UNIVERSIDAD NACIONAL DEL ALTIPLANO

FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

MODELO UNIVARIANTE PARA EL CONSUMO MENSUAL DE ENÉRGIA ELÉCTRICA DOMÉSTICA EN EL DISTRITO DE PUTINA – ELECTRO PUNO, PERIODO 2005- 2015

TESIS

PRESENTADA POR:

Bach. PERCY CESAR CARCASI MAMANI

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO ESTADÍSTICO E INFORMÁTICO

PUNO – PERÚ

2017

UNIVERSIDAD NACIONAL DEL ALTIPLANO

FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA.

MODELO UNIVARIANTE PARA EL CONSUMO MENSUAL DE ENÉRGIA ELÉCTRICA DOMÉSTICA EN EL DISTRITO DE PUTINA – ELECTRO PUNO, PERIODO 2005- 2015

TESIS

PRESENTADA POR:

PERCY CESAR CARCASI MAMANI

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO ESTADÍSTICO E INFORMÁTICO

APROBADA POR EL JURADO, CONFORMADO POR:

Presidente : ....
M.C. Santos Octavio Morillos Valderrama

Primer Miembro : ....
Dr. Alejandro Apaza Tarqui

Segundo Miembro : ....
Ing. Alcides Ramos Calcina

Director de Tesis : ....
M.C. Confesor Milán Vargas Valverde

Asesor de Tesis : ....
M.Sc. Luis Hugo Huacasi Vásquez

Área : **Estadística**

Tema : **Series de tiempo**

Fecha de sustentación : **21/12/2017**

DEDICATORIA

A Dios por el don de la vida y lo mucho que me ha regalado cada día de mi existencia.

A mi Madre por su amor y apoyo constante en el continuo andar de mi vida.

A mi Esposa e hijo por sus consejos y a mis hermanos por su afecto y compañía.

AGRADECIMIENTO

En primer lugar, deseo manifestar mi agradecimiento a la Universidad Nacional del Altiplano, y en especial a la Escuela Profesional de Ingeniería Estadística e Informática, por haber contribuido en mi formación como profesional al servicio de la ciencia y la colectividad.

A los docentes de la Escuela Profesional de Ingeniería Estadística e Informática, por su noble labor y reconocida calidad académica y profesional.

Mi más sincero reconocimiento a mi Director de Tesis M.Sc. Confesor Vargas Valverde, por su orientación y apoyo constante para la materialización de la presente investigación.

De igual forma mi gratitud a mi Asesor de Tesis M.Sc. Luis Hugo Huacasi Vásquez quien contribuyó a este esfuerzo con preocupación e infinita paciencia.

Así mismo a la Empresa Regional de Servicio Público de Electricidad - Electro Puno, quienes son objeto de estudio y que me permitieron el acopio de información necesaria para llevar adelante mi trabajo de investigación.

Finalmente, mi agradecimiento a todas las personas que de alguna manera han colaborado con sus ideas, comentarios y consejos durante todo el transcurso de mi carrera y especialmente en el desarrollo de esta investigación.

INDICE GENERAL

INDICE DE TABLAS

INDICE DE GRAFICOS

RESUMEN

Se considera que el problema en general consiste en la necesidad de anticiparse y proyectarse ante una demanda futura de energía eléctrica que deriva del rápido crecimiento poblacional del distrito de Putina, generando así un mayor consumo de Energía Eléctrica Domestica, lo que ocasiona la necesidad de previsión, para abastecer adecuadamente de energía eléctrica, por esta razón se plantea el objetivo como: determinar un modelo univariante que permita describir y predecir el consumo doméstico mensual de energía eléctrica. Los datos fueron recopilados de los registros existentes de consumo de energía eléctrica, Para identificar el modelo se realizó la diferenciación de la serie original convirtiéndola en estacionaria. Luego se identificó la forma del modelo usando la función de Autocorrelación y la función de Autocorrelación parcial. Para validar el modelo, se realizó el análisis de los residuos, con lo que se verifico que los residuos, sean compatibles con un ruido blanco, utilizando el test ampliado de **Dickey - Fuller.** El mejor modelo univariante para pronosticar la serie fue modelo univariante integrado ARIMA(0,2,1)(0,1,1) cuyos parámetros son:

$$\hat{Y}_t = 2y_{t-1} - y_{t-2} + y_{t-12} - y_{t-13} + \mathcal{E}_t - (0.95194)\mathcal{E}_{t-1} - (0.99410)\mathcal{E}_{t-12} + (0.94637)\mathcal{E}_{t-13}$$

En conclusión, se realizó las predicciones para los siguientes años 2015 y 2016 con un nivel de confianza del 95% y el pronóstico revela una réplica con un ajuste bueno a la serie.

Palabras Claves: Modelo Univariante, Consumo, Energía Eléctrica, Domestica, Distrito de Putina, Electro Puno.

ABSTRACT

It is considered that the problem in general consists of the need to anticipate and project in front of a future demand of electrical energy that derives from the fast population growth of the district of Putina, generating therefore a greater consumption of Domestic Electrical Energy, which causes the necessity of forecast, to adequately supply electricity, for this reason the objective is set as: to determine a univariate model that allows describing and predicting the monthly domestic consumption of electricity. The data was collected from the existing records of electric energy consumption. To identify the model, the differentiation of the original series was made, making it stationary. Then the shape of the model was identified using the Autocorrelation function and the partial Autocorrelation function. To validate the model, the analysis of the residues was carried out, with which it was verified that the residues are compatible with a white noise, using the extended Dickey - Fuller test. The best univariate model to predict the series was an integrated univariate model ARIMA (0.2.1) (0,1,1) whose parameters are:

$$\hat{Y}_t = 2y_{t-1} - y_{t-2} + y_{t-12} - y_{t-13} + \mathcal{E}_t - (0.95194)\mathcal{E}_{t-1} - (0.99410)\mathcal{E}_{t-12} + (0.94637)\mathcal{E}_{t-13}$$

In conclusion, predictions were made for the following years 2015 and 2016 with a confidence level of 95% and the forecast reveals a replica with a good fit to the series.

Key Words: Univariate Model, Consumption, Electric Power, Domestica, Putina District, Electro Puno.

INTRODUCCIÓN

Una de las grandes actividades económicas a nivel nacional es la producción de Energía Eléctrica Domestica, la cual comprende a los diferentes sistemas eléctricos de distribución: en nuestra Región, la generación, transmisión y comercialización de energía eléctrica es distribuida a través de la empresa de generación eléctrica San Gabán Sociedad Anónima. Red de energía eléctrica del Perú Sociedad Anónima (Unidad de Trasmisión Puno) y Electro Puno Sociedad Anónima Abierta.

La información obtenida del Consumo de Energía Eléctrica Domestica correspondiente a los periodos de los años 2005-2015, los mismos que fueron agrupados mensualmente, surge de la necesidad de evaluar el comportamiento de la serie histórica, a fin de tomar decisiones relacionadas con la variable en estudio.

Una serie temporal, llamada también serie histórica cronológica es una sucesión de valores observados, de una variable referida a periodos de tiempo generalmente regulares. El análisis univariante de una serie temporal consiste en hacer uso de estos datos para elaborar un modelo que describa adecuadamente el comportamiento de esta variable en pasado y permita realizar predicciones satisfactorias – metodología estocástica ARIMA. Que resulta ser uno de los métodos cuantitativos modernos de predicción más sofisticados.

En un proceso de planificación de Energía Eléctrica de una Región o País, uno de los puntos de gran importancia viene a ser la realización de un adecuado estudio de las variables de mayor representatividad de Energía Eléctrica, mediante el análisis del comportamiento histórico y el pronóstico del comportamiento futuro de cada una de estas variables seleccionadas.

Cuando se toma una decisión el investigador, se encuentra generalmente en un ambiente de incertidumbre respecto a los sucesos que se pueden producir en el futuro. En cualquier caso, el investigador podría lograr mejores resultados si en alguna medida logra reducir la incertidumbre sobre los sucesos situados en el futuro.

Al reducir la incertidumbre sobre el futuro, va dirigido precisamente la metodología estocástica ARIMA.

En el capítulo I, se explica los fundamentos para la realización de la tesis y se describen los objetivos.

En el capítulo II, se describe el marco teórico y presenta los diversos conceptos necesarios para el correcto entendimiento de la tesis.

En el capítulo III, se describe los materiales y métodos para el pronóstico del Consumo de Energía Eléctrica Domestica del Distrito de Putina.

En el capítulo IV, Se muestran los resultados de la investigación.

Por último, se muestra, las conclusiones y las recomendaciones sobre el modelo de predicción mensual del Consumo de Energía Eléctrica Domestica del Distrito de Putina correspondiente a los periodos de los años 2005-2015.

CAPITULO I

PLAN DE INVESTIGACIÓN

1.1. DESCRICION DEL PROBLEMA

Se considera que el problema en general consiste en la necesidad de anticiparse y proyectarse ante una demanda futura de energía eléctrica que deriva del rápido crecimiento poblacional del distrito de Putina, generando así un mayor consumo de Energía Eléctrica Domestica, lo que ocasiona la necesidad de previsión, para abastecer adecuadamente de energía a todo el Distrito de Putina, motivo del presente trabajo de investigación.

Contar con Servicios Básicos de buena calidad que atiendan a las necesidades de la población. Es un factor determinante en el desarrollo de la misma. Y es principalmente que el acceso a los servicios básicos, con los que antes no se contaba ha cobrado importancia fundamental, que la energía eléctrica domestica lo cual se ha convertido en una necesidad latente que ya no es exclusiva de los hogares urbanos que eran los más favorecidos con el adecuado abastecimiento de Energía Eléctrica Domestica.

Otro alcance del problema es que, en los últimos años, la población se ha incrementado considerablemente en un porcentaje de 2.68% por año, ocasionando un alto consumo de energía domestica siendo necesario realizar predicciones a futuro; esto conlleva a que la empresa comercializadora Electro-Puno, proveerá los sucesos a futuro que puede llegar a ocurrir en el transcurso de los años, para luego obtener resultado muy confiable. En la percepción de las actividades de la Provincia de San Antonio de Putina, del Distrito de Putina, es la variabilidad en el comportamiento de los consumidores de energía eléctrica doméstica, que comprende el desarrollo económico social, pretendiendo así encontrar un modelo de predicción que defina los promedios generales pretéritos en el futuro. Sin embargo, carece de información que se refiere a la predicción de consumo de energía eléctrica

Un sistema de energía eléctrica debe abastecer de energía a todos los usuarios con un servicio de calidad. Por tanto, un sistema eléctrico confiable debe funcionar por medio de una planeación exhaustiva del sistema, que permitirá conocer no solo su estado actual, sino también las medidas que deben adoptarse para condiciones futuras o necesidades futuras de sus usuarios.

Finalmente, las herramientas útiles en el planeamiento de un sistema eléctrico es la predicción del consumo de energía, la cual permite conocer de antemano la necesidad de expansión del sistema de energía eléctrica; la finalidad de la predicción es el mejoramiento del servicio, convirtiéndose en uno de los primeros pasos en cualquier proceso de planeamiento de un sistema eléctrico.

1.2. FORMULACIÓN DEL PROBLEMA

Frente a esta problemática de vital importancia, sobre consumo de energía eléctrica frecuentes y con miras a contribuir con el conocimiento para el análisis y proyección de datos a futuro, en la búsqueda de una solución inteligente al planteamiento del problema y dar alternativas de prevención a los problemas prioritarios del servicio eléctrico de la región. Considerando estas problemáticas se puede formular la siguiente interrogante:

¿Cuál es el modelo univariante que permita describir y predecir el comportamiento del consumo mensual de energía eléctrica domestica del distrito de Putina - Electro Puno periodo 2005-2015?

1.3. OBJETIVOS DE LA INVESTIGACIÓN

1.3.1. OBJETIVO GENERAL

Determinar el modelo univariante de ajuste que nos permita describir y predecir el Consumo de Energía Eléctrica Doméstica en el Distrito de Putina – Electro Puno, periodo 2005-2015.

1.3.2. OBJETIVOS ESPECÍFICOS

- Describir el comportamiento del Consumo de Energía Eléctrica Doméstica en el Distrito de Putina– Electro Puno, periodo 2005-2015.
- Validar el modelo estimado para el consumo de Energía Eléctrica Doméstica en el Distrito de Putina - Electro Puno, Periodo 2005-2015
- Realizar el pronóstico con el mejor modelo de ajuste para el Consumo de Energía Eléctrica Doméstica en el Distrito de Putina - Electro Puno, Periodo 2005-2015.

1.4. HIPÓTESIS GENERAL

El modelo univariante ARIMA multiplicativo de Box-Jenkins proporciona un mejor modelo de ajuste que un modelo no integrado de Box-Jenkins en el consumo mensual de energía eléctrica doméstica en el Distrito de Putina - Electro Puno, Periodo 2005-2015.

1.4.1. HIPÓTESIS ESPECÍFICAS

- El comportamiento de la serie histórica consumo de energía eléctrica en el Distrito de Putina presenta una tendencia creciente y positiva sin variaciones cíclicas y estacionales.
- El modelo univariante integrado multiplicativo estimado da un mejor ajuste y pronóstico de la serie histórica de consumo mensual de energía eléctrica domestica del distrito de Putina- Electro Puno, periodo 2005 - 2015.

1.5. JUSTIFICACION DE LA INVESTIGACION

La predicción de consumo de energía refleja las necesidades futuras de una población; esta previsión debe ser lo más ajustada a la realidad, ya que unos valores inferiores a los reales causarán deficiencias en la prestación del servicio en el futuro y un pronóstico de necesidades superior al real, motiva la inversión prematura en instalaciones que no tendrán un aprovechamiento inmediato. La demanda de electricidad se ha incrementado a lo largo de las últimas décadas. Por el crecimiento poblacional del distrito de Putina quienes necesitan energía eléctrica ya que conforman nuevas familias.

Para determinar el comportamiento del consumo de energía eléctrica y realizar proyecciones futuras, adoptamos como alternativa utilizar la metodología BOX-JENKINS que nos permitan describir, ver el comportamiento, pronosticar la serie histórica del consumo de energía del distrito de Putina atreves de un modelo univariante

Con el fin de conseguir servicios de mejor calidad, se espera encontrar modelo de predicción mensual que se ajuste al consumo de Energía Eléctrica domestico de manera que la población acceda a servicios de calidad que beneficie y que la Energía Eléctrica Domestico representa un factor básico para la producción en diversos sectores, entre los que se encuentran el industrial, comercial y residencial o doméstico. Por lo tanto, la prestación de mejores servicios, fundamentalmente de Energía Eléctrica Domestico, permitirá el desarrollo social y comercial de la zona y es de interés colectivo la planificación proactiva para brindar un mejor servicio.

1.6. LIMITACIONES DE LA INVESTIGACIÓN

Una limitación para el presente trabajo de investigación es la dificultad en la recopilación de información histórica por meses, ya que se encuentra en diferentes libros y estos desaparecieron o los datos no están completos, por lo cual solo se obtendrá la información disponible para el análisis y la elaboración de la investigación.

CAPITULO II

MARCO TEÓRICO

2.1. ANTECEDENTES DE LA INVESTIGACIÓN

ORBEZO, H. A. (2011) Determinó que el *Análisis estocástico ARIMA para el modelamiento y predicción de la demanda eléctrica en el sector residencial de lima sur*. MODELO ARIMA (p,d,q)x(p,d,q) = ARIMA (3,0,0)x(0,1,1) del consumo de energía incluido constante.

ARRAMATIA, A. (2010) Concluye que: *Los modelos univariantes que mejor se ajustan para decidir y predecir el comportamiento de la serie de la Energía Eléctrica (kw/mes), en la ciudad de Juliaca. es ARIMA (1,1,1);* $\Delta\, y_{t=}(1-\theta_1 B)a_t$ *y el número de usuarios de Energía Eléctrica periodo 2004-2009,* es ARIMA (0,2,1): $\Delta^2 y_{t=}(1-\theta_1 B)a_t$

COASACA, Y. F. (2010) Determinó que: *El mejor modelo univariante que nos permite describir y predecir el comportamiento del consumo de Energía Eléctrica para el servicio eléctrico de Ilave- Electro Puno*, es el modelo siguiente. ARIMA (0,1,1)$\Rightarrow$ $y_t = y_{t-1} - 0.37064\varepsilon_{t-1}$+ 0.0164763.

PAREDES, J. A. (2009) Determinó que: *Modelo econométrico para pronosticar el consumo mensual familiar de Energía Eléctrica en la Provincia de Tacna*, es de 5,84 personas; el 25.10 % cuenta con menos de 5 integrantes, el 71,20% entre 5 y 10 personas y el 3.7 % con más de 10 personas la cantidad media de focos y enchufes en los hogares de la Provincia de Tacna es de 14, 13 unidades el 12,60 % tiene menos de 10 y 15, y el 38,50% más de 15.

CURASI, J. (2006). Reporta que: *Los modelos univariantes que mejor se ajustan para decidir y predecir el comportamiento de la serie de tiempo de Consumo de Energía Eléctrica (Kw/h) y el número de usuarios de Energía Eléctrica en el Distrito de Puno*, periodos 1996-2005; están dados por: Δ Consumo: (1-0.95B $+0.35B^2 + 0.13B^3 + 0.01B^4 + 0.03B^5 + 0.32^6$ $(1 - B)\, Y_{t=} 43353.5 + (1 - 1.45B + 0.69B^2)a_t$.

2.2. BASE TEÓRICA

2.2.1. TÉCNICAS DE PREDICCIÓN

Las predicciones se basan con el uso de datos anteriores de una variable para predecir su desempeño futuro. A este respecto, los datos anteriores se presentan, generalmente en la forma de series de tiempo. Una hipótesis básica, en la aplicación de las técnicas de predicción, es el desempeño de los datos anteriores continúan ocurriendo en el futuro inmediato. Evidencias empíricas indican que este supuesto es válido en muchas situaciones reales, sobre todo cuando las series de tiempo se presentan una larga historia de las variables analizadas.

2.2.2. SERIES DE TIEMPO

La serie de tiempo es una información básica de la evolución de variables en el tiempo. Entre ellos los modelos de Box-Jenkins constituyen un conjunto de procedimiento para el tratamiento de serie de tiempo. Es un conjunto de observaciones ordenadas según una característica cuantitativa de un fenómeno individual, en diferentes momentos de tiempo.

En una serie de tiempo la observación no se debe ordenar de mayor a menor debido a que se perdería el grueso de la información debido a que nos interesa detectar como se mueve la variable en el tiempo, es muy importante respetar la secuencia temporal de las observaciones.

2.2.3. COMPONENTES DE UNA SERIE TEMPORAL

Según Eumed (2015) son los siguientes:

- ✓ LA TENDENCIA

Es un componente de una serie temporal que refleja su evolución a largo plazo. Puede ser de naturaleza estacionaria o constante (se representa con una recta paralela al eje de las abscisas), de naturaleza lineal, de naturaleza parabólica, de naturaleza exponencial, etc.

- ✓ LAS VARIACIONES CÍCLICAS

Es un componente de la serie que recoge oscilaciones periódicas de amplitud superior a un año. Estas oscilaciones periódicas no son regulares y se presentan en los fenómenos económicos cuando se dan de forma alternativa etapas de prosperidad o de depresión

- ✓ LAS VARIACIONES ESTACIONALES

Es una componente de la serie que recoge oscilaciones que se producen alrededor de la tendencia, de forma repetitiva y en periodos iguales o inferiores a un año.

- ✓ LAS VARIACIONES ACCIDENTALES

Es una componente de la serie que recoge movimientos provocados por factores imprevisibles (un pedido inesperado a nuestra empresa, una huelga, etc.). También recibe el nombre de variaciones irregulares, residuales o erráticas.

2.2.4. MODELO

Un modelo es una expresión formalizada de una teoría, o la representación matemática de los datos observados. En el análisis estadístico un modelo es expresado, en símbolos de forma matemática.

Para la construcción de un buen modelo es necesario contar con el conjunto de datos observados. También es importante la experiencia, la intuición, la imaginación, la simplicidad y la habilidad para seleccionar el subconjunto más pequeño de variables. El primer paso es establecer el problema en forma clara y lógica delimitando sus fronteras, luego viene la recogida y la depuración de datos, el diseño del experimento; las pruebas de contraste; la verificación del modelo y la validación de las hipótesis.

Un modelo debe ser una buena aproximación al sistema real, debe incorporar los aspectos importantes del sistema y debe resultar fácil de comprender y manejar.

2.2.5. MODELO DE SERIES TEMPORALES

Son formas teóricas determinísticas y/o aleatorias o la combinación de ambas, para realizar el análisis de una serie de tiempo.

- ✓ **Variables Temporales**: Son variables que se observan a lo largo del tiempo. Y_t indica la variable "*Y*" en el momento "*t*".
- ✓ **Serie Temporal:** Es el conjunto de "*t*" observaciones, una observación por cada una de las variables: Y_1, Y_2,…, Y_t También es denominada serie cronológica.

Existen tres modelos de series de tiempo, que generalmente se aceptan como buenas aproximaciones a las verdaderas relaciones, entre los componentes de los datos observados, estos son:

1. Aditivo: $Y(t) = T(t) + E(t) + C(t) + A(t)$
2. Multiplicativo: $Y(t) = T(t) * E(t) * C(t) * A(t)$
3. Mixto: $Y(t) = T(t) * E(t) - C(t) + A(t)$

Donde

Y (*t*): Serie observada en instante *t*.

T (*t*): Componente de Tendencia.

E (*t*): Componente Estacional.

C (*t*): Variaciones Cíclicas.

A (*t*): Componente Aleatoria (accidental).

Una suposición usual es que A (t) sea una componente aleatoria o ruido blanco con media cero y varianza constante.

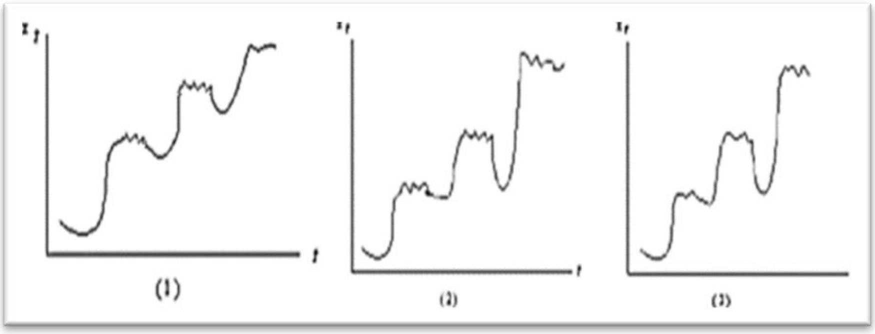

Figura 1 Proceso de modelos de series temporales

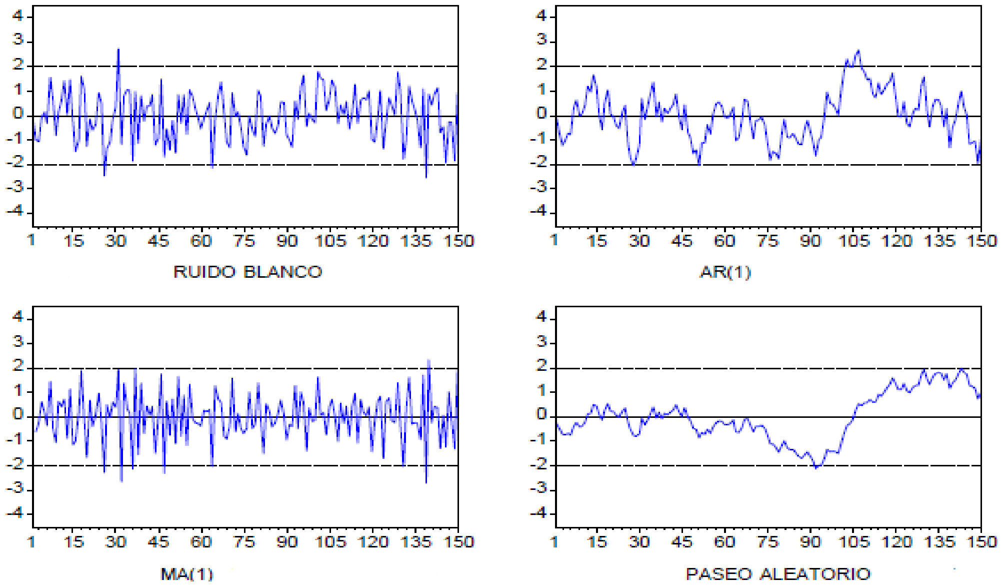

Figura Nº 02 Series temporales simuladas apartir de varios modelos ARIMA.

2.2.6. RUIDO BLANCO

El ruido blanco es una señal aleatoria (proceso estocástico) que se caracteriza porque sus valores de señal en dos instantes de tiempo diferentes no guardan correlación estadística. Como consecuencia de ello, su densidad espectral de potencia (PSD, Power Spectral Density) es una constante. Esto significa que la señal contiene todas las frecuencias y todas ellas tienen la misma potencia. Igual fenómeno ocurre con la luz blanca, lo que motiva la denominación.

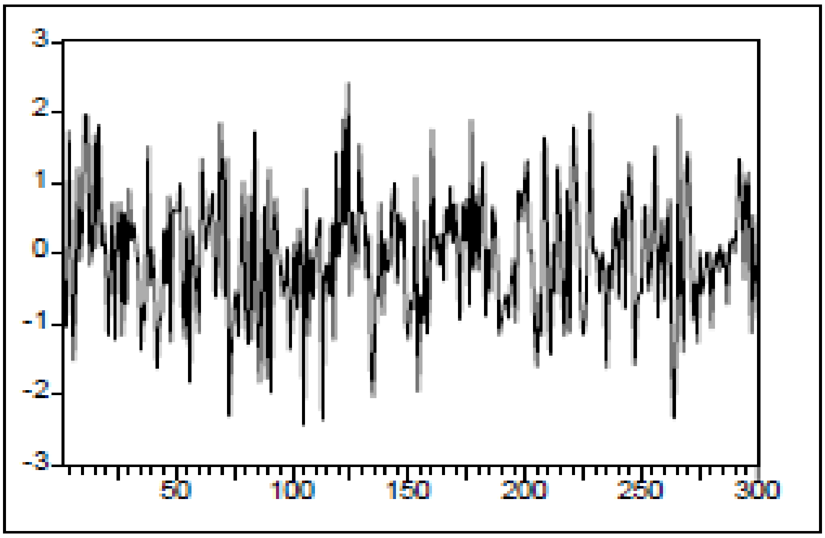

Figura Nº 03: Proceso de un ruido blanco

2.2.7. MODELO UNIVARIANTE

Es una serie de tiempo $\{Yt\}$, los modelos univariantes se consideran todos aquellos que solamente tiene una sola variable observada en el tiempo. Estos tipos de modelos se expresan en forma polinomial. Entre las técnicas univariantes existen algunas muy sencillas, tales como el modelo autorregresivo de primer orden, el modelo de tendencia lineal o exponencial, entre otros. Las técnicas más rigurosas para la predicción univariante son las denominadas técnicas o modelos de Box-Jenkins, o más concretamente modelos ARIMA, pues las técnicas de Box-Jenkins constituyen un conjunto más amplio, dentro del cual los modelos ARIMA univariantes son solo una parte. (USM, 2015)

MODELO UNIVARIANTE NO INTEGRADO

Los procesos autorregresivos AR (p), las Medias móviles MA (q) y procesos mixtos ARIMA (p, q) son considerados como los modelos no Integrados debido a que no interviene el grado de diferenciación y la estacionalidad de la serie.

MODELO UNIVARIANTE INTEGRADO

Son aquellos modelos que se pueden obtener mediante suma o integración de un proceso estacionario. A estos modelos se les denomina también modelos no estacionarios homogéneos.

SERIES DE TIEMPO ESTACIONARIAS

Una serie estacionaria se describe por una secuencia de datos o valores que no presentan ningún cambio sistemático en la media (la serie no representa tendencia alguna), ni cambio en la varianza, así se dice que un proceso es estacionario cuando, en cada uno de los puntos del tiempo.

En la práctica muchas series no son estacionarias; pero si sus primeras y segundas diferencias. El propósito de diferenciar una serie es volver estacionaria al diferencial de dicha serie. No obstante, debe recordarse que si toman diferencias también serán estacionarias; luego puede darse una sobre diferenciación de las series; lo que acarrea problemas de identificación respecto a aquel modelo que representa mejor el proceso que sigue la serie y se incrementa su varianza.

Una serie de tiempo es estacional cuando además de su tendencia y ciclo de largo plazo, muestra fluctuaciones que se repiten periódicamente. Como por ejemplo las observaciones mensuales; puede hacer similitud de comportamiento para observaciones del mismo mes; por ejemplo, venta de juguetes en los “meses de diciembre” también puede haber un patrón de comportamiento periódico con duración menor a un año; por ejemplo “cada seis meses” a partir de junio.

Las observaciones de los “meses de junio” y los “meses de diciembre” serán similares en su comportamiento, además de un comportamiento similar de las observaciones de los “meses de diciembre” entre sí, y de los meses de junio “entre sí”.

2.2.8. COMPONENTES DE UNA SERIE DE TIEMPO

HANKE (2006). Un método de análisis de los datos de series de tiempo incluye un intento por identificar los factores que influyen en cada valor de la serie. Este procedimiento de análisis se llama descomposición, cada componente se estudia por separado. Muchas veces es útil “descomponer” la serie de tiempo por sus principales componentes.

Tendencia: si una serie tiene tendencia, las observaciones sucesivas están muy correlacionadas y es típico que los coeficientes de correlación sean bastante diferentes de cero para los primeros retrasos de tiempo y entonces de forma gradual, caen hacia cero conforme aumenta el número de retrasos.

- Estacionalidad: si una serie presenta estacionalidad los efectos de fenómenos que ocurren o se reproducen periódicamente (fin de semana, diciembres, los viernes, etc.).
- Aleatoriedad: si una serie es irregular o aleatoria, las correlaciones entre y_t y y_{t-k} para cualquier retraso K son cercanas a 0. Los valores sucesivos de una serie de tiempo no se relacionan unos con otros.
- Cíclico: las variaciones cíclicas se producen a lo largo plazo y suelen ir ligadas a etapas de prosperidad o recesión económica. Suelen ser tanto más difíciles de identificar cuanto más largo sea su periodo, debido

fundamentalmente a que el tiempo de recogida de información no aporta suficientes datos.

Muchos usuarios de la información se limitan a desestacionalizar las series estocásticas (en parte por la generalización de métodos de des estacionalización), sin intentar un análisis estadístico más completo.

2.2.9. MODELOS DE SERIES DE TIEMPO

OPERADORES Y POLINOMIOS

Gutiérrez (2008). Los polinomios de retraso son muy útiles, porque permiten representar en forma concisa y simple modelos que son muy valiosos (pero que parecen complejos).

Operador de retraso o "backward" B, aplicable a z_t nos indica que se debe retrasar la variable un periodo:

Es decir, $B\, z_t = z_{t-1}$

También, $B^2 Z_t = B\,[B\, z_t] = B[z_{t-1}] = z_{t-2}$

Y en general $B^k \quad Z_{t-k}$

- **Operador diferencia ∇,** aplicable a Z_t nos indica que debe obtener las diferencias entre Z_t y su valor rezagado:

$$\nabla Z_t = Z_t - Z_{t-1} = (1 - B\,) Z_t$$

$$\nabla^2 Z_t = \nabla(Z_t - Z_{t-1}\,) = (Z_t - Z_{t-1}\,) - (Z_{t-1} - Z_{t-2}\,)$$

- **Polinomios formados por observaciones presentes y pasadas ponderadas;**

G(B) Z_t=Z_t-$g_1 Z_{t-1}$ -$g_2 Z_{t-2}$-…$g_k Z_{t-k}$ =Z_{t-} $\sum g_j Z_{t-j}$

- **Polinomios de retraso racionales:**

G(B)=A(B)/C(B)

A(B)=1-$\sum \mathrm{a_j B^j}$; C(B)=1-$\sum c_\mathrm{j} \mathrm{B^j}$

MODELO ARMA(p,q)

Proceso estocástico que sigue la variable aleatoria Z_t cuya desviación con respecto a su valor esperado μ lo denotamos por:

$Z_t = Z_{t-\mu}$

El modelo lo expresamos de la siguiente forma: $\phi(B)Z_t = \theta(B)a_t$

Donde ϕ(B), θ(B) son operadores de rezagos de orden p y q respectivamente, $\{a_t\}$ es una variable aleatoria con proceso de ruido banco (media cero y varianza finita).

Una forma alterna de escribir el proceso que sigue la variable Z_t seria:

(1+ $\emptyset_1 B + \emptyset_2 B^2 + \cdots + \emptyset_P B^P)Z_T$= (1+ $\theta_1 B + \theta_2 B^2 + \cdots + \theta_q B^q)a_t$ … (i)

O bien:

$z_t + \emptyset_1 z_{t-1} + \emptyset_2 z_{t-2}$+…..$\emptyset_p z_{t-p}$ =$a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2}$+…..$\theta_q a_{t-q}$ …(ii)

En el modelo ARMA (p,q) es una generalización de los modelos AR y MA, combinando ambas clases de modelos. Tal generalización surge de observar que las series de tiempo presentan, simultáneamente características de procesos AR y MA además el principio de parsimonia sugiere construir modelos que incluyen el menor número posible de parámetros.

Es de esperarse que no todas las series de tiempo sean estacionarias, supuesto bajo el cual está construido el modelo ARMA no obstante, sabemos que para casi cualquier serie no estacionaria, la primera, segunda o tercera diferencia de la serie si es estacionaria bajo estas condiciones se considera que si el proceso original.

$\{z_t\}$ adolece de no estacionariedad causada por una tendencia polinomial no determinista (a la cual se le denomina no estacionariedad homogénea) es posible construir un proceso estacionario $\{w_t\}$, tal que:

$$w_t = \nabla^d z_t \qquad \ldots\ldots (2)$$

para todo t. Para esta nueva serie es posible obtener un modelo ARMA:

$\phi(\mathrm{B})\, w_t = \theta(\mathrm{B})\, a_t$ equivalente a considerar el modelo ARIMA: $\phi(\mathrm{B})\, \nabla^d \tilde{Z}_t = \theta(B)\, a_t$

En el modelo ARIMA el término “integración” proviene de que z_t equivale a la suma de un número infinito de valores actuales y pasados de w_t. Consideramos la ecuación 2, para d=1. El valor de z_t se puede obtener multiplicando ambos lados de dicha ecuación por el operador ∇^{-1}, obtendríamos:

$z_t = \nabla^{-1} w_t = (1 - \mathrm{B})^{-1} w_t = w_t + w_{t-1} + w_{t-2} + w_{t-3} + \ldots\ldots\ldots$, una suma de un número infinito de términos.

COEFICIENTES DE AUTOCORRELACIÓN Y AUTOCORRELACIÓN PARCIAL DE LOS MODELOS AR(1) Y AR(2) HANKE JOHN, E. (2006).

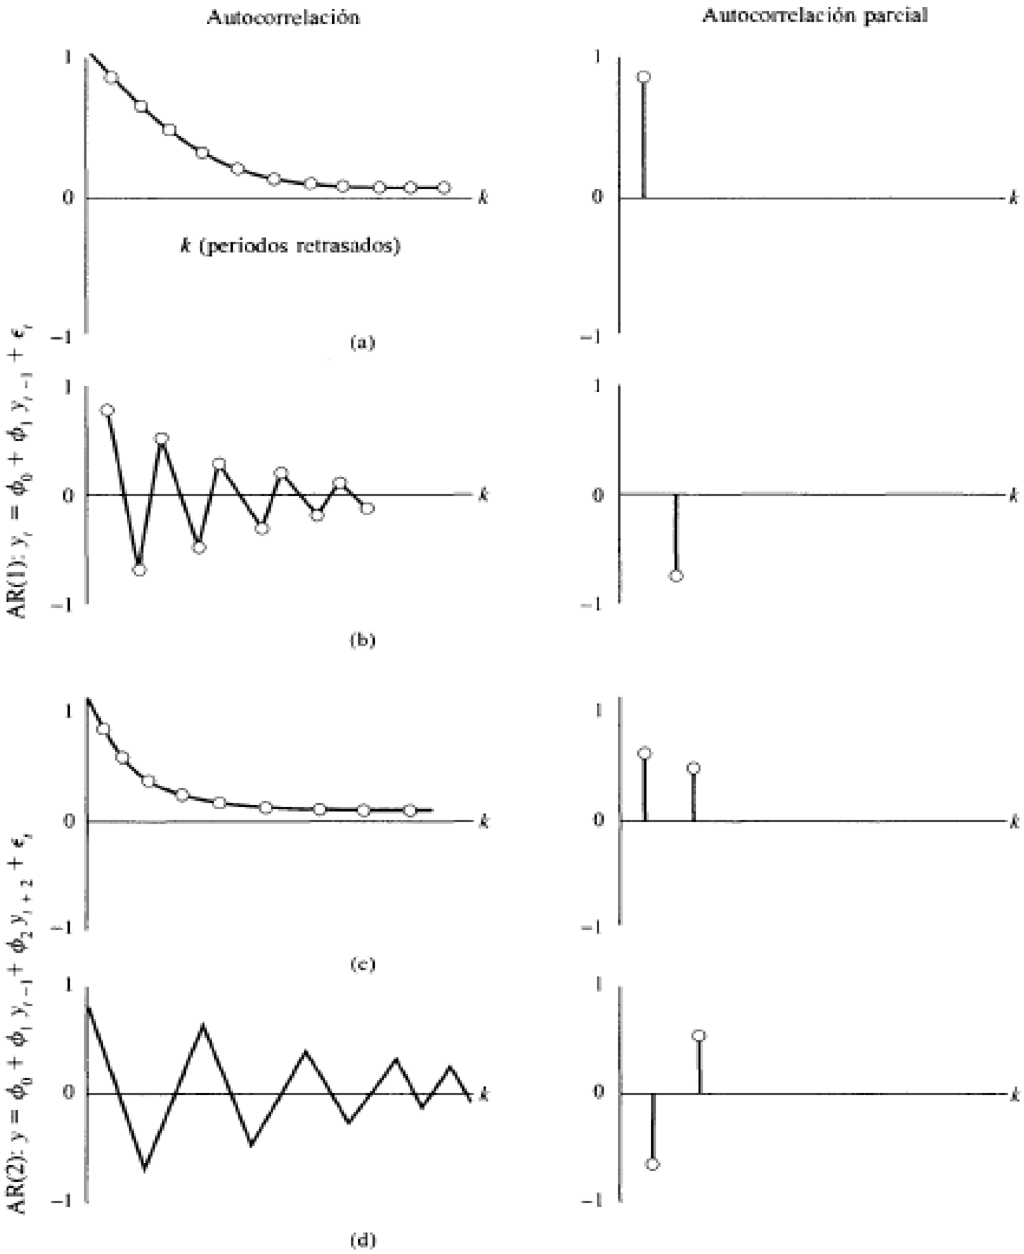

AR(1) $y_{t=}\emptyset_0 + \emptyset_1 y_{t-1} + \varepsilon_t$

AR(2) $y_{t=}\ \emptyset_0 + \emptyset_1 y_{t-1} + \emptyset_2 y_{t-2} + \varepsilon_t$

COEFICIENTES DE AUTOCORRELACION Y AUTOCORRELACION PARCIAL DE LOS MODELOS MA (1) Y MA (2) HANKE JOHN, E. (2006).

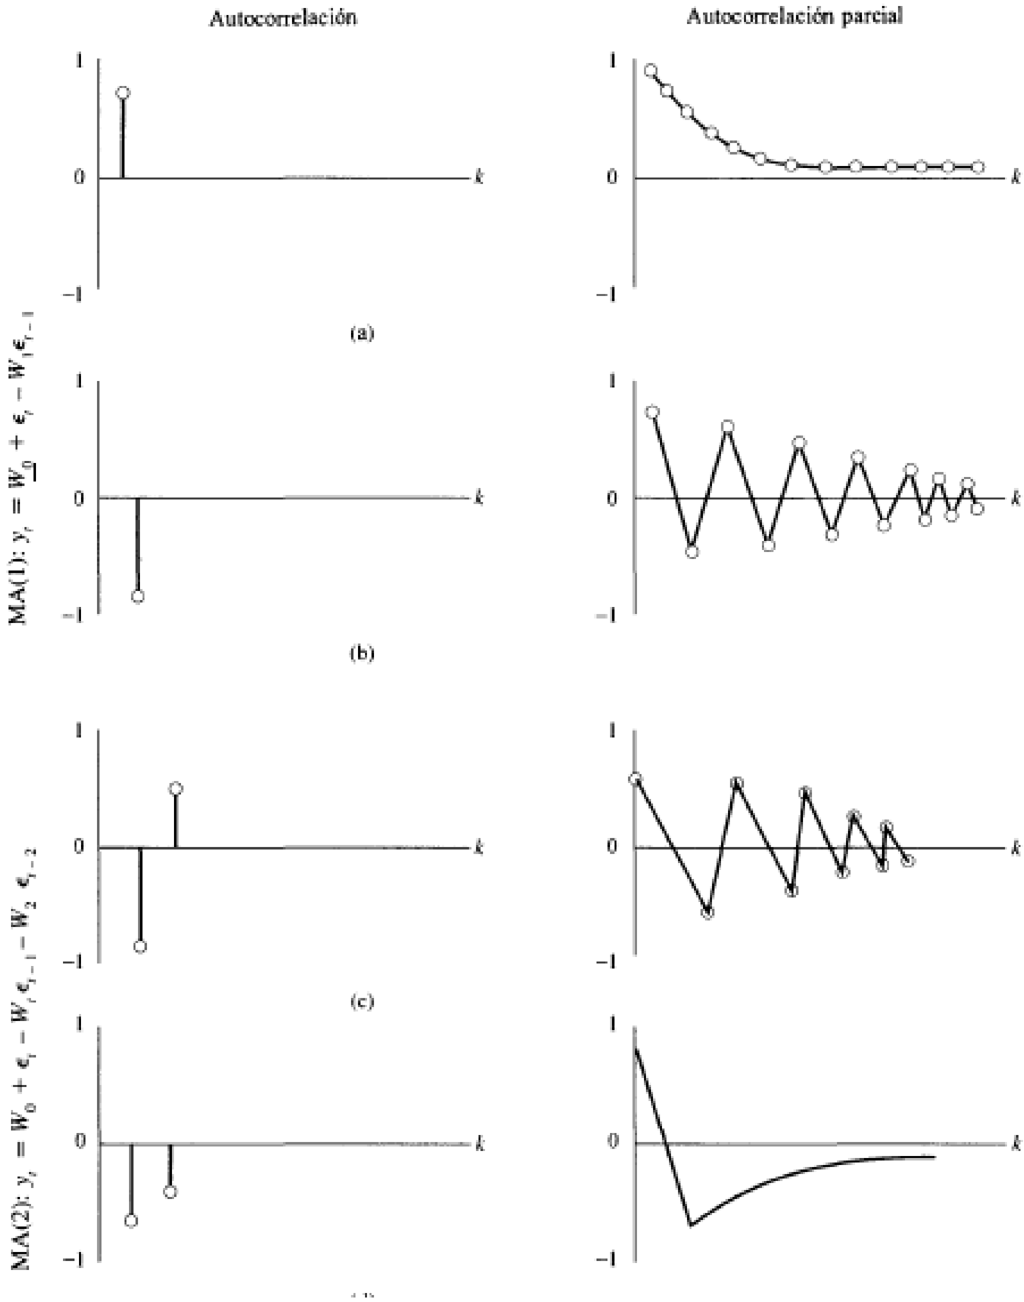

MA(1): $y_{t=} w_o + \varepsilon_t - w_1\varepsilon_{t-1}$

MA(2): $y_{t=} w_o + \varepsilon_t - w_1\varepsilon_{t-1} + w_2\varepsilon_{t-2}$

MODELO ARIMA (p,d,q)

Dado que en muchas ocasiones el proceso estocástico que sigue [z t - μ] = $\tilde{Z}$ no es de estacionariedad, pero si su diferencial de primero, segundo, tercer…enésimo orden, se puede formular una generalización del modelo ARMA para llegar a lo que se conoce como modelo ARIMA.

Tendremos finalmente:

(B)[∇^d $(z_{t-u}$)]=(B) ∇^d z_t=θBa_t.

Que constituye el llamado modelo autorregresivo integrado y de promedios móviles, o modelos ARIMA por sus siglas en inglés (autorregresive, integreted, moving average). El modelo ARIMA se describe más precisamente como: ARIMA (p,d,q), donde p es el número de rezagos que el polinomio operador de rezagos ϕ(B) realiza, d es el número de diferenciaciones sobre z_t que operador ∇^d realiza y q es el número de rezagos que el polinomio operador de rezagos θ(B) realiza.

(B)	∇^d z_t=	(B) a_t
Orden del polinomio de retraso (B) p	Orden del exponente en el operador diferencia d	Orden del polinomio de retraso (B) q

Un modelo ARIMA (p,d,q) indica que el modelo consta de un polinomio Autorregresivo de orden p, de una diferenciación en la variable de estudio z_t de orden d, y de un polinomio de promedios móviles de orden q.

MODELO MULTIPLICATIVO ESTACIONAL ARIMA (p, d, q) (p, d. q)$_E$

GUTIERREZ (2018). A fin de incorporar los efectos estocásticos estacionales y no estacionales a que están sujetos los valores observados de ciertas características de la población, o series de tiempo, BOX y Jenkins (1970) propusieron un modelo general del tipo:

$$\phi(B^E)\ \nabla_E^D\left(z_t - \mu\right) = \theta(B^E)\ a_t$$

Donde las variables $\{a_t\}$ no se suponen ruido blanco, sino generadores por un proceso ARIMA (p,d,q), o sea:

$$\text{(B)}\ \nabla^d\ a_t = \theta(B)a_t$$

Con (a_t) un proceso de ruido blanco. De estas dos últimas expresiones se obtiene el modelo multiplicativo estacional.

$$\text{(B)}\phi(B^E)\ \nabla_E^D(z_{t-u}) = \theta(B)\theta(B^E)a_t$$

El cual lo denotaremos por: modelo ARIMA (p,d,q)x$(\mathrm{P}, \mathrm{D}, \mathrm{Q})_E$ cómo es de esperarse, a mayor complejidad del modelo corresponde una estructura de autocorrelación más compleja. El modelo ARIMA, multiplicativo estacional para series con observaciones mensuales permite.

1) Considerar la relación que puede existir entre las observaciones de los meses contiguos dentro de los años.

2) Considerar la relación que puede haber ente años, para las observaciones de los mismos meses.

Es decir “se captura” simultáneamente, los efectos estacionales y de tendencia del proceso “multiplicativa” o de “auto refuerzo” de manera de tales efectos.

2.2.10. ELABORACIÓN DE MODELOS AR( ), MA( ), ARMA( ) Y ARIMA( )

Redalyc (2015). Los modelos ARIMA o modelos de promedio móvil autorregresivo integrado son un tipo general de los modelos Box-Jenkins para series de tiempo estacionarias. Una serie histórica estacionaria es aquella cuyo valor promedio no cambia a través del tiempo. Este grupo incluye a los modelos AR solo con término autorregresivo, los modelos MA solo con término de promedio móvil y los modelos ARIMA que comprenden tanto términos autorregresivos como de promedio móvil. La metodología Box-Jenkins permite al analista seleccionar el modelo que menor se ajuste a sus datos. Dado el concepto de proceso estacionario anteriormente definido, los modelos de pronóstico se dividen en:

2.2.11. MODELOS LINEALES ESTACIONARIOS

MODELO AUTORREGRESIVO AR ( )

Statistical ecology (2015). Se realiza tantas regresiones múltiples escalonadas como sea posible en las series combinadas, hasta que las series adicionales carezcan de poder explicatorio (o sea, que no mejoren los resultados de las regresiones, como el índice $\boldsymbol{R^2}$). La ecuación en prueba es:

$$Yt = \emptyset 1Yt-1+\cdots+\emptyset pYt-p+et$$

Dónde: e_t es el residuo o término de error, al que se supone una media igual a cero.

El número de periodos de demora "*p*" que requiere se determinará cuando se llegue a la estabilidad de los coeficientes. Si resulta que p=12 para datos mensuales, el modelo autorregresivo establece un modelo de índices estacionales que son los coeficientes estimados. Como se mencionó previamente, puede eliminarse el propio patrón estacional para investigar si hay otro modelo que abarca varios años, o si el modelo se extiende a un plazo más largo. Naturalmente, el modelo autorregresivo puede también revelar variaciones cíclicas menores de doce meses. El analista debe prestar atención a estos ciclos más cortos, eliminarlos de los datos, o no tenerlos en cuenta. La notación AR (p) se refiere a un modelo autorregresivo de orden p. Un modelo AR (p) puede escribirse como:

$$y_t = \mathrm{c} + \sum_{i=1}^{p} \emptyset_i y_{t-i} + e_t$$

Dónde: $\emptyset_1, \ldots, \emptyset_P$ son los parámetros del modelo, *c* es una constante *e* y et es un término de error (ruido blanco). El término constante es omitido por muchos autores para simplificar. Un modelo autorregresivo es esencialmente un filtro de respuesta infinita al impulso IR, con determinada interpretación adicional. Se debe tener en cuenta que es necesario imponer ciertas restricciones a los valores de los parámetros de este modelo para que funcione correctamente estacionario.

UN PROCESO AR (1)

Un modelo AR (1) viene definido por:

$$y_t = \emptyset_1 y_{t-1} + e_t$$

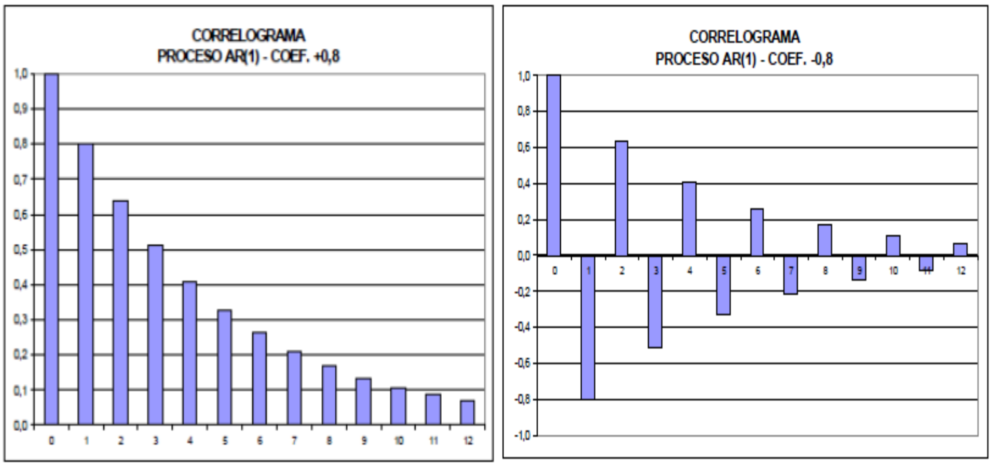

Figura Nº 04: Correlograma proceso AR (1)

UN PROCESO AR (2)

Un modelo AR (2) viene definido por:

$$y_t = \emptyset_1 y_{t-1} + \emptyset_2 y_{t-2} + e_t$$

PROCESOS DE MEDIAS MÓVILES MA ( ).

Este modelo de Box-Jenkins propone que una serie de tiempo tiene su explicación en una combinación de eventos aleatorios que se remontan a periodos del pasado.

Ningún fenómeno terrestre está libre de eventos aleatorios. Por ejemplo, la venta de productos está afectada por la introducción de otros nuevos y diferentes, o el mercado de acciones sufre un continuo bombardeo de nueva información aleatoria. Cuanto más tiempo haya pasado desde el suceso, menos influencia tendrá en las observaciones actuales. Como antes que se escoge de manera que los coeficientes sean estables y que no se consiga mayor poder explicatorio después de rebasar este valor. Los procesos de orden q de medias móviles, o abreviadamente MA (q), se define de la siguiente forma:

$$y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q}$$

Donde a_t es un ruido blanco con las propiedades ya definidas.

PROCESO MA (1) Un modelo MA (1) viene definido por:

$$y_t = \mu + a_t - \theta_1 a_{t-1}$$

Dónde: a_t es un ruido blanco con las propiedades ya definidas

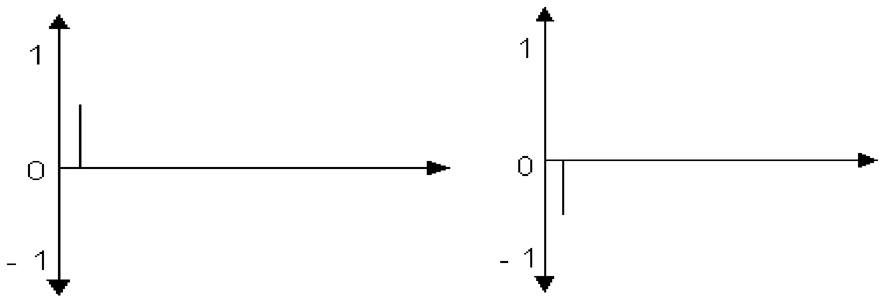

PROCESO ARMA [10]

PRESENTACION GENERAL

Scielo (2015). La combinación de procesos AR y MA da lugar a los procesos mixtos ARMA. La formulación general de un proceso ARMA (p, q) es:

$$y_{t=} \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \cdots + \varphi_p y_{t-p} + \mu + a_t - \theta_1 a_{t-1} - \cdots - \theta_q a_{t-q}$$

En particular, es importante analizar el correlograma de la serie.

Para el proceso

ARMA (1,1) Un proceso ARMA (1, 1), se excluye la constante por simplicidad:

$$y_{t=} \varphi_1 y_{t-1} + a_t - \theta_1 a_{t-1}$$

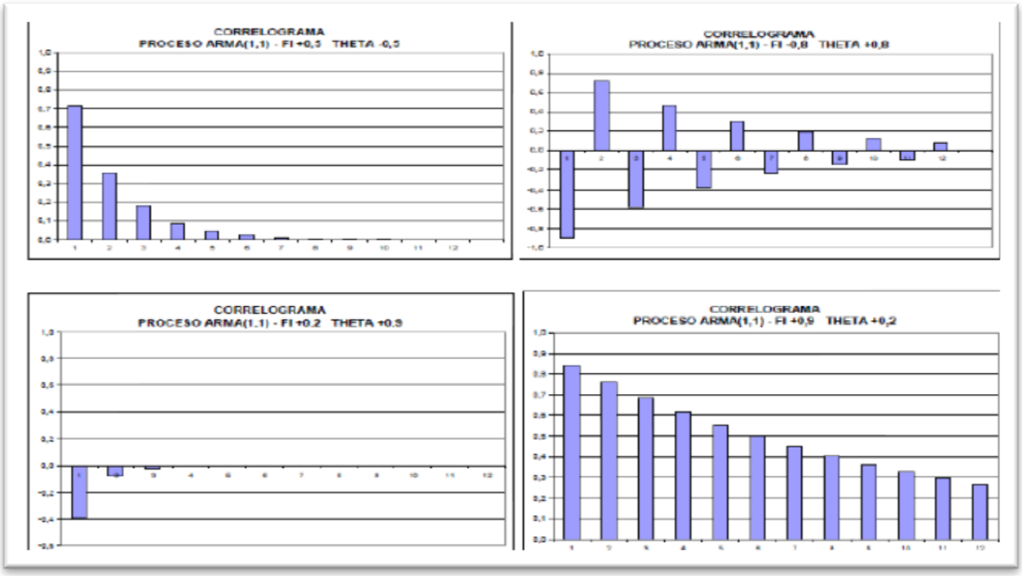

Figura Nº 05: Correlograma proceso ARMA (1,1)

PROCESO INTEGRADO ARIMA.

La mayor parte de las series corresponden a procesos no estacionarios. Así obtener un tratamiento de las series basadas en el "análisis de series de tiempo" (modelo ARIMA), es necesario discutir mecanismos de transformación de las series a procesos estacionarios.

En principio pueden representarse distintas (infinitas) formas por las que se introduce la no estacionariedad en un proceso estocástico. Sin embargo, interesa considerar solo algunas formas de la no estacionariedad que sean adecuados para describir el comportamiento de las series.

2.2.12. COEFICIENTE DE CORRELACIÓN

El Coeficiente de Correlación mide el grado de independencia de una variable relacionada con otra variable. Es una cantidad que esta entre -1 y +1, mientras este valor se aproxima a los límites, diremos que la correlación es buena, se expresa:

$$r = \sqrt{R^2}$$

Donde:

r: es el coeficiente de correlación.

R^2 : es el coeficiente de determinación.

El error siempre existirá, en Estadística es posible lograr un R^2 cercano a los límites, como lograr una menor varianza.

2.2.13. FUNCIÓN DE AUTOCORRELACIÓN

Hanke (2006). La autocorrelación es una herramienta matemática utilizada frecuentemente en el procesado de señales, la función de autocorrelación se define como la correlación cruzada de la señal consigo mismo. La función de autocorrelación resulta de gran utilidad para encontrar patrones repetitivos dentro de una señal, como la periodicidad de una señal enmascarada bajo el ruido o para identificar la frecuencia fundamental de una señal que no contiene dicha componente, pero aparecen numerosas frecuencias armónicas de esta. En Estadística, la autocorrelación de una serie temporal discreta de un proceso y_t es simplemente la correlación de dicho proceso con una versión desplazada en el tiempo de la propia serie temporal.

Si Y_i representa un proceso estacionario de segundo orden con un valor principal de μ se define entonces a función de autocorrelación.

$$R(K) = \frac{E[(Y_{i-}\mu)\,((Y_{i-k}-\mu))]}{\sigma^2}$$

Donde *E* es el valor esperado y *k* el desplazamiento temporal considerado (normalmente denominado desfase). Esta función entre el rango [−1,+1], donde +1 indica una correlación perfecta (la señal se superpone perfectamente tras un desplazamiento temporal de (K) y -1 indica una anticorrelación perfecta. Es una práctica común en muchas disciplinas el abandonar la normalización por σ^2 y utilizar los términos autocorrelación y autovarianza de manera intercambiable.

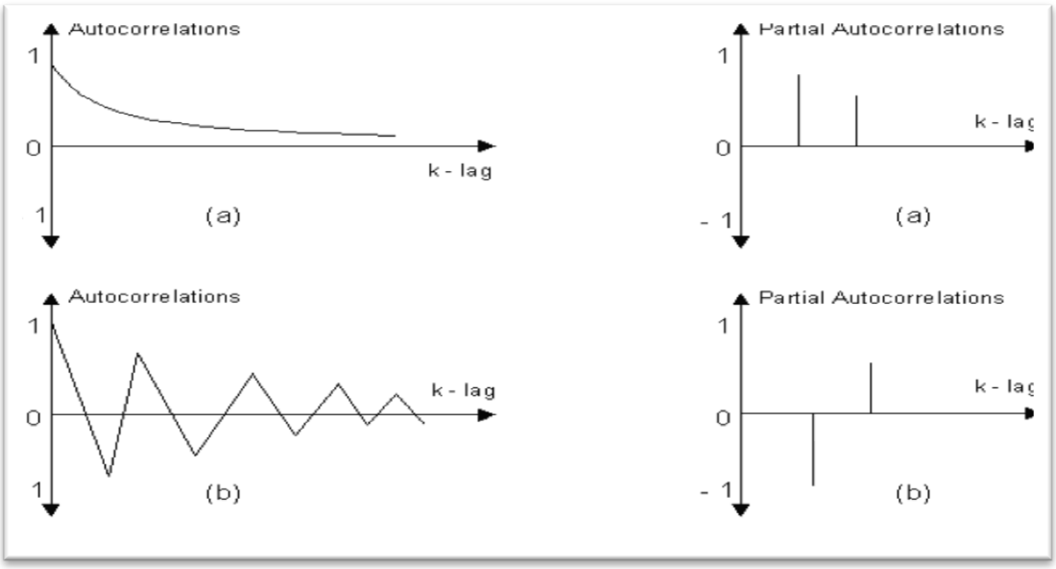

Figura Nº 06: Comportamiento De La Función De Autocorrelación Y Autocorrelación Parcial

2.2.14. CAMINATA AL AZAR

El proceso de caminata al azar se define como:

$$y_t = y_{t-1} + a_i$$

CASO GENERAL. - Dada una serie y_t que eventualmente corresponde a los logaritmos de los valores originales, si su diferencia de orden "d" puede ser representada por un proceso ARIMA (p, d, q).

La letra I en ARIMA corresponde a la “Integración”, la operación inversa a la diferenciación. Si $y_t = \Delta^d y_t$ y y_t sigue un proceso ARMA (p, q) estacionarios:

$$\left(1-\varphi_1 B^1-\cdots-\varphi_p B^p\right)Y_t=(1-\theta_1 B^1-\theta_2 B^2-\cdots-\theta_p B^p)a_t$$

Sigue un proceso ARIMA (p, d, q). También escribe a la variable original Y_t como

$$\omega_p(B)(1-B)^d Y_t = \tau(B)a_t$$

2.2.15. TRANSFORMACION DE BOX-COX

Box-Cox (1964) definieron una transformación instantánea en el sentido de que no está involucrado simultáneamente varios periodos de tiempo de carácter más general de la transformación logarítmica. Esta transformación se define por:

$$Y_t^\lambda = \begin{cases} \dfrac{(y_t^\lambda - 1)/\lambda}{\lambda} & \lambda \neq 0 \end{cases}$$

La transformación de Box-Cox requiere definir el parámetro **λ** de la transformación. Cuando el parámetro es **λ** = 1, la transformación de Box-Cox consiste prácticamente en tomar logaritmos. Cuando el parámetro es **λ** = 0, se define como la segunda igualdad (transformación logarítmica). La primera igualdad vale también, en el límite, el logarítmico de la serie original.

2.2.16. INTERVALOS DE CONFIANZA PARA LAS PREDICCIONES

La varianza del error de predicción puede utilizarse para obtener intervalos de confianza de las predicciones elaboradas, mediante la expresión:

$$E_t \ Y_{t-k} \ \pm \lambda_\alpha \delta_{et(k)}$$

Donde, si se supone que la innovación E_t Sigue una distribución normal, el parámetro λ_α se obtendrá de las tablas de dicha distribución al nivel de significancia α elegido.

PREDICCIÓN DE UNA SERIE DE DIFERENCIA

Si estimamos un modelo ARIMA con un número de diferencias, entonces será preciso recuperar las predicciones de la serie original a partir de las predicciones elaboradas para la serie de diferencias. Ellos se pueden realizarse de la forma: Supongamos que Y_t denota la serie en cuyo análisis estamos interesados, y que se ha especificado y estimado el modelo univariante para la serie de primeras diferencias. Entonces, es claro que:

$$EtYt \ + k \ = EtYt{-}k - EtYt{+}k{+}1$$

Por lo que:

$$EtYt{+}k = EtYt{-}k - EtYt{+}k{+}1$$

$$= Yt{+}k + Yt{+}k{+}1 + Yt{+}k{+}2 + \cdots + Yt{+}k{+}l \ + et$$

ERROR DE PREDICCIÓN

El error de predicción es la diferencia entre la realización de la variable aleatoria y la predicción hecha para dicho valor. El error cometido en la predicción de Y_{t+k} depende del periodo en que dicha predicción se realiza.

DESCRIPCION DE LA METODOLOGÍA BOX-JENKINS

Ezequiel (1985). La metodología de Box-Jenkins de previsión (1970) consiste en encontrar un modelo matemático que represente el comportamiento de una serie temporal de datos, los modelos que se utilizan en este trabajo son los modelos ARIMA univariantes, en los cuales se explica el comportamiento de una serie temporal a partir de las observaciones pasadas de la propia serie y partir de los errores pasados de previsión (o diferencias entre valores reales del pasado y las correspondientes previsiones utilizando el modelo). Un modelo ARIMA tiene la siguiente estructura general:

$$\phi_p(B)(1-B)^d x_{t=}K + \theta_q\,(B)a_t$$

Donde: x_t representa las observaciones en el periodo t de la serie objeto de estudio $\phi_p(B)$ y $\theta_q(B)a_t$ son dos polinomios, de órdenes de retardos

B (B$a_1 = X_{t-1}$), es el orden de las diferencias de primer orden que hay que tomar para hacer que la serie sea estacionaria en media y a_t es una serie de ruido blanco. Para las series estacionales, hay que incorporar al modelo la componente estacional. Una ventaja de los modelos de Box-Jenkins de previsión es que una vez adquirida experiencia en su metodología resulta más o menos rápido el mecanismo de búsqueda de los modelos, gracias al uso del ordenador. Además, una vez encontrado el modelo resulta inmediato hacer previsiones y comparaciones entre datos.

Otra característica de estos modelos es que se obtienen mejores previsiones a corto plazo, debido fundamentalmente a la propia estructura de los modelos ARIMA.

De todas estas conclusiones es una generalización ya que cada serie tiene sus propias particularidades. Hay que tener en cuenta que, para modelar una serie temporal con la metodología de Box-Jenkins, es necesario el empleo de alguna aplicación informática que facilite la tarea, ya que debido a la complejidad y gran cantidad de operaciones resulta imposible de llevar a cabo sin la ayuda de un ordenador. La metodología Box-Jenkins univariante divide en cuatro etapas el proceso de modelización. A continuación, se van a explicar brevemente cada una de estas cuatro etapas desde un punto de vista práctico, sin entrar en demasiadas explicaciones teóricas que están fuera del alcance de este trabajo.

IDENTIFICACIÓN

En la identificación de un modelo ordinario se analiza en primer lugar la estacionariedad de la serie en media y en varianza y su conversación en estacionaria en caso de que no lo fuera.

En esta etapa se identifica el orden d de la diferenciación, en caso de que esta sea necesaria, los órdenes p y q de los polinomios autorregresivo $\phi_p(B)$ y de medias móviles $\phi_q(B)$ del modelo ARIMA. Para llevar a cabo esta tarea se suele utilizar la ayuda de varias herramientas, entre las que destacan el gráfico temporal de la serie, y las funciones de autocorrelación (ACF), autocorrelación parcial (PACF), y autocorrelación extendida (EACF). De esta etapa pueden surgir varios modelos alternativos. En el modelo estacional hay que examinar si la serie es o no estacionaria en el componente estacional, en caso de que lo sea, se toman diferencias de orden estacional.

ESTIMACIÓN

En esta etapa se calculan los valores de los parámetros del modelo ARIMA identificado. En general se calcularán los valores de K, $\phi_{1,\ldots\ldots}\phi_p$, $\theta_{1\ldots\ldots}\theta_{\mathrm{q}}$ para el cálculo de estos valores se hace indispensable la ayuda del ordenador, debido a la complejidad de los cálculos es necesario estimar todos los modelos alternativos obtenidos en la etapa de identificación.

VALIDACIÓN

Una vez estimados los modelos ARIMA identificados en la primera fase, se pasa a realizar un diagnóstico sobre su validez, desde el punto de vista teórico. Existen multitud de test de diagnóstico, aunque para la elaboración de este trabajo se han utilizado los más reconocidos universalmente, que se indican a continuación. En primer lugar, hay que comprobar que todos los parámetros estimados son estadísticamente significativos. A continuación, se pasa a comprobar que la serie temporal formada por los residuos del modelo, es decir las diferencias entre los valores reales pasados de la serie y las previsiones obtenidas por el modelo, tiene un comportamiento similar a un ruido blanco, para lo cual se analiza su ACF. Es posible que varios de los modelos alternativos estimados pasen los test de diagnósticos, lo que quiere decir que todos ellos son válidos para realizar previsiones. Sin embargo, lo más lógico es quedarse en este momento nada más que con uno de ellos.

PREVISIÓN

En esta última fase, se realizan previsiones con el modelo seleccionado al final de la etapa anterior. Para ello vuelve a ser necesario el uso del ordenador, indicando al programa el número de previsiones que se quieren obtener y el periodo a partir del cual tiene que calcularlas.

2.3. DEFINICIÓN DE TÉRMINOS BÁSICOS

2.3.1. Consumo Del Sector Doméstica

EL consumo doméstico de energía es la cantidad que se gasta en los diferentes aparatos utilizados dentro de la vivienda.

Consumo Del Sector Comercial

Comprende el consumo de los establecimientos comerciales

Consumo Del Sector Industrial

Consumo de industrias

Consumo de uso general

Comprende iluminación de calles, plazas parques y vías de uso público en

Ciudades.

2.3.2. Central Eléctrica

Conjunto de equipos utilizados para la generación de energía incluyendo la maquinaria motriz y las obras civiles necesarios.

2.3.3. Sistema Principal de Transmisión

Es la parte del sistema de transmisión, común al conjunto de generadores de un sistema interconectado, que permite el intercambio de electricidad y la libre comercialización de la energía eléctrica.

2.3.4. Usuario

Persona que utiliza o trabaja con algún objeto dispositivo o que usa algún servicio en particular.

2.3.5. Proceso

Es cualquier fenómeno que sufre continuos cambios, parcialmente con respecto al tiempo.

2.3.6. Energía Eléctrica

Procobre (2015). La energía eléctrica es la forma de energía que resultará de la existencia de una diferencia de potencial entre dos puntos, situación que permitirá establecer una corriente eléctrica entre ambos puntos si se los coloca en contacto por intermedio de n conductor eléctrico para obtener el trabajo mencionado. La unidad de medida de la energía eléctrica es kilovatio-hora o kwh.

2.3.7. Nociones del Consumo de Energía

La energía eléctrica es el tipo de energía más conocida y utilizada por todos. Se produce por la atracción y repulsión de los campos magnéticos de los átomos de los cuerpos. La cantidad de energía eléctrica que consume un artefacto depende de la potencia del artefacto y de la cantidad de horas que se utiliza. El consumo de energía domestica mide en kilowatt por hora (Kw/h)

2.3.8. KILOWATT

Redalyc (2015). Es un múltiplo de la unidad de medida de la potencia eléctrica (el watt); representa la cantidad de energía consumida por unidad de tiempo. Esta unidad se relaciona muy a menudo con otras unidades comunes, potencia de un elemento receptor de energía, es la energía consumida por un elemento y se obtiene de multiplicar voltaje por corriente·

2.3.9. KILOWATT –HORA

Scielo (2015). Unidad de trabajo o energía equivalente a la que produce una potencia de un kilovatio durante una hora, es decir 3,6 millones de julios. Su símbolo es Kwh, se utiliza para registrar el consumo eléctrico.

2.3.10. MEGAVATIO- HORA

Es una medida de energía eléctrica equivalente a la potencia suministrada por un megavatio en una hora. Mega es el prefijo métrico para un millón, en este caso se trataría de un millón de vatios o de mil kilovatios suministrados en una hora, el Mwh se utiliza para medir el consumo de grandes industrias o conglomerados urbanos. El Mwh también se utiliza para conocer el índice producción de una central electrica aunque para estos casos también se de utiliza el concepto de megavatio por año que equivale a la energía suministrada por una central eléctrica durante un año.

2.3.11. ALEATORIO

Es cuando no sigue un patrón particular de que se pueda describir directamente por ecuaciones. Se basa más de la probabilidad. Al azar, estocástico. Este término representa una idea que debe ser expresada en términos del concepto de probabilidad.

2.3.12. CORRELOGRAMA

Representan grafica de los valores individuales de la función de autocorrelación total y parcial respecto a los rezagos.

2.3.13. MODELO

Un modelo es una representación externa y explicita de una parte de la realidad, el cual es visto por individuos que desean usar para entender, cambiar, manejar y controlar es parte de la realidad. Es la representación matemática de las variables de estudio y los parámetros que son estimados, con fines de predicción del comportamiento futuro de las variables.

2.3.14. MODELO MATEMÁTICO

Es la representación numérica de un problema básico, en el cual el comportamiento del sistema está representado por un conjunto de ecuaciones acompañadas de relaciones lógicas. (Thefreedictionary 2015)

2.3.15. MODELO DE PREDICCIÓN

Se entiende por predicción, anunciar algo que ha de suceder de un fenómeno físico dentro de un periodo de tiempo. Se incluye el estudio de datos históricos, para descubrir sus patrones y tendencia fundamentalmente, este conocimiento se utiliza para proyectar los datos a periodos futuros como pronóstico.

2.3.16. MODELO BOX-JENKINS

El modelo Box-Jenkins es uno de los métodos predictivos y se fundamenta en la estimación eficiente de los parámetros por medio de los procesos iterativos.

2.3.17. MODELO UNIVARIANTE DE BOX-JENKINS

Es una serie de tiempo, basado en la información existente del pasado.

2.3.18. MODELO UNIVARIANTE DE BOX-JENKINS NO INTEGRADO

Son los procesos de Medias Móviles MA (q), Autorregresivos AR (p) y Procesos Mixtos ARMA (p, q) se les considera como los modelos no integrados en vista de que no invierte la estacionalidad de las series observada.

2.3.19. MODELO UNIVARIANTE DE BOX-JENKINS INTEGRADO

A los procesos mixtos integrados ARIMA (p, d, q), proceso estacional mixto integrado ARIMA (p, d, q) * (P, D, Q), proceso de medias móviles exponenciales porque interviene la estacionalidad de la serie en estudio.

2.3.20. VARIABLE

Es una expresión que sirve para determinar una característica de los elementos de un conjunto de los cuales se asocia.

2.3.21. VARIABLE DEPENDIENTE

Son variables que influyen en el conjunto de relaciones y a su vez están influenciados por las variables independientes.

2.3.22. VARIABLE INDEPENDIENTE

Variables que influyen en el conjunto de relaciones, pero no están influenciados por ella.

2.3.23. SERIE

Una serie de tiempo es un conjunto de observaciones ordenadas en el tiempo (o en alguna otra dimensión).

2.3.24. PASEO ALEATORIO

Un proceso aleatorio es un proceso estocástico Yt cuyas primeras diferencias toman un proceso de ruido blanco.

2.3.25. RUIDO BLANCO

Es un proceso puramente aleatorio en donde las variables son distribuidas con media cero, varianza constante y ausencia de autocorrelación entre observaciones.

2.3.26. FUNCIÓN DE AUTOCORRELACIÓN PARCIAL

PACF: La autocorrelación parcial en el lapso determinado. El PACF variara entre -1 y +1 con valores cercanos ± 1, que indica fuerte correlación. El PACF: elimina el efecto de la autocorrelación. Retraso menor de la estimación de la correlación a mayores rezagos. Este cálculo solo es válido con un decimal.

2.3.27. CORRELOGRAMA

Es una representación gráfica de los valores individuales de la función de autocorrelación total y parcial respecto a los rezagos.

2.3.28. ESTACIONARIEDAD

Es una serie de tiempo, decimos que la serie es estacionaria si f(Yt) = f(Yt+k), es decir el comportamiento de la variable en el tiempo es el mismo si se produce un desplazamiento de la serie.

2.3.29. ESTACIONALIDAD

Puede definirse como la repetición de un cierto patrón de comportamiento en forma periódica; por ejemplo, se puede repetir cada 3 meses, 6 meses, cada año, cada 4 años, etc.

2.4. OPERACIONALIZACIÓN DE VARIABLES

Tabla 1 Operacionalizacion de variables

VARIABLES	INDICADORES	ÍNDICE
Variables Dependientes: - Consumo de Energía Domestica (Kwh/mes) del Distrito de Putina, Periodo 2005-2015	Expresada en kilowatts-hora	Kw/h
Variables Independientes: - Consumo de Energía Domestica (Kwh/mes) desfasado en distintos periodos de tiempo del Distrito de Putina.	Expresada en kilowatts-hora	Kw/h

CAPITULO III

MATERIALES Y MÉTODOS

3.1. POBLACIÓN

La población en estudio está representada por los registros existentes de Consumo de Energía Eléctrica Domestica (Kwh/mes), del servicio eléctrico del Distrito de Putina y recopilada por la oficina de Planeamiento (Electro Puno S.A.), desde su creación en el año 1989 hasta el presente año.

3.2. MUESTRA

La elección de la muestra de la población está conformada por la totalidad del Consumo de energía eléctrica domestica (Kwh/Mes), del distrito de Putina en el Periodo 2005-2015, este criterio de elección se tomó en cuenta debido a que el periodo de tiempo, considerando que constituye es el más reciente y representativo, recopilado por la oficina de planeamiento (Electro Puno S.A.), del Distrito de Putina.

3.3. MÉTODO DE RECOLECCIÓN DE DATOS

Para el presente trabajo de investigación se obtendrán los datos mediante el método directo, a través de la documentación proporcionada por el servicio eléctrico de Putina, Electro Puno.

3.4. MÉTODO DE TRATAMIENTO DE DATOS

En el presente trabajo de investigación se utilizará la teoría de WIENER- KOLMOGOROV, más conocido como el enfoque de Box-Jenkins en las series de tiempo. Los pasos que seguir en la obtención del modelo univariante por el método Box-Jenkins será:

a) Representación gráfica de las series

b) Cálculo de la función de autocorrelación (F.A.C.) y función de autocorrelación parcial (F.A.C.P.)

c) Proceso de identificación.

d) Estimación de parámetros.

e) Proceso de verificación y

f) Proceso de predicción.

MÉTODO DE BOX-JENKINS (Teoría de WIENER-KOLMOGOROV).

Ezequiel (1985). La metodología de Box-Jenkins sigue un proceso que consta de cuatro fases, las cuales son:

El método de Box-Jenkins (teoría de Wiener -kolmogorov), el método de Box-Jenkins es uno de los modelos predictivos, que se fundamenta en la estimación eficiente de los parámetros, por medio de procesos iterativos.

- Tareas relacionadas por el analista
- Tareas realizadas por el ordenador.

En definitiva, para que la metodología Box-Jenkins sirva para predecir la evolución futura de una acción, sino que es necesario contrastar que ese modelo de comportamiento no ha cambiado a lo largo del tiempo.

PRONOSTICO

Una vez identificado el proceso ARIMA que genera la serie temporal de interés, estimados los parámetros del modelo ARIMA correspondiente y después de haber pasado la etapa de verificación se utiliza el modelo para realizar pronósticos, con el menor error de predicción posible.

FUNCION DE AUTOCORRELACION

La función conformada por las correlaciones internas entre los términos de una serie observada (total de consumo de energía eléctrica doméstica) en el distrito de Putina, Periodo 2005-2015. Está definido por:

$$r(k)=\frac{cov\left(y_{t'}\,Y_{t-k}\right)}{r(0)}=\frac{E(y_t-u)(Y_{t-k}-u)}{r(0)}$$

Donde:

r(0) = Es la autocovarianza cuando no existe desplazamiento alguno; ósea, es la varianza del proceso a la que se ajusta al consumo de energía eléctrica doméstica.

u= es la media del proceso a la que se ajusten la serie de Consumo De Energía Eléctrica Domestica

$cov\left(y_{t'}\,Y_{t-k}\right)$= es la covarianza de la serie original y la serie desplazada en k periodos.

FUNCION DE AUTOCORRELACION PARCIAL

La matriz de autocorrelación para la serie estacionaria de longitud N, está dado por

$$P_k = \begin{bmatrix} 1 & r_1 & r_2 \ldots \ldots r_{N-1} \\ r_1 & 1 & r_1 \ldots \ldots r_{N-2} \\ \vdots & \vdots & \vdots \\ r_{N-1} & r_{N-2} & r_{N-3} \ldots\ldots \quad 1 \end{bmatrix}$$

El conjunto de autocorrelaciones parciales en varios desplazamientos, están definidos por:

$$\phi_{kk} = \frac{|Q_k|}{|P_k|}$$

Donde:

$|P_k|$= es la determinante de la matriz de autocorrelaciones de orden K x K.

$|Q_k|$= es la determinante de la matriz de autocorrelaciones. Con la última columna reemplaza por las funciones de autocorrelación generada por la serie de Consumo de Energía Eléctrica Domestica

$$\begin{bmatrix} r_1 \\ r_2 \\ \cdot \\ \cdot \\ \cdot \\ r_k \end{bmatrix}$$

r_k = la K-esima función de autocorrelacion del proceso a la que se ajusta la serie de consumo de energía eléctrica

N= tamaño de la serie con formado 3650 días equivalentes a 10 años (2005-2015) de la serie original.

CONSTRUCCIÓN DE MODELOS ESTOCÁSTICOS

El proceso de elaboración o construcción de los modelos se puede prestar 2 casos, que se genera de una serie de tiempo o identificación de proceso que genera la serie; la identificación del modelo se hace de forma iterativa, mediante la línea que conduce la validación x.

La construcción del modelo ARIMA (p,d,q) son las siguientes fases:

- Identificación
- Estimación
- Verificación o diagnostico

El método de la fase más crítica en la construcción del modelo es la identificación, la construcción de un modelo es un problema de inferencia estadística, es decir dado un conjunto de observaciones de una serie de tiempo, que debe obtener un modelo que permita ver el comportamiento anterior se debe verificar previamente el cumplimiento de este supuesto adicionado a una fase más, “análisis exploratorio de datos”.

FASE DE IDENTIFICACION DE MODELOS ESTOCASTICOS

Se trata de una determinación de estacionariedad de la serie (d y λ) y a continuación el número de parámetros autorregresivos (p) y media móvil (q), es decir si el modelo de la media atreves del tiempo, se trata de la serie no estacionaria entonces se aplica las transformaciones adecuadas con la finalidad de convertir en estacionarias e invertibles, especificando el grado de diferenciación y el algoritmo de Box-Jenkins haciendo el siguiente uso

- Representación gráfica de la serie; se visualiza fluctuaciones respecto a la media para confirmar la estacionariedad de la serie.
- Estimación de la función de autocorrelación y la función de la autocorrelación parcial; se demuestra la significancia de los r_k Y ϕ_{kk} y confirmar que ninguno de los parámetros estimados sea superior a 1 ni menor que -1.
- Calcular las raíces de la ecuación característica; en el proceso de identificación se compruebe la estacionariedad de la serie, solamente si las raíces caen dentro del circulo unitario, es conveniente realizar esta inspección.

FASE DE VERIFICACIÓN DEL MODELO

El objetivo para elaborar el modelo ARIMA se encontrará un modelo que sea lo más adecuado posible para representar el comportamiento de la serie, será el que cumpla los siguientes requisitos.

- El residuo del modelo estimado se aproxime al comportamiento de un “ruido blanco”
- Modelo estimado sea estacionario e invertido.
- Los coeficientes sean estadísticamente significativos, y están un poco correlacionadas entre sí.
- Los coeficientes del modelo son suficientes para representar la serie entre sí.
- El grado de ajuste es elevado en comparación al de otros modelos alternativos.

FASE DE PREDICCION O PRONOSTICOS

- Una vez que se encontró el modelo adecuado se puede realizar predicciones, selección de otro periodo de origen,
- Al haber más datos disponibles, se puede utilizar el mismo modelo para las predicciones, selección de otro periodo de origen.
- Si la serie parece cambiar a través del tiempo como pudiera ser necesario de calcular los parámetros o incluso desarrollar un modelo nuevo por completo.
- Para predecir los diferentes modelos se tiene.

$$y_t = \mathrm{B} + \emptyset_1 y_{t-1} + \cdots + \emptyset_p y_{t-p}$$

B,$\phi_{1,}\phi_{2\ldots\ldots}\phi_p$ = estimaciones de los parámetros para pronosticar.

p = es el número de periodos en el futuro y donde, para k menor a que cero, y_{p+k} es el pronóstico que se generaliza si el proceso es media móvil, mixto o estacionario.

MODELOS MIXTOS INTEGRADOS ARIMA (p,d,q).

Procesos ARIMA– No estacionarios

La determinación de los procesos o modelos, tratados en la fase anterior se han impuesto las condiciones de estacionariedad y/o invertibilidad; se conocen como generadores de procesos no estacionarios. Siguiendo a Box-Jenkins, un modelo ARIMA se define de la siguiente forma:

$$(1-\phi_1 B \ -\ldots - \phi_p B^p)(1-\mathrm{B})^d y_t^\lambda = (1- \theta_1 B - \ldots - \theta_q B^q) a_t$$

Donde:

d: es el número de diferencias necesarias para alcanzar la estacionariedad.

$|\phi_1, \dots \dots \phi_{p,}\theta_1, \dots\dots \theta_p|$: son los coeficientes de parte autorregresiva y media móvil respectivamente.

B: es el operador retardos.

λ: es el parámetro de la transformación Box-Cox.

ϕ_{p}(L): es el operador polinomial del proceso autorregresivo de orden p, se asume que es estacionario.

$\theta_q(B)$; Es el operador polinomial del proceso de media móvil invertible, es decir las raíces de $\theta_q(B) = 0$ que caen fuera del circulo unitario.

a_t= es la secuencia de desviaciones idénticamente distribuidas y no correlacionadas, se denomina ruido blanco. Se dice también que las desviaciones tienen la media igual a cero y la varianza es constante a lo largo del tiempo.

En principio pueden presentarse distintas (infinitas) formas por las que introduce la no estacionariedad en un proceso estocástico. Sin embargo, interesa considerar solo algunas formas de la no estacionariedad que sean adecuados para describir el comportamiento de serie consumo y al mismo tiempo, posible de ser transformados en procesos estacionarios. El proceso integrado x_t se denomina un proceso autorregresivo integrado de media móvil, ARIMA (p,d,q), se tomó la diferencia de orden (d) un proceso estacionario que se tiene en cuenta:

AR(p)=ARIMA(p,0,0) ≅ ARIMA(1,0,0)

MA(q)=ARIMA(0,0,q) ≅ARIMA(0,0,1)

ARMA(p,q)=ARIMA(p,0,q) ≅ ARIMA(1,0,1)

Esto aclara que los modelos ARIMA constituyen una clase particular de procesos no estacionarios, es posible eliminar sesgos desconocidos en los datos tomando diferencias de primer orden.

METODOLOGÍA DEL ENFOQUE BOX-JENKIN

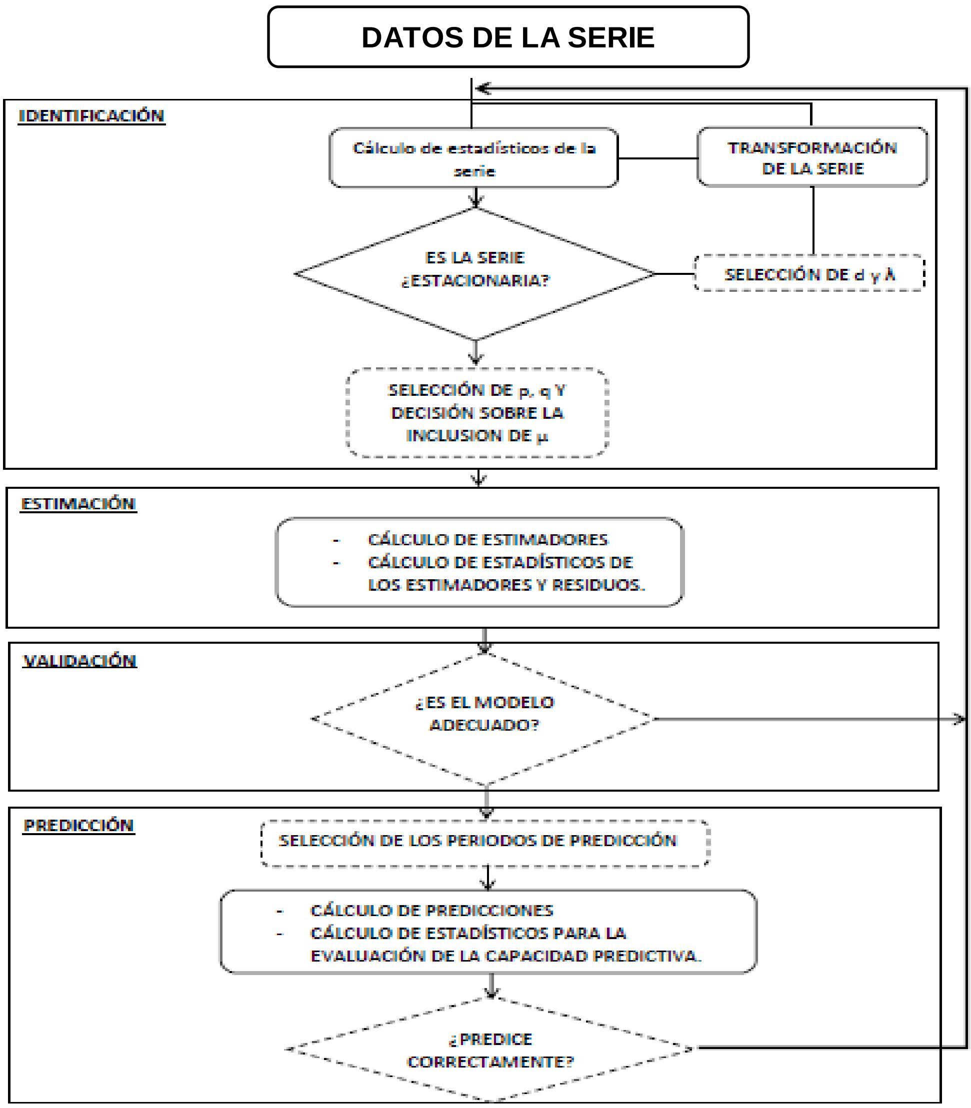

CAPITULO IV

RESULTADOS Y DISCUSION

4.1. APLICACIÓN DE LA METODOLOGIA BOX JENKINS

Valiéndonos de esta metodología en la presente investigación que consta de cuatro pasos indispensables, se llega al objetivo trazado que es el de determinar el modelo univariante que mejor se ajuste a los datos. Se presentan los cuadros y gráficos para el análisis, discusión e interpretación de los datos.

Se presentan los datos originales correspondientes a la serie de: "Consumo de energía eléctrica domestica para el servicio eléctrico del distrito de Putina – Electro Puno, periodo 2005-2015".

Una vez procesada la información, se presentan los cuadros y gráficos para el análisis, discusión e interpretación de los datos de la serie de consumo de energía eléctrica domestica para el servicio eléctrico del distrito de Putina – Electro Puno, periodo 2005-2015".

Tabla 2 SERIE HISTÓRICA DEL CONSUMO DOMESTICO DE ENERGÍA ELÉCTRICA (KWh/mes) DEL DISTRITO DE PUTINA, PERIODO 2005-2015

CONSUMO DE ENERGIA DEL DISTRITO DE PUTINA PERIODO 2005-2015 (KWh/mes)

	AÑOS										
	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
ENERO	615456	771202	897495	1308433	577566	95374	106759	113810	166294	164058	166958
FEBRERO	679551	954490	826475	1103922	1467754	86929	96985	115238	127626	122247	113210
MARZO	735732	831430	1041889	1356238	1353070	87393	99747	123256	123910	139061	137921
ABRIL	778054	946885	1091118	1413244	1697109	97858	115389	132522	139512	141980	142570
MAYO	585672	962367	1137566	1091230	88144	114101	130739	141402	148297	142846	143684
JUNIO	715843	900150	1123960	1699302	92657	123973	161035	148982	148619	146644	147922
JULIO	744959	1109694	1132187	1556741	86870	108203	131175	138629	161036	161553	
AGOSTO	843236	1020185	1096144	1347697	84830	110270	136375	140382	157731	171634	
SEPTIEMBRE	802276	977783	1170400	1337391	91846	108644	147454	146466	158310	159252	
OCTUBRE	921945	889330	1341609	1513749	94501	114119	132692	158523	146376	158413	
NOVIEMBRE	791955	836427	1193123	1268725	93526	126181	156519	165354	151662	155711	
DICIEMBRE	990615	977061	1392750	1588478	96298	129555	141358	133769	155342	163110	

FUENTE: Electro Puno.

4.2. IDENTIFICACION DEL MODELO

SERIE HISTÓRICA DEL CONSUMO DOMESTICO DE ENERGÍA ELÉCTRICA (Kw/mes) DEL DISTRITO DE PUTINA, PERIODO 2005-2015

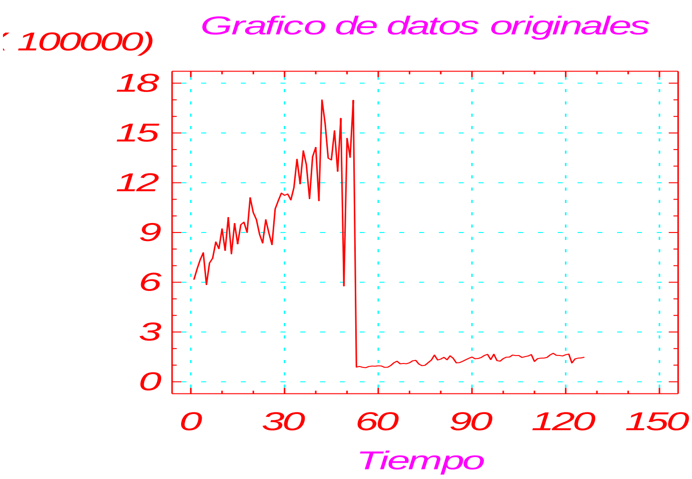

Gráfico N° 1 Grafico para la serie histórica del consumo doméstico de energía eléctrica del distrito de Putina. Periodo 2005-2015.

En el Grafico N° 01, los datos presentan una tendencia ascendente hasta el mes 52 que es la cúspide, luego se origina un cambio en la serie histórica que desciende a partir del mes 53 hasta el mes 64 cuya cantidad es de 97858 kwh/mes. Desde ese punto hacia adelante la serie histórica toma un cambio en su comportamiento donde no presenta mucha varianza en los datos y tiene una tendencia leve ascendente. En la primera fase también presenta periodos y mucha variabilidad en los datos por lo que nos va dando la idea de un modelo ARIMA multiplicativo.

Con la información original no se pudo conseguir un buen modelo utilizando la transformación BOX-COX con la que se realizó el proceso iterativo de la metodología BOX JENKINS.

SERIE DE DATOS TRANFORMADOS DEL CONSUMO DOMESTICA DE ENERGIA DEL DISTRITO DE PUTINA.

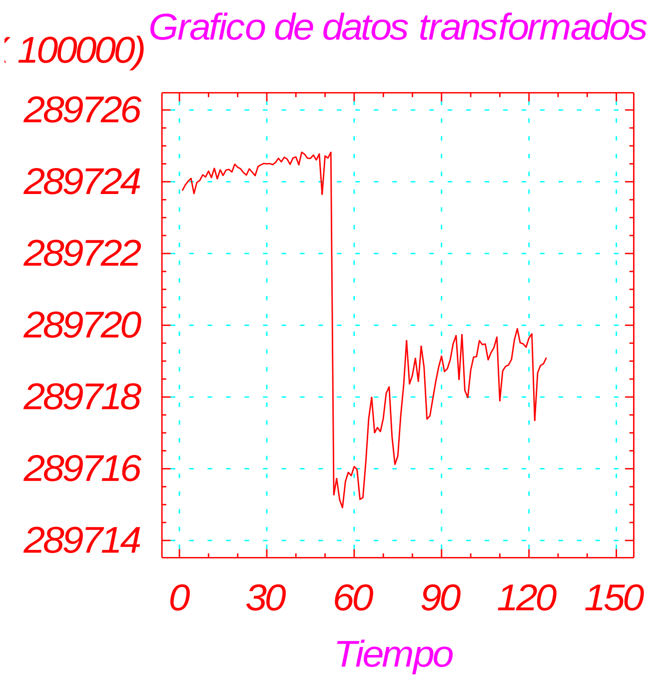

Gráfico N° 2 Grafico para la serie de datos transformados correspondiente al consumo doméstico de energía eléctrica del distrito de Putina.

En **Grafico Nro 2:** En vista de que con el primer grafico de los datos originales no tuvimos éxito en encontrar un buen modelo lo cual tuvimos que tranformar dichos datos, y en la primera fase de los datos tranformados nos muestra que no presentan mucha varianza, los cuales tienen una ascendencia leve hasta llegar a la cantidad de 289722 kwh/mes. A partir de ese punto la serie historia tiende a descender hasta llegar a 97858 kwh/mes y en la segunda fase los datos comiensan a tener variaciones ciclicas mostrando periodos.

FUNCION DE AUTOCORRELACION ESTIMADA DE LA SERIE DE CONSUMO DOMESTICA DE ENERGIA ELECTRICA DEL DISTRITO DE PUTINA

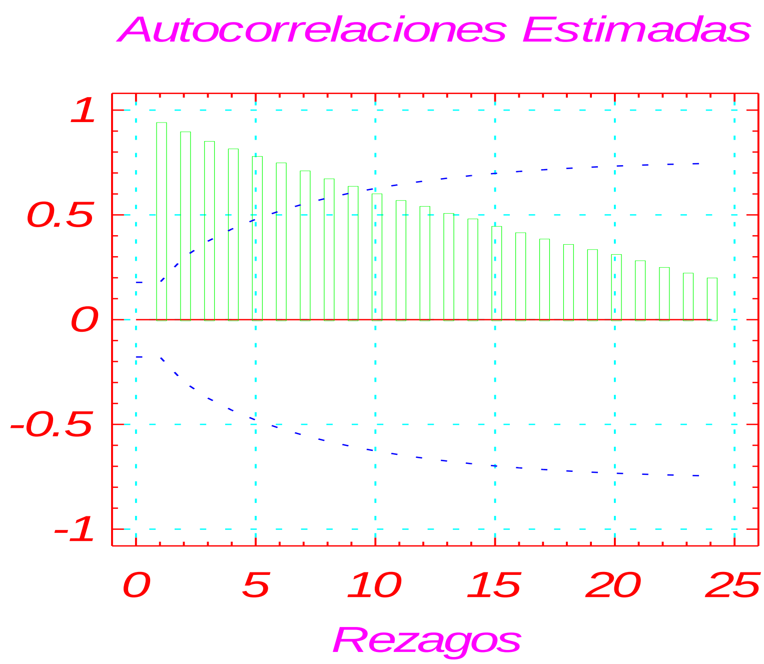

Gráfico N° 3 Grafico de la función de autocorrelaciones estimadas para la serie de consumo de energía domestica del distrito de Putina

Observamos en el **Grafico N° 3**. El comportamiento de la función de las autocorrelaciones estimadas es decreciente, los primeros 9 coeficientes son significativos, a partir del 10mo coeficiente están dentro de los límites de confianza ya que tienden a 0 por lo tanto, se afirma que los datos presentan tendencia y debemos proceder a diferenciarlos para crear una serie estacionaria.

FUNCION DE AUTOCORRELACIONES PARCIALES ESTIMADAS

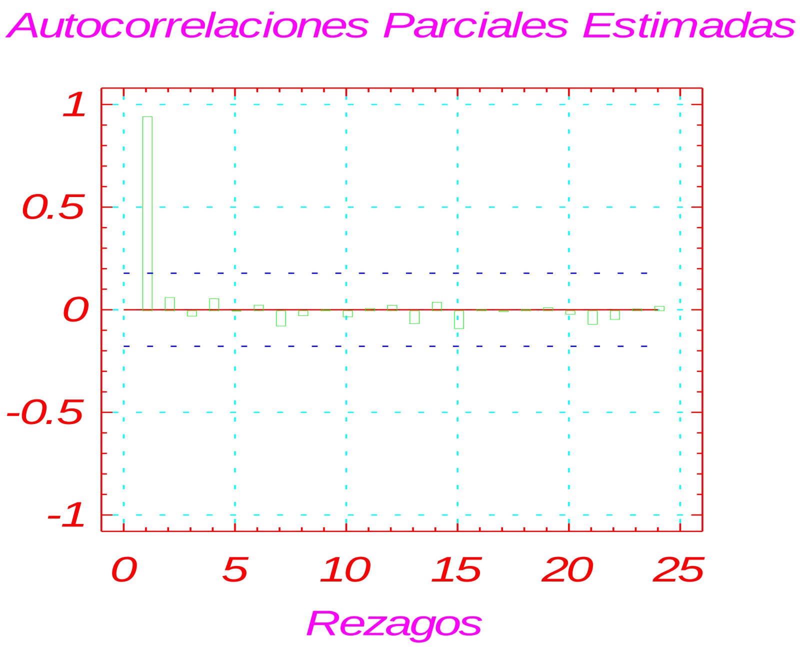

Gráfico N° 4 Gráfico de función de autocorrelaciones parciales estimadas para la serie de consumo domestica de energía eléctrica del distrito de Putina.

Observamos en el Grafico N° 4 el comportamiento de las autocorrelaciones parciales en donde el primer coeficiente tiene un retraso de tiempo a la vez es significativamente diferente a 0, a partir del segundo coeficiente hasta el último están dentro del intervalo de confianza y se aproximan a 0 la cual aún no es estacionaria y se acerca a un ruido blanco.

FUNCION DE DOS DIFERENCIAS NO ESTACIONAL POR UNA DIFERENCIA ESTACIONAL

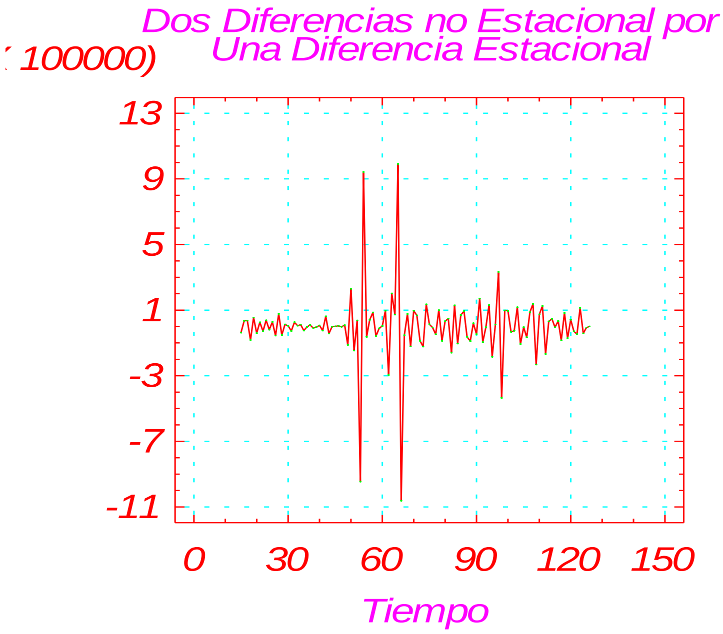

Gráfico N° 5 Gráfico de la función de dos diferencias no estacional por una diferencia estacional para la serie de consumo de energía para el distrito de Putina.

En el **Grafico N° 5**, Se identifica gráficamente que la trayectoria de la serie a lo largo del tiempo en el cual determinamos que la serie no muestra signos de tendencia, se observa además que existen algunos valores que muestran picos diferenciados, en los valores de tiempo 40 y 52 (bajas y altas). En tal caso podemos decir que estamos frente a una serie de datos casi estacionarios lo cual fue corroborado en las autocorrelaciones.

FUNCION DE AUTOCORRELACION ESTIMADAS PARA DOS DIFERENCIAS NO ESTACIONAL POR UNA ESTACIONAL

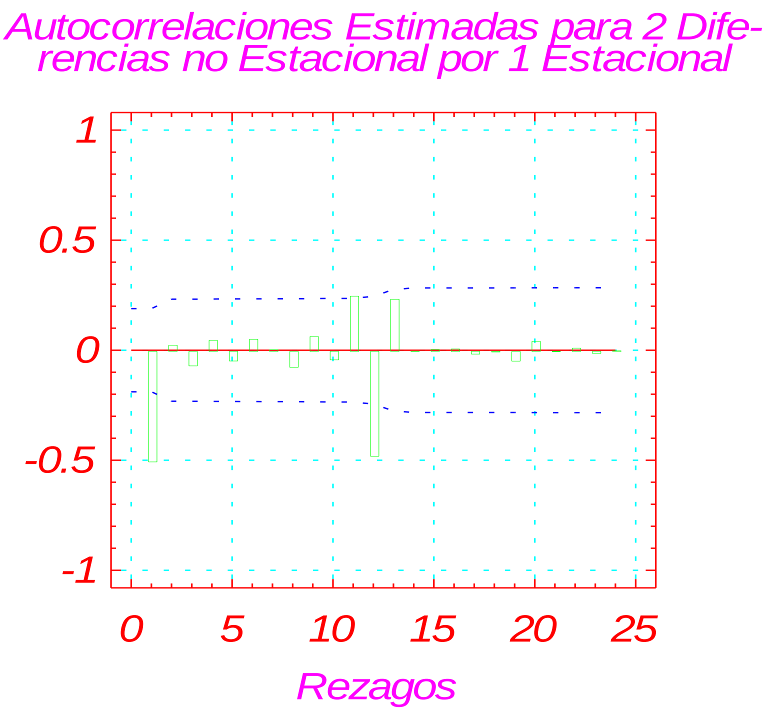

Gráfico N° 6 Función de autocorrelaciones estimadas para dos diferencias no estacional por una estacional para la serie de consumo de energía domestica del distrito de Putina

En el Grafico N° 6, se observa que los coeficientes 1 y 12 son significativos, el resto están dentro de los límites permitidos están ligeramente dentro del intervalo de confianza en cual podemos decir que los datos ya no son significativos,

FUNCION DE AUTOCORRELACIONES PARCIALES ESTIMADAS PARA DOS DIFERENCIAS NO ESTACION Y UNA ESTACIONAL

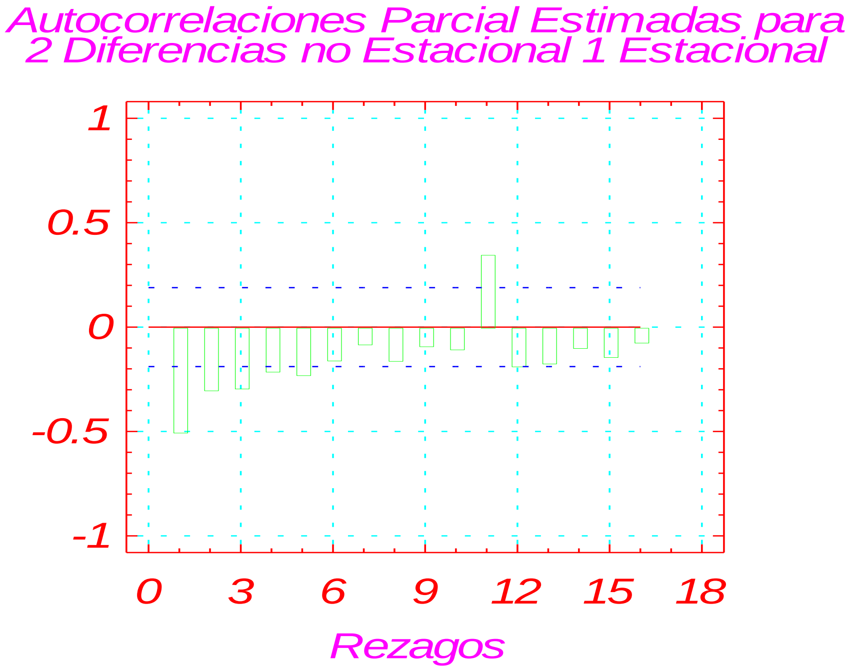

Gráfico N° 7 Función de autocorrelaciones parciales estimadas para dos diferencias no estacional y una estacional para la serie de consumo de energía domestica para el distrito de Putina.

En el Grafico Nro 7 presenta una caída exponencial dándonos la idea de que es un modelo de media móvil y SMA móvil. La función de autocorrelación parcial estimada nos sugiere un proceso integrado ARIMA(0.2.1)(0,1.1) multiplicativo que nos permitirá describir el comportamiento de la serie de consumo de energía eléctrica. Y aun no es estacionario.

PERIODOGRAMA PARA EL CONSUMO DE ENERGIA ELECTRICA DE PUTINA

(DATOS TRANSFORMADOS)

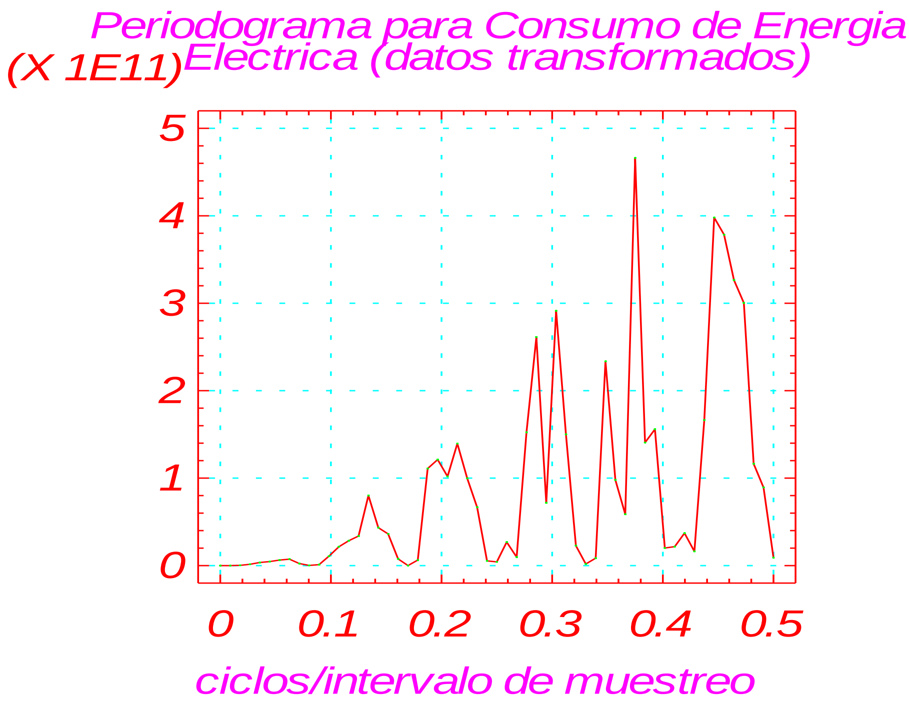

Gráfico N° 8 Periodograma para el consumo de energía eléctrica domestica del distrito e Putina

se observa en el **Grafico N° 8** que el periodo al inicio tiende una cierta continuidad y a partir del intervalo 0.1 empieza a subir con diferentes periodos.

MODELO IDENTIFICADO:

ARIMA(0,2,1)(0,1,1):

$$y_t = 2y_{t-1} - y_{t-2} + y_{t-12} - y_{t-13} + \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_{12}\varepsilon_{t-12} + \theta_{13}\varepsilon_{t-13}$$

4.3. ESTIMACIÓN DEL MODELO IDENTIFICADO

Después de llevar a cabo el proceso de identificación del modelo procedemos a la estimación del modelo ARIMA **(0,2,1)(0,1,1)**, para los datos de la serie de Consumo de Energía Eléctrica.

A continuación, presentamos los cuadros de Análisis de Varianza para los modelos estimados.

Tabla 3 ARIMA(0,2,1)(0,1,1,) DE LA SERIE CONSUMO DE ENERGÍA ELÉCTRICA

Resumen del modelo ajustado para: SERIES DE TIEMPO

Parametro	Estimacion	Erros estandar	T-valor	P-valor
MA (1)	0.95194	0.03142	30.29745	0.00000
SMA(12)	0.99410	0.05670	17.53189	0.00000

Modelo ajustado a las diferencias de orden 2
Modelo ajustado a las diferencias estacionales de orden 1 con longitud estacional = 12
Varianza estimada de ruido blanco = 1.25872E10 con 110 grados de libertad.
Desviación estándar del ruido blanco estimado (std err) = 112193
Estadística de prueba Chi-cuadrado en las primeras 20 autocorrelaciones residuales = 8.17026
con probabilidad de un valor mayor dado ruido blanco = 0.975993

Comparando los valores hallados para el parámetro que corresponde a la media móvil determinamos que ambos valores cumplen con la condición de ser significativos al ser menores que 0.05. Considerando la premisa anterior hacemos la elección del parámetro adecuado, basados en el error estándar; Cuya expresión es la que sigue:

MODELO ESTIMADO:

$$\hat{Y}_t = 2y_{t-1} - y_{t-2} + y_{t-12} - y_{t-13} - \hat{O}_1 e_{t-1} - \hat{O}_{12} e_{t-12} + \hat{O}_{13} e_{t-13}$$

ECUACION DE PRONOSTICO:

$$\hat{Y}_t = 2y_{t-1} - y_{t-2} + y_{t-12} - y_{t-13} - (0.95194)e_{t-1} - (0.99410)e_{t-12} + (0.94637)\mathcal{E}_{t-13}$$

Donde: $\hat{O}_{13} = \hat{O}_1\hat{O}_{12}$ $\hat{O}_{13} = (0.95194)(0.99410)$ $\hat{O}_{13} = 0.94637$

4.4. VALIDACIÓN DEL MODELO

Después de seleccionar un modelo ARIMA particular y de estimar sus parámetros, se trata de ver si el modelo seleccionado se ajusta a los datos en forma razonablemente buena, el detalle se encuentra en ver la medida en que los residuos del modelo estimado se aproximan al comportamiento de un ruido blanco.

a) $|\theta 1| < 1$, $|\theta 12| < 1$

MA(1) $\theta_1 = 0.95194 < 1$

SMA(12) $\theta_{12} = 0.99410 < 1$

b) El P estadístico < 0.05

P = 0.0000 <0.05 MA(1)

P = 0.0000 <0.05 SMA(12)

c) Prueba de la Chi cuadrada ARIMA(0,2,1)(0,1,1)$_{12}$

CONTRASTE GLOBAL DE BOX Y PIERCE.

Planteamiento de Hipótesis para el modelo ARIMA (0,2,1)(0,1,1)$_{12}$

H_0 : Los residuos sigue un proceso ruido blanco : $p_k > 0$

H_1 : Los residuos no siguen un proceso ruido blanco : $p_k > 0$

Niveles de significancia: α = 0.05 = 5%

Prueba estadística: $Q_{cal} = 8.17026$ donde: Q_{cal} $X^2_{(k-p-q)} \rightarrow (0.05)$

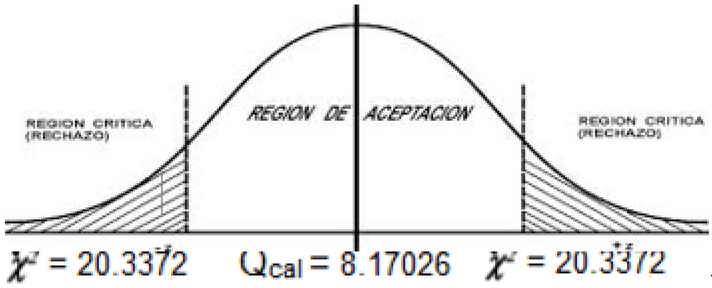

$X^2_{(21,0.05)} = 20.3372$

Por lo tanto como $\mathbf{Q_{cal} = 8.17026 < X^2_{(21,0.05)} = 20.3372}$, entonces aceptamos la $\mathbf{H_0}$ y rechazamos la $\mathbf{H_1}$, es decir los residuos siguen un proceso ruido blanco o son independientes. Entonces decimos que la serie histórica de consumo mensual de energía eléctrica domiciliaria del distrito de Putina es estacionaria.

FUNCION DE AUTOCORRELACION DE RESIDUALES ESTIMADOS

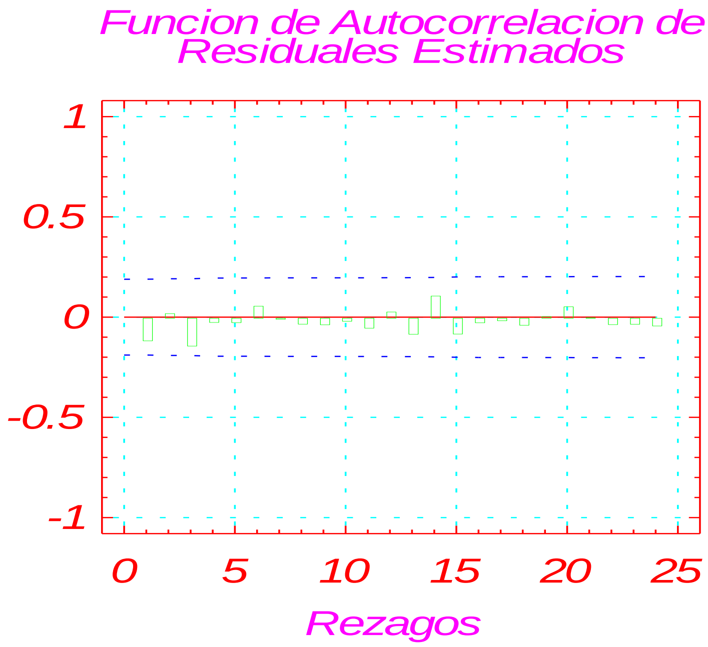

Gráfico N° 9 unción de autocorrelación de residuales estimadas para la serie de consumo de energía eléctrica domiciliaria del distrito de Putina

Verificamos en la Grafico N° 9 que la serie están dentro del intervalo de confianza. Entonces se afirma que los datos de la serie de consumo de energía son aleatorios.

FUNCION DE AUTOCORRELACION PARCIAL DE RESIDUALES ESTIMADOS

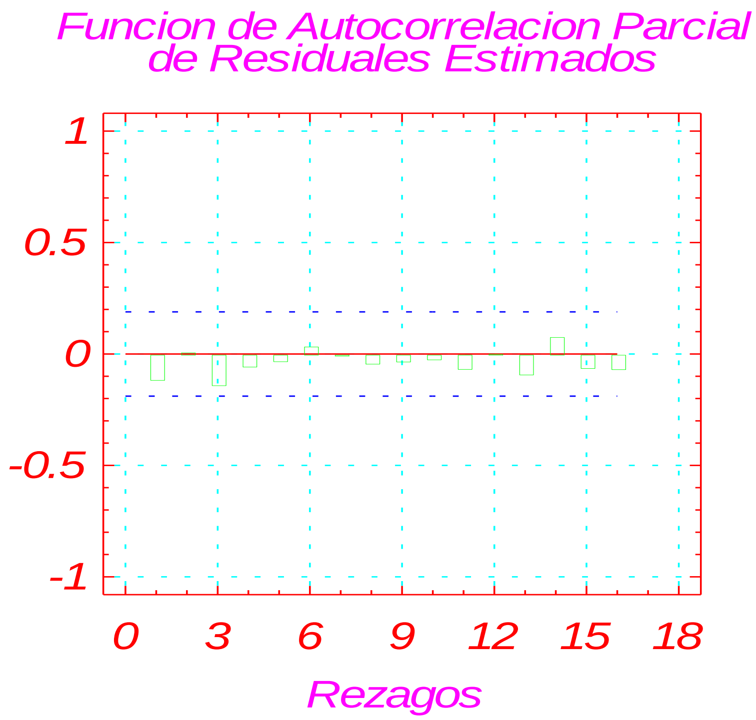

Gráfico N° 10 Función de autocorrelación parcial de residuales estimados para la seria de energía eléctrica domestica del distrito de Putina.

En el Grafico N° 10 Se observa la distribución de la función de autocorrelación parcial identificando que ningún coeficiente es significativo, por lo que se concluye que la serie es aleatoria.

4.5. PREDICCION

PRONOSTICOS ESTIMADOS

Tabla 4 DATOS DE PREDICCIONES ESTIMADAS (MWh/mes)

	AÑO	MES	PREDICCION	LIMITE INFERIOR	LIMITE SUPERIOR
127	2015	Julio	2.89719	2.89717	2.89722
128		Agosto	2.8972	2.89716	2.89723
129		Setiembre	2.8972	2.89716	2.89724
130		Octubre	2.8972	2.89715	2.89725
131		Noviembre	2.8972	2.89715	2.89725
132		Diciembre	2.8972	2.89714	2.89727
133	2016	Enero	2.8972	2.89713	2.89727
134		Febrero	2.89721	2.89713	2.89728
135		Marzo	2.89721	2.89713	2.89729
136		Abril	2.89721	2.89713	2.8973
137		Mayo	2.89721	2.89712	2.8973
138		Junio	2.89722	2.89712	2.8973
139		Julio	2.89722	2.89712	2.89732
140		Agosto	2.89722	2.89711	2.89733
141		Setiembre	2.89723	2.89711	2.89734
142		Octubre	2.89723	2.89711	2.89735
143		Noviembre	2.89723	2.8971	2.89736
144		Diciembre	2.89724	2.8971	2.89737
145	2017	Enero	2.89724	2.89709	2.89738
146		Febrero	2.89724	2.89709	2.89739
147		Marzo	2.89724	2.89709	2.8974
148		Abril	2.89725	2.89709	2.89741
149		Mayo	2.89725	2.89708	2.89741
150		Junio	2.89725	2.89708	2.89743

SECUENCIA ESTIMADA

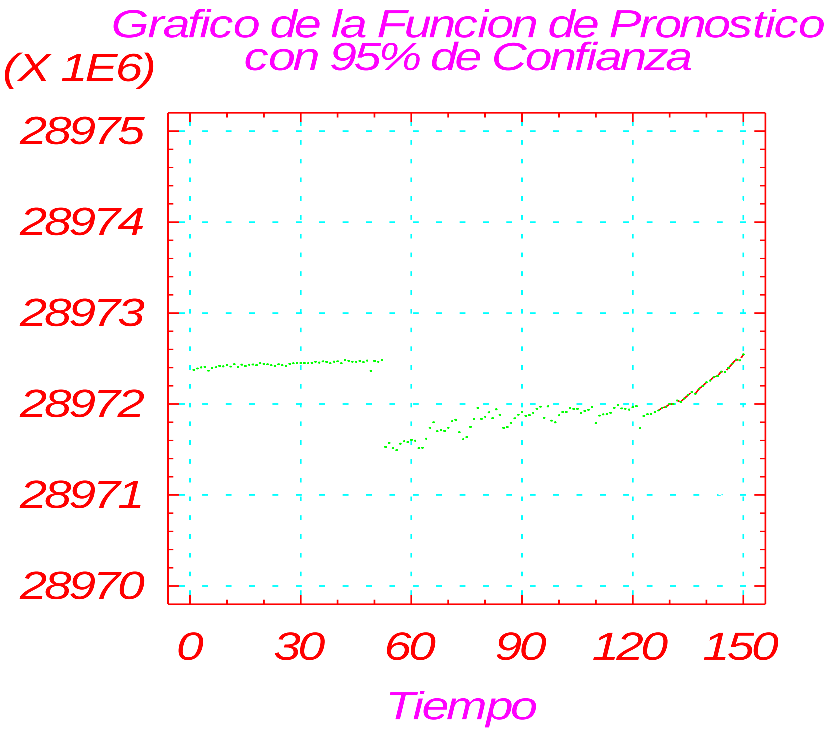

Gráfico N° 11 Función de pronóstico de con 95% de confianza para la serie de consumo de energía eléctrica domiciliario del distrito de Putina

En **Grafico N° 11,** La predicción del consumo de energía presenta una tendencia creciente, este comportamiento se explica debido al gradual incremento en la población y por ende un crecimiento en la demanda de la energía eléctrica.

CONCLUCIONES

- Los modelos univariantes integrados proporcionaron un mejor ajuste para la serie consumo de energía eléctrica para el servicio eléctrico del distrito de Putina

- La serie consumo de energía eléctrica en el servicio eléctrico del distrito de Putina, presenta una tendencia creciente, y no muestra signos de variaciones cíclicas y estacionales.

- El mejor modelo univariante que permite describir y predecir el comportamiento del consumo de energía eléctrica para el servicio eléctrico del distrito de Putina – Electro Puno

- El modelo conseguido que describe y ajusta a los datos es un modelo ARIMA multiplicativo.

ARIMA(0,2,1)(0,1,1)

$$\hat{Y}_t = \boldsymbol{2y_{t-1}} - \boldsymbol{y_{t-2}} + \boldsymbol{y_{t-12}} - \boldsymbol{y_{t-13}} + \mathcal{E}_t - (0.95194)\mathcal{E}_{t-1} - (0.99410)\mathcal{E}_{t-12} + (0.94637)\mathcal{E}_{t-13}$$

RECOMENDACIONES Y SUGERENCIAS

- Se recomienda realizar trabajos, pero utilizando con una serie de mayor tamaño para obtener un mejor modelo y debe hacerse cada cierto periodo de tiempo.

- Se recomienda hacer estos tipos de trabajo de investigación cada cierto periodo de tiempo con el fin de obtener resultados actualizados y que nos permita tener una mejor visión de la población.

- Evitar la sobre parametrización y la sobre diferenciación; por ello, conducen a la obtención de modelos erróneos.

- En el proceso de estimación se recomienda usar las herramientas necesarias para comprobar la estacionariedad e invertibilidad del proceso, como son los contrastes de Dickey-Fuller, Box-Pierce, Ljung-Box, entre otros.

BIBLIOGRAFÍA

ARNAU J. *Diseños De Series Temporales:* Técnicas de Análisis Barcelona, España. Edicions de la Universitat de Barcelona, 2001. 434 p.

ARNAU, J. (2001) *Diseños de Series Temporales Técnicas De Análisis*. Edición Editorial Printince May.

GUJARATI, D. (2004) *ECONOMETRÍA*. 4ª ed., México: Mc Graw-Hill Interamericana Editores. 2003. 955p.

GURAJATI, D. (2005) "*Econometría"* Quinta Edición Mc Graw Hill.

GUTIÉRREZ, (2008). *Series De Tiempo*. Primera Edición, Editorial Mc GranH

HANKE, E. (2006). *Pronóstico de Negocios*., Quinta Edición, Editorial Person Prentice Hall México.

HERNANDEZ, R. (2006). *Metodología de la Investigación*, México Segunda Edición Paraninfo

PULIDO, A. (2001) *MODELOS ECONOMÉTRICOS*. 3ª ed. España: Editorial Pirámide.

TAMAYO M. (2005) *METODOLOGÍA FORMAL DE LA INVESTIGACIÓN CIENTÍFICA.* 2ª ED. México: Editorial LIMUSA, 153 p.

URIEL, (1985) *"Análisis de series de tiempo Modelos ARIMA Primera Edición,* Editorial PARANINFO

ANEXOS

Variable: Residuales (Longitud = 126)							
1		33	**2445.58**	65	**173959**	97	**148663**
2		34	**-14715**	66	**26148.5**	98	**-194794**
3		35	**-933.759**	67	**-106578**	99	**-46383.3**
4		36	**-22277.9**	68	**1193.15**	100	**54613.9**
5		37	**16247.3**	69	**-3755.59**	101	**65321.5**
6		38	**-49071.7**	70	**22579.3**	102	**-48718.5**
7		39	**-9952.85**	71	**89386.3**	103	**24827.3**
8		40	**-20427.8**	72	**-11578.9**	104	**-44045**
9		41	**4297.57**	73	**-111263**	105	**-8324.52**
10		42	**-10734.8**	74	**-100153**	106	**-75510.8**
11		43	**-26267.7**	75	**9964.86**	107	**25574.6**
12		44	**-39917.4**	76	**101846**	108	**-23563.4**
13		45	**-6185.42**	77	**123683**	109	**47935.3**
14		46	**-18344.6**	78	**78635.4**	110	**-214775**
15	**-37393.3**	47	**-6079.52**	79	**-143004**	111	**59299.4**
16	**-842.525**	48	**-18966.4**	80	**-1221.26**	112	**-12792**
17	**35486.3**	49	**-93119.3**	81	**42045.7**	113	**32280.1**
18	**-48336.7**	50	**77580.3**	82	**-93444.6**	114	**-32597**
19	**8513.71**	51	**-35998.3**	83	**107435**	115	**34981.7**
20	**-32294.4**	52	**-8091.67**	84	**-97818.6**	116	**-680.012**
21	**-4867.42**	53	**-929714**	85	**-122992**	117	**-51308.3**
22	**-33411.2**	54	**42875.2**	86	**-17829.7**	118	**-33337**
23	**6136.23**	55	**-37959.1**	87	**24507.8**	119	**-6149.29**
24	**-13352.6**	56	**-9938.6**	88	**26381.6**	120	**-11874.4**
25	**15602.4**	57	**107853**	89	**71271.1**	121	**29623.1**
26	**-40410.3**	58	**32026.2**	90	**-18032.1**	122	**-277273**
27	**1261.21**	59	**30764.5**	91	**-63320.3**	123	**111811**
28	**-16441.4**	60	**19741**	92	**-21261.1**	124	**-4501.63**
29	**33110.7**	61	**40700.4**	93	**17962.5**	125	**33356.9**
30	**-46001.1**	62	**-91317.5**	94	**15153.9**	126	**-30638.6**
31	**-16956.8**	63	**5620.24**	95	**25116.8**	127	
32	**-30003.4**	64	**104100**	96	**-163131**	128	

Variable: Transformadas (Longitud = 126)							
1	2.89724	33	2.89725	65	2.89717	97	2.8972
2	2.89724	34	2.89725	66	2.89718	98	2.89718
3	2.89724	35	2.89725	67	2.89717	99	2.89718
4	2.89724	36	2.89725	68	2.89717	100	2.89719
5	2.89724	37	2.89725	69	2.89717	101	2.89719
6	2.89724	38	2.89724	70	2.89717	102	2.89719
7	2.89724	39	2.89725	71	2.89718	103	2.8972
8	2.89724	40	2.89725	72	2.89718	104	2.89719
9	2.89724	41	2.89724	73	2.89717	105	2.89719
10	2.89724	42	2.89725	74	2.89716	106	2.89719
11	2.89724	43	2.89725	75	2.89716	107	2.89719
12	2.89724	44	2.89725	76	2.89717	108	2.89719
13	2.89724	45	2.89725	77	2.89718	109	2.8972
14	2.89724	46	2.89725	78	2.8972	110	2.8971
15	2.89724	47	2.89725	79	2.89718	111	2.89719
16	2.89724	48	2.89725	80	2.89719	112	2.89719
17	2.89724	49	2.89724	81	2.89719	113	2.89719
18	2.89724	50	2.89725	82	2.89718	114	2.89719
19	2.89724	51	2.89725	83	2.89719	115	2.8972
20	2.89724	52	2.89725	84	2.89719	116	2.8972
21	2.89724	53	2.89715	85	2.89717	117	2.8972
22	2.89724	54	2.89716	86	2.89717	118	2.89719
23	2.89724	55	2.89715	87	2.89718	119	2.89719
24	2.89724	56	2.89715	88	2.89718	120	2.8972
25	2.89724	57	2.89716	89	2.89718	121	2.8972
26	2.89724	58	2.89716	90	2.89718	122	2.89717
27	2.89724	59	2.89716	91	2.89718	123	2.89719
28	2.89724	60	2.89716	92	2.89718	124	2.89719
29	2.89725	61	2.89716	93	2.89718	125	2.89719
30	2.89724	62	2.89715	94	2.89718	126	2.89719
31	2.89725	63	2.89715	95	2.8972	127	
32	2.89724	64	2.89716	96	2.89718	128	