, los procesos PULL se conocen como procesos reactivos.
- Con los procesos PUSH: la ejecución se inicia con la anticipación a los pedidos de los clientes, es así que en el momento de la ejecución de un proceso PUSH, la demanda no se conoce y se debe pronosticar. Para un proceso de EMPUJE, la gerencia debe planificar cada nivel de actividad tanto en producción, almacenamiento y transporte. Los procesos PUSH se denominan especulativos.

2.3. Procedimiento para pronosticar la demanda

2.3.1. Entender el objetivo del pronóstico

El primer paso es uno de los más importantes, el identificar claramente qué decisión nos lleva a realizar un pronóstico. Por ejemplo, qué cantidad se va a destinar a la producción del producto, con cuánto de inventario se debe contar, en qué punto se realiza una reposición y cuánto se debería solicitar.

Todos quienes intervienen en la toma de decisión dentro de la cadena de suministro deben estar informados de la relación entre el pronóstico y la decisión final.

2.3.2. Integrar la planeación y el pronóstico de la demanda en la cadena de suministro

Todas las actividades de la cadena de suministro deben estar atadas al pronóstico y la compañía debe velar porque esto se realice de esta forma. Las tareas encierran

básicamente la planeación de la capacidad de la planta y de la producción, la proyección de las promociones y las compras, etc. Este vínculo estar presente desde el sistema de información hasta la administración del personal de la empresa.

2.3.3. Entender e identificar los segmentos de clientes

Los segmentos de los clientes que la compañía atiende deben estar plenamente identificados, ya que los clientes pueden ser agrupados por requerimiento de servicios semejantes, capacidad de demanda, periodicidad de los pedidos, variabilidad en la demanda, etc.

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

Luego de esto, la compañía debe reconocer cuál es su demanda, su oferta y todos los aspectos que se relacionan con el producto contribuyen en el pronóstico de la demanda. Se debe identificar si la compañía está en crecimiento, en decaimiento o si está estable. Finalmente, todas las estimaciones que se realicen deben fundamentarse en la demanda total del mercado, más no en la información de ventas de la empresa

2.3.5. Determinar la técnica apropiada de pronóstico

Cuando se seleccione la mejor técnica para el pronóstico, la compañía debe visualizar los rasgos que son importantes para el pronóstico, por ejemplo: el área geográfica, grupos de productos y de clientes. La empresa debe tener claras las diferencias de la demanda con respecto a cada uno de estos rasgos ya que es muy probable que se requiera un pronóstico y una técnica diferente para cada uno.

2.3.6. Establecer medidas de desempeño y error para el pronóstico

Las empresas deben implantar mediciones palpables de las aptitudes y que de esta manera sirva para valorizar la exactitud y la conveniencia del pronóstico. Estas mediciones deben estar estrictamente en concordancia con los objetivos del negocio de donde está basado el pronóstico.

2.4. Tipos de Pronóstico

El pronóstico puede clasificarse en 4 tipos básicos: cualitativos, series de tiempo, relaciones casuales y simulación.

Puede ser complicado para la compañía decidir cuál método es el más efectivo para realizar el pronóstico, inclusive, existen varios estudios que determinan que emplear varios métodos de proyección para crear un pronóstico combinado es más conveniente que emplear un único tipo.

2.4.1. Cualitativos

Los métodos cualitativos son primordialmente subjetivos y se soportan en la percepción humana, están basados en estimaciones, juicios y opiniones del mercado. Son convenientes especialmente cuando el histórico de ventas no está disponible o los datos que se tienen no son suficientes. También se lo utiliza cuando se obtienen resultados de investigación del mercado (market intelligence) que pueden influir en el pronóstico. Este método puede funcionar también para realizar un pronóstico de demanda a largo plazo como varios años en el futuro de una nueva industria.

Los métodos cualitativos pueden ser:

- **Técnicas acumulativas:** se basa a través de la recopilación de información de quienes se encuentran al final de la cadena y que se relacionan más directamente con quien se pronostica. Por ejemplo, se puede desarrollar el pronóstico general de ventas recibiendo la información de cada uno de los vendedores que están más cerca de la zona.
- **Investigación de mercados:** se recopilan datos de diversas modalidades (encuestas, entrevistas, etc.) cuya finalidad es evidenciar alguna hipótesis que se tenga acerca del mercado. Comúnmente es usado para los pronósticos a largo plazo y para la introducción de nuevos productos.
- **Grupos de consenso:** se realizan lluvias de ideas en reuniones y la principal idea es que se realicen intercambio de opiniones y esto ayude a que se

realicen mejores pronósticos grupales, pueden participar ejecutivos, vendedores o clientes.

- Analogía histórica: hace una relación de lo que se desea pronosticar con un artículo parecido. Sirve en gran medida para planificar productos nuevos, en donde lo proyectado procede del historial de ventas de un producto similar.
- Método de Delfos: se realiza en grupo, donde colocan a un moderador y el resto del grupo responde un cuestionario. El moderador compila las respuestas y manifiesta nuevas preguntas que se presentan nuevamente al grupo. Es así que se logra cerrar un círculo de aprendizaje para todo el grupo al recibir la información, sin ninguna influencia o presión por parte de individuos dominantes.

2.4.2. Series de Tiempo

Las series de tiempo analizan la demanda o ventas pasadas como base para predecir lo que el mercado adquirirá en el futuro. Se considera una buena herramienta de pronóstico, ya que utilizan probabilidades para proyectar la repetitividad de un evento pasado, en la demanda próxima. Estos métodos son más certeros cuando el patrón de las ventas históricas no cuenta con una variabilidad alta. Son los métodos más sencillos de usar y sirven como un buen punto de inicio en un pronóstico.

Las series de tiempo poseen un componente sistemático y un componente aleatorio, es así que el objetivo de pronosticar bajo este método es realizar una predicción del primero y una estimación del segundo. En rasgos generales la información del componente sistemático está dada por un nivel, una tendencia y un factor estacional. Existen 3 formas de calcular el componente sistemático

Multiplicativo	Componente sistemático = Nivel x tendencia x factor estacional
Aditivo	Componente sistemático = Nivel + tendencia + factor estacional
Mixto	Componente sistemático = (Nivel + tendencia) x factor estacional

Tabla 1 – Componentes de las Series de Tiempo

Y, a su vez la técnica que se usa para llegar a este cálculo puede ser mediante un método estático o un método adaptativo.

- Método estático: dentro del método estático existe la hipótesis de que los estimados de nivel, tendencia y estacionalidad no varían conforme se acepta la nueva demanda, es decir se mantiene estable en el tiempo. En este caso se estiman cada uno de los parámetros en base a la información histórica y luego estos mismos valores son usados para los pronósticos futuros. Este método supone que el componente sistemático de la demanda es mixto.
- Método adaptativo: en el método adaptativo, los estimados del nivel, la tendencia y la estacionalidad se modifican luego de cada dato obtenido de la demanda. Dentro de este marco el componente sistemático también tiene una forma mixta. Se pueden considerar marcos en donde el método contenga nivel, tendencia y estacionalidad o marcos en los cuáles no existan tendencia o estacionalidad.

Por otro lado, el componente aleatorio se manifiesta en sí mismo como un error del pronóstico, el cual establece información importante que debe analizarse en el siguiente contexto:

- Se utiliza el análisis del error para determinar si el método de pronóstico seleccionado predice correctamente el componente sistemático.
- Los planes de contingencia analizados en las empresas deben considerar un error de pronóstico.

Ahora se analizará varios tipos de series de tiempo que utilizan la metodología adaptativa.

- Promedio móvil simple: se emplea cuando la demanda no cuenta ni con tendencia ni con estacionalidad, es así que:

Componente sistemático de la demanda = Nivel

Además, un promedio móvil, es útil para eliminar variaciones aleatorias del pronóstico. Su cálculo se realiza obteniendo el promedio de los datos, en

consecuencia, cada uno cuenta con el mismo peso. La fórmula se presenta a continuación.

$$F_t = \frac{A_{t-1} + A_{t-2} + A_{t-3} + \dots + A_{t-n}}{n}$$

donde:

F_t : Pronóstico del siguiente periodo

n : Número de periodos para promediar

A_{t-1} : Ocurrencia real en el periodo pasado

A_{t-2} , A_{t-3} y A_{t-n} : Ocurrencias reales hace dos periodos, hace tres periodos y así sucesivamente.

- Promedio móvil ponderado: a diferencia del promedio móvil simple, en este se ponderan los puntos más o menos que otros, acorde a la importancia, al final la suma de las ponderaciones debe ser igual a 1. La fórmula para el promedio móvil ponderado es la siguiente:

$$F_t = w_1 A_{t-1} + w_2 A_{t-2} + \dots + w_n A_{t-n}$$

donde:

w_1 : Ponderación dada a la ocurrencia real para el periodo $t - 1$

w_2 : Ponderación dada a la ocurrencia real para el periodo $t - 2$

w_n : Ponderación dada a la ocurrencia real para el periodo $t - n$

n : Número total de periodos en el pronóstico

- Suavización exponencial: los métodos de pronóstico revisados anteriormente (simple y ponderado), cuentan con una desventaja, se complica el manejo de gran cantidad de datos históricos. Con este método se agrega nueva información de dato, eliminando la anterior, por lo que se realiza el cálculo de un nuevo pronóstico, esto dado que se presume que las nuevas observaciones son más indicativas del futuro que las anteriores, es así que se consigue una probabilidad más alta de que el método sea más lógico. En conclusión, los puntos de datos recientes se ponderan más y la

ponderación sufre una reducción exponencial conforme los datos se vuelven más antiguos, cada incremento en el pasado se reduce a $(1-\alpha)$.

Componente sistemático de la demanda = Nivel

La suavización exponencial es una de la más usadas de las técnicas de pronóstico, ya que es usada con mucha frecuencia al ordenar el inventario de las empresas, la técnica usada es aceptada de forma general por las siguientes razones:

- Son más precisos.
- Son más sencillos de formular.
- El usuario entiende el modelo.
- Se usa pocos cálculos para usar el modelo.
- El requerimiento de memoria del computador es bajo, dado al uso limitado de datos históricos.
- Es fácil calcular las pruebas de precisión con respecto al funcionamiento del modelo.

Solo son necesarios tres elementos para realizar un pronóstico con suavización exponencial: el pronóstico más actual, la demanda real ocurrida durante el tiempo de pronóstico y la constante α que es la encargada de determinar el nivel de uniformidad y velocidad de reacción a la diferencia del pronóstico versus la ocurrencia real.

La ecuación para un pronóstico es la siguiente:

$$F_t = F_{t-1} + \alpha(A_{t-1} - F_{t-1})$$

donde:

F_t = El pronóstico suavizado exponencialmente para el periodo t

F_{t-1} = El pronóstico suavizado exponencialmente para el periodo anterior

A_{t-1} = La demanda real para el periodo anterior

α = El índice de respuesta deseado, o la constante de suavización

Existen variantes de la Suavización exponencial, dado que se le realizan correcciones por tendencia y correcciones por tendencia y estacionalidad.

- El método de suavización exponencial con corrección por tendencia (modelo de Holt) es adecuado cuando se supone que la demanda tiene un nivel y una tendencia en el componente sistemático, pero no estacionalidad, por lo que se tiene:

Componente sistemático de la demanda = nivel + tendencia

- El método de suavización exponencial con corrección por tendencia y estacionalidad (modelo de Winter) es adecuado cuando el componente sistemático de la demanda tiene un nivel, una tendencia y el factor estacional, así se tiene:

Componente sistemático de la demanda = (nivel + tendencia) x factor estacional

La constante de suavización alfa α , es un valor que se debe asignar entre 0 y 1, por lo que es importante realizar una correcta elección de este valor. Si la demanda real se considera estable, es prudente asignar un valor de alfa bajo para reducir los cambios a corto plazo, mientras si la demanda real aumenta o disminuye con rapidez se debe asignar un valor de alfa alto.

- **Análisis de regresión lineal:** se define como una relación funcional entre 2 o más variables correlacionadas, es así que ajusta una recta a los datos pasados casi siempre en relación con el valor de los datos. La técnica de ajuste más común es la de los mínimos cuadrados.

El principal inconveniente al utilizar el pronóstico de regresión lineal es que supone que los datos pasados y los pronósticos futuros caerán sobre una recta. También es usada para pronósticos causales.

2.4.3. Causal

Cuando se habla de métodos causales se estima que existe una alta correlación entre el pronóstico de la demanda y las variables exógenas (económicas, sociales, políticas, etc.), es decir comprenden la técnica profunda que rodea el elemento que

se va a pronosticar, por lo que emplean estimaciones de cómo se comportarán estas variables en una demanda futura. Por ejemplo, las compañías utilizan estos métodos para establecer cuál sería el impacto de una promoción basada en el precio sobre la demanda.

- **Análisis de regresión:** es parecido al método de los mínimos cuadrados en las series de tiempo, pero con la diferencia de que contiene diversas variables. Se basa principalmente en que el pronóstico es desarrollado debido a la probabilidad de la ocurrencia de otros eventos.
- **Modelos econométricos:** en donde se intenta describir cierto sector de la economía mediante varias ecuaciones interdependientes.
- **Modelos de entrada/salida:** Se basa en las ventas de una empresa a otros tipos de empresas y muestra la variación en las ventas que una industria productora de bienes puede esperar en consecuencia a los cambios en las compras por parte de la otra industria.
- **Principales indicadores:** Se indican en base a estadísticas que se van desplazando hacia el mismo lado que el ciclo que se está pronosticando, pero en primera instancia. Por ejemplo, un aumento en el precio de la gasolina repercutirá en una caída de las ventas de carros.

2.4.4. Simulación

Buscan reproducir la selección inicial del cliente que dará origen al deseo del mercado para llegar al pronóstico final, regularmente son modelos dinámicos realizados por software especiales y permiten a quien realiza las proyecciones establecer hipótesis sobre las variables endógenas y las variables exógenas. Usando la simulación y dependiendo de las variables que contenga el modelo, la empresa puede fusionar varios de los modelos de series de tiempo para contestar varias interrogantes como, por ejemplo: ¿qué impacto tendría una promoción en el precio?, las líneas aéreas realizan simulaciones para predecir cómo los pasajeros realizarán sus compras de asiento de tarifa alta, cuando no hay disponibilidad de asientos para tarifa baja.

2.5. Análisis de Series temporales

A finales del siglo XX existen nuevos desarrollos y nuevas propuestas para la modelación de series temporales, las cuales son consideradas bastante eficaces, ya que han logrado tratar con cualquier patrón de datos y producir pronósticos más precisos en base a los históricos analizados. Específicamente estos modelos son llamados modelos de autoregresión (AR), de medias móviles (MA), integrados (I) y sus posibles combinaciones entre ellos (ARMA, ARIMA).

La principal diferencia entre estos nuevos modelos y los clásicos es el enfoque estocástico que se les da a las series de tiempo en lugar de considerarlas de forma determinística. El objetivo de este nuevo enfoque es tratar de identificar el modelo probabilístico que represente las características principales del comportamiento de la serie (Aguirre, 1994).

Los modelos de series de tiempo pueden ser clasificados como:

- Univariantes: sólo se considera una serie de tiempo en función de su propio histórico.
- Multivariantes: el análisis se realiza en varias series de tiempo a la vez, donde se supone que hay una proporción de dependencia o relación entre los históricos de ambas series.

Cuando las observaciones se toman solamente en momentos específicos de tiempo, normalmente en tiempos iguales, se refiere a una serie de tiempo discreta, mientras que cuando se cuentan con un número infinito de observaciones, se denomina serie de tiempo continua.

2.5.1. Modelos AR, MA y Mixtos

- Proceso de ruido blanco: es una secuencia de variables aleatorias mutuamente independientes e idénticamente distribuidas.
- Modelo no estacionario de corrido aleatorio – (I): son las situaciones en donde la aleatoriedad tienden a sumarse o integrarse a medida que pasa el tiempo, la integración refleja una tendencia.

- Modelo autorregresivo de orden p – AR(p): es un modelo basado en la premisa de que una observación específica es predecible a partir de la observación anterior (modelo autorregresivo de primer orden) o a partir de dos observaciones anteriores (modelo autorregresivo de segundo orden).

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_3 Y_{t-3} + \dots + \varphi_p Y_{t-p} + a_t$$

donde:

Y_t = Es la variable dependiente

$Y_{t-1}, Y_{t-2}, Y_{t-p}$ = Son las variables independientes

a_t = Error o término residual

- Modelo medias móviles de orden q – MA(q): en este modelo una observación específica está relacionada por la aleatoriedad de las observaciones previas, es así que la observación presente es definida como la suma del impulso actual más la aleatoriedad de las anteriores con un peso determinado.

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

donde:

Y_t = Es la variable dependiente

$a_{t-1}, a_{t-2}, a_{t-p}$ = Son los valores anteriores del error

a_t = Error o término residual

- Modelo autorregresivo de medias móviles de orden p,q – ARMA(p,q): en este modelo se combinan las estructuras definidas anteriormente modelo autorregresivo y modelo de medias móviles, es así que estas observaciones se determinan tanto por observaciones específicas de datos previos como por la aleatoriedad de otras observaciones.

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

- Modelo autorregresivo integrado de medias móviles de orden p,d,q – ARIMA (p,d,q): al igual que en el modelo ARMA, es la unión de los modelos autorregresivos y el de medias móviles, con la principal característica de incluir un proceso de integración, es decir, el número de diferencias que hay que considerar en la serie para que sea estacionaria.

$$Y'_t = \varphi_1 Y'_{t-1} + \varphi_2 Y'_{t-2} + \dots + \varphi_p Y'_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

donde:

$Y'_t =$ Es la serie integrada a la estabilidad

2.6. Cálculo de Errores de pronóstico

El término de error dentro del pronóstico se refiere a la diferencia entre el valor que se pronosticó y el valor obtenido en la realidad.

<p>MSE: Una medida del error es el error medio cuadrático (Mean Square Error MSE), el cual está relacionado con la varianza del error del pronóstico.</p>	$MSE_n = \frac{1}{n} \sum_{t=1}^n E_t^2$
<p>MAD: También existe el término desviación absoluta media (Mean Absolute Deviation MAD) que es el promedio de la desviación absoluta durante todos los periodos.</p>	$MAD_n = \frac{1}{n} \sum_{t=1}^n A_t$
<p>MAPE: Finalmente el error medio absoluto porcentual (Mean Absolute Percentage Error MAPE) que es el error absoluto promedio y es expresado en forma de porcentaje.</p>	$MAPE_n = \frac{\sum_{t=1}^n \left \frac{E_t}{D_t} \right }{n} 100$

Tabla 2 – Errores de Pronóstico

2.7. Método de pronóstico apropiado

Los modelos de pronóstico por series de tiempo son los más comúnmente usados para realizar predicciones, a continuación, se presenta un cuadro en donde se resumen de mejor forma las características de cada uno, en donde se entiende por término de corto al periodo menor a 3 meses, mediano a un periodo entre 3 meses y 2 años y largo plazo al periodo de más de 2 años.

De manera general, se puede decir que los pronósticos dados en términos de corto plazo ajustan la variación aleatoria en el momento inmediato, mientras que los de mediano plazo son usados para predecir efectos estacionales y finalmente los de

largo plazo muestran tendencias generales y son útiles para identificar grandes cambios en la demanda.

Método de Pronóstico	Monto de Datos Históricos	Patrón de los Datos	Horizonte de Pronóstico
Promedio Móvil Simple	6 a 12 meses, a menudo se utilizan datos semanales	Los datos deben ser estacionarios	Corto a mediano
Promedio Móvil Ponderado y Suavización exponencial Simple	Para empezar, se necesitan de 5 a 10 observaciones	Los datos deben ser estacionarios	Corto
Suavización Exponencial con Tendencia	Para empezar, se necesitan de 5 a 10 observaciones	Estacionarios y tendencias	Corto
Regresión Lineal	De 10 a 20 observaciones; para la temporalidad, por lo menos 5 observaciones por temporada	Estacionarios, tendencias y temporalidad	Corto a mediano

Tabla 3 – Resumen Métodos de Pronóstico

Para realizar un adecuado modelo pronóstico, las empresas deben considerar lo siguiente:

1. La perspectiva de tiempo que se va a pronosticar.
2. La factibilidad de los datos.
3. La exactitud que se necesita.
4. La cantidad de presupuesto para el pronóstico.
5. Disponibilidad del personal idóneo.
6. Adaptabilidad a los cambios.

2.8. Pronósticos en el Sector de la Salud

Cabe recalcar que no se halló evidencia de que existan otros estudios específicos para disminuir el índice de caducidad de los productos de una empresa del sector de diagnóstico clínico, solamente existen estudios dentro del sector de la salud para realizar pronósticos, en donde se analizan modelos de suavización exponencial y modelos ARIMA para analizar tendencias y estacionalidad de los datos.

Es así que, se realizó una revisión de una tesis del 2015 realizada en la Escuela Superior Politécnica del Litoral en donde se desarrolla un Modelo de Crecimiento en Ventas para un Laboratorio Farmacéutico utilizando un Modelo Estadístico de Proyección (Cruz Gomez, 2015).

En este estudio, se toman en consideración otro tipo de métodos estadísticos ya que la finalidad es desarrollar un modelo de ventas. Un ejemplo es que desarrollan un modelo matemático de punto de cambio, esto permite analizar la relación entre las ventas y los descuentos establecidos, para lograr una mejor acogida del mercado, por consiguiente, una mayor proyección en ventas, mientras que el presente estudio establece un pronóstico de ventas que mejore el abastecimiento de los productos y reduzca el porcentaje de productos caducados en la compañía.

Luego el autor de este estudio realiza el desarrollo del pronóstico de la demanda, utilizando la información de ventas de los años 2011, 2012 y 2013 y buscan realizar la proyección del año 2014, se emplearon varios modelos de pronóstico como ARIMA con estacionalidad, Promedio Móvil Simple y Doble, Suavización Exponencial Aditiva y Doble Suavización Exponencial, así mismo se revisaron métodos de errores como RMSE, MAD y MAPE.

Considerando esta información obtenida como ejemplo, se puede desarrollar un estudio similar, pero no está destinada a incrementar las ventas mediante la relación que exista con los descuentos ofrecidos, sino que tendría el objetivo de desarrollar un modelo de pronóstico que ayude en el abastecimiento adecuado y en tiempo de los productos y exista una disminución del valor de los productos caducados de manera mensual.

CAPÍTULO 3

3. METODOLOGÍA

3.1. Marco Metodológico

Para realizar el presente trabajo, se consideró una combinación entre la investigación longitudinal y la investigación de campo, con respecto a la investigación longitudinal, esta abarca el tema de análisis de datos observados, ya que está basado en varios años de información, y acerca de la investigación de campo se utilizan criterios estadísticos que sirvan como base para realizar el pronóstico y hallar el modelo que más logre encajar con los números seleccionados.

Las variables seleccionadas son numéricas, ya que están directamente relacionados con las cifras, es decir las ventas en cantidades y dólares. No cuenta con variables categóricas, pues no se considera ninguna cualidad adicional sobre los datos.

La población está ligada a la totalidad de las ventas de la empresa. La finalidad es trabajar con la totalidad de la información y no considerar muestras, pues la finalidad es encontrar el mejor método de pronóstico de demanda y segregar información podría repercutir en el resultado final.

Entre los instrumentos utilizados para la ejecución del presente estudio, se encuentran la base de datos del sistema ERP que utiliza la empresa para almacenar la información, luego estos datos fueron transferidos al programa de hoja de cálculo Microsoft Excel para realizar toda la recopilación de la data y obtener resultados generales y específicos de la información de cada año, finalmente esta información resumida y específica es cargada al programa de análisis estadístico R Studio, en donde se realizan varias iteraciones de datos con diferentes métodos de pronóstico, hasta que se logre obtener el mejor resultado, el cual sería el que se aproxime más a los datos de ventas reales, realizando finalmente una comparación entre ellos.

El proceso para obtener los datos inició de la siguiente manera: primero se buscó recopilar toda la información histórica con la que cuenta la empresa, se analizaron

las ventas desde el 2014 (inicio de información en el ERP actual) hasta el 2018, es así que se cuentan con 5 años de datos para analizar. Luego se procedió a depurar la información, ya que existían datos duplicados (por notas de crédito de ventas, anulaciones), unificar la información de las cantidades vendidas (diferentes presentaciones de producto que se refieren a un mismo kit).

Se prosigue con la realización de tablas dinámicas en Excel para resumir la información por SKU, Marca, Mes, Año y Ventas en dólares, con esta información abreviada, se procede a realizar un análisis Pareto esto ayuda a determinar cuál es la principal marca de la compañía y en dónde el estudio debe enfocarse.

Posteriormente y luego de escoger la marca número 1, se desglosan en categorías de productos y se procede a realizar nuevamente un Pareto para definir la categoría principal e ir delimitando el estudio hacia un segmento específico de la marca.

Seguidamente se expande los productos contenidos dentro de la categoría seleccionada y para concluir se efectúa un Pareto final, pero en este último y para obtener una análisis más certero de la información y descartar errores en el análisis de información, se considerarán 2 variables para su realización, se establecerán un Pareto tanto para dólares como para unidades, ya que pueden existir SKUs cuya venta en dólares sea mínima, pero la cantidad en unidades sea considerable y viceversa, con este último análisis quedan establecidos los datos finales.

Una vez obtenida y delimitada la información con la que se va a realizar el trabajo se ingresan los datos en el programa R Studio, en donde se revisarán varios modelos de pronóstico de acuerdo a la tendencia que se visualice de los datos, se espera que se logre ajustar los datos a cualquiera de los modelos de pronóstico ya explicados y la forma en que se escogerá al mejor será analizando el menor de sus errores.

Finalmente se realizará un pronóstico para el año 2019 y se lo comparará con la información en ventas reales obtenidas de este mismo año, con esto se definirá si el modelo escogido en efecto es factible para esos datos o no.

3.2. Análisis de los datos

Como se explicó en el capítulo 1, la empresa en la cual se está trabajando es una importadora de insumos y reactivos para laboratorio clínico y el enfoque que se busca está dado en la mejorara del inventario de sus productos. La compañía cuenta con más de 40 marcas importadas y dentro de estas marcas cuenta con un manejo aproximado de 2000 SKU's fijos (es decir que éstos tienen una demanda estabilizada y se adquieren con frecuencia) y unos 1000 SKU's variables (que son considerados bajo solicitud expresa del cliente).

3.2.1. Análisis general de las ventas

Las ventas se describan a continuación, de acuerdo a productos importados y a productos comprados localmente:

VENTAS en dólares	2014	2015	2016	2017	2018	TOTAL
IMPORTADO	4,846,653	4,922,862	5,585,814	7,217,117	11,691,048	34,263,494
LOCAL	725,079	1,019,036	928,341	1,046,141	699,120	4,417,717
Total general	5,571,732	5,941,898	6,514,155	8,263,258	12,390,169	38,681,211

Tabla 4 – Análisis de Ventas

Porcentaje de crecimiento en los últimos 3 años:

CRECIMIENTO en porcentaje	2015-2016	2016-2017	2017-2018
IMPORTADO	13.47%	29.20%	61.99%
LOCAL	-8.90%	12.69%	-33.17%

Tabla 5 – Crecimiento en Ventas

Como se puede notar, existe un porcentaje de crecimiento constante de año a año y un considerable aumento en el crecimiento del 2018 con respecto al 2017, si la empresa proyecta un crecimiento similar para los siguientes años, se hace imperante este análisis ya que el pronóstico de ventas ayudaría a minimizar el error en las importaciones futuras, disminuir en lo posible el desabastecimiento y así mismo reducir el nivel de producto caducado.

De estas 40 marcas, el objeto de este estudio se centrará en la que es considerada número 1 en ventas:

MARCAS	2014	2015	2016	2017	2018	TOTAL	PARTIC.	ACUM.	ABC
MARCA 1 – LC	818,252	1,003,342	1,479,632	3,150,703	7,341,313	13,793,243	40.26%	40.26%	A
MARCA 2 – TB	534,213	715,032	1,124,384	1,154,840	1,157,071	4,685,543	13.68%	53.93%	A
MARCA 3 – RM	292,453	286,887	285,337	656,036	570,697	2,091,412	6.10%	60.04%	A
MARCA 4 – CT	332,452	347,989	478,599	387,202	337,497	1,883,741	5.50%	65.53%	A
MARCA 5 – ED	443,791	438,318	288,884	289,292	273,518	1,733,805	5.06%	70.59%	A
MARCA 6 – AB	285,811	384,832	335,676	177,150	160,403	1,343,875	3.92%	74.52%	A
MARCA 7 – DM	2,054	117	306,753	440,676	434,535	1,184,136	3.46%	77.97%	A
MARCAS 8 – 20	1,849,034	1,272,965	957,312	594,313	1,013,091	5,686,725	16.60%	94.57%	B
MARCAS 21 – 40	288,588	473,375	329,224	366,900	402,919	1,861,008	5.43%	100.00%	C

Tabla 6 – Pareto de Marcas




Gráfico 2 – Participación de Ventas




Gráfico 3 – Pareto de Marcas

Es así que, de acuerdo a la información presentada tanto en el gráfico 2 como en el gráfico 3 se procede a escoger la MARCA 1 – LC ya que, del total de las ventas reales en los últimos 5 años, estas ventas tienen un peso del 40%, la diferencia porcentual versus la segunda marca es de más del 60%.

3.2.2. Análisis por grupo

Dentro de la marca escogida, Marca 1 – LC, se cuenta con un total de 300 productos, de los cuales solamente 196 son considerados únicamente reactivos que realmente son comercializados, los demás productos se dividen entre equipos, los respectivos repuestos para estos equipos y además los consumibles (más comúnmente conocidos como soluciones de lavado) que deben ser utilizados obligatoriamente para el buen funcionamiento de estos equipos junto con los reactivos.

En la categoría de reactivos tenemos una diferenciación de 6 subgrupos, los cuales se clasifican de acuerdo al tipo de reactivo, modo de uso del mismo y metodología científica utilizada. Es así que pueden ser catalogados de la siguiente forma:

- Reactivos de Química: por ejemplo, glucosa, colesterol, triglicéridos, etc.
- Reactivos de Coagulación: tales como, TP, TPT, Fibrinógeno, etc.
- Reactivos de Elisa: como son, HIV, Hepatitis B, C, Helicobacter Pylori, etc.
- Reactivos Látex; son Eberth O, H, Paratífico A, B, etc.
- Reactivos de Turbidimetría: conocidos como, P-CRP, ASLO, R-F, etc.
- Reactivos de Eritrosedimentación: tubos de VSG.
- No se toma en cuenta el grupo de consumibles, así como el de equipos ya que no son considerados reactivos para el diagnóstico, que es en lo que se está basando el presente estudio.

GRUPO	2014	2015	2016	2017	2018	Promedio
Coagulación	6,814	26,002	64,436	71,005	64,436	2.66%
Consumibles	44,759	54,177	915,903	345,851	915,903	25.98%
Elisa	32,579	18,251	122,338	106,230	122,338	4.58%
Equipos	81,860	27,900	29,000	64,850	29,000	2.65%
Eritrosedimentación	29,729	19,954	21,323	26,038	21,323	1.35%
Látex	172,367	176,621	127,852	181,251	127,852	8.97%
Química	276,426	259,051	1,360,630	619,169	1,360,630	44.23%
Repuestos	46,001	25,802	20,354	19,811	20,354	1.51%
Turbidimetría	56,536	77,950	208,181	155,687	208,181	8.06%
Total general	747,075	685,711	2,870,015	1,589,894	2,870,015	100%

Tabla 7 – Análisis de Perfil de producto

De acuerdo a la información presentada en el cuadro, son 3 categorías que representan el 79.18% de la venta total, estas son consumibles (que no puede ser considerada ya que no representa una venta real de producto), látex y química, pero la categoría que representa más del 40% de la venta y cuya diferencia con la siguiente es de 20 puntos corresponde a Química, por lo que el presente estudio estará enfocado en esta categoría.

3.2.3. Análisis por producto

Al momento de escoger el grupo correspondiente a Química, éste cuenta con un total de 36 reactivos y de la misma forma se realiza un análisis Pareto para establecer cuál de estos productos cuenta con más participación con respecto a los demás.

Para realizar el análisis de los productos se contemplará tanto la venta en dólares de cada uno de ellos, así como las unidades vendidas en el mismo periodo de tiempo. Se considera realizar ambos análisis para disminuir el error que en ocasiones se genera al tomar muestras para los análisis.

- Análisis Pareto en dólares

PRODUCTOS	TOTAL VENTAS 2014 - 2018	Participación	Acumulada	PARETO
LDL COLESTEROL	448,983	14.98%	14.98%	A
TRIGLICERIDOS	417,720	13.93%	28.91%	A
HDL COLESTEROL	392,589	13.09%	42%	A
COLESTEROL	238,685	7.96%	49.96%	A
CREATININA	217,160	7.24%	57.21%	A
LIPASA	174,004	5.80%	63.01%	A
GLUCOSA	153,062	5.11%	68.12%	A
ACIDO URICO	147,851	4.93%	73.05%	A
UREA COLOR	118,693	3.96%	77.01%	A
TRANSAMINASA TGP CINETICO	113,118	3.77%	80.78%	B
TRANSAMINASA TGO CINETICO	112,908	3.77%	84.55%	B
UREA CINETICA	107,618	3.59%	88.14%	B
AMYLASA	94,626	3.16%	91.29%	B
GAMMA GT	34,485	1.15%	92.44%	B

FOSFATASA ALCALINA	32,650	1.09%	93.53%	B
ALBUMINA	23,370	0.78%	94.31%	B
PROTEINAS TOTALES	22,205	0.74%	95.05%	C
BILIRRUBINA TOTAL Y DIRECTA	18,639	0.62%	95.67%	C
POTASIO	17,015	0.57%	96.24%	C
SODIO	15,580	0.52%	96.76%	C
BILIRRUBINA DIRECTA	15,576	0.52%	97.28%	C
COLINESTERASA	15,456	0.52%	97.80%	C
HIERRO	11,020	0.37%	98.16%	C
BILIRRUBINA TOTAL	10,643	0.36%	98.52%	C
CALCIO OCC	10,185	0.34%	98.86%	C
LDH	10,125	0.34%	99.20%	C
COLORO	4,495	0.15%	99.35%	C
PROTEINAS EN ORINA	3,720	0.12%	99.47%	C
FOSFATASA ACIDA	3,662	0.12%	99.59%	C
HIERRO TIBC	2,444	0.08%	99.67%	C
TRANSAMINASA TGO COLOR	2,432	0.08%	99.76%	C
TRANSAMINASA TGP COLOR	2,432	0.08%	99.84%	C
MAGNESIO	2,371	0.08%	99.92%	C
HEMOGLOBINA	1,179	0.04%	99.95%	C
FOSFORO UV	881	0.03%	99.98%	C
CREATININA ENZIMATICA	438	0.01%	100%	C
CALCIO COLOR ARSENAZO	34	0%	100%	C

Tabla 8 – Análisis Pareto en Dólares

- Análisis Pareto en Unidades

PRODUCTOS	TOTAL UNIDADES 2014 - 2018	Participación	Acumulada	PARETO
CREATININA	15,701	15.73%	15.73%	A
GLUCOSA	9,941	9.96%	25.68%	A
COLESTEROL	9,016	9.03%	34.72%	A
TRIGLICERIDOS	8,497	8.51%	43.23%	A
ACIDO URICO	6,507	6.52%	49.75%	A
TRANSAMINASA TGP CINETICO	6,300	6.31%	56.06%	A
TRANSAMINASA TGO CINETICO	6,256	6.27%	62.32%	A
UREA COLOR	6,029	6.04%	68.36%	A
UREA CINETICA	4,468	4.48%	72.84%	A
HDL COLESTEROL	4,467	4.47%	77.31%	A
FOSFATASA ALCALINA	2,197	2.20%	79.51%	B
BILIRRUBINA TOTAL Y DIRECTA	2,071	2.07%	81.59%	B
PROTEINAS TOTALES	2,006	2.01%	83.60%	B
LDL COLESTEROL	1,975	1.98%	85.57%	B

ALBUMINA	1,962	1.97%	87.54%	B
BILIRRUBINA DIRECTA	1,919	1.92%	89.46%	B
LIPASA	1,849	1.85%	91.31%	B
GAMMA GT	1,537	1.54%	92.85%	B
AMYLASA	1,502	1.50%	94.36%	B
BILIRRUBINA TOTAL	1,159	1.16%	95.52%	C
LDH	750	0.75%	96.27%	C
CALCIO OCC	679	0.68%	96.95%	C
HIERRO	551	0.55%	97.50%	C
COLINESTERASA	483	0.48%	97.99%	C
PROTEINAS EN ORINA	372	0.37%	98.36%	C
COLORO	333	0.33%	98.69%	C
MAGNESIO	217	0.22%	98.91%	C
FOSFORO UV	215	0.22%	99.12%	C
HIERRO TIBC	188	0.19%	99.31%	C
TRANSAMINASA TGO COLOR	152	0.15%	99.47%	C
TRANSAMINASA TGP COLOR	152	0.15%	99.62%	C
FOSFATASA ACIDA	109	0.11%	99.73%	C
SODIO	101	0.10%	99.83%	C
HEMOGLOBINA	83	0.08%	99.91%	C
POTASIO	83	0.08%	99.99%	C
CREATININA ENZIMATICA	4	0.00%	100.00%	C
CALCIO COLOR ARSENAZO	2	0.00%	100.00%	C

Tabla 9 - Análisis Pareto en Unidades

- Análisis Pareto Final

PRODUCTOS	PARETO DÓLARES	PARETO CANTIDADES	ANALISIS FINAL
LDL COLESTEROL	A	B	A
TRIGLICERIDOS	A	A	A
HDL COLESTEROL	A	A	A
COLESTEROL	A	A	A
CREATININA	A	A	A
LIPASA	A	B	A
GLUCOSA	A	A	A
ACIDO URICO	A	A	A
UREA COLOR	A	A	A
TRANSAMINASA TGP CINETICO	B	A	A
TRANSAMINASA TGO CINETICO	B	A	A
UREA CINETICA	B	A	A
AMYLASA	B	B	B
GAMMA GT	B	B	B
FOSFATASA ALCALINA	B	B	B

ALBUMINA	B	B	B
PROTEINAS TOTALES	C	B	C
BILIRRUBINA TOTAL Y DIRECTA	C	B	C
POTASIO	C	C	C
SODIO	C	C	C
BILIRRUBINA DIRECTA	C	B	C
COLINESTERASA	C	C	C
HIERRO	C	C	C
BILIRRUBINA TOTAL	C	C	C
CALCIO OCC	C	C	C
LDH	C	C	C
CLORO	C	C	C
PROTEINAS EN ORINA	C	C	C
FOSFATASA ACIDA	C	C	C
HIERRO TIBC	C	C	C
TRANSAMINASA TGO COLOR	C	C	C
TRANSAMINASA TGP COLOR	C	C	C
MAGNESIO	C	C	C
HEMOGLOBINA	C	C	C
FOSFORO UV	C	C	C
CREATININA ENZIMATICA	C	C	C
CALCIO COLOR ARSENAZO	C	C	C

Tabla 10 – Análisis Pareto Final

Es así que finalmente se logra delimitar los SKU's que van a ser objeto del estudio final, de este último grupo conformado por 37, se escogerán finalmente 13, los mismos que son producto A tanto en la venta de producto en unidades y en la venta de producto en dólares.

3.2.4. Análisis de productos por perfil

Para entender cómo se relacionan las pruebas realizadas con otras pruebas, se debe primero establecer cuál es la correlación que existen entre todo el perfil de pruebas químicas que se van a analizar.

Existen varios perfiles dentro de los análisis químicos sanguíneos que se realizan para determinar cómo se encuentra una persona con respecto a su salud, estos

perfiles son perfil lipídico, perfil renal, perfil hepático, perfil pancreático, perfil diabético, perfil proteínico.

- Perfil Lipídico

Dentro del perfil lipídico se encuentra las pruebas de Colesterol, HDL Colesterol, LDL colesterol y Triglicéridos, estas pruebas sirven para medir la cantidad de colesterol y triglicéridos que sirven para determinar el riesgo que existe de acumulación de placas en las arterias, lo que puede provocar una enfermedad llamada aterosclerosis que son arterias estrechas bloqueadas en todo el cuerpo.

Un nivel elevado de sólo colesterol no tiene una determinación clínica importante, sólo es relevante si se realiza con las otras pruebas, es decir el perfil completo, si el perfil completo es elevado, existe una probabilidad riesgosa de desarrollar enfermedades cardiacas.

- Colesterol Total: es la suma de todos los colesterolos
- HDL Colesterol: es el conocido colesterol bueno, el que ayuda a mantener las arterias abiertas y que la sangre fluya de mejor forma.
- LDL Colesterol: llamado también colesterol malo, el exceso de esto produce acumulación de placas (depósitos de grasa) en las arterias que disminuye el flujo sanguíneo, cuando estas placas se rompen pueden provocar ataques cardiacos o accidente cerebrovascular.
- Triglicéridos: es el tipo de grasa que se encuentra en la sangre, el residuo de las calorías que el cuerpo no necesita y se almacenan en células grasas, los niveles altos se relacionan con sobrepeso, exceso de azúcares o ingesta excesiva de alcohol y la vida sedentaria.

- Perfil Renal

El perfil renal se lo realiza para diagnosticar y realizar seguimientos en problemas relacionados con el sistema renal, es decir evalúan el funcionamiento de los riñones, se la efectúan especialmente a las personas que presentan un alto riesgo de desarrollar enfermedades de este tipo o para monitorear a quienes ya la han

adquirido. Es así que se utiliza midiendo los niveles de pruebas como urea, creatinina y albumina.

- Urea: sirve para medir la cantidad de urea en la sangre, que es producida en el hígado como desecho luego de que el nitrógeno en forma de amonio se combina con otras moléculas. La urea es liberada y enviada al riñón donde se filtra y se excreta en la orina, si este valor es alto indica que existe un fallo en el riñón, un valor bajo no constituye ningún riesgo para las personas.
- Creatinina: sirve para medir la cantidad de creatinina en la sangre, la cual es un desecho producido en los músculos a partir de la degradación de un compuesto conocido como creatina que regularmente se desecha por los riñones. Un aumento de la creatinina en la sangre sugiere enfermedades o situaciones que afectan la función renal como lesiones o inflamación en los vasos sanguíneos del riñón, infección bacteriana del riñón, muerte de las células de los tubos renales, enfermedades prostáticas, cálculos renales, entre otros. Los niveles bajos no son considerados de preocupación.
- Albumina: la albumina se la realiza tanto con el perfil renal como con el perfil hepático y sirve para evaluar el estado nutricional especialmente de personas que se encuentran hospitalizadas. Es una proteína que se sintetiza en el hígado y evita que el fluido escape de los vasos sanguíneos, disminuye en mayor o menor grado en situaciones en donde se interfiere con su producción, pérdidas proteicas o aumento del volumen plasmático.

- Perfil Hepático

El perfil hepático es la determinación simultánea de una serie de diagnósticos para detectar, evaluar y monitorear una inflamación crónica o aguda del hígado, alguna enfermedad hepática o cualquier otro tipo de lesión hepática. La función del hígado es la de metabolizar medicamentos y elementos que son potencialmente venenosos para el cuerpo humano, además tiene la potestad de producir enzimas,

mantener un equilibrio natural, como almacén y depósito de vitaminas y minerales, también produce la bilis que sirve para la digestión de grasas. Las pruebas incluidas en el perfil hepático son:

- Transaminasa TGP: es una enzima que se encuentra en el hígado que está encargada de detectar la presencia de hepatitis. Un aumento en los niveles puede ser generado por un daño agudo infecciones, toxinas o fármacos, TGP más alta que TGO.
- Transaminasa TGO: es una enzima que se encuentra en el hígado, pero también en otros tejidos como el corazón. Un aumento en los niveles normales puede ser generado por una hepatitis alcohólico, cirrosis o cáncer hepático.
- Bilirrubinas Directa y Total: miden en diferentes formas y útiles la ictericia, la total asocia a todo lo que contiene la sangre y la directa la mide junto con otras sustancias, se le dice conjugada. Aumentadas suele ser una obstrucción de las vías biliares.
- Fosfatasa Alcalina: está relacionada con los conductos biliares pero también a los huesos, intestinos y placenta, de existir obstrucción suele estar aumentada. Aumentada por daños agudos, hepatitis alcohólica, cirrosis, obstrucción de las vías biliares o cáncer de hígado.
- Gamma: una encima hallada en las células del hígado. Un aumento del valor normal indica una afectación del hígado, entre más alto, más fuerte la lesión hepática, inclusive puede estar asociada a otras afectaciones como insuficiencia cardíaca congestiva, diabetes o pancreatitis, cuando está normal o baja, no implica ninguna afectación.
- Albumina: es una proteína producida en el hígado en que la alteración del nivel de producción trastorna el funcionamiento normal del hígado y el riñón. Cuando se encuentra disminuida suele ser por cáncer de origen hepático o autoinmune.

- Perfil Pancreático

En el perfil pancreático se revisa principalmente la función del páncreas que es el encargado de segregar enzimas digestivas que pasan al intestino delgado y endocrino, además es el encargado de producir hormonas como la insulina y el glucagón. Cuando se produce una lesión pancreática grave o una obstrucción de los conductos, se acumulan grandes cantidades de secreción en zonas seleccionadas.

- Lipasa: enzima que junto con la bilis del hígado digiere las grasas, la lipasa es mucho más específica que la amilasa para diagnosticar enfermedades pancreáticas. Un aumento en los niveles normales indica una pancreatitis aguda, una disminución también puede indicar un deterioro en las células pancreáticas.
- Amilasa: es la enzima responsable de la digestión de los carbohidratos, es una prueba sensible pero no específica para la pancreatitis. Un aumento implica una afectación al páncreas al igual que la obstrucción del conducto pancreático, al cáncer de páncreas o inclusive a una parotiditis. Mientras tanto una disminución puede deberse a una enfermedad renal o a una preclamsia.

- Perfil Diabético

La Diabetes se representa a un conjunto de enfermedades ligadas a la imposibilidad de un individuo para producir suficiente insulina o para proporcionar adecuadamente la insulina, lo que provoca elevadas concentraciones de glucosa en sangre conocido como hiperglicemia y acarrea problemas crónicos de salud.

- Glucosa: es una azúcar que constituye la principal fuente de energía para el organismo y la única fuente de energía para el cerebro y sistema nervioso, la prueba química se realiza para conocer los niveles de azúcar en sangre. Niveles altos de glucosa suelen indicar diabetes, pero existen otras enfermedades que también producen aumento de glucosa en sangre como acromegalia, estrés agudo,

insuficiencia renal, síndrome de Cushing, exceso de comida, hipertiroidismo, cáncer de páncreas o pancreatitis. Niveles bajos pueden estar dados como hipoglicemia una caída en la concentración de azúcares en la sangre que inclusive puede llegar a causar síntomas neurológicos e inclusive afectar al cerebro.

- **Perfil Proteínico**

Determina cuál es el estado nutricional de la persona o para cribar ciertas alteraciones en el sistema hepático, renal y otras enfermedades. Las proteínas componen los pilares de todas las estructuras de células y tejidos del organismo y son significativos para el desarrollo físico.

- **Proteínas Totales:** en la sangre se encuentran 2 tipos las albúminas que representan un 60% y las proteínas plasmáticas que son el 40%. Los resultados de estas pruebas se interpretan junto con otras y proporcionan una información general del individuo en relación a la alimentación o a los trastornos que puedan afectar a otros órganos vitales como el hígado o el riñón, es así que cuando existe una disminución de los niveles normales puede inducir a que exista enfermedades hepáticas o enfermedades renales. Mientras que un aumento de las proteínas suele sugerir deshidratación o una producción anormalmente elevada de proteínas (mielomas o trastornos inflamatorios)

3.2.5. Análisis de Tendencia y Estacionalidad

Al realiza el análisis de tendencia, se puede evidenciar que existe un crecimiento importante a partir del 3 trimestre del 2017, ya que la empresa ganó una licitación importante que ha hecho incrementar significativamente las ventas.

La estacionalidad está dada en picos altos entre el segundo y cuarto trimestre de cada año, se estima porque la venta de generalizada de la empresa está enfocada

en un 80% al sector público, por tanto, las asignaciones presupuestarias realizadas son en efecto en estos meses del año.

Todos los ítems clasificados en el Pareto como ítems A siguen una tendencia similar de aumento y disminución de ventas en los mismos momentos del año.




Gráfico 4 – Tendencia de Ventas

3.3. Diseño de Modelos de Pronóstico

De acuerdo a los datos seleccionados, se procede a diseñar varios modelos como los revisados en el capítulo 2.4.2, como el promedio móvil simple, promedio móvil ponderado, suavización exponencial, suavización exponencial adaptativo, doble suavización exponencial y regresión lineal.

Luego se selecciona el mejor de estos modelos para compararlo con modelos más avanzados que incluyan tendencia y estacionalidad como los ARIMA.

Ahora se procederá a realizar un análisis sobre cuál es el mejor modelo de acuerdo al producto, por la cantidad de datos se explicará cada producto dentro de la categoría A del Pareto.

(Ver Apéndice A y B para las categorías B y C del Pareto).

- Ácido Úrico:

Con respecto a este se presenta la Doble Suavización exponencial:

Smoothing parameters:
 alpha: 0.005473893
 beta : 0.933649
 gamma: 0.18153

Coefficients:
 [,1]
 a 573.6632646
 b 16.3278574
 s1 0.6681931
 s2 0.7442023
 s3 1.4143490
 s4 1.5347879
 s5 0.7925814
 s6 1.2539470
 s7 1.1769506
 s8 0.9808138
 s9 0.8991464
 s10 1.5282631
 s11 1.2080714
 s12 1.0386807

```
> predict(Holtwinters(Vtas_Ac_Ur,seasonal="multiplicative"),12)
```

	Jan	Feb	Mar	Apr	May	Jun
2019	394.2280	451.2240	880.6399	980.6906	519.3806	842.1889
	Jul	Aug	Sep	Oct	Nov	Dec
2019	809.6929	690.7735	647.9375	1126.2410	910.0036	799.3661

Y también se presenta Arima (3,1,1)(1,0,0)[12]

Coefficients:
 ar1 ar2 ar3 ma1 sar1
 -0.0301 -0.4045 -0.3175 -0.4624 -0.2858
 s.e. 0.1946 0.1144 0.1465 0.1801 0.1530

sigma^2 estimated as 31601: log likelihood=-387.92
 AIC=787.84 AICC=789.46 BIC=800.31

```
> forecast(m1_Ac_Ur)
```

Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	445.9113	218.09287	673.7297	97.49309	794.3295
Feb 2019	487.1317	231.65604	742.6075	96.41537	877.8481
Mar 2019	451.0106	194.12849	707.8927	58.14331	843.8779
Apr 2019	209.1874	00.00000	466.0824	00.00000	602.0744
May 2019	343.2913	75.71936	610.8633	00.00000	752.5074
Jun 2019	358.1667	68.61669	647.7168	00.00000	800.9953
Jul 2019	427.7432	125.09992	730.3865	00.00000	890.5962
Aug 2019	406.7142	99.75277	713.6756	00.00000	876.1712
Sep 2019	419.1666	108.13062	730.2026	00.00000	894.8552
Oct 2019	356.7463	37.42848	676.0642	00.00000	845.1009
Nov 2019	453.1191	123.01096	783.2272	00.00000	957.9759
Dec 2019	532.0500	193.57439	870.5256	14.39622	1049.7038

- Colesterol

Con respecto a este se presenta la Doble Suavización exponencial:

Smoothing parameters:

alpha: 0.08403431
beta : 0
gamma: 0.184491

Coefficients:

```

      [,1]
a 650.4730597
b -2.4439103
s1 0.8726226
s2 0.7473839
s3 1.2005722
s4 1.6601481
s5 0.9993052
s6 0.8669856
s7 1.1156296
s8 0.8552909
s9 0.7854292
s10 1.8855573
s11 1.2343368
s12 0.6941189

```

> predict(Holtwinters(Vtas_Col,seasonal="multiplicative"),12)

	Jan	Feb	Mar	Apr	May	Jun
2019	565.4849	482.5000	772.1376	1063.6526	637.8100	551.2378
	Jul	Aug	Sep	Oct	Nov	Dec
2019	706.6015	539.6217	493.6249	1180.4229	769.7201	431.1493

Y también se presenta Arima (2,1,2)(1,0,0)[12]

Coefficients:

	ar1	ar2	ma1	ma2	sar1
	0.8532	-0.7818	-1.4485	0.9199	-0.2977
s.e.	0.0902	0.0980	0.0799	0.0854	0.1548

sigma² estimated as 62195: log likelihood=-408.96

AIC=829.91 AICc=831.53 BIC=842.38

> m1_Col=auto.arima(Vtas_Col)

> forecast(m1_Col,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	484.1004	164.37638	803.8244	-4.87528	973.0760
Feb 2019	428.8246	83.84161	773.8076	-98.78135	956.4306
Mar 2019	380.1735	35.02597	725.3211	-147.68411	908.0311
Apr 2019	253.0220	-97.10105	603.1451	-282.44502	788.4891
May 2019	456.5832	57.19720	855.9692	-154.22498	1067.3914
Jun 2019	358.6720	-122.59280	839.9367	-377.35897	1094.7029
Jul 2019	357.2985	-175.90018	890.4973	-458.15852	1172.7556
Aug 2019	418.7715	-131.63580	969.1787	-423.00381	1260.5467
Sep 2019	539.3216	-18.02630	1096.6696	-313.06847	1391.7117
Oct 2019	420.7447	-149.10546	990.5948	-450.76590	1292.2552
Nov 2019	520.8422	-77.78737	1119.4718	-394.68272	1436.3671
Dec 2019	551.7127	-84.11630	1187.5418	-420.70386	1524.1293

- Creatinina

Con respecto a este se presenta la Suavización exponencial Adaptativa:

Smoothing parameters:

alpha: 0.4776876
beta : 0
gamma: 0.3251734

Coefficients:

```
[,1]
a    321.601399
b    -0.342366
s1  -181.075669
s2  -11.944947
s3   91.302187
s4  140.780907
s5  -62.713836
s6  -56.965904
s7   5.456389
s8  -37.432728
s9  -21.286592
s10 167.339904
s11  61.921424
s12 -28.239924
```

> predict(Holtwinters(Vtas_Cre),12)

	Jan	Feb	Mar	Apr	May	Jun
2019	140.1834	308.9717	411.8765	461.0128	257.1757	262.5813
	Jul	Aug	Sep	Oct	Nov	Dec
2019	324.6612	281.4297	297.2335	485.5176	379.7568	289.2531

Y también se presenta Arima (2,1,2)(1,0,0)[12]

Coefficients:

```
ar1    ar2    ma1    ma2    sar1
s.e.  0.894 -0.7622 -1.4877  0.9541 -0.3920
s.e.  0.089  0.1038  0.1389  0.1313  0.1633
```

sigma^2 estimated as 28499: log likelihood=-386.6

AIC=785.2 AICc=786.81 BIC=797.66

> m1_Cre=auto.arima(Vtas_Cre)

> forecast(m1_Cre,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		571.2206	354.36104	788.0802	239.56251	902.8788
Feb 2019		461.9217	227.55234	696.2910	103.48472	820.3586
Mar 2019		450.2768	215.42485	685.1288	91.10172	809.4520
Apr 2019		333.4561	94.05230	572.8598	-32.68040	699.5925
May 2019		441.6080	168.68321	714.5329	24.20553	859.0105
Jun 2019		396.4677	68.11019	724.8251	-105.71175	898.6470
Jul 2019		386.7956	19.66403	753.9272	-174.68370	948.2750
Aug 2019		491.9574	109.10602	874.8089	-93.56328	1077.4782
Sep 2019		522.6132	132.89817	912.3282	-73.40449	1118.6308
Oct 2019		497.4525	98.94887	895.9561	-112.00619	1106.9111
Nov 2019		561.4607	145.33142	977.5899	-74.95410	1197.8754
Dec 2019		630.4799	189.94455	1071.0153	-43.26078	1304.2206

- Glucosa

Con respecto a este se presenta la Doble Suavización Exponencial:

```
Smoothing parameters:
alpha: 0.1253875
beta : 0
gamma: 0.04930509
```

Coefficients:

```
[,1]
a 800.2485259
b -6.4101107
s1 0.7912584
s2 0.5360742
s3 1.0420338
s4 1.8046207
s5 0.6632903
s6 1.0997202
s7 1.1100515
s8 1.0997897
s9 0.7480808
s10 1.5294559
s11 1.2715913
s12 0.5343619
```

```
> predict(Holtwinters(Vtas_Gluc,seasonal="multiplicative"),12)
      Jan      Feb      Mar      Apr      May      Jun
2019 628.1313 422.1200 813.8473 1397.8738 509.5383 837.7535
      Jul      Aug      Sep      Oct      Nov      Dec
2019 838.5082 823.7069 555.4930 1125.9050 927.9276 386.5185
```

Y también se presenta Arima (2,1,2)

Coefficients:

```
      ar1      ar2      ma1      ma2
s.e. 0.1402 0.0886 0.1966 0.2299
```

```
sigma^2 estimated as 67387: log likelihood=-411.09
AIC=832.19 AICc=833.32 BIC=842.57
```

```
> m1_Gluc=auto.arima(Vtas_Gluc)
> forecast(m1_Gluc,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		655.7423	323.06124	988.4233	146.9505	1164.534
Feb 2019		885.7624	525.43519	1246.0897	334.6895	1436.835
Mar 2019		769.1352	408.51386	1129.7565	217.6125	1320.658
Apr 2019		501.4644	135.81827	867.1105	-57.7431	1060.672
May 2019		372.2315	-40.17997	784.6431	-258.4974	1002.961
Jun 2019		468.9127	-19.65072	957.4762	-278.2806	1216.106
Jul 2019		644.5582	108.10660	1181.0097	-175.8737	1464.990
Aug 2019		714.1951	160.95969	1267.4305	-131.9054	1560.296
Sep 2019		638.4578	77.01446	1199.9011	-220.1957	1497.111
Oct 2019		524.6451	-51.32060	1100.6109	-356.2184	1405.509
Nov 2019		489.3752	-115.56126	1094.3116	-435.7953	1414.546
Dec 2019		546.4383	-92.60584	1185.4825	-430.8954	1523.772

- HDL Colesterol

Con respecto a este se presenta la Doble Suavización Exponencial:

```
Holtwinters(x = Vtas_HDL, seasonal = "multiplicative")
```

Smoothing parameters:

```
alpha: 0.03093145
beta : 0
gamma: 0.2543582
```

Coefficients:

```
      [,1]
a 196.3386433
b -0.3484848
s1 0.1982391
s2 0.5079876
s3 2.1145615
s4 1.8380564
s5 0.5275892
s6 1.0295174
s7 0.3232947
s8 1.0028641
s9 1.0328134
s10 2.0120573
s11 1.7334407
s12 1.1174017
```

```
> predict(Holtwinters(Vtas_HDL, seasonal="multiplicative"), 12)
```

	Jan	Feb	Mar	Apr	May	Jun
2019	38.85292	99.38355	412.95946	358.31935	102.66687	199.98141
	Jul	Aug	Sep	Oct	Nov	Dec
2019	62.68661	194.10512	199.54190	388.03289	333.69654	214.71637

Y también se presenta Arima (0,1,1)

ARIMA(0,1,1) with drift

Coefficients:

```
      ma1      drift
-0.8622  4.4202
s.e.  0.0800  2.0300
```

sigma^2 estimated as 10439: log likelihood=-356.35

AIC=718.71 AICC=719.14 BIC=724.94

```
> m1_HDL=auto.arima(Vtas_HDL)
```

```
> forecast(m1_HDL, 12)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	263.1403	132.2003	394.0803	62.88485	463.3957
Feb 2019	267.5605	135.3835	399.7374	65.41330	469.7077
Mar 2019	271.9807	138.5783	405.3831	67.95928	476.0021
Apr 2019	276.4009	141.7841	411.0176	70.52233	482.2794
May 2019	280.8211	145.0009	416.6413	73.10198	488.5402
Jun 2019	285.2413	148.2282	422.2544	75.69780	494.7847
Jul 2019	289.6615	151.4658	427.8572	78.30936	501.0136
Aug 2019	294.0817	154.7134	433.4499	80.93627	507.2271
Sep 2019	298.5019	157.9708	439.0329	83.57815	513.4256
Oct 2019	302.9221	161.2378	444.6064	86.23461	519.6095
Nov 2019	307.3423	164.5140	450.1705	88.90532	525.7792
Dec 2019	311.7625	167.7994	455.7255	91.58993	531.9350

- LDL Colesterol

Con respecto a este se presenta la Suavización exponencial Adaptativa:

Smoothing parameters:

alpha: 0.1902901
beta : 0.06689618
gamma: 0.3934409

Coefficients:

```
[,1]
a    71.123427
b     1.591457
s1  -11.150634
s2    7.345267
s3   10.488691
s4   20.375702
s5    2.154801
s6   -1.407075
s7  -15.816895
s8   15.672139
s9   18.857625
s10  10.336485
s11  25.340599
s12 -16.059521
```

> predict(Holtwinters(Vtas_LDL),12)

	Jan	Feb	Mar	Apr	May	Jun
2019	61.56425	81.65161	86.38649	97.86496	81.23551	79.26509
	Jul	Aug	Sep	Oct	Nov	Dec
2019	66.44673	99.52722	104.30416	97.37448	113.97005	74.16139

Y también se presenta Arima (0,1,1)

Coefficients:

```
      ma1    drift
s.e. -0.8443  1.1080
      0.0735  0.5746
```

sigma^2 estimated as 677.8: log likelihood=-275.63

AIC=557.26 AICC=557.69 BIC=563.49

> m1_LDL=auto.arima(Vtas_LDL)

> forecast(m1_LDL,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		76.04448	42.68079	109.4082	25.01913	127.0698
Feb 2019		77.15246	43.38667	110.9182	25.51215	128.7928
Mar 2019		78.26044	44.09728	112.4236	26.01240	130.5085
Apr 2019		79.36842	44.81247	113.9244	26.51965	132.2172
May 2019		80.47640	45.53206	115.4207	27.03365	133.9192
Jun 2019		81.58439	46.25593	116.9128	27.55417	135.6146
Jul 2019		82.69237	46.98392	118.4008	28.08102	137.3037
Aug 2019		83.80035	47.71592	119.8848	28.61398	138.9867
Sep 2019		84.90833	48.45180	121.3649	29.15288	140.6638
Oct 2019		86.01631	49.19143	122.8412	29.69752	142.3351
Nov 2019		87.12430	49.93472	124.3139	30.24775	144.0008
Dec 2019		88.23228	50.68154	125.7830	30.80339	145.6612

> plot(forecast(m1_LDL))

- Lipasa

Con respecto a este se presenta la Suavización exponencial Adaptativa:

Smoothing parameters:

alpha: 0.01454526
beta : 1
gamma: 0.1780209

Coefficients:

```

a 47.41123882
b 1.37561402
s1 -2.57230917
s2 -2.45466660
s3 5.82646931
s4 8.60218007
s5 -0.72259991
s6 6.30202174
s7 -0.01578639
s8 -2.87797362
s9 -1.19866071
s10 1.14467806
s11 6.54261430
s12 -1.87035675

```

> predict(Holtwinters(Vtas_Lip),12)

	Jan	Feb	Mar	Apr	May	Jun
2019	46.21454	47.70780	57.36455	61.51587	53.56671	61.96694
	Jul	Aug	Sep	Oct	Nov	Dec
2019	57.02475	55.53818	58.59310	62.31206	69.08561	62.04825

Y también se presenta Arima (0,1,1)

Coefficients:

```

      ma1  drift
s.e. -0.8817  0.6438
      0.0833  0.2032

```

sigma^2 estimated as 132.1: log likelihood=-227.51

AIC=461.02 AICc=461.46 BIC=467.25

> m1_Lip=auto.arima(Vtas_Lip)

> forecast(m1_Lip,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	42.26047	27.53239	56.98856	19.73581	64.78513
Feb 2019	42.90424	28.07342	57.73506	20.22245	65.58602
Mar 2019	43.54801	28.61515	58.48086	20.71018	66.38583
Apr 2019	44.19177	29.15758	59.22597	21.19896	67.18459
May 2019	44.83554	29.70069	59.97039	21.68879	67.98230
Jun 2019	45.47931	30.24446	60.71416	22.17962	68.77900
Jul 2019	46.12308	30.78889	61.45727	22.67146	69.57470
Aug 2019	46.76685	31.33395	62.19974	23.16428	70.36942
Sep 2019	47.41061	31.87965	62.94158	23.65805	71.16318
Oct 2019	48.05438	32.42595	63.68281	24.15276	71.95600
Nov 2019	48.69815	32.97287	64.42343	24.64840	72.74790
Dec 2019	49.34192	33.52037	65.16347	25.14495	73.53889

- Transaminasa TGO Cinetico

Con respecto a este se presenta la Doble Suavización Exponencial :

```
Holtwinters(x = Vtas_TGO_Cin, seasonal = "multiplicative")
```

```
Smoothing parameters:
alpha: 0.4392284
beta : 0
gamma: 0.8281359
```

Coefficients:

```

          [,1]
a 299.1511110
b -0.6909965
s1 0.2721383
s2 0.6690086
s3 0.7552935
s4 0.8878514
s5 0.9002804
s6 0.8317911
s7 0.8612736
s8 0.9133681
s9 0.9791815
s10 1.2300945
s11 0.9293823
s12 0.6656388
```

```
> predict(Holtwinters(Vtas_TGO_Cin,seasonal="multiplicative"),12)
```

	Jan	Feb	Mar	Apr	May	Jun
2019	81.22244	199.21010	224.38118	263.14772	266.20944	245.38266
	Jul	Aug	Sep	Oct	Nov	Dec
2019	253.48501	268.18601	286.83373	359.48422	270.96156	193.60714

Y también se presenta Arima (2,1,2)(0,0,1)[12]

Coefficients:

```

          ar1      ar2      ma1      ma2      sma1|
s.e. 0.9341 -0.8115 -1.2888 0.8189 -0.5102
      0.1240 0.1265 0.1756 0.1487 0.2083
```

```
sigma^2 estimated as 9255: log likelihood=-352.67
AIC=717.33 AICc=718.95 BIC=729.8
```

```
> m1_TGO_Cin=auto.arima(Vtas_TGO_Cin)
```

```
> forecast(m1_TGO_Cin,12)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	437.3318	314.00124	560.6624	248.71398	625.9496
Feb 2019	318.9956	172.23788	465.7533	94.54903	543.4422
Mar 2019	303.9611	151.95191	455.9704	71.48309	536.4392
Apr 2019	291.3557	134.71406	447.9973	51.79300	530.9184
May 2019	256.7748	85.79656	427.7531	-4.71387	518.2635
Jun 2019	278.8598	81.44227	476.2774	-23.06428	580.7840
Jul 2019	259.2416	37.05990	481.4233	-80.55600	599.0392
Aug 2019	326.9900	90.67653	563.3036	-34.42029	688.4004
Sep 2019	300.0305	56.74416	543.3169	-72.04387	672.1049
Oct 2019	215.5601	-33.65904	464.7793	-165.58770	596.7079
Nov 2019	242.3164	-16.25830	500.8911	-153.13948	637.7723
Dec 2019	318.1798	45.71795	590.6417	-98.51464	734.8743

- Transaminasa TGP Cinetico

Con respecto a este se presenta la Doble Suavización Exponencial:

Smoothing parameters:

alpha: 0.5195129
beta : 0
gamma: 1

Coefficients:

```

a 255.6913911
b -0.2652972
s1 0.2340993
s2 0.6750734
s3 0.7351678
s4 0.8637402
s5 0.8691682
s6 0.8029255
s7 0.9122635
s8 0.8684278
s9 1.0871146
s10 1.2512367
s11 0.9698790
s12 0.7039736

```

> predict(Holtwinters(Vtas_TGP_Cin,seasonal="multiplicative"),12)

	Jan	Feb	Mar	Apr	May	Jun
2019	59.79507	172.25228	187.39095	219.93435	221.08588	204.02305
	Jul	Aug	Sep	Oct	Nov	Dec
2019	231.56377	220.20639	275.37017	316.61094	245.15935	177.75885

Y también se presenta Arima (0,1,2)(1,0,0)[12]

Coefficients:

```

          ma1      ma2      sar1      drift
s.e.  -0.3211  -0.4663  -0.3743  5.9838
       0.1318   0.1438   0.1528  2.3412

```

sigma^2 estimated as 9686: log likelihood=-353.85

AIC=717.69 AICc=718.83 BIC=728.08

> m1_TGP_Cin=auto.arima(Vtas_TGP_Cin)

> forecast(m1_TGP_Cin,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	434.6283	308.5006	560.7560	241.7327	627.5240
Feb 2019	367.2265	214.7795	519.6734	134.0790	600.3740
Mar 2019	341.7638	186.9764	496.5511	105.0370	578.4905
Apr 2019	341.7529	184.6600	498.8457	101.5001	582.0057
May 2019	360.4566	201.0916	519.8216	116.7288	604.1844
Jun 2019	412.0980	250.4928	573.7032	164.9441	659.2519
Jul 2019	397.8640	234.0492	561.6789	147.3309	648.3972
Aug 2019	455.8684	289.8734	621.8634	202.0009	709.7359
Sep 2019	424.7913	256.6444	592.9382	167.6328	681.9499
Oct 2019	417.2946	247.0229	587.5663	156.8866	677.7026
Nov 2019	499.6279	327.2577	671.9981	236.0105	763.2454
Dec 2019	558.3809	383.9374	732.8243	291.5926	825.1692

- Trigliceridos

Con respecto a este se presenta la Doble Suavización Exponencial:

```
Holtwinters(x = Vtas_Trig, seasonal = "multiplicative")
```

```
Smoothing parameters:
alpha: 0.1247415
beta : 0
gamma: 0.08157351
```

```
Coefficients:
```

```
      [,1]
a 604.7379098
b -3.0479312
s1 0.8461525
s2 0.6956138
s3 1.0305008
s4 1.7413345
s5 0.5840235
s6 1.2317579
s7 1.0810666
s8 1.1271624
s9 0.7437223
s10 1.4355901
s11 1.2256986
s12 0.5511215
```

```
> predict(Holtwinters(Vtas_Trig,seasonal="multiplicative"),12)
      Jan      Feb      Mar      Apr      May      Jun
2019 509.1215 416.4237 613.7602 1031.8211 344.2808 722.3648
      Jul      Aug      Sep      Oct      Nov      Dec
2019 630.6968 654.1538 429.3557 824.3999 700.1321 313.1267
```

Y también se presenta Arima (3,1,0)

```
Coefficients:
```

```
      ar1      ar2      ar3
s.e. -0.3150 -0.4659 -0.3575
      0.1215 0.1135 0.1212
```

```
sigma^2 estimated as 60929: log likelihood=-407.58
AIC=823.17 AICC=823.91 BIC=831.48
```

```
> m1_Trig=auto.arima(Vtas_Trig)
```

```
> forecast(m1_Trig,12)
```

```
      Point Forecast      Lo 80      Hi 80      Lo 95      Hi 95
Jan 2019      348.2812      31.94491      664.6174      -135.51338      832.0757
Feb 2019      552.4934      169.05714      935.9297      -33.92175      1138.9086
Mar 2019      487.4316      90.99472      883.8685      -118.86628      1093.7295
Apr 2019      349.4046      -53.26494      752.0742      -266.42533      965.2346
May 2019      350.1942      -86.78463      787.1730      -318.10724      1018.4956
Jun 2019      437.5134      -40.59173      915.6185      -293.68527      1168.7120
Jul 2019      458.9823      -42.37703      960.3416      -307.78063      1225.7452
Aug 2019      411.2537      -103.74427      926.2516      -376.36772      1198.8751
Sep 2019      385.0702      -148.50861      918.6491      -430.96820      1201.1087
Oct 2019      407.8809      -150.20385      965.9657      -445.63608      1261.3979
Nov 2019      429.9571      -149.97842      1009.8926      -456.97774      1316.8919
Dec 2019      421.7353      -174.99069      1018.4613      -490.87835      1334.3490
```


- Urea Berthelot Color

Con respecto a este se presenta la Doble Suavización Exponencial:

Smoothing parameters:

alpha: 0.01240695
 beta : 0.004144582
 gamma: 0.2571676

Coefficients:

```

[ ,1]
a 266.0502298
b 0.7233797
s1 0.6638721
s2 0.8530358
s3 1.4405367
s4 1.7676842
s5 0.9495738
s6 1.1188700
s7 1.1239834
s8 1.0089475
s9 0.8555006
s10 1.6149069
s11 1.5066992
s12 0.8580228

```

```
> predict(Holtwinters(Vtas_Urea_Col,seasonal="multiplicative"),12)
```

	Jan	Feb	Mar	Apr	May	Jun
2019	177.1036	228.1845	386.3813	475.4076	256.0688	302.5318
	Jul	Aug	Sep	Oct	Nov	Dec
2019	304.7275	274.2695	233.1758	441.3283	412.8467	235.7253

Y también se presenta Arima (0,1,0)

sigma^2 estimated as 21620: log likelihood=-378.17

AIC=758.34 AICC=758.41 BIC=760.41

```
> m1_Urea_Col=auto.arima(Vtas_Urea_Col)
```

```
> forecast(m1_Urea_Col,12)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	118	-167.9148	403.9148	-319.2690	555.2690
Feb 2019	118	-286.3446	522.3446	-500.3918	736.3918
Mar 2019	118	-377.2190	613.2190	-639.3721	875.3721
Apr 2019	118	-453.8297	689.8297	-756.5380	992.5380
May 2019	118	-521.3250	757.3250	-859.7632	1095.7632
Jun 2019	118	-582.3455	818.3455	-953.0860	1189.0860
Jul 2019	118	-638.4596	874.4596	-1038.9051	1274.9051
Aug 2019	118	-690.6893	926.6893	-1118.7835	1354.7835
Sep 2019	118	-739.7445	975.7445	-1193.8070	1429.8070
Oct 2019	118	-786.1421	1022.1421	-1264.7660	1500.7660
Nov 2019	118	-830.2722	1066.2722	-1332.2572	1568.2572
Dec 2019	118	-872.4381	1108.4381	-1396.7443	1632.7443

- Urea Cinética

Con respecto a este se presenta la Doble Suavización Exponencial:

Smoothing parameters:

alpha: 0.007478618
 beta : 0.8041636
 gamma: 0.1966179

Coefficients:

```

a 226.7599594
b 8.4589172
s1 0.6723372
s2 0.9592977
s3 0.9317795
s4 2.1921918
s5 1.1419144
s6 1.5246810
s7 0.9989320
s8 1.0331351
s9 1.3003046
s10 2.0753492
s11 1.6466090
s12 1.3714481
  
```

> predict(Holtwinters(Vtas_Urea_Cin,seasonal="multiplicative"),12)

	Jan	Feb	Mar	Apr	May	Jun
2019	158.1464	233.7596	234.9358	571.2756	307.2373	423.1195
	Jul	Aug	Sep	Oct	Nov	Dec
2019	285.6670	304.1873	393.8495	646.1582	526.5988	450.2011

Y también se presenta Arima (0,1,0)

Coefficients:

```

ma1
-0.7093
s.e. 0.0924
  
```

sigma^2 estimated as 5942: log likelihood=-339.91

AIC=683.82 AICc=684.03 BIC=687.97

> m1_Urea_Cin=auto.arima(Vtas_Urea_Cin)

> forecast(m1_Urea_Cin,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	245.1108	146.3266	343.8950	94.03343	396.1882
Feb 2019	245.1108	142.2376	347.9840	87.77986	402.4418
Mar 2019	245.1108	138.3051	351.9166	81.76553	408.4561
Apr 2019	245.1108	134.5123	355.7094	75.96491	414.2567
May 2019	245.1108	130.8453	359.3764	70.35673	419.8649
Jun 2019	245.1108	127.2923	362.9293	64.92301	425.2986
Jul 2019	245.1108	123.8435	366.3781	59.64843	430.5732
Aug 2019	245.1108	120.4900	369.7316	54.51976	435.7019
Sep 2019	245.1108	117.2245	372.9972	49.52553	440.6961
Oct 2019	245.1108	114.0403	376.1814	44.65569	445.5659
Nov 2019	245.1108	110.9316	379.2900	39.90139	450.3202
Dec 2019	245.1108	107.8933	382.3283	35.25476	454.9669

3.4. Análisis de Sensibilidad y Error

3.4.1. Sensibilidad del modelo de pronóstico

Se han analizado los errores obtenidos de cada uno de los modelos especificados en el punto 3.3 y se han seleccionado los 3 menores con los siguientes resultados:

PRODUCTO	PARETO	D(AES)	D(DES)	ARIMA
ACIDO URICO	A	63.00%	49.93%	17.17%
COLESTEROL	A	56.22%	48.18%	15.91%
CREATININA	A	50.58%	59.17%	50.09%
GLUCOSA	A	52.14%	40.75%	14.15%
HDL COLESTEROL	A	326.21%	91.54%	403.76%
LDL COLESTEROL	A	55.40%	208.40%	2089.01%
LIPASA	A	28.10%	108.40%	131.90%
TRANSAMINASA TGO CINETICO	A	46.85%	41.58%	12.87%
TRANSAMINASA TGP CINETICO	A	41.05%	40.69%	11.57%
TRIGLICERIDOS	A	56.35%	50.88%	16.04%
UREA BERTHELOT COLOR	A	80.50%	20.80%	73.74%
UREA CINETICA	A	64.00%	17.50%	57.70%
ALBUMINA	B	61.30%	16.38%	57.50%
AMYLASA	B	61.39%	17.55%	56.56%
FOSFATASA ALCALINA	B	58.61%	15.83%	56.25%
GAMMA GT	B	59.60%	15.51%	44.76%
BILIRRUBINA DIRECTA	C	158.27%	39.68%	1869.02%
BILIRRUBINA TOTAL	C	111.74%	30.52%	951.56%
BILIRRUBINA TOTAL Y DIRECTA	C	70.83%	20.43%	65.18%
CALCIO OCC	C	76.56%	20.99%	68.19%
COLORO	C	31.82%	27.61%	329.67%
COLINESTERASA	C	100.00%	100.00%	643.42%
FOSFATASA ACIDA	C	76.35%	19.99%	166.68%
FOSFORO UV	C	73.50%	20.79%	206.22%
HEMOGLOBINA	C	78.65%	21.56%	118.11%
HIERRO	C	77.41%	21.09%	68.09%
HIERRO TIBC	C	106.23%	27.64%	253.65%
LDH	C	50.00%	67.51%	883.62%
MAGNESIO	C	86.21%	22.94%	233.95%
POTASIO	C	103.09%	25.82%	151.11%
PROTEINAS EN ORINA	C	109.26%	28.29%	317.48%
PROTEINAS TOTALES	C	73.69%	20.49%	72.23%
SODIO	C	89.47%	61.06%	164.93%
TRANSAMINASA TGO COLOR	C	97.33%	21.93%	243.25%
TRANSAMINASA TGP COLOR	C	88.96%	23.15%	235.22%

Tabla 11 – Sensibilidad por Modelo de Pronóstico 1

Se han subrayado con amarillo los valores con menor error. Además, se utiliza el software R Studio para pronosticar de acuerdo a los modelos de series temporales indicado en el punto 5.2.1.

PRODUCTO	PARETO	ARIMA	AIC	AICc	BIC
ACIDO URICO	A	(3,1,1)(1,0,0)[12]	787.84	789.46	800.31
COLESTEROL	A	(2,1,2)(1,0,0)[12]	829.91	831.53	842.38
CREATININA	A	(2,1,2)(1,0,0)[12]	785.2	786.81	797.66
GLUCOSA	A	(2,1,2)	832.19	833.32	842.57
HDL COLESTEROL	A	(0,1,1)	718.71	719.14	724.94
LDL COLESTEROL	A	(0,1,1)	557.26	557.69	563.49
LIPASA	A	(0,1,1)	461.02	461.46	467.25
TRANSAMINASA TGO CINETICO	A	(2,1,2)(0,0,1)[12]	717.33	718.95	729.8
TRANSAMINASA TGP CINETICO	A	(0,1,2)(1,0,0)[12]	717.69	718.83	728.08
TRIGLICERIDOS	A	(3,1,0)	823.17	823.91	831.48
UREA COLOR	A	(0,1,0)	758.34	758.41	760.41
UREA CINETICA	A	(0,1,1)	683.82	684.03	687.97
ALBUMINA	B	(0,1,1)	594.74	594.95	598.89
AMYLASA	B	(0,1,3)	508.12	508.86	516.43
FOSFATASA ALCALINA	B	(0,1,1)	594.01	594.22	598.17
GAMMA GT	B	(5,1,3)(0,0,1)[12]	548.36	553.97	571.21
BILIRRUBINA DIRECTA	C	(0,1,1)	603.02	603.46	609.26
BILIRRUBINA TOTAL	C	(0,1,1)	528.06	528.28	532.22
BILIRRUBINA TOTAL Y DIRECTA	C	(0,1,1)	528.06	528.28	532.22
CALCIO OCC	C	(0,1,1)	380.6	380.82	384.76
COLORO	C	(0,0,0)	368.55	368.76	372.74
COLINESTERASA	C	(4,1,0)	477.51	478.64	487.89
FOSFATASA ACIDA	C	(0,1,1)	264.2	264.41	268.35
FOSFORO UV	C	(0,0,0)	291.73	291.95	295.92
HEMOGLOBINA	C	(0,0,0)	225.53	225.74	229.72
HIERRO	C	(0,1,1)(1,0,0)[12]	371.1	371.54	377.34
HIERRO TIBC	C	(0,1,1)	328.92	329.13	333.07
LDH	C	(0,1,1)	523.31	523.53	527.47
MAGNESIO	C	(0,1,1)	316.55	316.76	320.7
POTASIO	C	(0,0,0)	253.89	254.1	258.08
PROTEINAS EN ORINA	C	(1,0,0)	356.51	356.93	362.79
PROTEINAS TOTALES	C	(0,1,1)	623.12	623.34	627.28
SODIO	C	(0,0,0)(1,0,0)[12]	298.32	298.75	304.6
TRANSAMINASA TGO COLOR	C	(0,0,1)	322.83	323.26	329.11
TRANSAMINASA TGP COLOR	C	(1,0,0)	317.96	318.38	324.24

Tabla 12 – Sensibilidad por Modelo de Pronóstico 2

3.4.2. Error del modelo de pronóstico

Finalmente, cuando se realiza la proyección y se la compara gráficamente con la venta del año 2019 se puede claramente ver las tendencias y cómo se acercan o se alejan de los datos reales, adicional también se realiza los cálculos respectivos para obtener los errores estadísticos de la venta versus cada modelo y así se puede tomar la decisión final del mejor modelo adaptado.

- **Ácido Úrico:** de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección ascendente que discrepa de la estacionalidad establecida por tanto se aleja mucho de los datos reales, mientras que la proyección ARIMA se acerca más a los datos ya que sí considera la estacionalidad establecida en el cuarto o quinto mes, finalmente al revisar los errores el MAPE, se rectifica que el menor es el de ARIMA con 56%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 5 – Comparación de Pronósticos vs Real Ácido Úrico

```
> accuracy(ac_ur_19, ac_ur_arm)
Test set      ME      RMSE      MAE      MPE      MAPE
              140.25  286.0208  246.4167  25.25341  56.20579
> accuracy(ac_ur_19, ac_ur_des)
Test set      ME      RMSE      MAE      MPE      MAPE
              367.5   570.0262  502.5    22.68082  85.41648
```

- Colesterol: de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección diferente en donde tiene picos más altos en otros meses, por lo que se aleja de los datos reales, mientras que la proyección ARIMA se acerca más a los datos, finalmente al revisar los errores el MAPE menor es el de ARIMA con 40%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 6 – Comparación de Pronósticos vs Real Colesterol

> accuracy(col_19,col_arm)

	ME	RMSE	MAE	MPE	MAPE
Test set	78.5	271.5646	213	9.62913	40.82481

> accuracy(col_19,col_des)

	ME	RMSE	MAE	MPE	MAPE
Test set	182.0833	421.9292	339.25	8.919009	65.75855

- Creatinina: de acuerdo a los modelos revisados con respecto a este ítem la doble suavización exponencial se aleja de los datos reales, ya que le es imposible proyectar el incremento de ventas que se tiene en un periodo establecido, mientras que la proyección ARIMA se acerca más a los datos, ya que si logra realizar esta proyección. Finalmente al revisar los errores el MAPE, se rectifica que el menor es el de ARIMA con 25%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 7– Comparación de Pronósticos vs Real Creatinina

> accuracy(cre_19, cre_arm)

	ME	RMSE	MAE	MPE	MAPE
Test set	149.5833	244.6905	172.75	20.22996	25.94082

> accuracy(cre_19, cre_des)

	ME	RMSE	MAE	MPE	MAPE
Test set	-117.75	241.5842	169.0833	-52.11761	63.49453

- Glucosa: de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección ascendente que se aleja de los datos reales, mientras que la proyección ARIMA se acerca más a los datos, finalmente al revisar los errores el MAPE menor es el de ARIMA con 56%, por lo consiguiente se escoge este modelo de pronóstico.

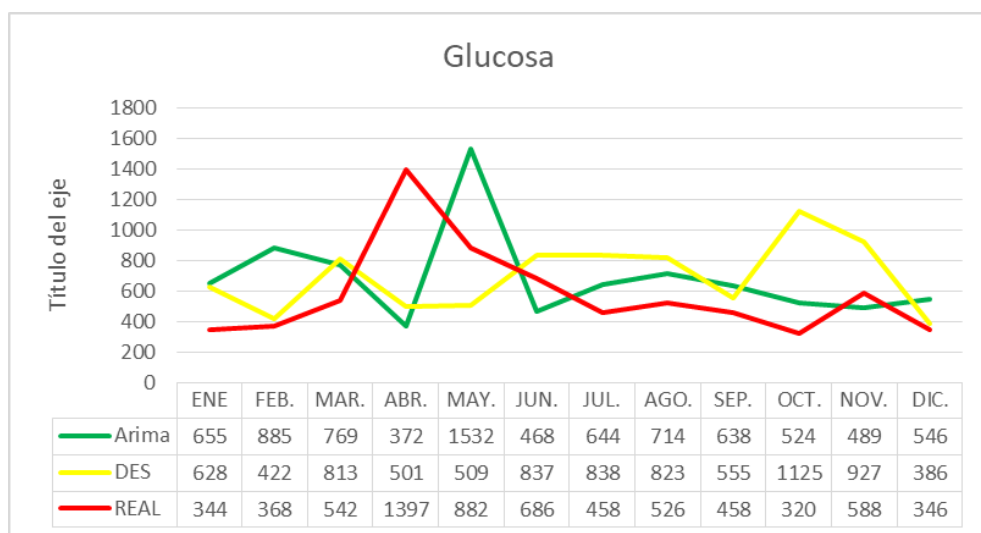


Gráfico 8– Comparación de Pronósticos vs Real Glucosa

```
> accuracy(glu_19,glu_arm)
```

```
Test set      ME      RMSE      MAE      MPE      MAPE
120.75      421.1416    332.25    6.222391  48.24293
```

```
> accuracy(glu_19,glu_des)
```

```
Test set      ME      RMSE      MAE      MPE      MAPE
110.0833     421.302    333.75   -0.46093  56.59977
```

- HDL Colesterol: de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección más cercana a los datos reales, mientras que la proyección ARIMA es un poco más linear con un pico que se desvía de los datos, finalmente al revisar los errores el MAPE, se rectifica que el menor es la de la Doble Suavización Exponencial con 36%, por lo consiguiente se escoge este modelo de pronóstico.

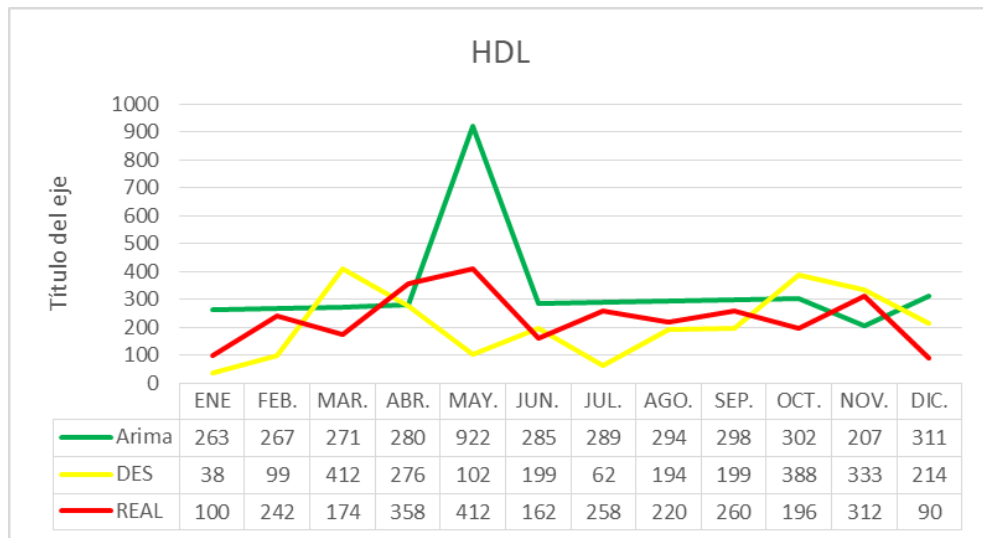


Gráfico 9 – Comparación de Pronósticos vs Real HDL Colesterol

```
> accuracy(hdl_19,hdl_arm)
```

```
Test set      ME      RMSE      MAE      MPE      MAPE
-53.25      141.9122    115.5833  -99.45674  121.5114
```

```
> accuracy(hdl_19,hdl_des)
```

```
Test set      ME      RMSE      MAE      MPE      MAPE
100.4167     181.8651    130.9167  23.48611  36.58307
```

- LDL Colesterol: de acuerdo a los modelos revisados, la suavización exponencial adaptativa tiene una proyección que se asimila a la de los datos reales, mientras que la proyección ARIMA se aleja de los datos, finalmente al revisar los errores el MAPE, el menor es el de Suavización Exponencial Adaptativa con 38%, por tanto se escoge este modelo de pronóstico.




Gráfico 10 -- Comparación de Pronósticos vs Real LDL Colesterol

> accuracy(ldl_19, ldl_arm)

Test set ME RMSE MAE MPE MAPE

> accuracy(ldl_19, ldl_aes)

Test set ME RMSE MAE MPE MAPE

- Lipasa: de acuerdo a los modelos revisados, la suavización exponencial adaptativa tiene una proyección que se acerca más a los datos reales, mientras que la proyección ARIMA se aleja, finalmente al revisar los errores el MAPE, el menor es el de la suavización exponencial adaptativa con 26%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 11 – Comparación de Pronósticos vs Real Lipasa

```

> accuracy(lip_19, lip_arm)
Test set      ME      RMSE      MAE      MPE      MAPE
> accuracy(lip_19, lip_aes)
Test set      ME      RMSE      MAE      MPE      MAPE

```

- TGO Cinético de acuerdo: a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección cerca a la linealidad que se aleja de los datos reales, mientras que la proyección ARIMA se acerca más a los datos, finalmente al revisar los errores el MAPE menor es el de ARIMA con 20%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 12 – Comparación de Pronósticos vs Real TGO Cinético

```

> accuracy(tgo_19, tgo_arm)
Test set      ME      RMSE      MAE      MPE      MAPE
> accuracy(tgo_19, tgo_des)
Test set      ME      RMSE      MAE      MPE      MAPE

```

- TGP Cinético: de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección cerca a la linealidad que se aleja de los datos reales, mientras que la proyección ARIMA se acerca más a los datos, finalmente al revisar los errores el MAPE, se rectifica que el menor es el de ARIMA con 43%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 13– Comparación de Pronósticos vs Real TGP Cinético

> accuracy(tgp_19,tgp_arm)

Test set ME RMSE MAE MPE MAPE

 208.3333 225.3183 208.3333 43.58935 43.58935

> accuracy(tgp_19,tgp_des)

Test set ME RMSE MAE MPE MAPE

 -50.5 159.2341 98.33333 -42.57526 57.43724

- Triglicéridos: de acuerdo a los modelos revisados, la doble suavización exponencial la proyección se aleja de los datos reales, mientras que la proyección ARIMA se acerca más a los datos incluyendo los picos de ventas que tiene, finalmente al revisar los errores el MAPE, el menor es el de ARIMA con 39%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 14– Comparación de Pronósticos vs Real Triglicéridos

```

> accuracy(trig_19,trig_arm)
      ME      RMSE      MAE      MPE      MAPE
Test set  75.16667  302.5222  199      4.279215  39.19087
> accuracy(trig_19,trig_des)
      ME      RMSE      MAE      MPE      MAPE
Test set  106.8333  348.4973  299.3333  3.938385  59.71701

```

- Urea Color: de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección similar a la de los datos reales, mientras que la proyección ARIMA tiene una linealidad que hace que se aleje más de los datos obtenidos, finalmente al revisar los errores el MAPE, se rectifica que el menor es el de la doble suavización exponencial con 30%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 15 – Comparación de Pronósticos vs Real Urea Color

```

> accuracy(urea_col_19,urea_col_arm)
      ME      RMSE      MAE      MPE      MAPE
Test set -175.9167  196.5691  175.9167  -149.0819  149.0819
> accuracy(urea_col_19,urea_col_des)
      ME      RMSE      MAE      MPE      MAPE
Test set  16.33333  92.95877   85      0.31525  30.78895

```

- Urea Cinética de acuerdo a los modelos revisados con respecto a este ítem, la doble suavización exponencial tiene una proyección similar a la de los datos reales, mientras que la proyección ARIMA se aleja por la linealidad, finalmente al revisar los errores el MAPE, el menor es el de doble

suavización exponencial con 38%, por lo consiguiente se escoge este modelo de pronóstico.




Gráfico 16 – Comparación de Pronósticos vs Real Urea Cinética

```

> accuracy(urea_cin_19,urea_cin_arm)
      ME      RMSE      MAE      MPE      MAPE
Test set -131.25 183.5073 161.9167 -53.57143 66.08844
> accuracy(urea_cin_19,urea_cin_des)
      ME      RMSE      MAE      MPE      MAPE
Test set 1.41667 177.7313 134.5833 -11.6271 38.36697

```

CAPÍTULO 4

4. RESULTADOS

4.1. Resultados preliminares

Finalmente se presentan los resultados obtenidos luego del análisis de cada ítem junto con su pronóstico respectivo.

Ácido Úrico	ARIMA
Colesterol	ARIMA
Creatinina	ARIMA
Glucosa	ARIMA
HDL Colesterol	DES
LDL Colesterol	AES
Lipasa	AES
Transaminasa TGO Cinético	ARIMA
Transaminasa TGP Cinético	ARIMA
Triglicéridos	ARIMA
Urea Color	DES
Urea Cinética	DES

Tabla 13 – Resultados del Pronóstico

Una vez finalizada la elección del método adecuado se realiza un gráfico en base al pronóstico con los métodos seleccionados:




Gráfico 17 – Pronóstico Ventas 2019

Y en base a esta información se debería trabajar en los pedidos de importación, la recomendación principal es que se lo realice de manera bimensual, ya que así se puede tener un ahorro significativo en costos de importación.

Así mismo trimestralmente se deberían realizar ajustes al pronóstico, ajustándolo a las ventas reales para hacerlo mucho más específico y cerrado a las ventas reales, ya que considerando que las ventas son direccionadas principalmente al sector público, las ventas tienen una alta correlación con el presupuesto general establecido para el sector salud, así que cualquier modificación que se genere por situaciones ajenas a la economía, tendrá una repercusión significativa en las ventas.

Es así que realizando un análisis final de pronóstico versus ventas 2019, se podría establecer los puntos en donde los ajustes de los pronósticos debieron realizarse.

- **Ácido Úrico:** se realiza el análisis por trimestre del primer ítem, donde la venta versus se encuentra dentro del rango el límite inferior del pronóstico y el pronóstico promedio, al menos 3 de 4 trimestres. En el segundo trimestre la venta sobrepasa el pronóstico, por lo que se debería analizar el realizar ajustes.




Gráfico 18 – Relación Ventas vs Pronóstico Ácido Úrico

- **Colesterol:** se realiza el análisis por trimestre del segundo ítem, donde la venta versus se encuentra dentro del rango el límite inferior del pronóstico y el pronóstico promedio, en lo cual denota que la venta está dentro de este rango, al menos 3 de

4 trimestres. En el segundo trimestre la venta sobrepasa el pronóstico, por lo que se debería analizar el realizar ajustes.




Gráfico 19 – Relación Ventas vs Pronóstico Colesterol

- Creatinina: se realiza el análisis por trimestre del tercer ítem, donde la venta se encuentra entre el límite inferior del pronóstico y el pronóstico promedio, en lo cual denota que la venta está dentro de este rango en todos los trimestres. Los ajustes que se realizarían en este ítem son mínimos.




Gráfico 20 – Relación Ventas vs Pronóstico Creatinina

- Glucosa: se realiza el análisis por trimestre del cuarto ítem, donde la venta se encuentra entre el límite inferior del pronóstico y el pronóstico promedio, en lo cual denota que la venta está dentro de este rango de 3 de los 4 trimestres. Se debe considerar realizar ajustes en este ítem.




Gráfico 21 – Relación Ventas vs Pronóstico Glucosa

- HDL: se realiza el análisis del quinto ítem el cual tiene un comportamiento bastante variable en los años anteriores, por lo que el pronóstico se desfasa entre el segundo y tercer trimestre, por lo que hay que colocar una particular atención para realizar ajustes al pronóstico a tiempo.

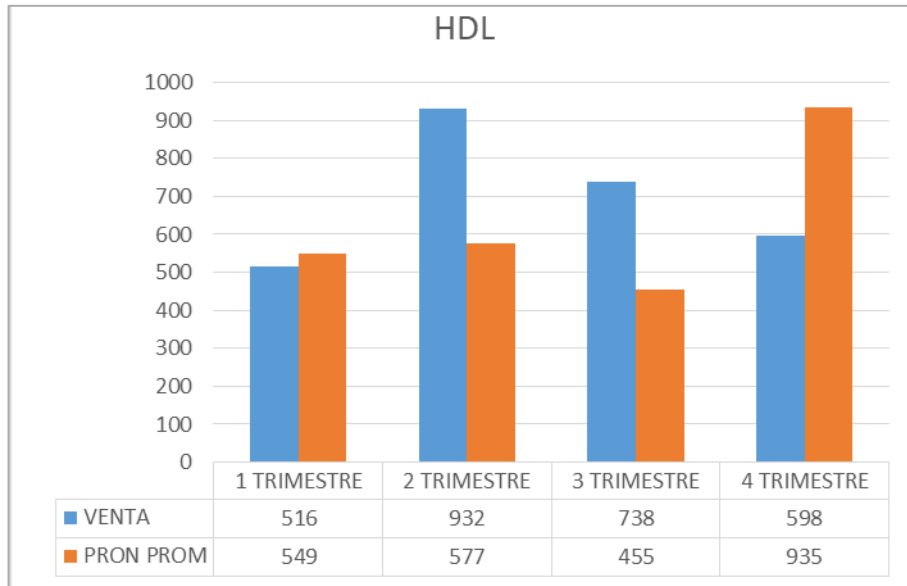


Gráfico 22 – Relación Ventas vs Pronóstico HDL Colesterol

- LDL: se analiza el sexto ítem en donde se nota que existe una variabilidad de los datos por lo que 1 trimestre existe un desfase, por tanto en este ítem al igual que el anterior hay que realizar ajustes al pronóstico de manera mensual para evitar desabastecimiento o exceso de producto.



Gráfico 23 – Relación Ventas vs Pronóstico LDL Colesterol

- Lipasa: Con el ítem séptimo hay una tendencia parecida al ítem anterior LDL, por tanto, es importante que este ítem tenga un ajuste mensual, de lo contrario la venta se puede ver afectada por la variabilidad que tiene el producto.




Gráfico 24 – Relación Ventas vs Pronóstico Lipasa

- TGO Cinético: con el octavo ítem se logra visualizar que la venta se encuentra entre el límite inferior de pronóstico y el pronóstico promedio, aun así se debe considerar realizar ajustes para evitar exceso de inventario.




Gráfico 25 – Relación Ventas vs Pronóstico TGO Cinético

- TGP Cinético: El noveno ítem el TGP Cinético cuenta con un desfase entre el pronóstico establecido y las ventas reales generadas en cada trimestre, la diferencia está establecida en casi un 50% por lo que se debería realizar ajustes al pronóstico de manera mensual para disminuir el impacto generado.




Gráfico 26 – Relación Ventas vs Pronóstico TGP Cinético

- Triglicéridos: El décimo ítem Triglicéridos tiene un pronóstico muy certero en el segundo, tercer y cuarto trimestre, solamente existe un desfase en el primer trimestre, en donde la venta está un 40% por debajo del pronóstico establecido.




Gráfico 27 – Relación Ventas vs Pronóstico Triglicéridos

- El undécimo ítem Urea Color tiene un pronóstico muy similar a la venta, por lo que los ajustes realizados deben ser mínimos para todos los trimestres, con un ajuste bimensual disminuirá al mínimo la diferencia.




Gráfico 28 – Relación Ventas vs Pronóstico Urea Color

- Urea Cinética: al analizar el último ítem se visualiza que se tiene un desfase en varios trimestres, por lo que se deben realizar ajustes a los pronósticos de manera mensual para evitar estas diferencias.




Gráfico 29 – Relación Ventas vs Pronóstico Urea Cinética

4.2. Resultados finales acumulados

Finalmente, y luego de la aplicación adecuada del pronóstico de venta establecido se logra establecer el porcentaje del caducado vs la venta en el año 2019, la venta total fue de \$ 10'383,671 mientras que el caducado ascendió a \$ 199,247 por lo que en porcentaje medio representa el 2.32% que hace que sea menor al caducado obtenido el año anterior que oscilaba entre el 4%.



Gráfico 30 – Ventas vs Caducado 2019

CAPÍTULO 5

5. Conclusiones y Recomendaciones

- La primera conclusión a la que se llega luego de realizada esta investigación es que los datos analizados tienen una alta variabilidad ya que al ser el principal cliente el gobierno, depende de la cantidad de dinero y del momento del tiempo en que se le asignen a cada una de las direcciones distritales los recursos respectivos para que puedan realizar sus compras.
- La segunda conclusión, es que no se puede establecer un mismo modelo de pronóstico para todos los productos, ya que cada uno de ellos tienen un propio estilo de demanda, inclusive siendo productos que se encuentran en un mismo perfil, pueden tener diferencias en las proyecciones.
- La tercera conclusión que se obtiene es que al establecerse un rango de pronóstico para los ítems que tienen el modelo ARIMA, las ventas reales caen dentro de este rango, por lo que se concluye que el modelo se ajusta de manera eficiente al pronóstico. Mientras que en los modelos que son de suavización exponencial, se debe establecer ajustes mensuales a los pronósticos siguientes para cerrar la brecha entre el pronóstico y la venta final.
- La cuarta conclusión a la que se llega es que en el año 2019 usando los pronósticos establecidos y sin realizar ningún ajuste se logra disminuir el porcentaje de caducados de 4.08% a 2.32% lo que implica que los modelos de pronósticos establecidos sí funcionaron para mejorar las cantidades adquiridas con la demanda.
- La primera recomendación es derivada de las anteriores conclusiones, ya que, al tener una alta variabilidad, no se puede establecer un pronóstico fijo para todo el año, lo más aconsejable es realizar ajustes al modelo del pronóstico cada 2 meses para lograr tener números más específicos.

- La segunda recomendación siguiendo con la línea del pronóstico que ayudará a mejorar el aprovisionamiento de productos de la empresa, es que se defina un abastecimiento trimestral de los productos, de esta forma se optimizarán costos de importación.
- La tercera recomendación sería continuar realizando pronósticos para las otras líneas de producto de la empresa, ya que entre más se logren ajustar el pronóstico a la venta real, se logrará disminuir los caducados generados y el desabastecimiento de producto al mercado.

6. Próximas Líneas de Investigación

De acuerdo al estudio que se ha realizado, es de vital importancia para los médicos lograr realizar las pruebas de laboratorio de forma conjunta de acuerdo al perfil que se requiera, de existir algún desfase en cualquiera de ellas, no se lograría tener un diagnóstico completo.

Las pruebas químicas de laboratorio que están dentro de esta marca se realizan para la detección de varias enfermedades relacionadas con el hígado, los riñones, entre otros músculos, si estas pruebas están fuera de los rangos establecidos quiere decir que existe un cambio importante en la salud del paciente, que debe ser analizado y tratado a tiempo.

Los resultados de los análisis están dados de manera diferente de acuerdo a la edad, sexo, raza, alimentación, medicamentos, etc.

Es importante mencionar también que existen ciertas pruebas que tienen una tendencia o una estacionalidad de acuerdo a la patología de cada persona e incluso de acuerdo a la temporada del año, un ejemplo claro son las enfermedades estacionarias en la época de invierno como el Dengue y la Malaria, y así mismo enfermedades que afectan el tracto respiratorio como la Influenza o Virus Sincitial Respiratorio que se dan cuando se generan cambios climáticos o de temporada. Inclusive dentro de un mismo país pueden existir diversas enfermedades en diferentes regiones y en distintas épocas del año, por ejemplo la influenza en la Costa se da entre los meses de enero a marzo, mientras que en la Sierra los meses de mayor contagio están dados entre agosto a octubre.

Existen varios desarrollos tecnológicos que son lanzadas al mercado cada año en ferias internacionales para lograr actualizar las metodologías de pruebas de laboratorio realizadas, en cualquiera de los perfiles que se han mencionado e incluso en otros más que no han sido objetos de este estudio. Lo que buscan los departamentos de investigación y desarrollo de las compañías que se dedican a la manufactura es reducir los tiempos de reacción y aumentar al máximo la sensibilidad y especificidad de cada prueba. Esto quiere decir pruebas reactivas

que dan resultados más rápidos con un mínimo porcentaje de error, así mismo se busca que la metodología sea más sencilla y automatizada, de esta forma se pueden realizar mayor cantidad de pruebas, en vista de que el aumento poblacional en cada ciudad amerita esto.

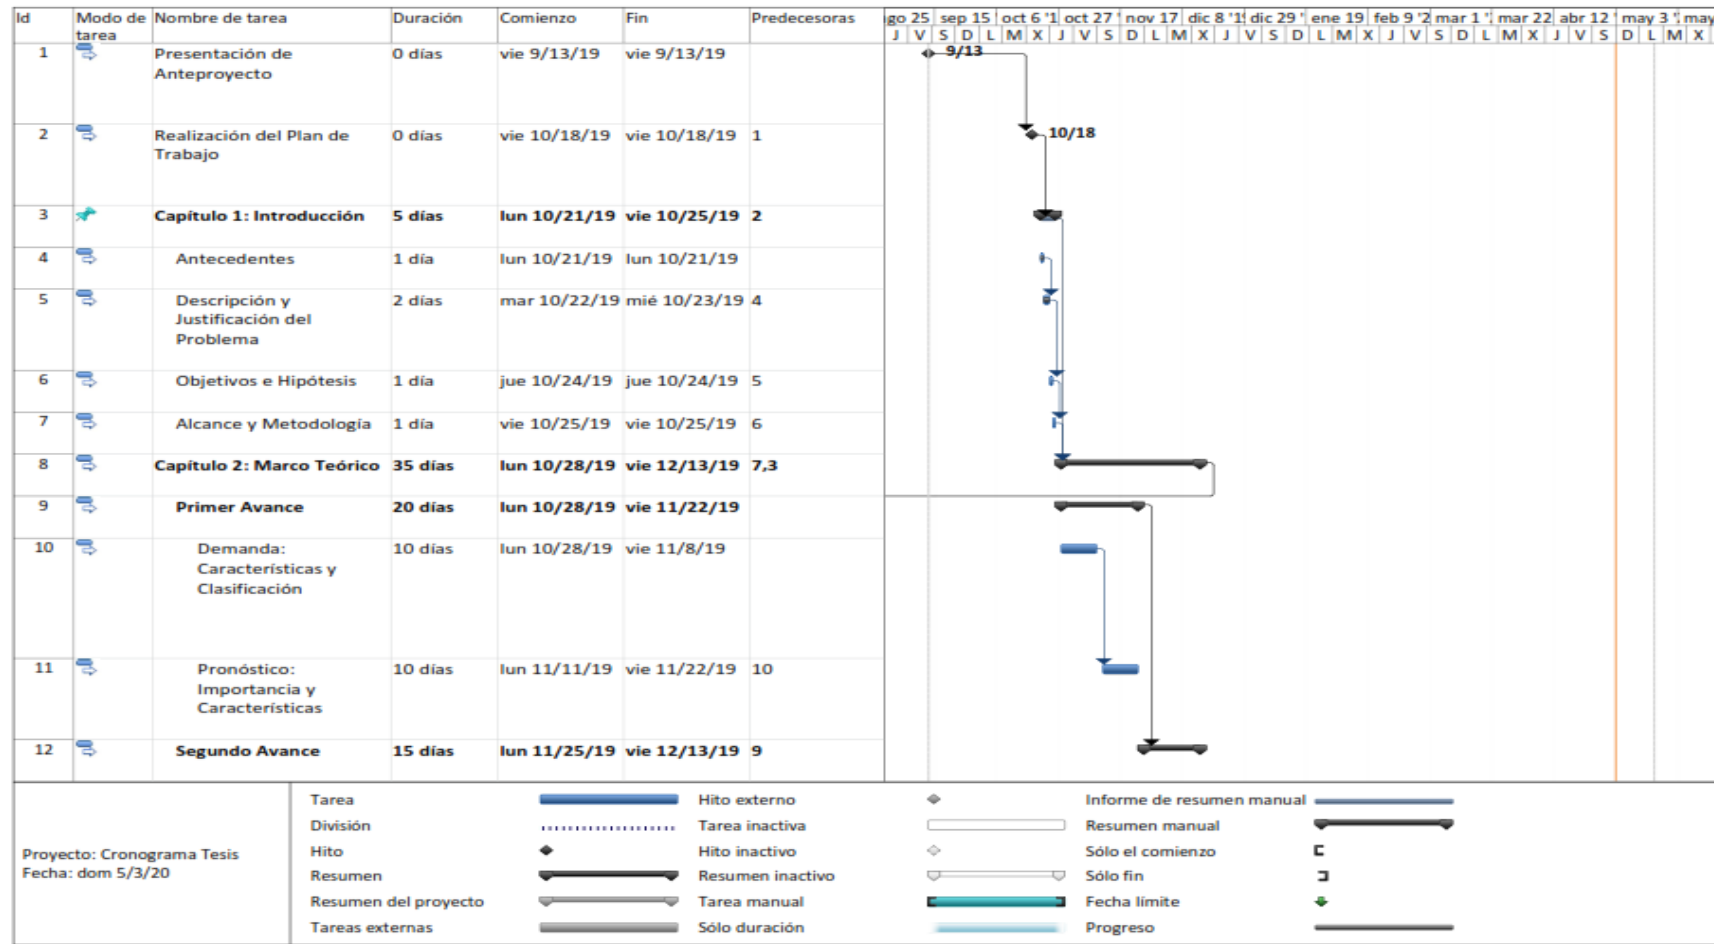
Para las pruebas que se analizan en este estudio no se han realizado investigaciones más profundas ya que son consideradas pruebas de rutina y ya han alcanzado la mayor eficiencia que se pueda desarrollar, normalmente las compañías centran sus análisis en pruebas mucho más específicas, las que están ligadas a la detección de enfermedades oncológicas o para la detección de enfermedades autoinmunes, que son las que actualmente que es más complejo obtener un diagnóstico o no tienen una medicación específica establecida, sino que son tratamientos varios experimentales que se usan.

7. Referencias

- Cruz Gomez, X. (2015). Desarrollo de un Modelo de Crecimiento en Ventas para un Laboratorio Farmacéutico dirigido a clientes importantes aplicando un Modelo Estadístico de Proyección . Guayaquil.
- Kotler, P., & Keller, K. L. (2006). *Dirección de Marketing*. México: Pearson Education, Inc.
- ONLINE, L. T. (2017). *LAB TESTS ONLINE*. Obtenido de <https://labtestsonline.es/tests/>
- Pampillón, R. (2008). *Diccionario de Economía*. Madrid: Departamento de Publicaciones del IE Business School.
- Rodríguez, C. (2009). *Diccionario de Economía*. Mendoza.
- Stanton, W., Etzel, M., & Walker, B. (2004). *Fundamentos de Marketing*. Mc Graw Hill-Interamericana.

8. Apéndices y anexos

8.1. Anexo A: Cronograma de la Tesis





8.2. Apéndice A: Modelos de los Pareto B

ALBUMINA

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.6687
s.e. 0.1047

sigma^2 estimated as 1315: log likelihood=-295.37

AIC=594.74 AICc=594.95 BIC=598.89

> m1_Alb=auto.arima(vtas_Alb)

> forecast(m1_Alb,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	89.40732	42.93329	135.8813	18.3314278	160.4832
Feb 2019	89.40732	40.44920	138.3654	14.5323416	164.2823
Mar 2019	89.40732	38.08521	140.7294	10.9169236	167.8977
Apr 2019	89.40732	35.82541	142.9892	7.4608602	171.3538
May 2019	89.40732	33.65714	145.1575	4.1447713	174.6699
Jun 2019	89.40732	31.57009	147.2445	0.9529128	177.8617
Jul 2019	89.40732	29.55578	149.2589	-2.1277121	180.9424
Aug 2019	89.40732	27.60709	151.2076	-5.1079806	183.9226
Sep 2019	89.40732	25.71799	153.0967	-7.9971049	186.8117
Oct 2019	89.40732	23.88333	154.9313	-10.8029686	189.6176
Nov 2019	89.40732	22.09867	156.7160	-13.5323802	192.3470
Dec 2019	89.40732	20.36011	158.4545	-16.1912682	195.0059

AMYLASA

ARIMA(0,1,3)

Coefficients:

 ma1 ma2 ma3
 -0.5752 -0.3857 0.3703
s.e. 0.1306 0.1483 0.2035

sigma^2 estimated as 291.1: log likelihood=-250.06

AIC=508.12 AICc=508.86 BIC=516.43

> m1_Amy=auto.arima(vtas_Amy)

> forecast(m1_Amy,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	32.22902	10.3637971	54.09424	-1.210953	65.66899
Feb 2019	43.37613	19.6200728	67.13219	7.044376	79.70788
Mar 2019	32.20937	8.4379689	55.98078	-4.145852	68.56460
Apr 2019	32.20937	6.8085532	57.61019	-6.637829	71.05658
May 2019	32.20937	5.2775398	59.14121	-8.979312	73.39806
Jun 2019	32.20937	3.8289989	60.58975	-11.194664	75.61341
Jul 2019	32.20937	2.4508847	61.96786	-13.302308	77.72105
Aug 2019	32.20937	1.1338260	63.28492	-15.316575	79.73532
Sep 2019	32.20937	-0.1296377	64.54838	-17.248876	81.66762
Oct 2019	32.20937	-1.3455612	65.76431	-19.108470	83.52722
Nov 2019	32.20937	-2.5189382	66.93768	-20.902996	85.32174
Dec 2019	32.20937	-3.6539452	68.07269	-22.638839	87.05759

FOSFATASA ALCALINA

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.5439
s.e. 0.1362

sigma^2 estimated as 1304: log likelihood=-295.01

AIC=594.01 AICc=594.22 BIC=598.17

> m1_Fosf_Alc=auto.arima(Vtas_Fosf_Alc)

> forecast(m1_Fosf_Alc,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	60.81195	14.527960	107.0959	-9.973302	131.5972	
Feb 2019	60.81195	9.940802	111.6831	-16.988755	138.6126	
Mar 2019	60.81195	5.734371	115.8895	-23.421936	145.0458	
Apr 2019	60.81195	1.827158	119.7967	-29.397503	151.0214	
May 2019	60.81195	-1.836846	123.4607	-35.001113	156.6250	
Jun 2019	60.81195	-5.298092	126.9220	-40.294632	161.9185	
Jul 2019	60.81195	-8.586923	130.2108	-45.324465	166.9484	
Aug 2019	60.81195	-11.726796	133.3507	-50.126485	171.7504	
Sep 2019	60.81195	-14.736283	136.3602	-54.729100	176.3530	
Oct 2019	60.81195	-17.630395	139.2543	-59.155262	180.7792	
Nov 2019	60.81195	-20.421464	142.0454	-63.423833	185.0477	
Dec 2019	60.81195	-23.119769	144.7437	-67.550535	189.1744	

GAMMA GT

Series: Vtas_GGT

ARIMA(5,1,3)(0,0,1)[12] with drift

Coefficients:

	ar1	ar2	ar3	ar4	ar5	ma1	ma2	ma
3 sma1	0.2871	-0.8841	-0.4165	-0.1903	-0.5071	-1.2253	1.1946	-0.494
4 -0.7450								
s.e. 0.1623	0.1751	0.1760	0.1240	0.1538	0.1925	0.1756	0.214	
4 0.2827								
drift								
0.8365								
s.e. 0.2572								

sigma^2 estimated as 427.9: log likelihood=-263.18

AIC=548.36 AICc=553.97 BIC=571.21

> m1_GGT=auto.arima(Vtas_GGT)

> forecast(m1_GGT,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	112.35836	85.617130	139.09959	71.461178	153.25554	
Feb 2019	121.91506	95.127789	148.70233	80.947464	162.88265	
Mar 2019	77.49297	50.560455	104.42548	36.303244	118.68269	
Apr 2019	49.60248	22.654362	76.55060	8.388889	90.81607	
May 2019	47.56315	20.209319	74.91697	5.729078	89.39722	
Jun 2019	78.92151	51.517462	106.32556	37.010635	120.83239	
Jul 2019	33.67032	5.568614	61.77203	-9.307531	76.64818	
Aug 2019	104.97229	74.241091	135.70348	57.972979	151.97160	
Sep 2019	100.67169	68.326635	133.01675	51.204195	150.13919	
Oct 2019	66.24824	33.903259	98.59323	16.780858	115.71563	
Nov 2019	45.03729	12.646775	77.42780	-4.499727	94.57430	
Dec 2019	71.96391	39.491695	104.43612	22.301944	121.62588	

8.3. Apéndice A: Modelos de los Pareto C

BILIRRUBINA DIRECTA

ARIMA(0,1,1) with drift

Coefficients:

	ma1	drift
	-0.9224	1.4552
s.e.	0.1379	0.5132

sigma^2 estimated as 1456: log likelihood=-298.51
 AIC=603.02 AICc=603.46 BIC=609.26

```
> m1_Amy=auto.arima(Vtas_Bil_D)
> forecast(m1_Bil_D,12)
> m1_Bil_D=auto.arima(Vtas_Bil_D)
> forecast(m1_Bil_D,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		80.15046	31.25028	129.0506	5.364086	154.9368
Feb 2019		81.60567	32.55842	130.6529	6.594372	156.6170
Mar 2019		83.06087	33.86700	132.2547	7.825330	158.2964
Apr 2019		84.51608	35.17601	133.8561	9.056955	159.9752
May 2019		85.97129	36.48546	135.4571	10.289240	161.6533
Jun 2019		87.42649	37.79533	137.0577	11.522180	163.3308
Jul 2019		88.88170	39.10563	138.6578	12.755769	165.0076
Aug 2019		90.33691	40.41635	140.2575	13.990001	166.6838
Sep 2019		91.79211	41.72749	141.8567	15.224871	168.3594
Oct 2019		93.24732	43.03903	143.4556	16.460373	170.0343
Nov 2019		94.70253	44.35099	145.0541	17.696502	171.7086
Dec 2019		96.15774	45.66336	146.6521	18.933252	173.3822

BILIRRUBINA TOTAL

ARIMA(0,1,1)

Coefficients:

	ma1
	-0.7807
s.e.	0.0864

sigma^2 estimated as 422.3: log likelihood=-262.03
 AIC=528.06 AICc=528.28 BIC=532.22

```
> m1_Bil_T=auto.arima(Vtas_Bil_T)
> forecast(m1_Bil_T,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		38.63556	12.300064	64.97107	-1.641109	78.91224
Feb 2019		38.63556	11.673959	65.59717	-2.598654	79.86978
Mar 2019		38.63556	11.062067	66.20906	-3.534461	80.80559
Apr 2019		38.63556	10.463462	66.80767	-4.449949	81.72108
May 2019		38.63556	9.877314	67.39382	-5.346384	82.61751
Jun 2019		38.63556	9.302877	67.96825	-6.224910	83.49604
Jul 2019		38.63556	8.739476	68.53165	-7.086558	84.35769
Aug 2019		38.63556	8.186497	69.08463	-7.932266	85.20340
Sep 2019		38.63556	7.643383	69.62775	-8.762887	86.03402
Oct 2019		38.63556	7.109625	70.16151	-9.579200	86.85033
Nov 2019		38.63556	6.584754	70.68638	-10.381921	87.65305
Dec 2019		38.63556	6.068341	71.20279	-11.171706	88.44284

BILIRRUBINA TOTA Y DIRECTA

ARIMA(0,1,1)

Coefficients:

```
      ma1
      -0.7807
s.e.    0.0864
```

sigma² estimated as 422.3: log likelihood=-262.03

AIC=528.06 AICC=528.28 BIC=532.22

```
> m1_Bil_T=auto.arima(Vtas_Bil_T)
```

```
> forecast(m1_Bil_T,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		38.63556	12.300064	64.97107	-1.641109	78.91224
Feb 2019		38.63556	11.673959	65.59717	-2.598654	79.86978
Mar 2019		38.63556	11.062067	66.20906	-3.534461	80.80559
Apr 2019		38.63556	10.463462	66.80767	-4.449949	81.72108
May 2019		38.63556	9.877314	67.39382	-5.346384	82.61751
Jun 2019		38.63556	9.302877	67.96825	-6.224910	83.49604
Jul 2019		38.63556	8.739476	68.53165	-7.086558	84.35769
Aug 2019		38.63556	8.186497	69.08463	-7.932266	85.20340
Sep 2019		38.63556	7.643383	69.62775	-8.762887	86.03402
Oct 2019		38.63556	7.109625	70.16151	-9.579200	86.85033
Nov 2019		38.63556	6.584754	70.68638	-10.381921	87.65305
Dec 2019		38.63556	6.068341	71.20279	-11.171706	88.44284

CALCIO

ARIMA(0,1,1)

Coefficients:

```
      ma1
      -0.7537
s.e.    0.1009
```

sigma² estimated as 34.75: log likelihood=-188.3

AIC=380.6 AICC=380.82 BIC=384.76

```
> m1_Cal=auto.arima(Vtas_Cal)
```

```
> forecast(m1_Cal,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		16.19623	8.641832	23.75063	4.642773	27.74969
Feb 2019		16.19623	8.416004	23.97646	4.297400	28.09507
Mar 2019		16.19623	8.196550	24.19592	3.961773	28.43069
Apr 2019		16.19623	7.982956	24.40951	3.635110	28.75736
May 2019		16.19623	7.774779	24.61769	3.316730	29.07574
Jun 2019		16.19623	7.571625	24.82084	3.006033	29.38643
Jul 2019		16.19623	7.373147	25.01932	2.702488	29.68998
Aug 2019		16.19623	7.179037	25.21343	2.405622	29.98684
Sep 2019		16.19623	6.989018	25.40345	2.115013	30.27745
Oct 2019		16.19623	6.802843	25.58962	1.830283	30.56218
Nov 2019		16.19623	6.620286	25.77218	1.551086	30.84138
Dec 2019		16.19623	6.441145	25.95132	1.277114	31.11535

COLORO

ARIMA(0,0,0) with non-zero mean

Coefficients:

 mean
 5.5500
s.e. 0.6517

sigma² estimated as 25.91: log likelihood=-182.27

AIC=368.55 AICc=368.76 BIC=372.74

> m1_Clo=auto.arima(Vtas_Clo)

> forecast(m1_Clo,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Feb 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Mar 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Apr 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
May 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Jun 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Jul 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Aug 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Sep 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Oct 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Nov 2019	5.55	-0.973678	12.07368	-4.427105	15.5271
Dec 2019	5.55	-0.973678	12.07368	-4.427105	15.5271

COLINESTERASA

ARIMA(4,1,0)

Coefficients:

 ar1 ar2 ar3 ar4
 -0.9505 -0.9399 -0.7003 -0.5601
s.e. 0.1210 0.1618 0.1664 0.1489

sigma² estimated as 166.6: log likelihood=-233.75

AIC=477.51 AICc=478.64 BIC=487.89

> m1_Colin=auto.arima(Vtas_Colin)

> forecast(m1_Colin,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	51.34877	34.8055272	67.89202	26.048061	76.64949
Feb 2019	11.93152	-4.6319627	28.49500	-13.400140	37.26318
Mar 2019	8.51680	-8.0480890	25.08169	-16.817012	33.85061
Apr 2019	16.91477	-0.1224952	33.95203	-9.141478	42.97102
May 2019	11.54480	-5.7073690	28.79697	-14.840116	37.92972
Jun 2019	33.22376	13.4762802	52.97124	3.022596	63.42492
Jul 2019	13.69643	-6.1468655	33.53972	-16.651271	44.04413
Aug 2019	10.93805	-8.9640152	30.84011	-19.499530	41.37562
Sep 2019	19.74074	-0.7824657	40.26395	-11.646794	51.12827
Oct 2019	15.49846	-5.3377899	36.33470	-16.367832	47.36474
Nov 2019	24.12553	2.3715040	45.87955	-9.144381	57.39544
Dec 2019	15.29341	-6.6469660	37.23378	-18.261498	48.84831

FOSFATASA ACIDA

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.8987
s.e. 0.0568

sigma^2 estimated as 4.766: log likelihood=-130.1

AIC=264.2 AICc=264.41 BIC=268.35

> m1_Fosf_Ac=auto.arima(Vtas_Fosf_Ac)

> forecast(m1_Fosf_Ac,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	0.7634981	-2.034162	3.561159	-3.515155	5.042151
Feb 2019	0.7634981	-2.048482	3.575479	-3.537055	5.064051
Mar 2019	0.7634981	-2.062730	3.589726	-3.558845	5.085841
Apr 2019	0.7634981	-2.076906	3.603902	-3.580525	5.107521
May 2019	0.7634981	-2.091011	3.618007	-3.602097	5.129093
Jun 2019	0.7634981	-2.105047	3.632044	-3.623564	5.150560
Jul 2019	0.7634981	-2.119015	3.646011	-3.644926	5.171922
Aug 2019	0.7634981	-2.132916	3.659912	-3.666185	5.193181
Sep 2019	0.7634981	-2.146750	3.673746	-3.687342	5.214338
Oct 2019	0.7634981	-2.160518	3.687515	-3.708399	5.235395
Nov 2019	0.7634981	-2.174222	3.701219	-3.729358	5.256354
Dec 2019	0.7634981	-2.187863	3.714859	-3.750219	5.277215

FOSFORO

ARIMA(0,0,0) with non-zero mean

Coefficients:

 mean
 3.6833
s.e. 0.3436

sigma^2 estimated as 7.203: log likelihood=-143.87

AIC=291.73 AICc=291.95 BIC=295.92

> m1_Fosf=auto.arima(Vtas_Fosf)

> forecast(m1_Fosf,12)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Feb 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Mar 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Apr 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
May 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Jun 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Jul 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Aug 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Sep 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Oct 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Nov 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603
Dec 2019	3.683333	0.2438277	7.122839	-1.576937	8.943603

HEMOGLOBINA

ARIMA(0,0,0) with non-zero mean

Coefficients:

 mean
 1.4833
s.e. 0.1979

sigma² estimated as 2.39: log likelihood=-110.77

AIC=225.53 AICc=225.74 BIC=229.72

```
> m1_Hemg=auto.arima(Vtas_Hemg)
```

```
> forecast(m1_Hemg,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Feb 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Mar 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Apr 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
May 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Jun 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Jul 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Aug 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Sep 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Oct 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Nov 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078
Dec 2019		1.483333	-0.49771	3.464377	-1.546411	4.513078

HIERRO

ARIMA(0,1,1)(1,0,0)[12]

Coefficients:

 ma1 sar1
 -0.7571 0.2228
s.e. 0.0999 0.1245

sigma² estimated as 28.8: log likelihood=-182.55

AIC=371.1 AICc=371.54 BIC=377.34

```
> m1_Iron=auto.arima(Vtas_Iron)
```

```
> forecast(m1_Iron,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		9.749507	2.8722642	16.62675	-0.7683285	20.26734
Feb 2019		7.521600	0.4443758	14.59882	-3.3020804	18.34528
Mar 2019		9.303926	2.0322182	16.57563	-1.8171913	20.42504
Apr 2019		9.526717	2.0655933	16.98784	-1.8840869	20.93752
May 2019		8.635554	0.9897057	16.28140	-3.0577617	20.32887
Jun 2019		9.526717	1.7005029	17.35293	-2.4424444	21.49588
Jul 2019		9.081135	1.0786199	17.08365	-3.1576558	21.31993
Aug 2019		9.303926	1.1289103	17.47894	-3.1986815	21.80653
Sep 2019		8.858345	0.5143940	17.20229	-3.9026266	21.61932
Oct 2019		10.417880	1.9083473	18.92741	-2.5963269	23.43209
Nov 2019		9.081135	0.4091822	17.75309	-4.1814724	22.34374
Dec 2019		8.412763	-0.4186241	17.24415	-5.0936780	21.91920

LDH

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.8394
s.e. 0.0756

sigma^2 estimated as 387.8: log likelihood=-259.66

AIC=523.31 AICc=523.53 BIC=527.47

> m1_LDH=auto.arima(Vtas_LDH)

> forecast(m1_LDH,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	23.85925	-1.377204	49.09571	-14.73658	62.45509	
Feb 2019	23.85925	-1.700739	49.41925	-15.23138	62.94989	
Mar 2019	23.85925	-2.020230	49.73874	-15.72000	63.43851	
Apr 2019	23.85925	-2.335824	50.05433	-16.20266	63.92117	
May 2019	23.85925	-2.647661	50.36617	-16.67957	64.39808	
Jun 2019	23.85925	-2.955872	50.67438	-17.15094	64.86945	
Jul 2019	23.85925	-3.260580	50.97909	-17.61695	65.33546	
Aug 2019	23.85925	-3.561903	51.28041	-18.07779	65.79629	
Sep 2019	23.85925	-3.859950	51.57846	-18.53361	66.25212	
Oct 2019	23.85925	-4.154827	51.87333	-18.98458	66.70309	
Nov 2019	23.85925	-4.446631	52.16514	-19.43086	67.14937	
Dec 2019	23.85925	-4.735458	52.45397	-19.87258	67.59109	

MAGNESIO

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.8211
s.e. 0.0955

sigma^2 estimated as 11.68: log likelihood=-156.27

AIC=316.55 AICc=316.76 BIC=320.7

> m1_Mag=auto.arima(Vtas_Mag)

> forecast(m1_Mag,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	7.054256	2.674930	11.43358	0.35665479	13.75186	
Feb 2019	7.054256	2.605392	11.50312	0.25030543	13.85821	
Mar 2019	7.054256	2.536924	11.57159	0.14559298	13.96292	
Apr 2019	7.054256	2.469478	11.63903	0.04244410	14.06607	
May 2019	7.054256	2.403011	11.70550	-0.05920922	14.16772	
Jun 2019	7.054256	2.337480	11.77103	-0.15943022	14.26794	
Jul 2019	7.054256	2.272847	11.83566	-0.25827778	14.36679	
Aug 2019	7.054256	2.209076	11.89943	-0.35580686	14.46432	
Sep 2019	7.054256	2.146134	11.96238	-0.45206887	14.56058	
Oct 2019	7.054256	2.083989	12.02452	-0.54711193	14.65562	
Nov 2019	7.054256	2.022611	12.08590	-0.64098121	14.74949	
Dec 2019	7.054256	1.961973	12.14654	-0.73371916	14.84223	

POTASIO

ARIMA(0,0,0) with non-zero mean

Coefficients:

mean
1.3833
s.e. 0.2507

sigma² estimated as 3.834: log likelihood=-124.95

AIC=253.89 AICc=254.1 BIC=258.08

> m1_Pot=auto.arima(Vtas_Pot)

> forecast(m1_Pot,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Feb 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Mar 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Apr 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
May 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Jun 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Jul 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Aug 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Sep 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Oct 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Nov 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	
Dec 2019	1.383333	-1.125896	3.892563	-2.454202	5.220869	

PROTEINAS EN ORINA

ARIMA(1,0,0) with non-zero mean

Coefficients:

ar1 mean
0.4063 6.1733
s.e. 0.1163 0.9641

sigma² estimated as 20.8: log likelihood=-175.25

AIC=356.51 AICc=356.93 BIC=362.79

> m1_Prot_0=auto.arima(Vtas_Prot_0)

> forecast(m1_Prot_0,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	5.696591	-0.1476792	11.54086	-3.241449	14.63463	
Feb 2019	5.979606	-0.3286018	12.28781	-3.667965	15.62718	
Mar 2019	6.094591	-0.2869558	12.47614	-3.665143	15.85432	
Apr 2019	6.141308	-0.2522640	12.53488	-3.636816	15.91943	
May 2019	6.160288	-0.2352663	12.55584	-3.620868	15.94145	
Jun 2019	6.168000	-0.2278821	12.56388	-3.613657	15.94966	
Jul 2019	6.171133	-0.2248030	12.56707	-3.610607	15.95287	
Aug 2019	6.172406	-0.2235390	12.56835	-3.609348	15.95416	
Sep 2019	6.172923	-0.2230233	12.56887	-3.608833	15.95468	
Oct 2019	6.173133	-0.2228134	12.56908	-3.608623	15.95489	
Nov 2019	6.173218	-0.2227281	12.56917	-3.608538	15.95497	
Dec 2019	6.173253	-0.2226934	12.56920	-3.608503	15.95501	

PROTEINAS TOTALES

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.6974
s.e. 0.1160

sigma^2 estimated as 2125: log likelihood=-309.56

AIC=623.12 AICc=623.34 BIC=627.28

> m1_Prot_T=auto.arima(Vtas_Prot_T)

> forecast(m1_Prot_T,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		97.50804	38.43086	156.5852	7.1572845	187.8588
Feb 2019		97.50804	35.78503	159.2310	3.1108476	191.9052
Mar 2019		97.50804	33.24806	161.7680	-0.7691235	195.7852
Apr 2019		97.50804	30.80750	164.2086	-4.5016252	199.5177
May 2019		97.50804	28.45315	166.5629	-8.1022943	203.1184
Jun 2019		97.50804	26.17647	168.8396	-11.5841854	206.6003
Jul 2019		97.50804	23.97023	171.0458	-14.9583308	209.9744
Aug 2019		97.50804	21.82829	173.1878	-18.2341541	213.2502
Sep 2019		97.50804	19.74532	175.2708	-21.4197802	216.4359
Oct 2019		97.50804	17.71671	177.2994	-24.5222732	219.5384
Nov 2019		97.50804	15.73841	179.2777	-27.5478206	222.5639
Dec 2019		97.50804	13.80685	181.2092	-30.5018783	225.5180

SODIO

ARIMA(0,0,0)(1,0,0)[12] with non-zero mean

Coefficients:

 sar1 mean
 0.312 1.7063
s.e. 0.176 0.4728

sigma^2 estimated as 7.749: log likelihood=-146.16

AIC=298.32 AICc=298.75 BIC=304.6

> m1_Sod=auto.arima(Vtas_Sod)

> forecast(m1_Sod,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		1.485944	-2.0814883	5.053377	-3.969973	6.941862
Feb 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868
Mar 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868
Apr 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868
May 2019		2.733920	-0.8335125	6.301353	-2.721997	8.189837
Jun 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868
Jul 2019		2.109932	-1.4575004	5.677365	-3.345985	7.565850
Aug 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868
Sep 2019		1.485944	-2.0814883	5.053377	-3.969973	6.941862
Oct 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868
Nov 2019		2.421926	-1.1455064	5.989359	-3.033991	7.877843
Dec 2019		1.173950	-2.3934823	4.741383	-4.281967	6.629868

TGO Color

ARIMA(0,0,1) with non-zero mean

Coefficients:

	ma1	mean
	0.2143	2.5234
s.e.	0.1181	0.5300

sigma² estimated as 11.89: log likelihood=-158.42

AIC=322.83 AICc=323.26 BIC=329.11

```
> m1_TGO_Color=auto.arima(Vtas_TGO_Color)
```

```
> forecast(m1_TGO_Color,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		2.076834	-2.342314	6.495983	-4.681670	8.835339
Feb 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Mar 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Apr 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
May 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Jun 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Jul 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Aug 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Sep 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Oct 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Nov 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442
Dec 2019		2.523440	-1.996075	7.042955	-4.388562	9.435442

TGP Color

ARIMA(1,0,0) with non-zero mean

Coefficients:

	ar1	mean
	0.2138	2.5151
s.e.	0.1257	0.5323

sigma² estimated as 10.96: log likelihood=-155.98

AIC=317.96 AICc=318.38 BIC=324.24

```
> m1_TGP_Color=auto.arima(Vtas_TGP_Color)
```

```
> forecast(m1_TGP_Color,12)
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019		1.977279	-2.265939	6.220496	-4.512163	8.466720
Feb 2019		2.400072	-1.939065	6.739209	-4.236065	9.036209
Mar 2019		2.490476	-1.852996	6.833948	-4.152291	9.133243
Apr 2019		2.509807	-1.833863	6.853476	-4.133263	9.152876
May 2019		2.513940	-1.829739	6.857619	-4.129144	9.157024
Jun 2019		2.514824	-1.828855	6.858503	-4.128260	9.157908
Jul 2019		2.515013	-1.828666	6.858692	-4.128071	9.158097
Aug 2019		2.515053	-1.828626	6.858733	-4.128031	9.158137
Sep 2019		2.515062	-1.828617	6.858741	-4.128022	9.158146
Oct 2019		2.515064	-1.828616	6.858743	-4.128021	9.158148
Nov 2019		2.515064	-1.828615	6.858743	-4.128020	9.158148
Dec 2019		2.515064	-1.828615	6.858743	-4.128020	9.158148

TIBC

ARIMA(0,1,1)

Coefficients:

 ma1
 -0.7978
s.e. 0.0829

sigma^2 estimated as 14.43: log likelihood=-162.46

AIC=328.92 AICc=329.13 BIC=333.07

> m1_TIBC=auto.arima(Vtas_TIBC)

> forecast(m1_TIBC,12)

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2019	3.902112	-0.9656986	8.769923	-3.542562	11.34679	
Feb 2019	3.902112	-1.0642486	8.868473	-3.693281	11.49751	
Mar 2019	3.902112	-1.1608806	8.965105	-3.841067	11.64529	
Apr 2019	3.902112	-1.2557026	9.059927	-3.986085	11.79031	
May 2019	3.902112	-1.3488126	9.153037	-4.128484	11.93271	
Jun 2019	3.902112	-1.4403001	9.244524	-4.268402	12.07263	
Jul 2019	3.902112	-1.5302470	9.334471	-4.405964	12.21019	
Aug 2019	3.902112	-1.6187286	9.422953	-4.541285	12.34551	
Sep 2019	3.902112	-1.7058144	9.510039	-4.674471	12.47870	
Oct 2019	3.902112	-1.7915683	9.595793	-4.805621	12.60985	
Nov 2019	3.902112	-1.8760498	9.680274	-4.934824	12.73905	
Dec 2019	3.902112	-1.9593136	9.763538	-5.062165	12.86639	