



**FACULTAD DE ECONOMIA Y NEGOCIOS
MAGISTER EN GESTION DE SISTEMAS DE SALUD**

TRABAJO DE GRADO

Análisis y proyección de las compras de insulina del Hospital Curicó

ALUMNO

Juana González Lara

PROFESOR GUIA

Dra. Sandra Alvear Vega

**TRABAJO DE GRADO PARA OPTAR AL GRADO DE MAGISTER
EN GESTION DE SISTEMAS DE SALUD**

Diciembre, 2017

CONSTANCIA

La Dirección del Sistema de Bibliotecas a través de su unidad de procesos técnicos certifica que el autor del siguiente trabajo de titulación ha firmado su autorización para la reproducción en forma total o parcial e ilimitada del mismo.



Talca, 2019

Contenido

1.- Introducción.....	4
2.- Identificación del Problema	5
2.1 Preguntas de Investigación	5
3. Objetivos.....	5
3.1 Objetivo General:	5
3.2 Objetivos específicos:.....	5
4.- Revisión de literatura	6
5. Antecedentes.....	7
5.1 Contextualización de la Red Sanitaria	7
5.2 Epidemiología de la Diabetes	7
5.3 Legislación Relacionada.....	8
5.3.1 Plan AUGE	8
5.3.2 Ley de Compras Públicas	8
6.- Metodología.....	9
6.1 Recolección de los datos.....	9
6.2 Metodología de análisis.....	9
7.- Datos.....	11
8.-Resultados	12
8.1 Análisis descriptivo de los datos.....	12
8.1.1. Histograma	12
8.1.2 Boxplot	13
8.1.3 Plot.....	14
8.1.4 Media de Cuartiles.....	16
8.2 Determinación de Modelos y Pronósticos.....	16
8.2.1 Modelo ARIMA.....	16
8.2.2 Pronóstico	20
09. Conclusiones	22
10. Recomendaciones	23
11. Limitaciones.....	23
12. Bibliografía.....	24

Anexos	25
Anexo N° 1: Modelos ARIMA.....	25
Anexo N° 2: Tabla de Error Cuadrático Medio	27

1.- Introducción

Según la Encuesta Nacional de Salud 2009-2010 la prevalencia de Diabetes en Chile es de 9,4% de la población, la cual tiene una tendencia al alza, esto sumado a la mala calidad de hábitos alimenticios y deportivos de la población, que son determinantes de la patología, ponen al país un tremendo desafío que enfrentar para cubrir los costos que esta alza de pacientes requerirán (Minsal, 2010)

En el año 2010 el Ministerio de Salud, incorporó la Diabetes al Régimen de Garantías Explícitas en Salud (GES, denominado anteriormente Plan Auge), con lo cual obliga a los establecimientos de salud a prestar de forma oportuna y garantizada, tanto el diagnóstico como el tratamiento de la enfermedad.

Existen estudios de costos de la Diabetes, uno de ellos realizado por la Asociación Americana de Diabetes, determinó el costo total estimado de esta enfermedad en \$ 245 mil millones en el año 2012, y señala también que los costos que tiene una persona diabética son 2,3 veces mayores a los de una persona sin la enfermedad.

Debido a lo anteriormente expuesto, este trabajo tiene por objetivo analizar la evolución de las compras de insulina del Hospital de Curicó, de modo de poder describir, modelar y pronosticar esta serie de datos, ya que los Hospitales tienen un presupuesto reducido, y por ser la Diabetes una patología del Plan Auge están obligados a cubrir el tratamiento de los pacientes que lo requieran de forma oportuna, por lo cual es de vital importancia que conozcan el impacto financiero que esto significa, para que lo consideren en los presupuestos de los años siguientes.

Para realizar este trabajo se realizará un análisis de serie de tiempo, basado en la metodología definida por Box y Jenkins en el año 1970, de las compras de insulinas que ha realizado el Hospital Curicó.

Las compras de insulina tienen un comportamiento variable. Sin embargo, es posible pronosticar estos datos para el periodo siguiente, el cual para enero 2017 es de \$ 26.672.398, el cual va aumentando hasta llegar a diciembre 2017 a valor total de las compras de insulina de \$ 40. 933.071.

A continuación, se detallara en sección dos y tres identificación del problema y objetivos del estudio; en la sección cuatro una revisión de la literatura relevante asociada al tema; posteriormente en la sección cinco la metodología y datos empleados, para finalizar con los resultados, conclusiones obtenidas y bibliografía utilizada.

2.- Identificación del Problema

Año tras año los Hospitales en Chile se ven enfrentados a definir un plan de compras para el periodo siguiente, para lo cual deben considerar que cuentan con un presupuesto limitado y una demanda creciente por sus servicios, por esta razón es de vital importancia analizar el comportamiento de las compras de años anteriores, de modo de identificar posibles tendencias que nos ayuden a pronosticar el periodo siguiente de forma más fiable.

Por otra parte, tenemos que tras la implementación del Plan Auge, se les obliga a los Hospitales a dar un tratamiento oportuno a los pacientes, si el plan de compras no es adecuado y no se ajusta a la realidad, los hospitales no contarán con los recursos necesarios para prestar la atención, hacer un correcto diagnóstico, y dar inicio al tratamiento requerido, lo cual repercute en la satisfacción de los usuarios. Lo anterior sumado a las restricciones que impone la Ley de Compras Públicas, para efectuar compras de forma rápida y directa, pone aún más en riesgo la oportuna disposición de los recursos para los usuarios.

Por lo anterior, y considerando que según la Encuesta Nacional de Salud 2009-2010 el 9.4% de la población chilena padece diabetes, lo cual tiene una tendencia al alza, en este trabajo se centrará en la Patología Diabetes Mellitus tipo II, etapa tratamiento, ya que se analizarán las compras mensuales de insulina, que han realizado el Hospital entre el periodo 2012-2016.

2.1 Preguntas de Investigación

- ¿Cómo es la evolución de las compras de insulinas del Hospital Curicó?
- ¿Es posible pronosticar las compras de insulina para el periodo siguiente?

3. Objetivos

3.1 Objetivo General:

- Realizar un análisis de la evolución de las compras de insulinas que realizó el Hospital Curicó entre los años 2012-2016.

3.2 Objetivos específicos:

- Realizar un análisis descriptivo de compras de insulinas
- Identificar un modelo que represente las compras de insulina
- Proyectar el comportamiento de las compras de insulina para el periodo siguiente.

4.- Revisión de literatura

En torno al tema de estudio, se han realizado trabajos referentes a los costos que la Diabetes genera, a continuación se dan a conocer algunos de los resultados que se han obtenido.

La Asociación Americana de Diabetes (2012), determina el costo del tratamiento, costos indirectos, y costo relacionados a la pérdida de productividad que genera la enfermedad. En este estudio se concluye que el costo total estimado de la diabetes diagnosticada en 2012 es de \$ 245 mil millones; de los cuales \$176 mil millones son en costos médicos directos (43% en atención médica de pacientes hospitalizados, 18% medicamentos, 12% suministros, 9% consultas médicas y 8% cuidados de enfermería) y \$ 69 mil millones en productividad reducida. También el estudio señala que los gastos médicos de un paciente diabéticos son 2,3 veces superiores a los de una persona sin la enfermedad.

En tanto en Chile, un estudio señala que el costo total estimado de la diabetes en el año 2007 fue de \$27.969 millones el cual va aumentando progresivamente, hasta llegar el año 2010 a \$ 31.124 millones. Posteriormente se realiza una estimación de los costos de la diabetes para el CESFAM Rosario Palomar, para lo cual considera fármacos e insumos, exámenes de laboratorio, horas de profesionales médicos, enfermeras y nutricionistas. Para realizar el costeo de los fármacos e insumos utilizó el precio de los productos de la Central Nacional de Abastecimiento (CENABAST), y proyecta las recetas de cada producto para el año 2012, de este modo obtiene un costo total de medicamentos e insumos de \$ 16.760.136, el cual está compuesto en un 39% por Metformina 850 mg comprimido, 27% jeringa de insulina 1 ml, 26% Insulina NPH 100 UI/ml, seguido con un 6% la Glibenclamida 5 mg , el 2% restante lo componen en forma similar la sacarina sachet y la clorpropamida 250 mg. En cuanto a los exámenes de laboratorio también estima la cantidad de muestras a analizar para el 2012, utilizando el precio del Fondo Nacional de Salud (FONASA) para valorizarlos, y obtuvo un costo total estimado de \$ 45.147.480, dentro de los exámenes el más relevante es de glucosa en sangre (40%), seguido de la Hemoglobina Glicosilada (24%). Posteriormente realiza una estimación del costo por nivel de especialidad, para lo cual utiliza datos obtenidos del Sistema de Codificación y costeo Winsig y GRD del Hospital el Salvador, con ello logra establecer un costo de especialidad de atención a pacientes diabéticos en el Hospital el Salvador de \$ 26.994 (González, 2012)

En el Reino Unido un estudio determinó los costos actuales y futuros de la diabetes tipo 1 y tipo 2 en este país, incluye los costos directos e indirectos. Para lo cual se utiliza como base el periodo 2010/2011, y determina el costo a través de una serie de factores que influyen tales como, prevalencia, incidencia, mortalidad de la diabetes, estilos de vida, consultas médicas entre otros. Dentro de los resultados obtenidos señala que en el periodo 2010/2011 el costo de la diabetes en el Reino Unido es de £¹23,7bn., dicho valor está compuesto en un 41% por costo directo, y el 59% restante por costo indirecto, el costo de la diabetes mellitus tipo II tanto directo como indirecto es el 90% del total. Con estos datos se estimó que el costo total para el periodo 2035/2036 en £39,8bn y se mantiene la proporción de costo directo e indirecto. Este estudio concluye que la diabetes, tanto tipo I como tipo II, representa una carga económica significativa en el Reino Unido, y que las complicaciones relacionadas a esta enfermedad representan una proporción sustancial de los costos directos en salud. (Hex, et al, 2012)

¹ Libras esterlinas.

5. Antecedentes

5.1 Contextualización de la Red Sanitaria

En la Séptima Región del Maule, la Red de Salud está consolidada a través del Servicio de Salud del Maule, el cual declara que posee tres Hospitales de Alta Complejidad, los cuales son el Hospital San Juan de Dios de Curicó (Hospital Curicó), Hospital Regional de Talca Dr. Cesar Garavagno Burotto (Hospital de Talca), y el Hospital de Linares General Carlos Ibáñez del Campo (Hospital Linares). Se entiende por Hospital de alta complejidad (tipo1) a aquello que dan cobertura a toda la población del Servicio de Salud para prestaciones complejas, según su cartera de servicios, definida previamente por el gestor de la red (Minsal, 2016).

Según la encuesta de caracterización socioeconómica (CASEN) del 2013, el 88% de la población de la Región del Maule tiene previsión al Fondo Nacional de Salud (FONASA), por lo que podemos inferir que se atiende principalmente en los establecimiento públicos de salud.

El Hospital de Curicó tiene como misión ser un centro de salud, asistencial docente, articulado en red, que otorga servicios de calidad certificada, con personal comprometido y empático, atendiendo las necesidades de sus usuarios, a través del mejoramiento continuo de procesos y gestión de recursos. Fue fundado el año 1863, tiene una población beneficiaria de 282.137; fue acreditado en Calidad y Seguridad del Paciente en el año 2016, y en septiembre del 2016 comenzó la construcción de su nuevo recinto hospitalario, con el cual aumentará significativamente su capacidad. Dentro de su producción del año 2016, podemos observar 78.233 consultas de urgencia, 14.482 consultas de especialidad, 13.684 egresos hospitalarios, 15.051 operaciones quirúrgicas (9 pabellones), y cumplimiento de un 99,9% de las patologías GES. Por otra parte, en el ámbito financiero durante el año 2016 tuvo M\$ 3.553.539 de ingreso propios; y un costo total de M\$ 37.282.217, el cual incluye costo en recurso humano, bienes y servicios, entre otros. (Canteros, 2016)

5.2 Epidemiología de la Diabetes

La prevalencia mundial de la diabetes en adultos se ha casi duplicado desde el año 1980 al 2014. Se entiende por Diabetes: una grave enfermedad crónica que se desencadena cuando el páncreas no produce suficiente insulina (una hormona que regula el nivel de azúcar, o glucosa, en la sangre), o cuando el organismo no puede utilizar con eficacia la insulina que produce (OMS, 2016).

Según la Encuesta Nacional de Salud 2009-2010 la prevalencia de Diabetes en Chile es de 9,4, la cual no difiere significativamente entre las regiones al ajustar ésta por sexo y edad. Sin embargo, la séptima región tiene una prevalencia de 9,7, la cual es superior al promedio nacional.

Según la Guía Clínica de Diabetes del Ministerio de Salud de Chile, una persona con >200 mg/dl debe iniciar el tratamiento de Diabetes. En primera instancia, y mientras el paciente se encuentre estable sólo utiliza medicamentos, principalmente Metformina

850 mg. Sin embargo, cuando se desestabiliza debe comenzar a utilizar como tratamiento el uso de insulinas.

La edad media de inicio de uso de insulina entre los adultos que no controlan su diabetes/glicemia/azúcar, es 53,24 años (46,52 – 59,95); solo uno de los 46 casos registrados inició insulina antes de los 18 años. (Encuesta Nacional de Salud 2009-2010)

5.3 Legislación Relacionada

5.3.1 Plan AUGE

Debido al creciente aumento de la prevalencia de esta patología, en Chile en enero del 2010 el Ministerio de Salud incorporó la Diabetes al Régimen Explícito de Garantías en Salud, con lo cual asegura el acceso a todos los pacientes que presenten este problema de salud; oportunidad en cuanto asegura el diagnóstico dentro de 45 días posteriores a la primera consulta con glicemia elevada; tratamiento dentro de 24 horas desde la confirmación diagnóstica; y protección financiera para cubrir todo el diagnóstico y tratamiento. (Decreto Supremo N° 1, 2010).

5.3.2 Ley de Compras Públicas

En Chile en el año 2015 se promulgo la Ley N° 19.886 sobre compras públicas y su reglamento, en ella se estableció que todos los organismos del Estado, deben realizar las compras de bienes, a través de una plataforma Web denominada mercado público, la cual cuenta con un catálogo electrónico de productos (Convenio Marco), con los cuales se han realizado previamente convenios con los proveedores, donde los organismos públicos pueden optar a comprar los productos allí incluidos. Si se desea comprar un producto que no está incluido en el Convenio Marco, los organismos deben realizar una Licitación, la cual consiste en publicar vía la plataforma web, los productos que necesitan especificando cantidades, características y condiciones de compra, posteriormente los proveedores a través del mismo mecanismo ofrece los productos que cumplen con lo solicitado, luego el organismo comprador evalúa todas las ofertas y determina aquella que mejor cumple las condiciones y características solicitadas, y a este proveedor le realiza la compra, para lo cual se emite una Orden de Compra electrónica. El plazo en que la licitación esta publicada para que los proveedores realicen sus ofertas depende del monto estimado de la compra, ya que a mayor monto mayor tiempo de publicación.

Este nuevo mecanismo de compra busca transparentar en un 100% las transacciones que se realizan con recursos públicos, y busca mayor eficiencia.

6.- Metodología

6.1 Recolección de los datos

Para llevar a cabo este análisis en primer lugar se determina cuales son los Hospitales de Alta Complejidad de la Séptima Región, y se realiza una breve descripción de los aspectos relevantes de cada establecimiento, de modo de situar el contexto del estudio.

Posteriormente se realiza una caracterización de la epidemiología de la Diabetes en Chile y específicamente en la séptima región; así como la vinculación de esta patología con las compras que realizan los Hospitales.

Luego se lleva a cabo la recolección y consolidación de los datos, es decir, las compras de insulinas (según periodo), que han realizado los Hospitales a analizar, para lo cual se utiliza el portal web www.mercadopublico.cl, en donde a través de su buscador de licitaciones, se realiza el filtro por establecimiento comprador, por periodo y por tipo de producto, de este modo se obtienen las licitaciones realizadas según los criterios filtrados, y permite acceder a la licitación. Una vez que se accede a la licitación es posible visualizar el tipo de producto adquirido la cantidad, el periodo que dura el contrato de la licitación, y las Órdenes de Compra que se han generado por cada producto. Cada orden de compra individualiza los datos del comprador, del proveedor, el o los productos adquiridos, el precio, entre otros aspectos relevantes.

6.2 Metodología de análisis

Debido a que los datos se presentan de forma cronológica y periódica mes a mes, el análisis se basa en series de tiempo, entendiendo por esta a los registros realizados en periodo, los cuales son de carácter numérico y varían en el tiempo. Estas variaciones pueden ser sistemáticas (que ocurren con frecuencia) o aleatorias (situaciones aisladas provocadas por situaciones extraordinarias), estas últimas son difícil de modelar. A su vez existen tres tipos de variaciones que podemos encontrar en una serie de tiempo:

- Tendencia secular: se da en series de largo plazo y se produce debido a fuerzas importantes como crecimiento de la población, cambios en tecnologías, entre otras, pueden ser ascendente, descendente o ninguna.
- Variación estacional: se da en series de tiempo de intervalos inferiores a un año, y pueden reflejar comportamientos estacionales que se repiten de forma regular año tras año.
- Variaciones cíclicas: corresponden a fluctuaciones a largo plazo, que se repiten regularmente cada cierto número de años (Moreno, 2013).

Para describir la serie de datos se utilizan gráficas, las cuales se obtienen al procesar los datos en el software de análisis estadístico RCommander, tales como las que se presentan a continuación:

- Histograma: el cual es una representación gráfica de una variable en forma de barras, donde la superficie de cada barra es proporcional a la frecuencia de los valores representados (Sanmiguel, 2014)

- Boxplot: es un instrumento gráfico que permite realizar un análisis más detallado y conciso respecto a la distribución de los datos en la muestra. Adicionalmente un Diagrama de Cajas permite determinar si la muestra tiene elementos “outliers” y si presenta un sesgo a la izquierda a la derecha (Cóndor, 2009)
- Plot: representación gráfica de objetos en R. Los gráficos más sencillos que permite generar esta función son nubes de puntos (x,y). (Santana, et al, 2016)

Para identificar el modelo se utiliza la metodología desarrollada por Box y Jenkins en el año 1970, la cual está destinada a identificar, estimar y diagnosticar modelos dinámicos de series temporales. Estos modelos son univariantes, ya que son explicados exclusivamente por una variable “exógena”: su propio pasado. Se utiliza el Modelo Autorregresivo Integrados de Medias Móviles (ARIMA), en este sentido se define un modelo autorregresivo si la variable endógena de un periodo t es explicada por las observaciones de ella misma de periodos anteriores, más un término de error, estos modelos se abrevian con la palabra AR tras la cual se indica el orden del modelo: AR(1) , AR (2)... AR(n), es decir, indica el número de observaciones que intervienen en la ecuación. El término error se denomina ruido blanco, y este debe tener media nula, varianza constante y covarianza nula entre los errores correspondientes a observaciones diferentes. Por su parte, el modelo de medias móviles (MA) explica el valor de una determinada variable en un periodo t en función de un término independiente y una sucesión de errores de periodos precedentes, los cuales han sido ponderados convenientemente. Para utilizar los modelos AR y MA debemos en primer lugar asegurarnos que la serie es estacionaria, si no cumple este criterio debemos transformar la serie para que si cumpla este requisito. Es estacionaria si tiene media igual en series temporales de iguales periodos, dentro del rango analizado. (Mahía, 1999)

Para seleccionar el modelo que utilizaremos para predecir consideraremos los criterios de Akaike (AIC) (Akaike, 1973) y Bayesiano de Schwarz (BIC) (Schwarz, 1978). Cuyas expresiones vienen dadas por: $BIC = -2\log(L) + s \log(N)$, y $AIC = -2\log(L) + 2s$. Estos criterios, que se utilizan para seleccionar la estructura de covarianza y media del modelo, son funciones del logaritmo de la verosimilitud ($\log L$) y un término de penalidad basado en el número de parámetros del modelo (s). Ambos criterios se diferencian por el valor de la penalización. Se prefieren modelos con valores pequeños de ambos criterios (García, et al, 2014)

El objetivo de un modelo univariante de series temporales es predecir, por lo tanto una vez identificado el modelo ARIMA, se debe determinar la mejor predicción de los valores a futuro de una serie a partir de su propia historia. Por lo anterior, se debe seleccionar el predictor óptimo, éste será “el que menos se equivoca”, es decir, aquel que minimiza el error cuadrático medio respecto a otro potencial predictor alternativo. Para hacer estas predicciones se tienen los siguientes supuestos: los parámetros de las funciones presentadas son conocidos; y las perturbaciones aleatorias se conocen en el período muestral y tiene carácter de ruido blanco para los valores de predicción. (Arce, et al, 2012)

Se entiende por Ruido Blanco que es una secuencia de variables aleatorias de media cero, varianza constante y covarianzas nulas, este proceso es muy útil en el análisis de series temporales porque es la base para la construcción de los modelos ARIMA. (González, 2009)

7.- Datos

Como se describió en la sección de la metodología los datos para este estudio fueron extraídos de fuentes de información de acceso público, como es el portal de Chile Compra. Este estudio considera datos mensuales (desde enero a diciembre) del periodo 2012-2016.

Una vez obtenidas las Órdenes de Compra por cada Hospital, estas fueron tabuladas en un archivo Excel, ordenadas cronológicamente de forma mensual desde enero 2012 a diciembre 2016. Los datos obtenidos representan el 100% de las compras que han realizado estos recintos Hospitalarios.

De los datos recolectados el Hospital de Curicó durante los cinco años que abarca el estudio realizó 214 compras de insulinas; cuyo monto promedio mensual de las compras es de \$ 11.162.525, el cual se compone de 2.175 unidades, a un precio promedio de \$ 5.140.-

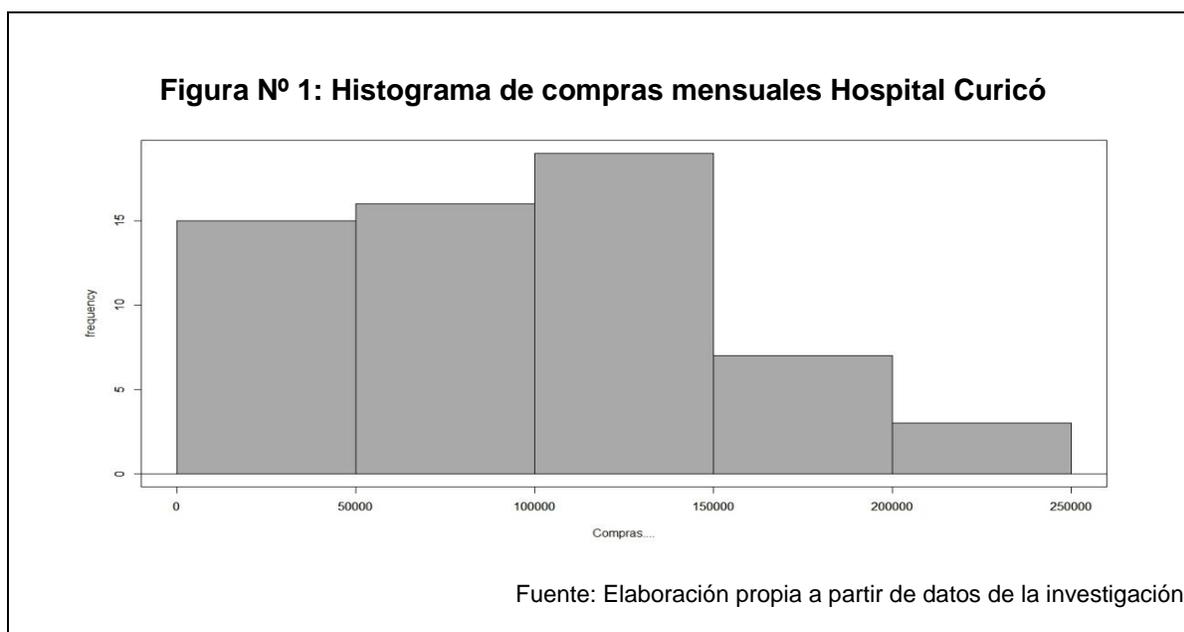
Cabe destacar que el mercado de las insulinas en Chile es bastante limitado, ya que solo hay tres oferentes de dichos productos. Estos son los Laboratorios Sanofi Aventis de Chile, Novonordisk y Lili Ely. Sin embargo, el Hospital de Curicó sólo compra insulinas a Sanofi Aventis y Novonordisk.

8.-Resultados

8.1 Análisis descriptivo de los datos.

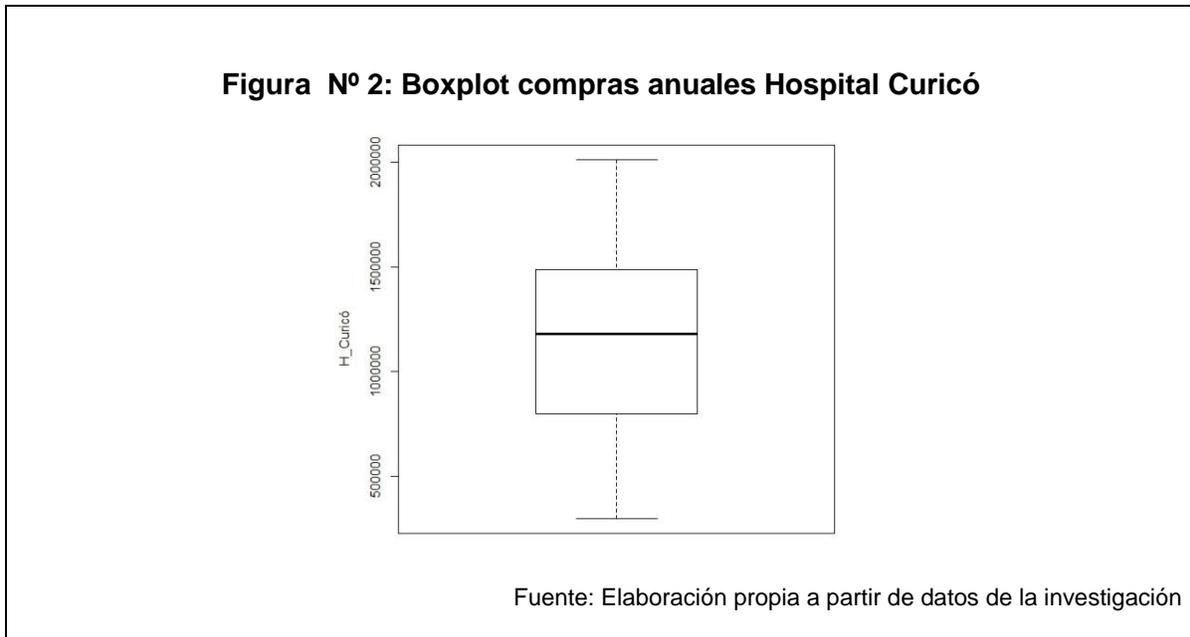
8.1.1. Histograma

A continuación se muestra un histograma, como se puede observar el comportamiento de las compras de insulina no se aproxima a una distribución normal, ya que la mayoría de sus compras están concentradas en lado izquierdo del diagrama. Figura 1



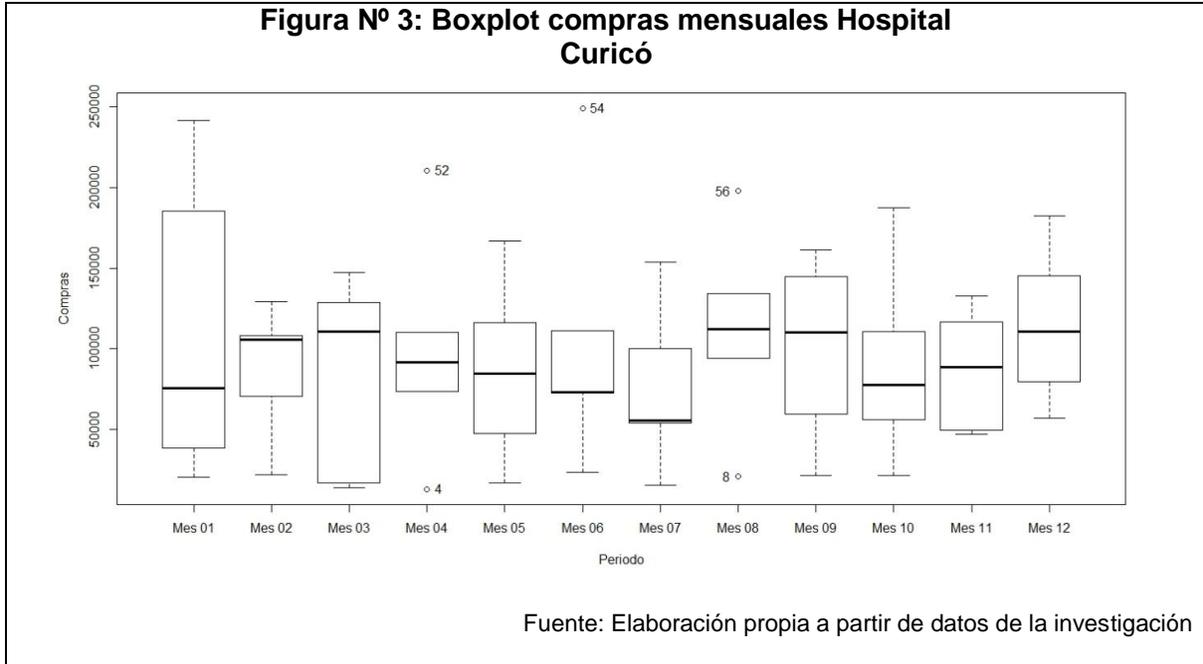
8.1.2 Boxplot

Continuaremos con el análisis de los datos a través de un boxplot (o diagrama de cajas). La Figura N° 2 muestra las compras de insulina de forma anual, de él se puede desprender que al analizar los datos de forma anual , existe cierta asimetría en éstos, ya que la media está casi al centro del rectángulo. Figura 2



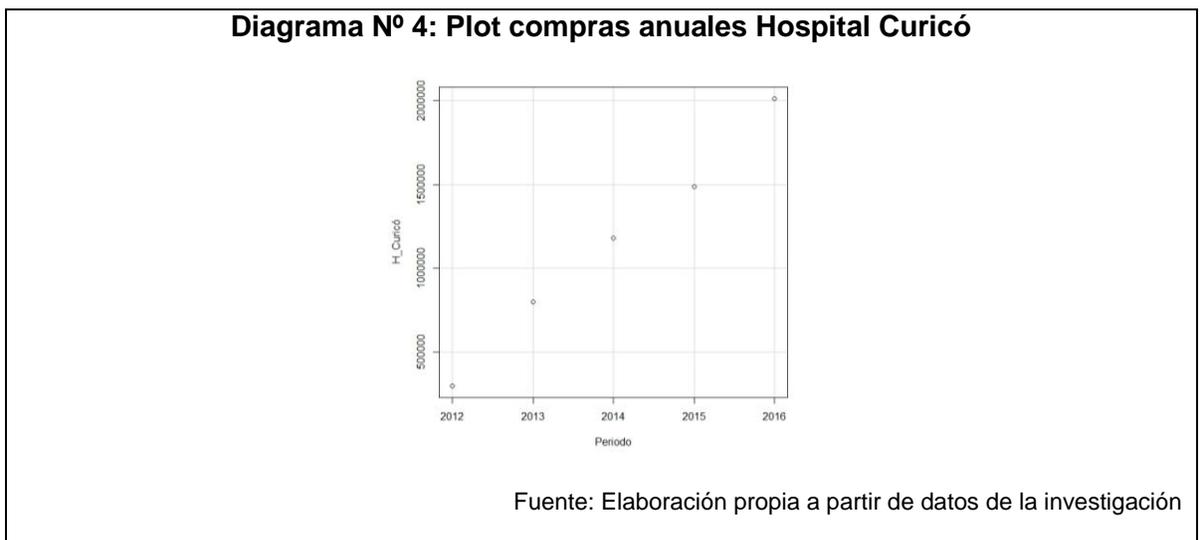
De la figura N° 3, que representa las compras mensuales, podemos observar que para abril, agosto, diciembre, mayo, noviembre la distribución de los datos tiende a ser simétrica, dado que la mediana se encuentra al centro del rectángulo. Sin embargo, para los meses de enero, febrero, julio, junio, marzo, octubre y diciembre los datos no son simétricos. Para todos los meses se observa la presencia de valores atípicos a la serie, por ello es recomendable identificar los Límites Inferior (LI) e Límite Superior (LS).

Se observa que las compras de insulina se concentran en los meses de enero, marzo y septiembre, por lo que podríamos decir que el Hospital compra realiza grandes compras de forma trimestral. Figura 3



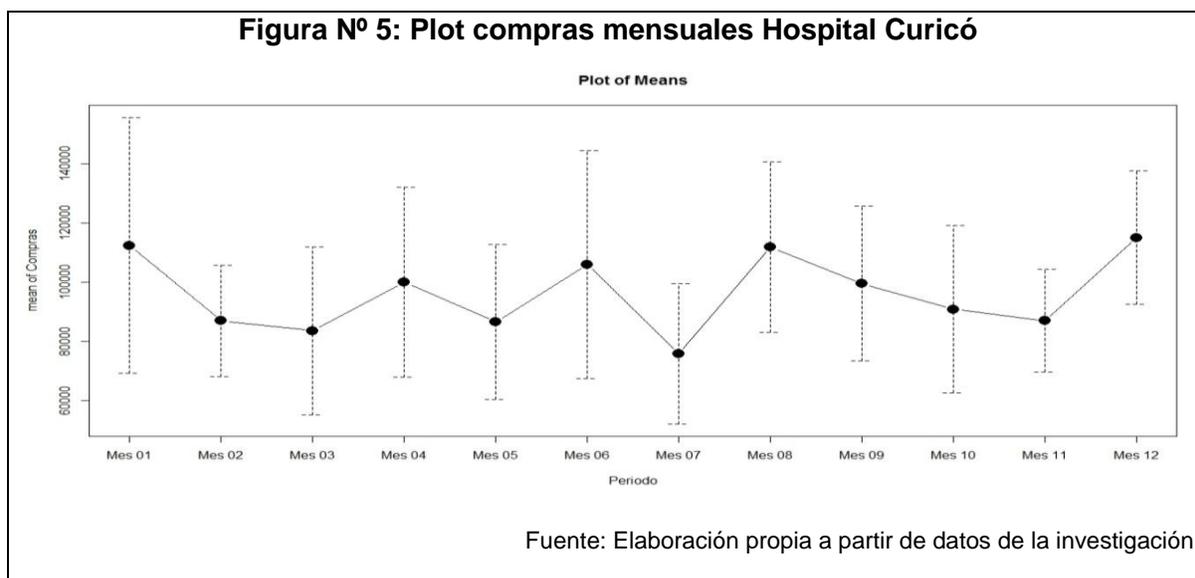
8.1.3 Plot

Continuando con el análisis descriptivo de los datos con un diagrama tipo plot, en el cual se puede observar que al analizar las compras de insulina de forma anual, éstas tienen un comportamiento lineal, ya que va ascendiendo año tras año. Figura 4



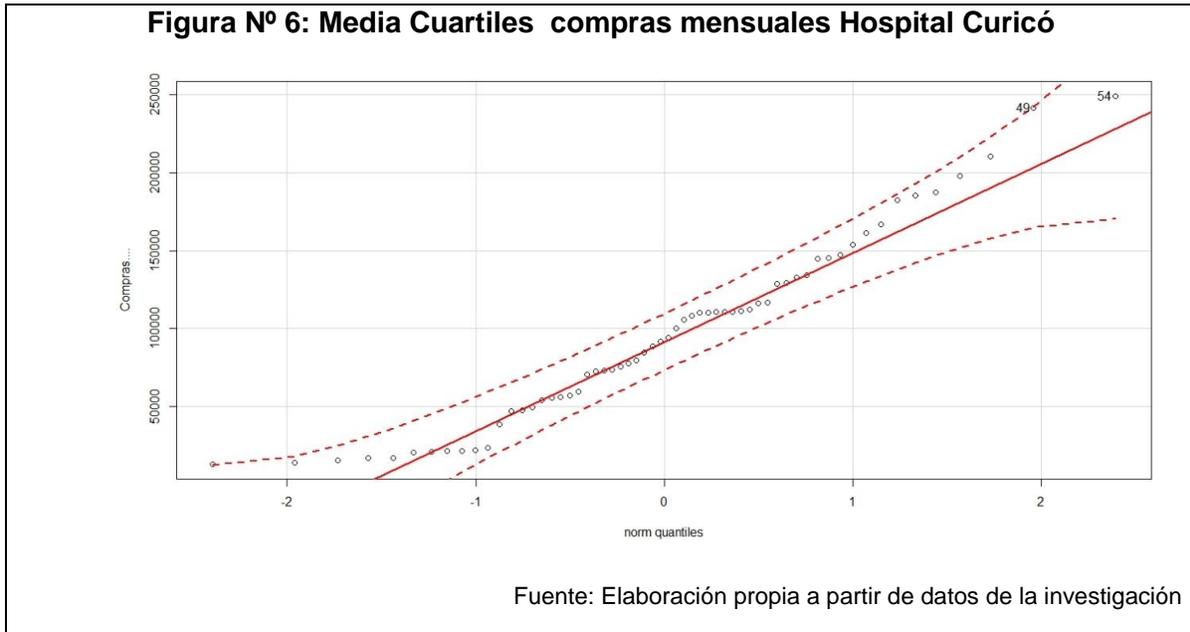
De la figura N° 4 podemos desprender que las compras de insulina tienen un comportamiento decreciente desde enero hasta marzo, aumenta en abril y junio, para luego bajar en mayo y julio respectivamente, posteriormente aumenta en agosto y decrece hasta noviembre, para tener nuevamente un alza en diciembre.

Por lo anterior, podemos observar que la serie de tiempo analizada tiene un componente de variaciones estacional, dado que las observaciones se presentan en meses, por lo tanto estas reflejan el comportamiento estacional que se refleja año tras año. Figura 5



8.1.4 Media de Cuartiles

De la Figura N° 6 podemos concluir que la serie de datos tiene un comportamiento lineal, y que está distribuida principalmente en el segundo y tercer cuartil, ya que en el cuartil cuarto se generan dos valores atípicos. Figura 6

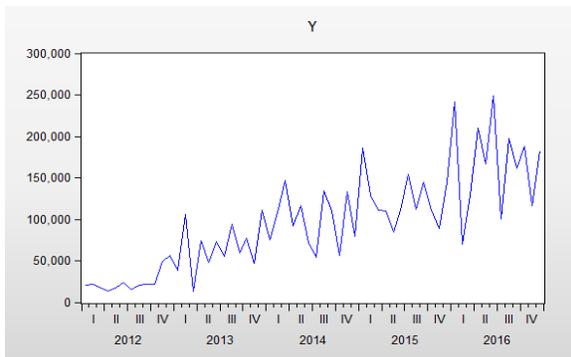


8.2 Determinación de Modelos y Pronósticos

8.2.1 Modelo ARIMA

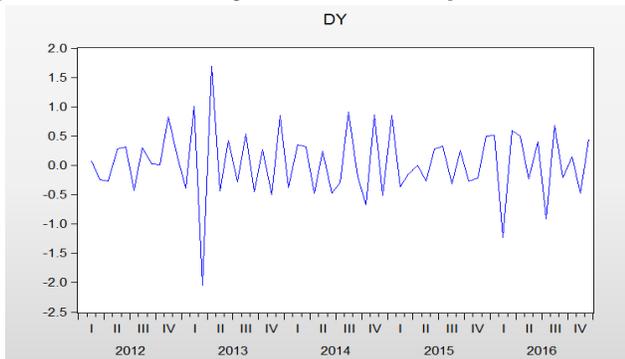
En primer lugar se grafican los datos de la serie como los muestra la Figura N° 7, en la cual se puede observar que los datos (y) están agrupados por trimestre en los respectivos años, así se mantiene cierta estacionalidad, ya que aumenta y disminuye constantemente, sin embargo los datos tiene un componente lineal (que va aumentando con el tiempo), dicha situación se corrige creando la serie $dy=(\log(y),1)$, de esta forma se elimina el crecimiento a través del tiempo, como lo muestra la Figura N° 8

Figura N° 7: Serie de compras de insulina periodo 2012-2016



Fuente: Elaboración propia a partir de datos de la investigación

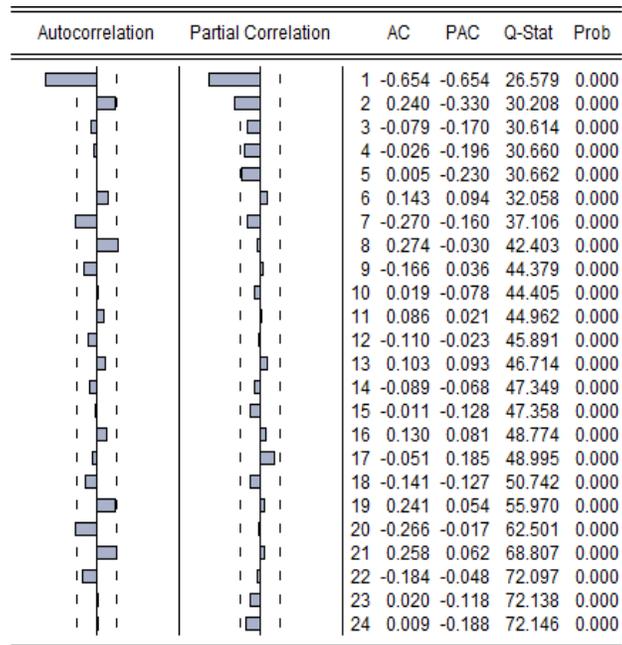
Figura N° 8: Serie Ajustada de compras de insulina periodo 2012-2016



Fuente: Elaboración propia a partir de datos de la investigación

Posteriormente se extrae un correlograma de la serie de datos ajustada, el cual nos permite identificar aquellos parámetros de autocorrelación (AR) y correlación parcial (MA) que son significativos para la serie. En este caso, como nos muestra la Figura N° 9, tomaremos los parámetros uno y dos en ambos casos.

Figura N° 9: Correlograma serie de datos ajustada.



Fuente: : Elaboración propia a partir de datos de la investigación

El análisis continúa determinando el modelo (ecuación) que mejor se ajusta a la serie de datos, por lo tanto en primer lugar utilizamos la ecuación : $d(\log(y),1) c ar(1) ar(2) ma(1) ma(2)$, donde: $d(\log(y),1)$ es nuestra variable dependiente; c es una constante, y ar y ma son los parámetros de autocorrelación y correlación parcial, combinando estos últimos podemos obtener seis modelos diferentes los cuales se detallan a continuación: Tabla 1

Tabla N° 1: Modelos ARIMA								
	Variables	Coefficientes	Error estándar	T-estadístico	Prob.	R2 ajustado	Akaike	Schwarz
Modelo 1	C	0,038952	0,014	2,761	0,079	0,498	1,232	1,444
	Ar(1)	-1,092710	0,146	-0,953	0,344			
	Ar(2)	-0,212377	0,477	-0,444	0,658			
	MA(1)	0,091596	0,107	0,082	0,934			
	Ma(2)	-0,562073	0,746	-0,753	0,454			
	Sigmasq	0,160713	0,028	5,704	0,000			
Modelo 2	C	0,038977	0,013	2,794	0,007	0,506	1,200	1,376
	Ar(1)	-0,420714	0,520	-0,807	0,422			
	MA(1)	-0,582776	0,555	-1,048	0,299			
	Ma(2)	-0,093077	0,447	-0,210	0,833			
	Sigmasq	0,161000	0,028	5,687	0,000			
Modelo 3	C	0,038937	0,014	2,753	0,008	0,515	1,167	1,308
	Ar(1)	-0,317713	0,159	-1,991	0,051			
	MA(1)	-0,693570	1,101	-6,814	0,000			
	Sigmasq	0,161173	0,028	4,734	0,000			
Modelo 4	C	0,039105	0,013	2,835	0,006	0,502	1,192	1,333
	Ar(1)	-0,874728	0,080	-10,89	0,000			
	MA(2)	-0,582941	0,128	-4,539	0,000			
	Sigmasq	0,165435	0,029	5,793	0,000			
Modelo 5	C	0,035123	0,028	1,274	0,208	0,465	1,258	1,399
	Ar(1)	-0,861085	0,131	-6,652	0,000			
	Ar(2)	-0,321242	0,128	-2,517	0,015			
	Sigmasq	0,177652	0,033	5,366	0,000			
Modelo 6	C	0,039083	0,015	2,677	0,010	0,510	1,177	1,318
	Ma(1)	-0,994419	0,114	-8,760	0,000			
	Ma(2)	-0,231015	0,126	1,839	0,071			
	Sigmasq	0,162718	0,027	5,932	0,000			

Fuente: Elaboración propia a partir de datos de la investigación

Una vez obtenidos los modelos, se selecciona el más predictivo, para lo cual se debe considerar el criterio de información Akaike y el criterio Schwarz, los cuales según la información de la tabla N° 1 indica que debemos seleccionar el modelo N° 3. Este modelo seleccionado tiene una significancia de 51% y tanto el parámetro ar(1) como ma(1) son estadísticamente significantes. Por otra parte si analizamos el correlograma de los residuos en la Figura N°10, podemos observar que todos los retardos tanto en la autocorrelación (AC) como en la correlación parcial (PAC) están dentro de la banda de confianza por lo cual se cumple la hipótesis de ruido blanco.

Figura N° 10: Correlograma de los residuos Modelo $d(\log(y),1)$ c $ar(1)$ $ma(1)$

Autocorrelacion	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.003	-0.003	0.0006	
		2	0.023	0.023	0.0332	
		3	-0.051	-0.051	0.1998	0.655
		4	-0.068	-0.069	0.5064	0.776
		5	0.070	0.073	0.8363	0.841
		6	0.086	0.088	1.3392	0.855
		7	-0.129	-0.142	2.4938	0.777
		8	0.152	0.156	4.1277	0.659
		9	-0.063	-0.042	4.4176	0.731
		10	-0.002	-0.019	4.4177	0.818
		11	0.077	0.073	4.8628	0.846
		12	-0.047	-0.025	5.0322	0.889
		13	0.022	0.011	5.0692	0.928
		14	-0.064	-0.096	5.3958	0.943
		15	0.054	0.124	5.6317	0.959
		16	0.171	0.131	8.0867	0.885
		17	-0.076	-0.106	8.5793	0.898
		18	-0.149	-0.141	10.532	0.837
		19	0.061	0.098	10.867	0.863
		20	-0.145	-0.124	12.814	0.803
		21	0.045	-0.057	13.007	0.838
		22	-0.204	-0.197	17.067	0.649
		23	-0.128	-0.087	18.707	0.604
		24	0.032	-0.014	18.814	0.657

Fuente: Elaboración propia a partir de datos de la investigación

8.2.2 Pronóstico

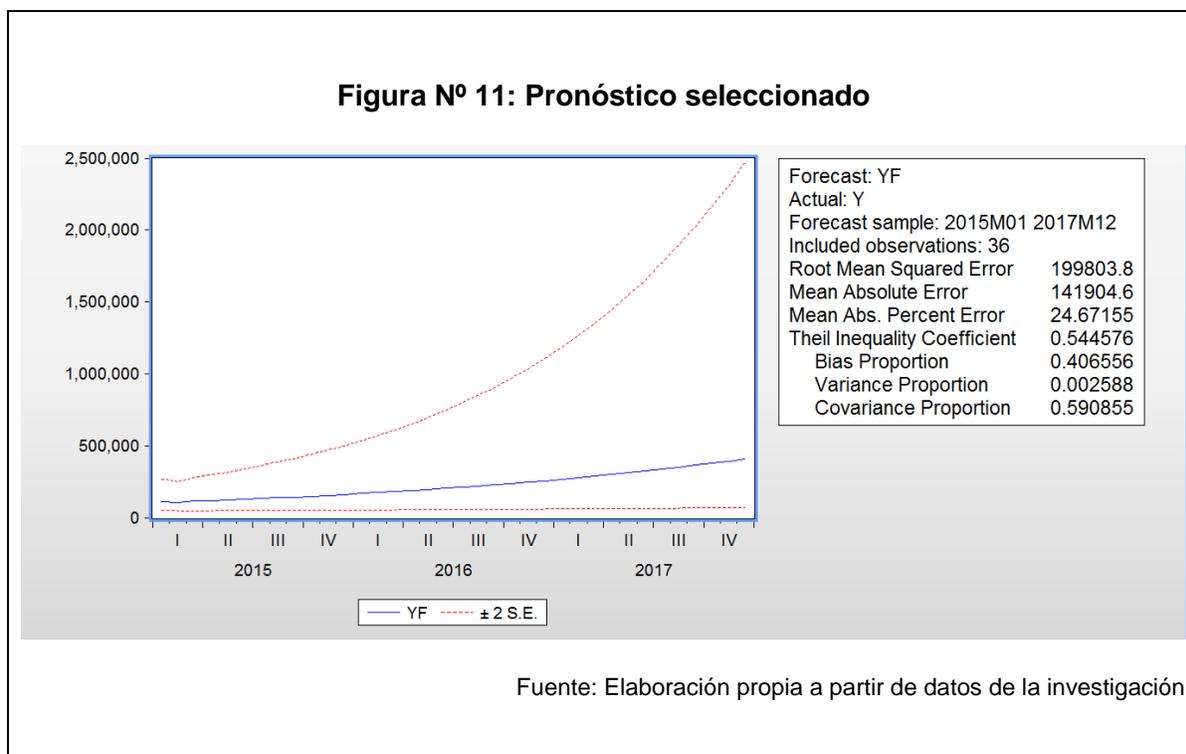
Por lo anterior, para determinar el pronóstico de la serie de datos utilizaremos el Modelo 3 que fue el seleccionado, de acuerdo a los criterios de Akaike y Schwarz descritos anteriormente; y a través del Error Cuadrático Medio se seleccionara la mejor predicción, en la tabla N° 2 se muestra un resumen de los pronósticos, y el detalle de los datos se encuentra en el Anexo N° 2.

Pronóstico	Periodo Base	Periodo estimado	Error Medio	ECM
Pronóstico 1	Enero 2012- Diciembre 2013	Enero 2014- Diciembre 2016	5.256.429	2.293
Pronóstico 2	Enero 2012- Diciembre 2014	Enero 2015- Diciembre 2016	3.548.516	1.884
Pronóstico 3	Enero 2012- Diciembre 2015	Enero 2016- Diciembre 2016	4.784.711	2.187

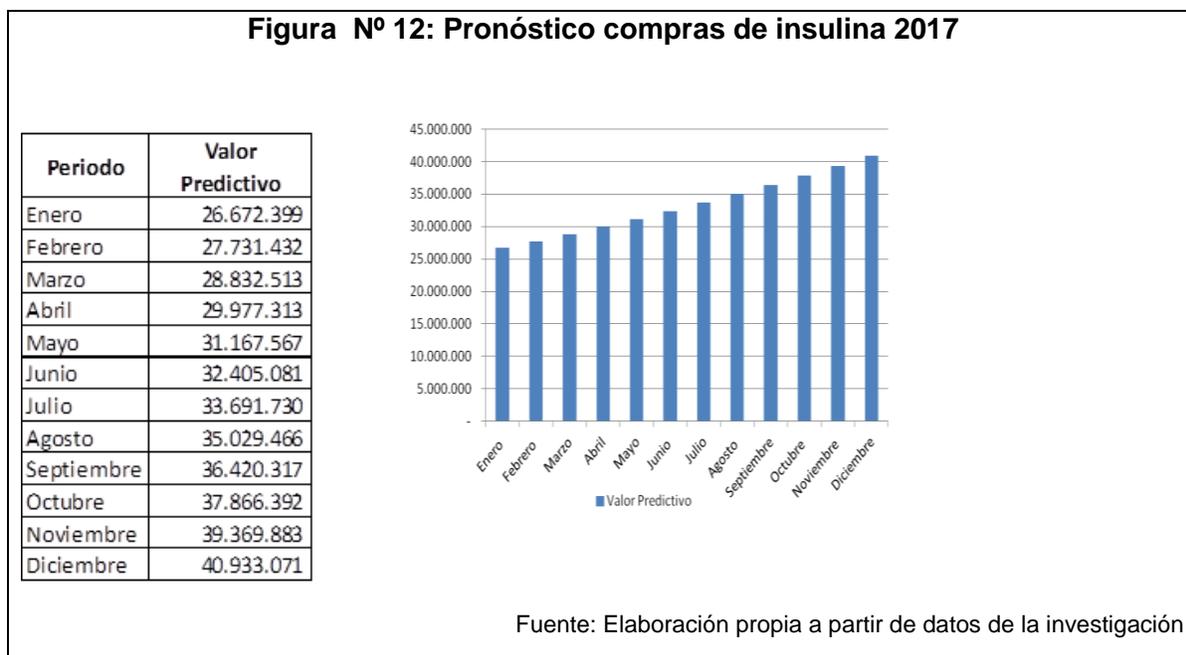
Fuente: Elaboración propia a partir de datos de la investigación

De la tabla anterior podemos concluir que el pronóstico N° 2, es el mejor predictor ya que tiene una media de los errores y un error cuadrático medio, inferior a los otros dos pronósticos realizados. Por lo tanto, a partir de este modelo podemos predecir el año

2017, como lo muestra la Figura N° 11, el pronóstico va creciendo año tras año, sin embargo el límite superior aumenta significativamente a partir del año 2017. Figura N° 11



Al utilizar este pronóstico obtenemos los siguientes valores mensuales de las compras de insulina para el año 2017.



09. Conclusiones

Las compras de insulina en el periodo analizado tienen una gran variabilidad y presentan valores atípicos al analizar los datos de forma mensual, esto se corrige al analizar los datos de forma anual. Por otra parte, tanto de forma mensual como anual, las compras tienen un comportamiento creciente.

La serie temporal de compras de insulina no es estacionaria, por lo cual es necesario ajustar ésta para determinar el modelo ARIMA. El mejor modelo para la serie de datos analizados, esta dado por la ecuación $d(\log(y),1) \sim ar(1) ma(1)$, ya que este tiene un menor criterio de selección akaike , el modelo explica las compras de insulina en un 51%, y los residuos de este modelo tienen el denominado ruido blanco, es decir, son variables que presentan aleatoriedad.

Al pronosticar las compras de insulina para el periodo 2017, obtenemos una serie de datos creciente, cuyo error medio mensual es \$ 3.548.516. Sin embargo, durante el año 2017 el límite superior es significativamente mayor al valor pronosticado.

Debido a los resultados obtenidos, el Hospital de Curicó, debe mantener un resguardo en su planificación de compras para el periodo siguiente (año 2017 según los datos analizados), de modo de no estimar cantidades rígidas y mantener una provisión financiera, que le permita contrarrestar las fluctuaciones que puede presentar el valor real, en relación al pronóstico entre las bandas de confianza (límite superior principalmente). De este modo, podrá dar cumplimiento oportunamente a la entrega de este producto a todos los pacientes que los requieran, cumpliendo así con el Plan Auge, y evitando además mayores descompensaciones y/o alteraciones mayores en los pacientes diabéticos, debido a la falta de insulinas, lo cual generan un círculo vicioso ya que requerirá otros servicios médicos asistenciales que tendrán un mayor costo.

Por otra parte, pronosticar de forma adecuada le permite al Hospital de Curicó, generar mecanismos de compra a largo plazo, con lo cual puede obtener un mejor precio, y asegura el abastecimiento periódicamente según sus necesidades ya que como se explicó anteriormente en Chile el mercado de las insulinas está limitado a tan sólo tres proveedores. Adicionalmente, es importante determinar estos pronósticos de las compras de insulinas, ya que es un producto que se utiliza sólo en los pacientes descompensados, a los cuales los medicamentos orales ya no tienen eficacia terapéutica, por lo cual es muy difícil proyectar la demanda por el lado de los pacientes, además hay que considerar que esta patología (diabetes) lamentablemente tendrá una tendencia al alza, ya que sus principales factores de riesgo en Chile según la Encuesta Nacional de Salud 2017 , no son alentadores , puesto que la encuesta reflejó que el 31,2% de la población es obesa (8 puntos más que la medición anterior), y el 86,7% de la población es sedentaria.

10. Recomendaciones

Por consiguiente, y debido a lo anteriormente expuesto este estudio contribuye a demostrar la utilidad y confiabilidad que presenta aplicar técnicas, como el análisis de serie de tiempo en el área de salud, e incentivar a los Hospitales a masificar su uso. A su vez establece una metodología de análisis que es posible replicar a otras series de datos, tales como: compras de otros productos, consultas médicas, cantidad de exámenes, entre otros.

11. Limitaciones

Este trabajo tiene como limitante la cantidad de datos utilizados, ya que se recomienda aplicar el análisis de serie de tiempo en un rango de 5 a 10 años. Sin embargo, no fue posible debido a e extraer de forma confiable la información de años anteriores de compras de insulinas de los años anteriores al 2012.

13. Bibliografía

Arce, R., Mahía R,(2012), Modelos Arima, Depto. Economía Aplicada, Universidad Autónoma de Madrid.

Asociación Americana de Diabetes, (2013). Economic Costs of Diabetes in the U.S in 2012. Diabetes Care, Edición 36, pág. 1033-1046.

Canteros Gatica, J, (2016), Cuenta Pública Hospital Curicó. Consultado el 20 del 08 de 2017. Disponible en: http://www.hospitalcurico.cl/web/index.php/index/cuenta_publica2016

Comones, F.,(2002), Control de Calidad de los procesos estadísticos , INEI-Lima.

González Perez, C. (2012). Tesina. Estimación de la prevalencia y costo de Diabetes Mellitus Tipo 2 en Chile, y determinación de estrategias implementadas en población preescolar y/o escolar, efectivas en la disminución de factores de riesgo de aparición de Diabetes Mellitus Tipo 2. . Universidad Andres Bello

Gonzalez, M., (2009), Análisis de series temporales: Modelo ARIMA, Universidad del país Vasco.

Hex, N., Bartlet, C., Wright, D., & Varley, M. T. (2012). Article: Health Economics. Estimating the current and future costs of Type 1 and Type 2 diabetes in the UK, including direct health costs and indirect societal and productivity costs. Diabetes Medicine

Minsal (2010), Encuesta Nacional de Salud 2009-2010. Consultado el 10 del 08 de 2017. Disponible: <http://web.minsal.cl/portal/url/item/bcb03d7bc28b64dfe040010165012d23.pdf>

Minsal (2016). Resolución Exenta N° 646. Aprueba Norma General Técnica N° 150 sobre criterios de clasificación según nivel de complejidad de establecimientos Hospitalarios.

Moreno, E., (2013), Predicción con series de tiempo. Panorama N° 4: Tecnologías de sistemas para pymes.

Newbold, P., Carlson, W., Thorne, B, (2008), Estadística para Administración y Economía, Prentice Hall, Sexta edición .

Anexos

Anexo N° 1: Modelos ARIMA

Los modelos son elaboración propia a partir de datos de la investigación

Modelo 1	Modelo 2																																																																
<div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>Dependent Variable: D(LOG(Y),1) Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 11/17/17 Time: 19:04 Sample: 2012M02 2016M12 Included observations: 59 Convergence achieved after 44 iterations Coefficient covariance computed using outer product of gradients</p> </div> <table border="1" style="width: 100%; border-collapse: collapse; margin-bottom: 5px;"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>t-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.038977</td> <td>0.013946</td> <td>2.794827</td> <td>0.0072</td> </tr> <tr> <td>AR(1)</td> <td>-0.420714</td> <td>0.520816</td> <td>-0.807798</td> <td>0.4228</td> </tr> <tr> <td>MA(1)</td> <td>-0.582776</td> <td>0.555858</td> <td>-1.048426</td> <td>0.2991</td> </tr> <tr> <td>MA(2)</td> <td>-0.093077</td> <td>0.441782</td> <td>-0.210685</td> <td>0.8339</td> </tr> <tr> <td>SIGMASQ</td> <td>0.161000</td> <td>0.028308</td> <td>5.687523</td> <td>0.0000</td> </tr> </tbody> </table> <div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>R-squared 0.540817 Mean dependent var 0.037228 Adjusted R-squared 0.506803 S.D. dependent var 0.597217 S.E. of regression 0.419413 Akaike info criterion 1.200624 Sum squared resid 9.499011 Schwarz criterion 1.376687 Log likelihood -30.41841 Hannan-Quinn criter. 1.269352 F-statistic 15.90002 Durbin-Watson stat 2.020427 Prob(F-statistic) 0.000000</p> </div> <table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td>Inverted AR Roots</td> <td>-.42</td> <td></td> </tr> <tr> <td>Inverted MA Roots</td> <td>.71</td> <td>-.13</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	t-Statistic	Prob.	C	0.038977	0.013946	2.794827	0.0072	AR(1)	-0.420714	0.520816	-0.807798	0.4228	MA(1)	-0.582776	0.555858	-1.048426	0.2991	MA(2)	-0.093077	0.441782	-0.210685	0.8339	SIGMASQ	0.161000	0.028308	5.687523	0.0000	Inverted AR Roots	-.42		Inverted MA Roots	.71	-.13	<div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>Dependent Variable: D(LOG(Y),1) Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 11/22/17 Time: 21:57 Sample: 2012M02 2016M12 Included observations: 59 Convergence achieved after 32 iterations Coefficient covariance computed using outer product of gradients</p> </div> <table border="1" style="width: 100%; border-collapse: collapse; margin-bottom: 5px;"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>t-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.039083</td> <td>0.014597</td> <td>2.677487</td> <td>0.0098</td> </tr> <tr> <td>MA(1)</td> <td>-0.994419</td> <td>0.113513</td> <td>-8.760377</td> <td>0.0000</td> </tr> <tr> <td>MA(2)</td> <td>0.231015</td> <td>0.125603</td> <td>1.839248</td> <td>0.0713</td> </tr> <tr> <td>SIGMASQ</td> <td>0.162718</td> <td>0.027432</td> <td>5.931613</td> <td>0.0000</td> </tr> </tbody> </table> <div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>R-squared 0.535918 Mean dependent var 0.037228 Adjusted R-squared 0.510604 S.D. dependent var 0.597217 S.E. of regression 0.417794 Akaike info criterion 1.177509 Sum squared resid 9.600350 Schwarz criterion 1.318359 Log likelihood -30.73651 Hannan-Quinn criter. 1.232491 F-statistic 21.17118 Durbin-Watson stat 2.054649 Prob(F-statistic) 0.000000</p> </div> <table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td>Inverted MA Roots</td> <td>.62</td> <td>.37</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	t-Statistic	Prob.	C	0.039083	0.014597	2.677487	0.0098	MA(1)	-0.994419	0.113513	-8.760377	0.0000	MA(2)	0.231015	0.125603	1.839248	0.0713	SIGMASQ	0.162718	0.027432	5.931613	0.0000	Inverted MA Roots	.62	.37
Variable	Coefficient	Std. Error	t-Statistic	Prob.																																																													
C	0.038977	0.013946	2.794827	0.0072																																																													
AR(1)	-0.420714	0.520816	-0.807798	0.4228																																																													
MA(1)	-0.582776	0.555858	-1.048426	0.2991																																																													
MA(2)	-0.093077	0.441782	-0.210685	0.8339																																																													
SIGMASQ	0.161000	0.028308	5.687523	0.0000																																																													
Inverted AR Roots	-.42																																																																
Inverted MA Roots	.71	-.13																																																															
Variable	Coefficient	Std. Error	t-Statistic	Prob.																																																													
C	0.039083	0.014597	2.677487	0.0098																																																													
MA(1)	-0.994419	0.113513	-8.760377	0.0000																																																													
MA(2)	0.231015	0.125603	1.839248	0.0713																																																													
SIGMASQ	0.162718	0.027432	5.931613	0.0000																																																													
Inverted MA Roots	.62	.37																																																															
<div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>Dependent Variable: D(LOG(Y),1) Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 11/22/17 Time: 21:46 Sample: 2012M02 2016M12 Included observations: 59 Convergence achieved after 23 iterations Coefficient covariance computed using outer product of gradients</p> </div> <table border="1" style="width: 100%; border-collapse: collapse; margin-bottom: 5px;"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>t-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.038937</td> <td>0.014143</td> <td>2.753037</td> <td>0.0080</td> </tr> <tr> <td>AR(1)</td> <td>-0.317713</td> <td>0.159560</td> <td>-1.991182</td> <td>0.0514</td> </tr> <tr> <td>MA(1)</td> <td>-0.693570</td> <td>0.101775</td> <td>-6.814660</td> <td>0.0000</td> </tr> <tr> <td>SIGMASQ</td> <td>0.161173</td> <td>0.028107</td> <td>5.734325</td> <td>0.0000</td> </tr> </tbody> </table> <div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>R-squared 0.540323 Mean dependent var 0.037228 Adjusted R-squared 0.515249 S.D. dependent var 0.597217 S.E. of regression 0.415807 Akaike info criterion 1.167867 Sum squared resid 9.509231 Schwarz criterion 1.308717 Log likelihood -30.45209 Hannan-Quinn criter. 1.222850 F-statistic 21.54971 Durbin-Watson stat 2.004831 Prob(F-statistic) 0.000000</p> </div> <table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td>Inverted AR Roots</td> <td>-.32</td> <td></td> </tr> <tr> <td>Inverted MA Roots</td> <td>.69</td> <td></td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	t-Statistic	Prob.	C	0.038937	0.014143	2.753037	0.0080	AR(1)	-0.317713	0.159560	-1.991182	0.0514	MA(1)	-0.693570	0.101775	-6.814660	0.0000	SIGMASQ	0.161173	0.028107	5.734325	0.0000	Inverted AR Roots	-.32		Inverted MA Roots	.69		<div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>Dependent Variable: D(LOG(Y),1) Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 11/22/17 Time: 21:47 Sample: 2012M02 2016M12 Included observations: 59 Convergence achieved after 26 iterations Coefficient covariance computed using outer product of gradients</p> </div> <table border="1" style="width: 100%; border-collapse: collapse; margin-bottom: 5px;"> <thead> <tr> <th>Variable</th> <th>Coefficient</th> <th>Std. Error</th> <th>t-Statistic</th> <th>Prob.</th> </tr> </thead> <tbody> <tr> <td>C</td> <td>0.039105</td> <td>0.013793</td> <td>2.835199</td> <td>0.0064</td> </tr> <tr> <td>AR(1)</td> <td>-0.874728</td> <td>0.080311</td> <td>-10.89177</td> <td>0.0000</td> </tr> <tr> <td>MA(2)</td> <td>-0.582941</td> <td>0.128429</td> <td>-4.539019</td> <td>0.0000</td> </tr> <tr> <td>SIGMASQ</td> <td>0.165435</td> <td>0.028559</td> <td>5.792712</td> <td>0.0000</td> </tr> </tbody> </table> <div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>R-squared 0.528170 Mean dependent var 0.037228 Adjusted R-squared 0.502433 S.D. dependent var 0.597217 S.E. of regression 0.421267 Akaike info criterion 1.192900 Sum squared resid 9.760639 Schwarz criterion 1.333750 Log likelihood -31.19056 Hannan-Quinn criter. 1.247883 F-statistic 20.52243 Durbin-Watson stat 2.281083 Prob(F-statistic) 0.000000</p> </div> <table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td>Inverted AR Roots</td> <td>-.87</td> <td></td> </tr> <tr> <td>Inverted MA Roots</td> <td>.76</td> <td>-.76</td> </tr> </tbody> </table>	Variable	Coefficient	Std. Error	t-Statistic	Prob.	C	0.039105	0.013793	2.835199	0.0064	AR(1)	-0.874728	0.080311	-10.89177	0.0000	MA(2)	-0.582941	0.128429	-4.539019	0.0000	SIGMASQ	0.165435	0.028559	5.792712	0.0000	Inverted AR Roots	-.87		Inverted MA Roots	.76	-.76		
Variable	Coefficient	Std. Error	t-Statistic	Prob.																																																													
C	0.038937	0.014143	2.753037	0.0080																																																													
AR(1)	-0.317713	0.159560	-1.991182	0.0514																																																													
MA(1)	-0.693570	0.101775	-6.814660	0.0000																																																													
SIGMASQ	0.161173	0.028107	5.734325	0.0000																																																													
Inverted AR Roots	-.32																																																																
Inverted MA Roots	.69																																																																
Variable	Coefficient	Std. Error	t-Statistic	Prob.																																																													
C	0.039105	0.013793	2.835199	0.0064																																																													
AR(1)	-0.874728	0.080311	-10.89177	0.0000																																																													
MA(2)	-0.582941	0.128429	-4.539019	0.0000																																																													
SIGMASQ	0.165435	0.028559	5.792712	0.0000																																																													
Inverted AR Roots	-.87																																																																
Inverted MA Roots	.76	-.76																																																															

Modelo 5

Dependent Variable: D(LOG(Y),1)
 Method: ARMA Maximum Likelihood (OPG - BHHH)
 Date: 11/22/17 Time: 22:01
 Sample: 2012M02 2016M12
 Included observations: 59
 Convergence achieved after 7 iterations
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.035123	0.027568	1.274024	0.2080
AR(1)	-0.861085	0.131211	-6.562592	0.0000
AR(2)	-0.321242	0.127637	-2.516838	0.0148
SIGMASQ	0.177652	0.033109	5.365670	0.0000

R-squared	0.493325	Mean dependent var	0.037228
Adjusted R-squared	0.465688	S.D. dependent var	0.597217
S.E. of regression	0.436546	Akaike info criterion	1.258605
Sum squared resid	10.48146	Schwarz criterion	1.399455
Log likelihood	-33.12885	Hannan-Quinn criter.	1.313587
F-statistic	17.85027	Durbin-Watson stat	2.134043
Prob(F-statistic)	0.000000		

Inverted AR Roots	-.43-.37i	-.43+.37i
-------------------	-----------	-----------

Modelo 6

Dependent Variable: D(LOG(Y),1)
 Method: ARMA Maximum Likelihood (OPG - BHHH)
 Date: 11/22/17 Time: 21:57
 Sample: 2012M02 2016M12
 Included observations: 59
 Convergence achieved after 32 iterations
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.039083	0.014597	2.677487	0.0098
MA(1)	-0.994419	0.113513	-8.760377	0.0000
MA(2)	0.231015	0.125603	1.839248	0.0713
SIGMASQ	0.162718	0.027432	5.931613	0.0000

R-squared	0.535918	Mean dependent var	0.037228
Adjusted R-squared	0.510604	S.D. dependent var	0.597217
S.E. of regression	0.417794	Akaike info criterion	1.177509
Sum squared resid	9.600350	Schwarz criterion	1.318359
Log likelihood	-30.73651	Hannan-Quinn criter.	1.232491
F-statistic	21.17118	Durbin-Watson stat	2.054649
Prob(F-statistic)	0.000000		

Inverted MA Roots	.62	.37
-------------------	-----	-----

Anexo Nº 2: Tabla de Error Cuadrático Medio

Pronóstico Nº 1

Periodo		Valor Real	Valor Estimado	Residuo
Enero	2014	7.562.800	7.013.602	549.198
Febrero	2014	10.800.300	8.536.113	2.264.187
Marzo	2014	14.729.800	8.441.819	6.287.981
Abril	2014	9.169.200	8.917.672	251.528
Mayo	2014	11.621.200	9.225.030	2.396.170
Junio	2014	7.250.600	9.606.718	2.356.118
Julio	2014	5.410.000	9.983.063	4.573.063
Agosto	2014	13.402.800	10.381.123	3.021.677
Septiembre	2014	11.006.000	10.792.752	213.248
Octubre	2014	5.616.400	11.221.464	5.605.064
Noviembre	2014	13.291.200	11.666.953	1.624.247
Diciembre	2014	7.971.500	12.130.212	4.158.712
Enero	2015	18.555.000	12.611.837	5.943.163
Febrero	2015	12.900.000	13.112.595	212.595
Marzo	2015	11.083.600	13.633.232	2.549.632
Abril	2015	11.033.600	14.174.542	3.140.942
Mayo	2015	8.470.000	14.737.344	6.267.344
Junio	2015	11.135.000	15.322.493	4.187.493
Julio	2015	15.370.000	15.930.875	560.875
Agosto	2015	11.237.800	16.563.414	5.325.614
Septiembre	2015	14.459.000	17.221.067	2.762.067
Octubre	2015	11.082.800	17.904.832	6.822.032
Noviembre	2015	8.845.000	18.615.747	9.770.747
Diciembre	2015	14.517.700	19.354.888	4.837.188
Enero	2016	12.902.434	20.123.377	7.220.943
Febrero	2016	14.100.341	20.922.379	6.822.038
Marzo	2016	14.429.858	21.753.106	7.323.248
Abril	2016	15.078.475	22.616.817	7.538.342
Mayo	2016	15.652.127	23.514.821	7.862.694
Junio	2016	16.281.865	24.448.481	8.166.616
Julio	2016	16.925.608	25.419.213	8.493.605
Agosto	2016	17.598.544	26.428.487	8.829.943
Septiembre	2016	18.296.999	27.477.834	9.180.835
Octubre	2016	19.023.583	28.568.847	9.545.263
Noviembre	2016	19.778.886	29.703.178	9.924.292
Diciembre	2016	18.239.800	30.882.547	12.642.747
Media				5.256.429
Raíz Cuadrada Media				2.293

Pronóstico N° 2

Periodo		Valor Real	Valor Estimado	Residuo
Enero	2015	18.555.000	11.286.254	7.268.746
Febrero	2015	12.900.000	10.637.875	2.262.125
Marzo	2015	11.083.600	11.410.411	326.811
Abril	2015	11.033.600	11.746.565	712.965
Mayo	2015	8.470.000	12.251.448	3.781.448
Junio	2015	11.135.000	12.725.168	1.590.168
Julio	2015	15.370.000	13.234.626	2.135.374
Agosto	2015	11.237.800	13.758.720	2.520.920
Septiembre	2015	14.459.000	14.305.471	153.529
Octubre	2015	11.082.800	14.873.321	3.790.521
Noviembre	2015	8.845.000	15.463.919	6.618.919
Diciembre	2015	14.517.700	16.077.900	1.560.200
Enero	2016	12.902.434	16.716.281	3.813.847
Febrero	2016	14.100.341	17.380.002	3.279.661
Marzo	2016	14.429.858	18.070.079	3.640.221
Abril	2016	15.078.475	18.787.554	3.709.079
Mayo	2016	15.652.127	19.533.517	3.881.390
Junio	2016	16.281.865	20.309.099	4.027.234
Julio	2016	16.925.608	21.115.475	4.189.867
Agosto	2016	17.598.544	21.953.869	4.355.324
Septiembre	2016	18.296.999	22.825.551	4.528.551
Octubre	2016	19.023.583	23.731.843	4.708.260
Noviembre	2016	19.778.886	24.674.120	4.895.235
Diciembre	2016	18.239.800	25.653.800	7.414.000
Media				3.548.516
Raíz Cuadrada Media				1.884

Pronóstico N° 3

Periodo		Valor Real	Valor Estimado	Residuo
Enero	2016	12.902.434	24.161.300	11.258.866
Febrero	2016	14.100.341	7.045.000	7.055.341
Marzo	2016	14.429.858	12.852.500	1.577.358
Abril	2016	15.078.475	21.039.000	5.960.525
Mayo	2016	15.652.127	16.682.200	1.030.073
Junio	2016	16.281.865	24.904.100	8.622.235
Julio	2016	16.925.608	10.023.500	6.902.108
Agosto	2016	17.598.544	19.766.800	2.168.256
Septiembre	2016	18.296.999	16.156.000	2.140.999
Octubre	2016	19.023.583	18.755.500	268.083
Noviembre	2016	19.778.886	11.670.600	8.108.286
Diciembre	2016	18.239.800	20.564.200	2.324.400
Media				4.784.711
Raíz Cuadrada Media				2.187