

UNIVERSIDAD NACIONAL DE INGENIERIA

FACULTAD DE INGENIERIA MECANICA



**OPTIMIZACIÓN DE UN MODELO ARIMA-ECONOMÉTRICO
PARA PROYECTAR LAS VENTAS DE ENERGÍA ELÉCTRICA
DEL SECTOR ELÉCTRICO EN EL DEPARTAMENTO DE LIMA**

TESIS

**PARA OPTAR EL TITULO PROFESIONAL DE:
INGENIERO MECANICO ELECTRICISTA**

ALEX FRANCO MOLINARI GAVIDIA

PROMOCION 2012-I

LIMA-PERU

2013

ÍNDICE

Prólogo

I. CAPÍTULO I: INTRODUCCIÓN

1.1 Generalidades

1.2 Realidad Problemática, Problema Principal y Problemas Específicos

1.2.1 Realidad Problemática

1.2.2 Problema Principal

1.2.3 Problemas Específicos

1.3 Objetivos

1.3.1 Objetivo General

1.3.2 Objetivos Específicos

1.4 Hipótesis de la investigación

1.4.1 Hipótesis General

1.4.2 Hipótesis Específicas

1.5 Justificación e Importancia

II. CAPÍTULO II: MARCO TEÓRICO

2.1 Conceptos básicos

2.2 ¿Qué es un modelo Econométrico?

2.2.1 Condiciones Estadísticas

2.2.2 Modelo de Corrección de Errores

- 2.2.2.1 Serie Estacionaria
- 2.2.2.2 La Cointegración.
- 2.2.2.3 Autocorrelación
- 2.2.3 Condiciones de la Teoría Económica
- 2.2.4 Análisis de las Regresiones
- 2.2.5 Estimador de mínimos cuadrados Ordinarios
- 2.2.6 Formulación del Modelo Econométrico
- 2.2.7 Proceso de Cálculo
 - 2.2.7.1 Estacionariedad y Orden de Integración
 - 2.2.7.2 Colinealidad
 - 2.2.7.3 Especificación Funcional
 - 2.2.7.4 Estabilidad de los parámetros
 - 2.2.7.5 Causalidad Unidireccional
- 2.3 Modelos Estocásticos de Predicciones
 - 2.3.1 Modelo de Serie Temporal
 - 2.3.2 Procesos estocásticos
 - 2.3.3 Procesos estocásticos estacionarios
 - 2.3.4 Procesos estocásticos no estacionarios
 - 2.3.5 Proceso estocástico “ruido-blanco”
 - 2.3.6 Modelos estocásticos estacionarios lineales
 - 2.3.6.1 Modelo de medias móviles MA(q)
 - 2.3.6.2 Modelo autorregresivo AR(P)
 - 2.3.6.3 Modelo mixto ARMA(p, q)
 - 2.3.7 Modelos ARIMA
 - 2.3.7.1 Modelos lineales no estacionarios homogéneos
 - 2.3.7.2 Modelos estacionales no estacionarios homogéneos
 - 2.3.7.3 Modelos estacionales multiplicativos

- 2.3.8 Etapas para la elaboración de un modelo ARIMA
- 2.3.9 Proceso de cálculo y elementos de programación
- 2.4 Programas de Optimización
 - 2.4.1 ¿Qué es el Programa E-Views?
 - 2.4.2 Conceptos básicos de E-Views
 - 2.4.3 Descripción del entorno de E-Views
 - 2.4.4 Los menús de E-Views
 - 2.4.5 El Objeto Principal: La Serie de Datos

III. CAPÍTULO III: EVALUACIÓN DEL MODELO ECONOMETRICO ACTUAL

- 3.1 Método Econométrico
- 3.2 Presentación y evaluación de los datos utilizados
 - 3.2.1 Variables del Modelo Econométrico
 - 3.2.2 Variables Dependientes
 - 3.2.2.1 Ventas de Electricidad
 - 3.2.3 Variables Independientes
 - 3.2.3.1 Producto Bruto Interno
 - 3.2.3.2 Tarifa Promedio de eléctrica
 - 3.2.3.3 Número de Clientes de Energía Eléctrica
- 3.3 Especificación del Modelo Econométrico mensual
 - 3.3.1 Análisis de Estacionariedad
- 3.4 Estimación de los parámetros mensuales
- 3.5 Contraste o Validación del modelo actual mensual
 - 3.5.1 Prueba de Heteroscedasticidad de WHITE
 - 3.5.2 Colinealidad en variables explicativas
 - 3.5.3 Especificación funcional: Prueba de Ramsey

- 3.5.4 Estabilidad de los parámetros
- 3.5.5 Normalidad del Residuo
- 3.6 Estimación del modelo de corrección de errores mensual
- 3.7 Proyecciones Econométricas mensuales
- 3.8 Resultados de la evaluación del modelo actual mensual
- 3.9 Especificación del Modelo Económico Anual
- 3.10 Estimación de los parámetros anuales
- 3.11 Contraste o Validación del modelo actual anual
 - 3.11.1 Prueba de Heteroscedasticidad de WHITE
 - 3.11.2 Normalidad del Residuo
 - 3.11.3 Colinealidad en variables explicativas
 - 3.11.4 Especificación funcional: Prueba de Ramsey
- 3.12 Estimación del modelo de corrección de errores Anual
- 3.13 Proyecciones Econométricas anuales
- 3.14 Resultados de la evaluación del modelo actual anual

IV. CAPÍTULO IV: PROPUESTAS DE OPTIMIZACIÓN

- 4.1 Método Arima
- 4.2 Procedimientos de cálculo del modelo Arima
 - 4.2.1 Identificación: Estabilidad en Varianza
 - 4.2.2 Identificación: Estabilidad en Media y de Estacionalidad
 - 4.2.3 Identificación: Determinación de Ordenes AR y MA
 - 4.2.4 Estimación y Ajuste de Modelos
 - 4.2.5 Identificación y Estimación de Intervenciones y Atípicos
 - 4.2.6 Validación del Modelo Seleccionado

4.3 Estimación de la Serie Ventas de Energía Eléctrica mensual del Modelo Arima

4.3.1 Identificación del Modelo

4.3.1.1 Prueba de Raíz Unitaria

4.3.2 Estimación y Ajustes de Modelos

4.3.3 Contraste o Validación del Modelo Arima

4.3.3.1 Prueba de Heteroscedasticidad de WHITE

4.3.3.2 Normalidad del Residuo

4.3.3.3 Especificación funcional: Prueba de Ramsey

4.3.4 Proyección del Modelo Arima mensual

4.3.5 Resultados de la estimación del Modelo Arima mensual

4.4 Estimación de la Serie Ventas de Energía Eléctrica mensual del Modelo Econométrico propuesto

4.4.1 Variables Temperatura en Lima

4.4.2 Especificación del Modelo Econométrico mensual

4.4.2.1 Análisis de Estacionariedad

4.4.3 Estimación de los parámetros mensuales

4.4.4 Contraste o Validación del Modelo Econométrico Propuesto

4.4.4.1 Prueba de Heteroscedasticidad de WHITE

4.4.4.2 Normalidad del Residuo

4.4.4.3 Colinealidad en variables explicativas

4.4.4.4 Especificación funcional: Prueba de Ramsey

4.4.4.5 Estabilidad de los parámetros

4.4.5 Estimación del modelo de corrección de errores mensual

4.4.6 Proyección Econométrica Propuesta mensual

4.4.7 Resultados de la estimación del Modelo Econométrico propuesto mensual

4.5 Optimización del Modelo Arima-Econométrico para proyectar las Ventas de Energía Eléctrica Anuales

4.5.1 Estimación del modelo econométrico propuesto

4.5.2 Contraste o Validación del Modelo Arima-Econométrico

4.5.2.1 Normalidad del Residuo

4.5.2.2 Correlograma de residuos

4.5.2.3 Prueba de Heteroscedasticidad de WHITE

4.5.2.4 Especificación funcional: Prueba de Ramsey

4.5.2.5 Estabilidad de los parámetros

4.5.3 Proyección del Modelo Arima-Econométrico

4.5.4 Resultados de la estimación del Modelo Arima-Econométrico anual

4.6 Optimización del Modelo Econométrico Propuesto para proyectar las Ventas de Energía Eléctrica Anuales

4.6.1 Estimación del modelo econométrico propuesto

4.6.2 Contraste o Validación del Modelo Econométrico Anual Propuesto

4.6.2.1 Correlograma de residuos

4.6.2.2 Normalidad del Residuo

4.6.2.3 Prueba de Heteroscedasticidad de WHITE

4.6.3 Estimación del modelo de corrección de errores Anual

4.6.4 Proyección del modelo Econométrico

4.6.5 Resultados de la estimación del Modelo Arima-Econométrico anual

V. CAPÍTULO V: ANÁLISIS DE RESULTADOS Y CONTRASTACIÓN DE LA HIPÓTESIS

5.1 Análisis comparativo de Resultados

5.1.1 Indicadores de calidad de Predicción

5.2 Contrastación de las Hipótesis

5.2.1 Contrastación de las Hipótesis Específica

5.2.2 Contrastación de la Hipótesis General

CONCLUSIONES

RECOMENDACIONES

APÉNDICE A

ÍNDICE DE GRÁFICOS

Gráfico N° 2.1	Procedimiento de Cálculo del Modelo Econométrico
Gráfico N° 2.2	Metodología del Modelo Econometrico
Gráfico N° 2.3	Esquema de Cálculo de un Modelo Econométrico
Gráfico N° 2.4	Residual Diagnostics>Heteroskedasticity Test
Gráfico N° 2.5	Prueba de Heteroscedasticidad de White
Gráfico N° 2.6	Prueba de Reset Ramsey
Gráfico N° 2.7	Ejemplo de serie compuesta por tendencia, Estacionalidad y componente aleatoria.
Gráfico N° 2.8	Serie de datos con ciclos
Gráfico N° 2.9	Serie de datos con componente tendencial
Gráfico N° 2.10	Función de Autocorrelación y Autocorrelación Parcial
Gráfico N° 2.11	Serie de datos con Estacionalidad
Gráfica N° 2.12	Metodología de cálculo de Predicciones
Gráfico N° 2.13	Ventana de Eviews
Gráfico N° 2.14	Serie de datos de una variable
Gráfico N° 2.15	Diferentes vistas (Views) para una misma serie de datos
Gráfica N° 3.1	Evolución de las Ventas de Energia Eléctrica
Gráfica N° 3.2	Evolución del Producto Bruto Interno
Gráfica N° 3.3	Evolución del Precio Promedio de Electricidad
Gráfica N° 3.4	Evolución del número de clientes de Energía Eléctrica
Gráfica N° 3.5	Prueba Dickey-Fuller Aumentado-ventas

- Gráfica N° 3.6** Prueba Dickey-Fuller Aumentado-PBI
- Gráfica N° 3.7** Prueba Dickey Fuller Aumentado-Tarifa
- Gráfica N° 3.8** Prueba Dickey Fuller Aumentado-Clientes
- Gráfica N° 3.9** Estimación de la ecuación MET_1_MENSUAL
- Gráfica N° 3.10** Resultados de la Regresión MET_1_MENSUAL
- Gráfica N° 3.11** Evolución de los errores MET_1_MENSUAL
- Gráfica N° 3.12** Prueba de Heteroscedasticidad MET_1_MENSUAL
- Gráfica N° 3.13** Evaluación de la colinealidad
- Gráfica N° 3.14** Prueba de Ramsey MET_1_MENSUAL
- Gráfica N° 3.15** Evaluación de la estabilidad de parámetros
- Gráfica N° 3.16** Evaluación de la Normalidad MET_1_MENSUAL
- Gráfica N° 3.17** Estimación de la ecuación ECONOMETRICST
- Gráfica N° 3.18** Resultados de la Regresión ECONOMETRICST
- Gráfica N° 3.19** Evolución de los errores ECONOMETRICST
- Gráfica N° 3.20** Prueba de Heteroscedasticidad ECONOMETRICST
- Gráfica N° 3.21** Evaluación de la Normalidad ECONOMETRICST
- Gráfica N° 3.22** Evaluación de la colinealidad
- Gráfica N° 3.23** Prueba de Ramsey ECONOMETRICST
- Gráfica N° 3.24** Forecast Static- Variable mensual Ventas
- Gráfica N° 3.25** Forecast Dinamic- Variable mensual Ventas
- Gráfica N° 3.26** Evolución de la Proyección de Ventas
- Gráfica N° 3.27** Resultados de la Regresión EC3_ECONOMETRIC
- Gráfica N° 3.28** Evolución de los errores EC3_ECONOMETRIC
- Gráfica N° 3.29** Prueba de Heteroscedasticidad EC3_ECONOMETRIC
- Gráfica N° 3.30** Evaluación de la Normalidad EC3_ECONOMETRIC
- Gráfica N° 3.31** Evaluación de la colinealidad
- Gráfica N° 3.32** Prueba de Ramsey EC3_ECONOMETRIC

- Gráfica N° 3.33** Resultados de la Regresión EC3_ECONOMETRIC2
- Gráfica N° 3.34** Evolución de los errores EC3_ECONOMETRIC2
- Gráfica N° 3.35** Prueba de Heteroscedasticidad EC3_ECONOMETRIC2
- Gráfica N° 3.36** Evaluación de la Normalidad EC3_ECONOMETRIC2
- Gráfica N° 3.37** Correlograma- EC3_ECONOMETRIC2
- Gráfica N° 3.38** Evaluación de la colinealidad
- Gráfica N° 3.39** Prueba de Ramsey EC3_ECONOMETRIC2
- Gráfica N° 3.40** Proyección de la Variable Anual Ventas
- Gráfica N° 3.41** Resultados de la Proyección Anual
- Gráfica N° 3.42** Resultados de las Proyección de las Ventas de Energía Eléctrica
- Gráfica N° 4.1** Procedimiento de Cálculo del Modelo Arima
- Gráfica N° 4.2** Cuadro de Identificación de los modelos Autorregresivos y de Medias Móviles
- Gráfica N° 4.3** Prueba Dickey-Fuller Aumentado-ventas
- Gráfica N° 4.4** Prueba Dickey-Fuller Aumentado-DLOGVENTASSA
- Gráfica N° 4.5** Resultados de la Regresión ECUACION_3_ARIMA
- Gráfica N° 4.6** Evolución de los errores ECUACION_3_ARIMA
- Gráfica N° 4.7** Prueba de Heteroscedasticidad ECUACION_3_ARIMA
- Gráfica N° 4.8** Evaluación de la Normalidad ECUACION_3_ARIMA
- Gráfica N° 4.9** Correlograma-ECUACION_2_ARIMA
- Gráfica N° 4.10** Prueba de Ramsey ECUACION_2_ARIMA
- Gráfica N° 4.11** Forecast Estatic ECUACION_2_ARIMA
- Gráfica N° 4.12** Forecast Dinamic ECUACION_2_ARIMA
- Gráfica N° 4.13** Evolución de la variable Temperatura
- Gráfica N° 4.14** Prueba Dickey-Fuller Aumentado-Temperatura
- Gráfica N° 4.15** Resultados de la Regresión EQ01IMPORTANT
- Gráfica N° 4.16** Evolución de los errores EQ01IMPORTANT

- Gráfica N° 4.17** Prueba de Heteroscedasticidad EQ01IMPORTANT
- Gráfica N° 4.18** Evaluación de la Normalidad EQ01IMPORTANT
- Gráfica N° 4.19** Evaluación de la colinealidad
- Gráfica N° 4.20** Prueba de Ramsey EQ01IMPORTANT
- Gráfica N° 4.21** Prueba de Cusum-EQ01IMPORTANT
- Gráfica N° 4.22** Resultados de la Regresión EQ02IMPORTANT
- Gráfica N° 4.23** Evolución de los errores EQ02IMPORTANT
- Gráfica N° 4.24** Correlograma-EQ02IMPORTANT
- Gráfica N° 4.25** Evaluación de la Normalidad EQ02IMPORTANT
- Gráfica N° 4.26** Prueba de Heteroscedasticidad EQ02IMPORTANT
- Gráfica N° 4.27** Prueba de Ramsey EQ02IMPORTANT
- Gráfica N° 4.28** Gráfica de la proyección de la variable ventas de energía eléctrica en el departamento de Lima para el período 2013-2015
- Gráfica N° 4.29** Procedimiento de cálculo del Modelo Arima-Económico
- Gráfica N° 4.30** Resultados de la Regresión EC1_ECONOMETRIC
- Gráfica N° 4.31** Evolución de los errores EC1_ECONOMETRIC
- Gráfica N° 4.32** Evaluación de la Normalidad EC1_ECONOMETRIC
- Gráfica N° 4.33** Correlograma-EC1_ECONOMETRIC
- Gráfica N° 4.34** Prueba de Heteroscedasticidad EC1_ECONOMETRIC
- Gráfica N° 4.35** Prueba de Ramsey EC1_ECONOMETRIC
- Gráfica N° 4.36** Prueba de Cusum-EC1_ECONOMETRIC
- Gráfica N° 4.37** Resultados de la Regresión EC2_ECONOMETRIC
- Gráfica N° 4.38** Evolución de los errores EC2_ECONOMETRIC
- Gráfica N° 4.39** Prueba de Heteroscedasticidad EC2_ECONOMETRIC
- Gráfica N° 4.40** Evaluación de la Normalidad EC2_ECONOMETRIC
- Gráfica N° 4.41** Correlograma-EC2_ECONOMETRIC
- Gráfica N° 4.42** Proyecciones Dinámicas Período 2012-2018

- Gráfica N° 4.43** Proyección de las Ventas de Energía Eléctrica Anuales
- Gráfica N° 4.44** Resultados de la Regresión EC1_ECONOMETRIC2
- Gráfica N° 4.45** Evolución de los errores EC1_ECONOMETRIC2
- Gráfica N° 4.46** Correlograma- EC1_ECONOMETRIC2
- Gráfica N° 4.47** Evaluación de la Normalidad EC1_ECONOMETRIC2
- Gráfica N° 4.48** Prueba de Heteroscedasticidad EC1_ECONOMETRIC2
- Gráfica N° 4.49** Resultados de la Regresión EC2_ECONOMETRIC2
- Gráfica N° 4.50** Evolución de los errores EC2_ECONOMETRIC2
- Gráfica N° 4.51** Correlograma- EC2_ECONOMETRIC2
- Gráfica N° 4.52** Evaluación de la Normalidad EC2_ECONOMETRIC2
- Gráfica N° 4.53** Proyecciones de las Ventas Anuales Período 2016-2018
- Gráfica N° 4.54** Evolución de las Ventas de Energía Eléctrica Período 1994-2018
- Gráfica N° 5.1** Omitted variables
- Gráfica N° 5.2** Prueba de Omisión de la Variable Temperatura
- Gráfica N° 5.3** Redundant variables
- Gráfica N° 5.4** Prueba de Redundancia de la Variable Temperatura

ÍNDICE DE TABLAS

Tabla N° 2.1	Intervalos Estadísticos de Durbin Watson
Tabla N° 2.2	Formas Lineales de la Prueba de Ramsey
Tabla N° 2.3	Funciones Teóricas de Autocorrelación y Autocorrelación Parcial
Tabla N° 2.4	Menús de Eviews
Tabla N° 3.1	Histórico de Ventas de Energía Eléctrica MWh
Tabla N° 3.2	Histórico del Producto Bruto Interno
Tabla N° 3.3	Histórico de la Tarifa Promedio De Electricidad
Tabla N° 3.4	Histórico del Número de Clientes de Energía Eléctrica
Tabla N° 3.5	Proyección de las Ventas de Energía Eléctrica
Tabla N° 4.1	Proyección de Ventas de Energía con el Modelo Arima
Tabla N° 4.2	Histórico de la Temperatura Promedio de Lima
Tabla N° 4.3	Proyección Econométrica Mensual con Temperatura
Tabla N° 4.4	Datos Calculados de la Proyección Econométrica Período 2016-2018
Tabla N° 4.5	Proyecciones Anuales de las Ventas de Energía Eléctrica Modelo Arima-Econométrico
Tabla N° 5.1	Proyección de las Ventas de Energía Eléctrica (MWh) Mensual (2013-2015)
Tabla N° 5.2	Proyección de las Ventas de Energía Eléctrica (MWh) Anual (2016-2018)
Tabla N° 5.3	Evaluación de la calidad predictiva en frecuencia mensual
Tabla N° 5.4	Evaluación de la calidad predictiva en frecuencia anual

PRÓLOGO

En las últimas décadas, numerosos académicos, profesionales e investigadores se han ocupado de estudiar la proyección de las ventas de energía eléctrica y han venido desarrollando todo un cuerpo de pensamiento alrededor del concepto de proyección del sector eléctrico, como aquel “que predice la capacidad de generación presente y la capacidad de generación futura”.

A partir de este concepto, de la constatación del mercado eléctrico para responder con eficacia al reto planteado y de la acumulación de evidencias en torno al problema del cambio climático, se presentan propuestas para abordar el desafío. Poco a poco, estas propuestas han ido convergiendo para generar una respuesta al problema.

En el fondo, se trata de cambiar nuestro modelo de cálculo de las ventas de energía eléctrica para desplazarnos a uno basado en un mejor grado de bondad considerando la intervención del medio ambiente, con implicaciones profundas en la innovación. Por esta razón, El presente documento se encuadra dentro de la optimización de un modelo Arima-Econométrico para proyectar las ventas de energía para un horizonte de mediano plazo.

La presente Tesis, titulada Optimización de un modelo Arima-Econométrico para proyectar las ventas de energía eléctrica del sector eléctrico en el departamento de Lima, consta de cinco (5) capítulos, que a continuación se detallan:

El primer capítulo define la realidad, los problemas, los objetivos y las hipótesis con los que se fundamentan la presente tesis.

En el segundo capítulo se presenta el Marco Teórico de los modelos Econométricos que se vienen utilizando actualmente y los modelos Arima el cual se utilizará para la optimización.

En el tercer capítulo se desarrolla la evaluación del modelo Econométrico Actual el cual se evaluó en frecuencia mensual y anual.

El cuarto capítulo señala las diferentes alternativas de optimización del modelo Arima-Econométrico, de donde se obtiene el modelo Arima-Econométrico que se recomienda aplicar.

En el quinto capítulo se presenta el análisis de los resultados y el contraste de las hipótesis.

Finalmente, se presentan las conclusiones y recomendaciones obtenidas del desarrollo de la tesis.

En el desarrollo de este trabajo recibí la ayuda desinteresada (y el cariño) de muchas personas; en especial quiero agradecer a las siguientes personas:

Guillermo Echeandía González, por creer en mi proyecto desde el principio, darme un espacio para realizarlo libremente y por todo el apoyo, visible e invisible, que me prestó en este período.

Gilberto Becerra Arévalo, por estar dispuesto a ayudarme cuando fuera necesario, los excelentes consejos y correcciones, sugerirme poner los pies en la tierra, forzarme a dar a este documento una estructura coherente y por preocuparse de que todo saliera bien.

Cesar Mamani Cienfuegos, por compartirme su trabajo y sus ideas.

Sheila Suárez Zevallos, por todos los consejos, el soporte y los comentarios a la tesis.

Para mi familia por una genuina muestra de amor, leer y corregir cuidadosamente este documento.

CAPÍTULO I

INTRODUCCIÓN

1.1 GENERALIDADES

La predicción de la demanda de electricidad es un insumo fundamental para la toma de decisiones operativas y estratégicas que realizan los agentes del mercado, cuya falta de precisión puede traer altos costos económicos, principalmente, debido a que por cada sobreestimación de uno por ciento en el nivel de la demanda eléctrica para cada año del período de proyección produce un incremento del orden de cinco por ciento en el nivel de la tarifa regulada. ¹

La liberalización del mercado y las integraciones energéticas regionales han causado una gran incertidumbre sobre la evolución de los precios debido a la gran cantidad de factores que intervienen en el mercado, los cuales también han aumentado la incertidumbre inherente al crecimiento de la demanda.

La gran cantidad de publicaciones realizadas en la última década son una evidencia de los grandes esfuerzos que ha realizado la comunidad académica por desarrollar nuevos y mejores métodos para el pronóstico de la demanda de electricidad. El análisis de dicha información es uno de los objetivos de esta tesis.

¹Osinergmin-Estudios Económicos. "Estimación de la demanda agregada de electricidad". 2004. Lima-Perú.

La demanda eléctrica global es el conjunto de cargas individuales de distintas clases, tales como industrial, residencial, comercial, etc. Esta demanda eléctrica crece cada año por lo cual resulta de suma importancia su administración.

La demanda es uno de los factores determinantes de los precios de la electricidad en los mercados eléctricos liberalizados, junto con las complejidades y el comportamiento del sistema de generación de electricidad y las reglas de mercado impuestas por la regulación.

La evolución de la demanda está estrechamente relacionada con la evolución de los diferentes sectores económicos de la sociedad, los avances tecnológicos encaminados al uso más eficiente y racional de la energía, y la estacionalidad del clima que puede variar los comportamientos típicos de estación a estación.

La predicción de la demanda es un insumo fundamental para los procesos decisivos operativos y estratégicos que realizan los agentes del mercado, pero resulta ser una tarea difícil debido a la cantidad y complejidad de los factores que influyen en su comportamiento.

De acuerdo al artículo 47º de la Ley de Concesiones Eléctricas (LCE)² el Comité de Operación Económica del Sistema Interconectado Nacional (COES), ente encargado de la coordinación del sistema eléctrico peruano, es el responsable de realizar cada seis meses una propuesta sustentada para la fijación de las tarifas en barra. Más específicamente, el COES debe presentar un estudio técnico-económico en los que se incluya la estimación de la demanda eléctrica del Sistema Eléctrico Interconectado Nacional (SEIN) en los 48 meses siguientes a la fijación tarifaria, el programa de operaciones que optimiza económicamente el funcionamiento del SEIN y el cálculo de los costos marginales

² La LCE aprobado por el Decreto Ley N° 25844. Año 1992. Perú

asociados a la operación. Utilizando, además, los factores de pérdida y los costos de transmisión correspondientes, el COES debe proponer los precios (“tarifas en barra de energía y potencia”).

Ante la creciente demanda eléctrica en los próximos años el país requiere incrementar la capacidad de generación eléctrica al Sistema Eléctrico Nacional para garantizar el suministro eléctrico para el vital sector industrial y minero del país.

“Este año 2013 se espera 400 megavatios de nueva demanda que va a ingresar, pero la nueva oferta en el mismo periodo será de 1400 megavatios, es decir estamos creciendo bastante más que la demanda en el mismo tiempo”, dijo el viceministro de Energía, Edwin Quintanilla.³

Aunque debemos recordar que los proyectos de generación y transmisión eléctrica son de larga maduración, por la magnitud de la inversión y el período de vida útil de sus instalaciones, por lo que las previsiones económicas y de financiamiento de los agentes económicos que participan en el mercado se deben proyectar en ese horizonte, dentro de un plan a largo plazo.

La falta de inversión y planificación a largo plazo en el sistema eléctrico del Perú amenazan con frustrar los proyectos mineros, vitales para asegurar el crecimiento económico del país. Analistas y empresarios del sector, citados por Reuters, creen que el país podría sufrir en el 2017 la misma suerte que le tocó a Sudáfrica en el 2008 o a Chile tres años más tarde, cuando distintas crisis energéticas afectaron a las mineras y los precios de los metales se dispararon.⁴

En el análisis de los requerimientos de demanda, de oferta de generación, de transmisión del SEIN, y de gasoductos, se formula una visión de planificación del SEIN con perspectiva de largo plazo, esbozando la orientación de la expansión de la generación y transmisión

³ “MEM: La oferta de energía eléctrica crece “bastante más” rápido que la demanda”, Diario Gestión, 02-01-2013. Perú

⁴ “Déficit de electricidad amenaza desarrollo de proyectos mineros”, Diario El Comercio, 22-02-2012. Lima, Perú.

del SEIN, y de gasoductos para uso de generación eléctrica, en un horizonte de por lo menos 20 años.⁵

Si las condiciones de energía son normales, no debería ser motivo de preocupación. Además, hay que tener en cuenta que a fines del 2013 deberían entrar en operación las plantas de reserva fría de 400 MW en el norte y 500 MW en el sur.⁶

Existen varios motivos por los cuales cuantificar la importancia de los factores que determinan la demanda de electricidad y predecir la misma es de gran importancia. La primera, y quizás la más importante, está relacionada con el capital necesario de inversión y los plazos de tiempo requeridos para la planificación, construcción y puesta en marcha de centrales eléctricas. Una mala predicción de la demanda de electricidad puede implicar un déficit en la generación, problemas de suministro e importantes pérdidas económicas a éstas asociadas.

Es por todas estas razones la necesidad de contar con optimizar las herramientas que permitan realizar mejores proyecciones de la demanda de electricidad en el Perú, por cuanto el modelo utilizado a la fecha para el proceso de fijación tarifaria posee un conjunto de deficiencias que llevan a proyecciones inexactas, las que tienen un fuerte impacto sobre las tarifas.

En esta perspectiva en este documento que tiene como principal objetivo optimizar un modelo Arima - Econométrico se tomará el departamento de Lima, debido a que representa el principal consumo eléctrico del país, para realizar las proyecciones de las ventas de energía eléctrica, las cuales permitirán un mejor capacidad predictiva.

⁵MINEM-DGE-Dirección de Estudios y Promoción Eléctrica "Plan Referencial de Electricidad 2008 - 2017 ". Año 2012. Perú.

⁶ "Si hay escasez de lluvias, habrá racionamiento de energía ", Diario El Comercio, 29-11-2012.

1.2 REALIDAD PROBLEMÁTICA, PROBLEMA PRINCIPAL Y PROBLEMAS ESPECÍFICOS

1.2.1 REALIDAD PROBLEMÁTICA

Un primer problema con la metodología del modelo econométrico que viene siendo utilizada por las concesionarias eléctricas, radica en la estimación por medio del método de Mínimos Cuadrados Ordinarios (MCO) para las ventas de energía eléctrica, dado que presenta ciertas deficiencias en su metodología al considerar series estacionarias, característica no satisfecha por numerosas series económicas como el PBI, el consumo eléctrico, la población, entre otras. El resultado de la aplicación de la metodología en condiciones de no estacionariedad conducen al problema de la relación *espuria*⁷, por el cual las variables independientes entre sí están estadísticamente muy relacionadas. Este problema no tiende a desaparecer, aún en el caso de muestras grandes. Debido a estas limitaciones el uso de MCO ha sido gradualmente dejado de lado con el desarrollo de metodologías de predicción superiores basadas en series de tiempo y por modelos estructurales con especificaciones de error menos restrictivas. Esta última etapa ha conducido al uso de técnicas de cointegración, actualmente implementadas mediante modelos de corrección de error.

Un segundo problema con la metodología del modelo econométrico actual radica en la no consideración de la variable explicativa temperatura, variable que relaciona los niveles de frío y calor y que inciden en las ventas de energía eléctrica mediante la utilización de aparatos de calefacción y frío.

⁷ Una relación espuria es una relación en la cual dos acontecimientos no tienen conexión lógica, aunque da la impresión de la existencia de un vínculo apreciable entre dos grupos que es inválido cuando se examina objetivamente.

1.2.2 PROBLEMA PRINCIPAL

En virtud de lo anterior, el problema principal se fundamenta en la siguiente interrogante:

¿De qué manera la optimización de un modelo Arima – Econométrico incidirá en la proyección de las ventas de energía eléctrica del sector Eléctrico en el departamento de Lima?

1.2.3 PROBLEMAS ESPECÍFICOS

¿En qué medida el actual método de Corrección de error contribuye a la proyección de las ventas de energía eléctrica actual del Sistema Eléctrico?

¿Cómo contribuye la propuesta de optimización del modelo Arima-Econométrico en la proyección de las ventas de energía eléctrica

¿Cómo influye en el modelo con la introducción de la temperatura en el actual método de Corrección de error.

¿De qué manera el programa Eviews contribuye como herramienta de cálculo para la proyección de las ventas de energía eléctrica?

1.3 OBJETIVOS

1.3.1 OBJETIVO GENERAL

- Lograr la Optimización de un modelo Arima - Econométrico para proyectar las ventas de energía eléctrica en el departamento de Lima.

1.3.2 OBJETIVOS ESPECÍFICOS

- Evaluar el actual método de Corrección de error para la proyección de las ventas de energía eléctrica para el departamento de Lima.
 - Proponer la alternativa de optimización del modelo Arima-Econométrico para la proyección de las ventas de energía eléctrica.
 - Analizar la contribución de la variable temperatura en el actual método de Corrección de error.
 - Manejar el programa Eviews como herramienta de cálculo para la proyección de las ventas de energía eléctrica.
-

1.4 HIPÓTESIS DE LA INVESTIGACIÓN

1.4.1 HIPÓTESIS GENERAL

La optimización de un modelo Arima – Econométrico permitirá una mejor proyección de las ventas de energía eléctrica.

1.4.2 HIPÓTESIS ESPECÍFICAS

H.1 La evaluación del actual método de corrección de error presenta ciertas carencias en comparación con el modelo Arima – Econométrico.

H.2 En la medida que se optimice el modelo Arima – Econométrico contribuirá con un mejor grado de proyección a las ventas de energía eléctrica actual del departamento de Lima mediante una estimación más precisa.

H.3 La intervención de la temperatura en el actual método de Corrección de error influirá positivamente en la proyección de las ventas de energía eléctrica.

H.4 El manejo del programa Eviews como herramienta de cálculo facilitará los cálculos para la proyección de las ventas de energía eléctrica.

1.5 JUSTIFICACIÓN E IMPORTANCIA

Dentro del campo de la investigación y desarrollo, el pronóstico es una técnica que ayuda a predecir lo que ocurrirá en el futuro. El futuro, por lo general no es determinístico; ninguna técnica de pronóstico será aplicable a todos los procesos de decisión en una organización productiva de bienes y servicios. En este sentido, es importante adoptar las técnicas predictivas en mutua correspondencia con la pericia en la materia a predecir. Desde una perspectiva científica y bajo un sentido cuantitativo, se entienden predicción, previsión y proyección, como sinónimos para anticipar el futuro de un determinado suceso.

La predicción de las ventas de electricidad se realiza para horizontes de corto, mediano y largo plazo. El corto plazo corresponde a la predicción en tiempo real para la hora siguiente y con un horizonte de hasta una semana hacia delante; el pronóstico se basa en los datos históricos de demanda diaria y factores climáticos.

El mediano plazo corresponde al pronóstico mensual con un horizonte de hasta un año a partir de las ventas históricas de electricidad, y la predicción de algunas variables explicativas como el crecimiento de la economía o el clima. Finalmente, el largo plazo abarca un horizonte de uno hasta diez años; la predicción de las ventas en el largo plazo es usada para la planeación y expansión de la generación y de la transmisión; los datos usados para este pronóstico son la demanda anual, el precio de la electricidad, el precio de productos sustitutos, la evolución demográfica e indicadores económicos, entre otros.

La presente tesis se justifica porque el pronóstico de las ventas en el mediano plazo permite definir la cantidad de energía a generar para el mes siguiente, permite realizar el monitoreo del comportamiento de la red con el fin de identificar puntos críticos. También, permite el análisis del comportamiento del mercado. En el largo plazo, permite detectar los períodos para los cuales existen excesos y faltantes de capacidad de generación con la

finalidad de planificar las inversiones en la expansión del sistema de generación y adoptar medidas de la conservación de la energía. Y es importante porque plantea un método de proyectar las ventas de energía eléctrica del departamento de Lima para el mediano y largo plazo.

CAPÍTULO II

MARCO TEÓRICO

La determinación de las predicciones del comportamiento futuro de variables energéticas, desempeña un papel importante en el desarrollo de una adecuada planificación energética. Cada una de las series históricas (series temporales) originadas por las diversas actividades energéticas tiene un comportamiento particular, dado que poseen un determinado tipo de tendencia y componente estacional. Para alcanzar buenos resultados, las técnicas de predicción a adoptar deben estar en estrecha relación con las características propias de cada variable temporal.

Así, en este capítulo se menciona la teoría estadística y económica para la evaluación de predicciones de variables energéticas mediante el análisis cuantitativo univariante de series temporales, utilizando el enfoque determinístico y el enfoque estocástico. Bajo el enfoque determinístico se hace la formulación de los métodos de ajuste de tendencias, medias móviles y alisados exponenciales múltiples, mientras que bajo el enfoque estocástico se tiene la modelización ARIMA (Autoregressive Integrated Moving Average).

2.1 CONCEPTOS BÁSICOS

Cualquier ejercicio de análisis económico simple requiere de un manejo de información cuantitativa obtenida de la recolección de datos. En ocasiones, el objetivo es la utilización de complejos procedimientos de análisis estadístico o econométrico, procedimientos que se encuentran en las correspondientes asignaturas específicas. El objeto de esta tesis no es ilustrar tales procedimientos sino revisar de forma muy básica algunos de los conceptos fundamentales en torno a las principales operaciones que se realizan en los siguientes capítulos.

Econometría. Es la rama de la economía que hace un uso extensivo de modelos matemáticos y estadísticos así como de la programación lineal y la teoría de juegos para analizar, interpretar y hacer predicciones sobre sistemas económicos, prediciendo variables como el precio, las reacciones del mercado, el coste de producción, la tendencia de los negocios y las consecuencias de la política económica.

Serie de Datos. Es cualquier conjunto de datos relativos a una misma variable.

Tipos de series de datos. De entre las muchas clasificaciones referentes a las series de datos interesa especialmente la que distingue:

➤ **Series Temporales.** Cuyos datos se refieren a los distintos períodos de un rango de Tiempo.

- **Series Transversales.** Cuyos datos hacen referencia a distintos individuos u objetos para un mismo momento del tiempo.

- **Datos de Panel.** Cuyos datos cubren, a un tiempo, un espacio temporal y transversal. Generalmente, según predomine la dimensión temporal o transversal en el análisis suelen distinguirse los paneles MICRO (predominio de dimensión transversal) de los paneles MACRO (predominio de la dimensión temporal).

2.2 ¿QUÉ ES UN MODELO ECONOMETRICO?

Un modelo econométrico, en términos generales, viene a ser una relación funcional entre una variable dependiente (por ejemplo las ventas de energía eléctrica) y otra u otras variables independientes o explicativas de la primera (por ejemplo el producto bruto interno PBI, la población, la tarifa eléctrica, etc.), bajo el cumplimiento de condicionantes tanto estadísticos como de la teoría económica.

La exigencia cada vez mayor de lograr acertar con mayor eficiencia el futuro de cualquier variable temporal, sea económico, energético o social, viene a ser la garantía del éxito en cualquier tipo de planificación estratégica. En el ámbito energético, los modelos econométricos cobran especial importancia, dentro de un plan de desarrollo de corto, mediano o largo plazo.

Sus aplicaciones son diversas, entre ellas se tienen:

- Plan referencial de electricidad de sistemas eléctricos integrados, nacionales y regionales.
- Plan referencial de electricidad de sistemas eléctricos aislados.
- Plan referencial de energía, por fuentes.
- Plan referencial de energía, por usos.
- Balance de energía final.
- Balance de energía Útil.
- Fijación Tarifaria de la energía eléctrica.

2.2.1 CONDICIONANTES ESTADÍSTICAS DE LOS MODELOS ECONOMÉTRICOS

Bajo el plano estadístico, el modelo de regresión lineal por mínimos cuadrados ordinarios que describe y proyecta a la variable dependiente, deberá cumplir con los siguientes requisitos:

- Las variables participantes deben ser o transformarse en estacionarias.
- El término de error del modelo lineal, debe comportarse como un ruido blanco; es decir, que la esperanza matemática del término de error sea cero, la varianza del error sea constante y se demuestre ausencia de autocorrelación entre los errores (covarianza nula).
- No existencia de colinealidad entre regresores o variables independientes, consecuentemente, ausencia de multicolinealidad en la matriz de observaciones correspondientes a las variables independientes del modelo.
- Los parámetros o coeficientes de cada variable explicativa deben ser constantes.

Entre las pruebas a realizar para el cumplimiento de estas condicionantes se tienen:

- Bondad o buen grado de ajuste del modelo, medido por el coeficiente de determinación R^2 .
- Estacionariedad, medido por el estadístico Dickey–Fuller Aumentado, ADF.
- Prueba de significancia de la variable en el modelo, medido por el estadístico t-Student.
- Contraste de la presencia de autocorrelación serial de primer orden, medido por el estadístico Durbin Watson, DW.

2.2.2 MODELO DE CORRECCIÓN DE ERRORES

Considerando que las series estadísticas, tanto económicas como las referidas al mercado eléctrico, son series no estacionarias se procede a desarrollar y estimar modelos de corrección de errores (MCE), lo que implica estimar, en primer lugar, un modelo de corto plazo, mediante el MCE, la cual incorpora los errores del primer modelo, ajustando la predicción de corto plazo.

Engle y Granger (1987) establecen una equivalencia entre los conceptos de cointegración y modelos MCE, en cuanto cointegración implica un modelo de MCE y a la vez un modelo MCE implica cointegración.

El concepto de cointegración es que dos variables que participan en una relación económica deben mantener dicha relación en el largo plazo, aun cuando se trate de variables no estacionarias, es decir, debe existir un equilibrio. Un estado de equilibrio entre dos o más variables se define como

uno en el cual no existe una tendencia inherente al cambio. Existen por lo menos tres razones para considerar al concepto de cointegración como central para la modelación econométrica con variables integradas:

- a) El concepto de cointegración formaliza la idea de que una combinación lineal de dos variables integradas de orden 1 pueden tener una combinación lineal estacionaria.
- b) Si la cointegración se relaciona con el equilibrio, se puede distinguir entre el concepto de “relaciones con sentido” y el de “relaciones espurias”.
- c) Las variables cointegradas poseen una representación de corrección de errores: reconciliación entre modelos de series de tiempo y modelos estructurales.

En el caso de la demanda agregada de electricidad, el modelo de largo plazo a evaluar está dado por la ecuación de la demanda agregada de electricidad.

$$\log(v_t) = \beta_0 + \beta_1 * \log(y_t) + \beta_2 * \log(p_t) + \beta_3 * \log(a_t) + \varepsilon_t \varepsilon_t \sim N(0, \sigma^2)$$

Donde:

v_t : Ventas de energía eléctrica.

y_t : Producto bruto interno (PBI).

p_t : Tarifa de electricidad.

a_t : Número de clientes.

Siguiendo la metodología de estimación en dos etapas propuesta por Engle y Granger, se debe verificar que el residuo de la expresión anterior sea estacionario para verificar la presencia de cointegración. Si este es el caso, el

vector formado por $(\beta_0, \beta_1, \beta_2, \beta_3)$ será el vector de cointegración. Una vez determinada la estacionariedad de los residuos se procede a estimar un modelo de corrección de errores, determinado por un modelo de rezagos distribuidos de la forma:

$$\Delta \log(v_t) = -\lambda * [\log(v_{t-1}) - \beta_1 * \log(y_{t-1}) - \beta_2 * \log(p_{t-1}) - \beta_3 * \log(a_{t-1})] - \sum_{j=1}^{p-1} b_j \Delta \log(v_{t-j}) - \sum_{j=0}^{q-1} \gamma_{1j} \Delta \log(y_{t-j}) - \sum_{j=0}^{r-1} \gamma_{2j} \Delta \log(p_{t-j}) - \sum_{j=0}^{s-1} \gamma_{3j} \Delta \log(a_{t-j}) + \mu_t$$

Donde:

v_t : Ventas de energía eléctrica

y_t : PBI

p_t : Tarifa de electricidad

a_t : Número de clientes

Δ : Operador de primeras diferencias.

La importancia de los MCE y del concepto de cointegración es que permite conciliar dos puntos de vista divergentes sobre el análisis de los datos de series de tiempo en economía: por una parte el enfoque puramente estadístico de las series de tiempo, los llamados modelos de transferencias, en los que solo aparecen variables en diferencias, especificación que, si bien supera el problema de las regresiones espurias, no tiene en cuenta la información de largo plazo contenida en los niveles de las variables; de otra, el enfoque econométrico con modelos basados en la teoría económica con estimaciones de ecuaciones estáticas, pero que presentan los problemas asociados a las regresiones espurias.

Las especificaciones tipo MCE al combinar variables en diferencias y combinaciones lineales de niveles de las series que son estacionarias, permiten superar estos dos problemas: la información de las teorías económicas se incorpora en la desviación del equilibrio (variables en niveles) a la vez que se evitan las regresiones espurias y los problemas inferenciales del uso de series no estacionarias.

Frente a las especificaciones dinámicas tradicionales, como los modelos de rezagos distribuidos y modelos de ajuste parcial, los modelos MCE tiene varias ventajas: en primer lugar, la multicolinealidad, que aqueja las formulaciones de rezagos distribuidos, tiende a ser menor por cuanto la correlación lineal entre las variables en diferencias y las en niveles es menor, permitiendo una estimación más precisa de los parámetros; en segundo lugar, el modelo MCE puede captar más fácilmente la información dinámica contenida en los datos de series de tiempo económicas, al incluir diferencias de todas las variables.

El Modelo Econométrico descrito, se puede apreciar a continuación:

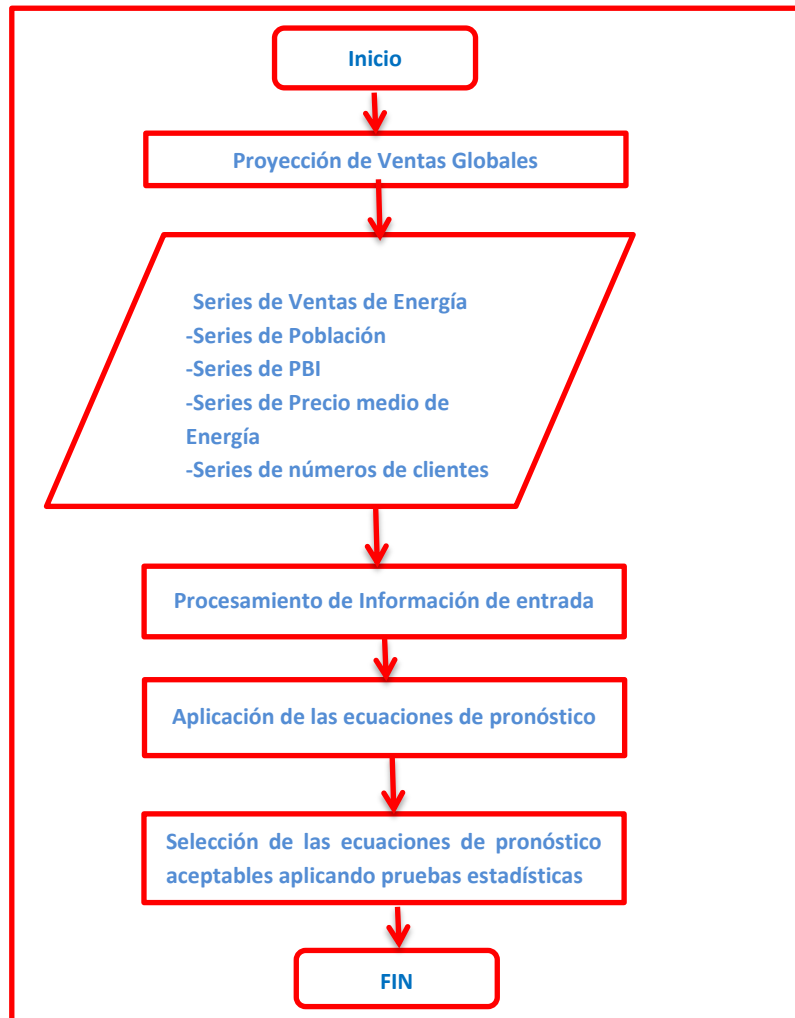


Gráfico N° 2.1 Procedimiento de Cálculo del Modelo Econométrico

2.2.2.1 SERIE ESTACIONARIA

Una variable temporal, alcanza la condición de estacionaria cuando su comportamiento no depende del tiempo; es decir; no posee ni tendencia ni estacionalidad. Ello se mide, en el sentido amplio (débil), cuando su esperanza matemática y varianza no dependen del tiempo, y la covarianza entre dos periodos de tiempo distintos solamente depende del lapso de tiempo transcurrido entre estos dos periodos.

En el campo aplicativo, como es el caso, prácticamente no existe variable o series históricas que sean estacionarias de origen, dado que siempre se caracterizan por tener tendencia y/o estacionalidad. Consecuentemente, para darle un tratamiento modelístico a la serie original necesariamente se tendrá que aplicar transformaciones apropiadas hasta alcanzar el nivel de estacionariedad aproximada.

Para eliminar la tendencia de una serie original, se realizan diferencias sucesivas (diferencia entre el valor de una variable de un periodo a otro inmediato anterior). El número de veces que se efectúa estas diferencias sucesivas se denomina orden de diferenciación o grado de integración.

2.2.2.2 LA COINTEGRACIÓN

Una regresión clásica de variables temporales supone que cada variable participante es estacionaria, o que bajo las transformaciones practicadas alcanzan un mismo orden de integración. Sin embargo en la práctica, muchas veces no se logra satisfacer este condicionante y por tanto se estaría frente a una regresión espuria; es decir, una relación donde la no estacionariedad de

las series o variables involucradas, sesga los resultados hacia la aceptación de tal relación cuando en realidad ésta no existe.

En una regresión de dos series no estacionarias, es posible que una de ellas explique totalmente el comportamiento no estacionario de la otra, si es que el residuo de la regresión (parte no explicada de la respuesta), tiene un comportamiento estacionario. En estas circunstancias se dice que tales variables están cointegradas.

Uno de los arreglos de regresiones que involucra a variables cointegradas es el modelo econométrico de Corrección de Errores.

Existen por lo menos tres razones para considerar al concepto de cointegración como central para la modelación econométrica con variables integradas:

- a) El concepto de cointegración formaliza la idea de que una combinación lineal de dos variables integradas posee un menor orden de integración. Más específicamente, variables integradas de orden 1 pueden tener una combinación lineal estacionaria.
- b) Si cointegración se relaciona con equilibrio, se puede distinguir entre el concepto de “relaciones con sentido” y el de “relaciones espurias”.
- c) Las variables cointegradas poseen una representación de corrección de errores: reconciliación entre modelos de series de tiempo y modelos estructurales.

2.2.2.3 AUTOCORRELACIÓN

El fenómeno de la autocorrelación residual consistía en la existencia de un determinado nivel de correlación entre las perturbaciones (errores) de los sucesivos períodos.

La ausencia de autocorrelación es una de la hipótesis que más frecuentemente se incumple en las especificaciones iniciales de un modelo ya que muchos de los incumplimientos del resto de hipótesis (especificación errónea, cambio estructural,...etc.) se pueden manifestar como correlaciones entre los errores de períodos adyacentes.

La forma más habitual de contrastar la existencia de autocorrelación, además de la observación directa del gráfico de residuos, es mediante el conocido estadístico de Durbin-Watson para la autocorrelación de primer orden, y que como hemos visto a lo largo de los apartados anteriores, se presenta de forma automática en el grupo de estadísticos conjuntos del objeto ecuación.

Así, por ejemplo, la función de producción presenta un valor del estadístico de Durbin-Watson, de 0.23, claramente alejado del valor de referencia 2, este indicaría la existencia de una autocorrelación positiva en los residuos y muy próxima a la unidad.

Dicho valor de referencia del estadístico de DW que se corresponde, como decíamos con un coeficiente de autocorrelación residual, con lo que los

intervalos del estadístico vendrían definidos como aparecen en la siguiente tabla:

Autocorrelación negativa	$4 > DW > 2,875$ (4-1,125)
Zona de duda de autocorrelación negativa	$(4-1,125) 2,875 > DW > 2,462$ (4-1,538)
Ausencia de autocorrelación	$(4-1,538) 2,462 > DW > 1,538$
Zona de duda de autocorrelación positiva	$1,538 > DW > 1,125$
Autocorrelación positiva	$1,125 > DW > 0$

Tabla N° 2.1 Intervalos Estadísticos de Durbin Watson

2.2.3 CONDICIONANTES DE LA TEORÍA ECONÓMICA

Estas condicionantes muestran la interrelación de las variables participantes obedeciendo la teoría económica. Una relación económica entre las ventas eléctricas, el PBI y la tarifa eléctrica, sería la siguiente:

- Las ventas de energía eléctrica, ventas, se comporta como el consumo de un bien necesario.
- El producto bruto interno, PBI, se comporta como el ingreso económico para la adquisición del bien necesario.
- La tarifa eléctrica, TARIFA, se comporta como el precio para la adquisición del bien necesario.

Bajo este criterio, una forma de modelo econométrico podría estar conformada por la siguiente relación:

$$Ventas = C * PBI^\alpha * TARIFA^\beta$$

Donde:

- α : Elasticidad ingreso del bien ventas de energía eléctrica, que puede adoptar valores positivos mayores a cero y no menores a uno.
- β : Elasticidad del precio del bien Ventas, adoptará valores negativos entre -1 y 0.
- C: Constante.

La forma linealizada de la anterior expresión, se determina aplicando logaritmos naturales:

$$\ln Ventas = C_0 + \alpha * \ln PBI + \beta * \ln TARIFA$$

Bajo esta forma los parámetros α y β responderán al concepto de elasticidad ingreso y elasticidad precio constantes. Las elasticidades constantes permiten determinar el crecimiento porcentual que experimentaría las ventas de energía eléctrica frente a cada punto de crecimiento del PBI o TARIFA.

Por tanto, bajo el criterio de la teoría económica, es recomendable estructurar un modelo en el que se practique una transformación logarítmica a las variables Ventas, PBI y TARIFA.

El grado de complicación para alcanzar buenos resultados en la aplicación de esos modelos, dependerá de las siguientes características de cada una de las variables participantes o series históricas:

- Número de observaciones.
- Tendencia evolutiva.
- Estacionalidad y/o ciclaje.
- Irregularidad o aleatoriedad.

2.2.4 ANÁLISIS DE REGRESIONES

En un modelo econométrico, el análisis de regresión determina la relación existente entre la variable dependiente y las otras independientes, sobre la base de la estimación de la media poblacional de la primera condicionada a los valores ya conocidos y fijos de las segundas.

Para fines de predicción, lo más habitual es que se utilicen datos de las variables referidas a un período temporal, relacionadas mediante el siguiente modelo matemático denominado regresión lineal de la variable dependiente y con k variables explicativas x :

$$y_t = \alpha_0 + \alpha_1 x_{1t} + \alpha_2 x_{2t} + \dots + \alpha_k x_{kt} + u_t$$

Siendo:

$\alpha_1 x_{1t} + \alpha_2 x_{2t} + \dots + \alpha_k x_{kt}$: Combinación lineal de las variables

independientes

- α_0 : Constante o Intercepto.
- u_i : Término de error o perturbación, parte aleatoria.

Este ordenamiento matemático se puede descomponer en una parte determinística, conformada por la combinación lineal de las variables independientes incluyendo el intercepto, y una parte aleatoria dada por el término de error. Este término de error origina que el modelo sea estocástico, cuya inclusión representa la existencia de un componente aleatorio en las respuestas de los agentes económicos y a la presencia de innumerables influencias de menor importancia no modeladas de forma explícita.

2.2.5 ESTIMADOR DE MÍNIMOS CUADRADOS ORDINARIOS

Los parámetros o coeficientes α deben ser estimados por una función estimador, el mismo que se vale de los datos históricos disponibles de las variables participantes. Así, partir de los datos históricos de cada una de las variables implicadas se determina el estimador lineal de los parámetros α del modelo, tal que minimiza la suma de los errores al cuadrado (de allí en nombre de estimador de Mínimos Cuadrados Ordinarios):

$$\text{Min} \sum_{i=1}^n e_i^2 = \text{Min} \sum_{i=1}^n (y_i - \alpha_0 - \alpha_1 x_{1i} - \dots - \alpha_k x_{ki})^2$$

El objetivo del análisis de regresión no se basa únicamente en la estimación matemática de los coeficientes α , sino también en la posibilidad de hacer inferencia estadística acerca de la significancia de dichos estimados. Un

coeficiente resulta significativo cuando la variable que lo acompaña, ofrece un aporte marginal estadísticamente importante a la explicación del comportamiento de la variable explicada.

Dado que los estimadores depende de la variable aleatoria y , estos son también una variable aleatoria, por lo que es posible conocer su distribución y hacer inferencia acerca de cuan cerca o lejos se encuentran dichos valores estimados de los verdaderos valores poblacionales. Para realizar este análisis ha de tenerse en cuenta el cumplimiento de algunos de los supuestos siguientes, quienes determinarán la posibilidad de interpretar adecuadamente los estimados obtenidos y que garantizan que el estimador de Mínimos Cuadrados Ordinarios sea el más apropiado para el cálculo predictivo.

El modelo es de carácter estocástico:

- El término de error o perturbación obedece a un ruido blanco. Un ruido blanco es un proceso estocástico que posee esperanza matemática nula, varianza constante y ausencia de autocorrelación entre errores.
- El modelo es lineal en los parámetros.
- Los parámetros son constantes.
- Las variables explicativas son linealmente independientes.
- Las variables independientes son fijas o determinísticas.

2.2.6 FORMULACIÓN DEL MODELO ECONÓMTRICO

La formulación del modelo que ha de pronosticar el comportamiento de una variable dependiente, o variable en estudio, a partir de otras variables independientes, o explicativas, obedeciendo a criterios estadísticos y econométricos, se puede resumir bajo el siguiente diagrama de flujo:

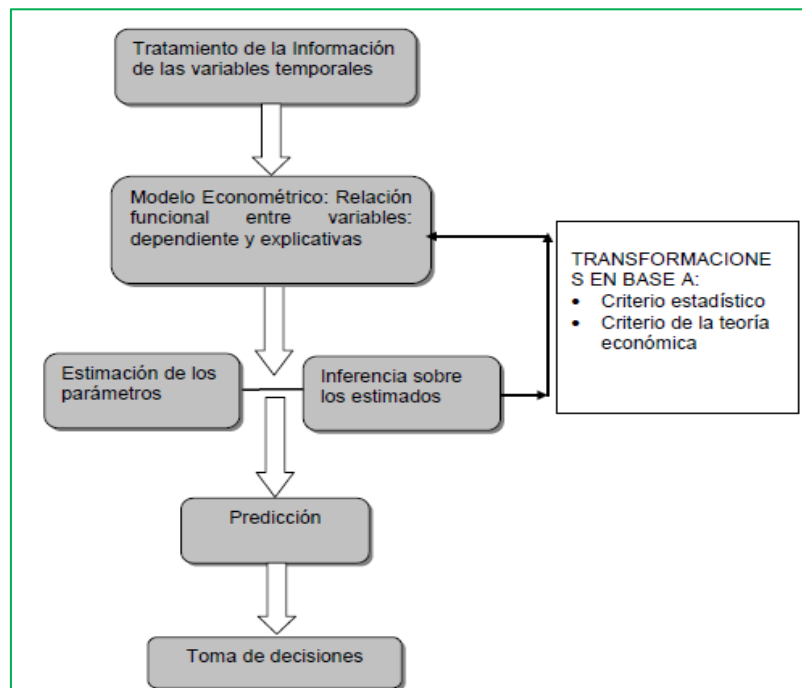


Gráfico N° 2.2 Metodología del Modelo Económico

2.2.7 PROCESO DE CÁLCULO

El procedimiento de cálculo mediante un modelo econométrico, se resume según el siguiente esquema:

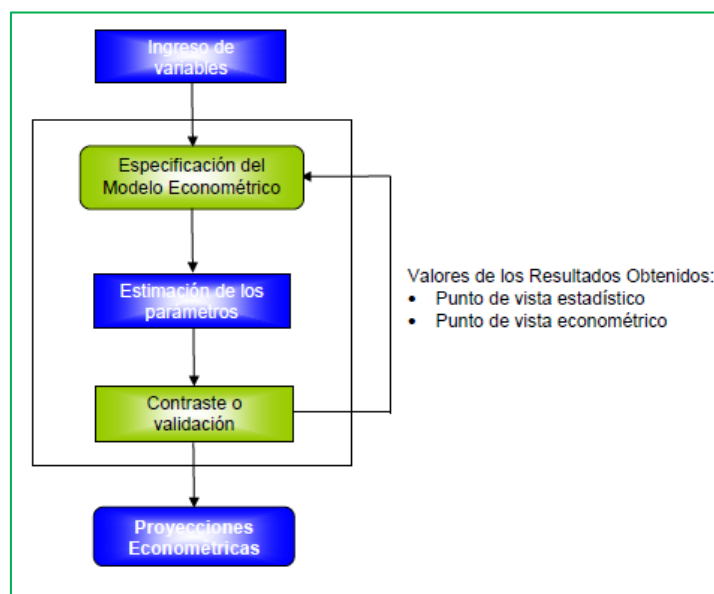


Gráfico N° 2.3 Esquema de Cálculo de un Modelo Económico

El cálculo de las proyecciones econométricas se realiza utilizando el Programa E-Views, tomando como data de entrada la información histórica de la variable dependiente en estudio.

La secuencia de cálculo de un Modelo Económico utilizando el Programa E-Views, para un caso como el de las Ventas de electricidad del departamento de Lima, es la siguiente:

2.2.7.1 ESTACIONARIEDAD Y ORDEN DE INTEGRACIÓN

Prueba de raíz unitaria de Dickey-Fuller Aumentado (ADF)

La presencia de raíz unitaria es indicativo de que la variable en prueba no es estacionaria, lo cual se demuestra cuando los valores absolutos de los estadísticos ADF son menores que el valor crítico absoluto de Mackinnon al

5% de significancia. En el caso de que se demuestre ausencia de raíz unitaria, será indicativo que la serie en prueba es estacionaria.

Las series económicas presentan un componente irregular por lo que se analiza la raíz unitaria, es un indicador de series no estacionarias. En este documento presentaremos la prueba de Dickey Fuller Aumentado (ADF).

Considerando el siguiente modelo:

$$Y_t = Y_{t-1} + \varepsilon_t$$

Donde ε representa un término de error estocástico que representa los supuestos clásicos, esto quiere decir que tiene una media cero, varianza constante y no se encuentra correlacionada. (Ruido Blanco).

Como el coeficiente de Y_{t-1} es 1, nace la raíz unitaria que presenta un escenario de no estacionalidad. Se denomina a una serie que presenta una raíz unitaria como un camino o paseo aleatorio "Random Walks".

Si establecemos un parámetro para el coeficiente de Y_{t-1} la regresión estaría representada como:

$$Y_t = \rho * Y_{t-1} + \varepsilon_t$$

Donde $\rho = 1$, entonces la variable estocástica Y_t presentará una raíz unitaria, por lo que será necesario diferenciarla una vez. Para esto restaremos Y_{t-1} ha ambos miembros de la ecuación anterior:

$$Y_t - Y_{t-1} = \rho * Y_{t-1} - Y_{t-1} + \varepsilon_t \dots (\alpha)$$

Si factorizamos Y_{t-1} en el lado derecho de la ecuación y definimos $\Delta Y_t = Y_t - Y_{t-1}$, como el operado de primera diferencia:

$$\Delta Y_t = (\rho - 1) * Y_{t-1} + \varepsilon_t$$

$$\Delta Y_t = \gamma * Y_{t-1} + \varepsilon_t$$

Ahora establecemos la hipótesis nula que sería $\gamma = 0$, donde la serie estocástica γ_t presenta una raíz unitaria.

Después se estima la ecuación (α), se divide el ρ entre el error estándar para calcular el estadístico τ (tau) de Dickey –Fuller, luego se consulta en la tabla de Dickey-Fuller para ver si la probabilidad de rechazar la hipótesis nula $\rho = 1$ (la ausencia de raíz unitaria).

Prueba de Dickey – Fuller Gls (Ers)

Plantea que los shocks corrientes tienen efectos de largo plazo en las series, debemos plantear la hipótesis nula, que sería el coeficiente de Y_{t-1} , que sigue un estadístico τ (tau), que cuyos valores han sido trabajados por Dickey – Fuller. MacKinnon desarrollo tablas más extensas que son incorporadas con EViews.

Las pruebas de Dickey -Fuller pueden ser estimadas de tres distintas formas, bajo tres hipótesis nulas distintas.

- Si Y_t es un camino aleatorio (Random Walks) $\Delta Y_t = \gamma * Y_{t-1} + \varepsilon_t$, en este modelo no se ha incorporado ni la tendencia ni el intercepto.
- Si Y_t es un camino aleatorio (Random Walks) con intercepto (drift)

$\Delta Y_t = \alpha + \gamma * Y_{t-1} + \varepsilon_t$, en este modelo se incorpora el intercepto.

- Si Y_t es un camino aleatorio (Random Walks) con intercepto (drift) y con tendencia.

$\Delta Y_t = \alpha + \beta * t + \gamma * Y_{t-1} + \varepsilon_t$, este es un modelo más completo.

En cada uno de los casos la hipótesis nula es que existe una raíz unitaria (serie no estacionaria) y la hipótesis alternativa es $\gamma < 0$, que representa la estacionalidad de la serie Y_t , con media distinta de cero y con una tendencia determinística.

H_0 : La serie de tiempo no es estacionaria ($\gamma = 0$) y presenta raíz unitaria.

Por lo que $\gamma = 0$, $\alpha = 0$, $\beta = 0$

H_1 : La serie de tiempo es estacionaria ($\gamma < 0$) y no presenta raíz unitaria.

Por lo que $\gamma < 0$, $\alpha \neq 0$, $\beta \neq 0$

El procedimiento a seguir es para calcular el Dickey – Fuller es: Primero calcular el modelo por Mínimos Cuadrados Ordinarios (MCO), después se divide el coeficiente de Y_{t-1} entre su error estándar, para de esta manera calcular el estadístico de tau (τ) y después consultando la tabla de MacKinnon dirá si existe o no la raíz unitaria.

$|t - \text{calculado}(t - \text{estadístico o tau})| > |t - \text{crítico de la tabla de MacKinnon}|$

Esto quiere decir que si el t-calculado es mayor que el t-crítico de la tabla de MacKinnon o de DF en valor absoluto, entonces diremos que a series es estacionaria y no existe raíz unitaria.

$$|t - calculado(t - estadístico o tau)| < |t - crítico de la tabla de MacKinnon|$$

Esto quiere decir que el valor absoluto de tau no excede al t-crítico al 1%, 5% o 10% de la tabla de MacKinnon o de DF, diremos que la serie es estacionaria y que presenta raíz unitaria.

En forma resumida mencionare que esta prueba DFGLS consiste en extraer primero la tendencia de la serie original, pero se trata de una casi diferencia (cuasidiferencia) dada por $Y_t - a * Y_{t-1}$, donde a toma el valor de uno en el caso de Dickey Fuller Aumentado. Por lo que el valor de a representará un punto específico contra el cual se contrastará la hipótesis nula de un valor menor que uno.

$H_0 : a = 1$, La serie no es estacionaria y presenta raíz unitaria.

$H_1 : a < 1$, La serie de tiempo es estacionaria y no presenta raíz unitaria.

Prueba de Dickey Fuller Aumentado (ADF)

Esta prueba supone que el término error (ε_t) no es ruido blanco. Considerando que la Serie de tiempo se representa como un proceso autoregresivo de orden p.

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varepsilon_t$$

Cuando se extrae el término de $\beta_p Y_{t-p+1}$ nos da:

$$\Delta Y_t = \alpha + \phi Y_{t-1} + \sum_{i=2}^p \psi_i \Delta Y_{t-i+1} + \varepsilon_t$$

Donde:

$$\phi = -\left(1 - \sum_{i=1}^p \beta_i\right) \quad \wedge \quad \beta_i = \sum_{j=1}^p \beta_j$$

El número de rezagos óptimos para el modelo se determina de manera empírica, siendo la idea de incluir los términos suficientes para que el error del modelo no este seriamente relacionado.

De la ecuación, se desprenden tres modelos de series de tiempo que son: El paseo aleatorio (Random Walks) pero, el paseo aleatorio con intercepto (drift) y paseo aleatorio con intercepto y tendencia (componente determinístico).

Paseo aleatorio puro:

$$\Delta Y_t = \phi Y_{t-1} + \sum_{i=2}^p \psi_i \Delta Y_{t-i+1} + \varepsilon_t$$

Paseo aleatorio con drift:

$$\Delta Y_t = \alpha + \phi Y_{t-1} + \sum_{i=2}^p \psi_i \Delta Y_{t-i+1} + \varepsilon_t$$

Paseo aleatorio con drift y tendencia:

$$\Delta Y_t = \alpha + \phi Y_{t-1} + \sum_{i=2}^p \psi_i \Delta Y_{t-i+1} + \delta.t + \varepsilon_t$$



Ecuación completa que se recomienda para el test

Si se observa la última ecuación incorpora la sumatoria que ha estado presente en las anteriores ecuaciones hasta p rezagos de la primera diferencia de la variable. Esta sumatoria establece la representación aumentada de la prueba de ADF, a su vez que corrige la presencia de correlación serial en los residuo de la ecuación, pero si la serie analizada presenta un orden de autorregresión superior a uno.

Si se usa el modelo general la hipótesis nula es $\phi=0$, que dice de la presencia de una raíz unitaria en la serie. Si se rechaza la hipótesis nula se concluye que la serie no presenta raíz unitaria.

Prueba de White

Este contraste es el más general por que no especifica concretamente la heteroscedasticidad.

$$H_0 : \sigma_i^2 = \sigma^2 \quad \text{No existe Heteroscedasticidad}$$

$$H_1 : \text{no se verifica } H_0$$

White sin termino cruzado (no cross terms)

$$\hat{\varepsilon}_i^2 = \rho_0 + \rho_1 x_{1i} + \rho_2 x_{2i} + \rho_{11} x_{1i}^2 + \rho_{22} x_{2i}^2 + \rho_{12} x_{1i} x_{2i} + u_i \quad i = 1 \dots N$$

Esta prueba es similar a MCG que considera los residuos del cuadrado como variable dependiente.

$$LM = T * R^2 \approx \chi_{2k}^2$$

White con termino cruzado (cross terms)

La varianza toma forma general en función de regresores al cuadrado y de su producto cruzado

$$\hat{\epsilon}_i^2 = \rho_0 + \rho_1 x_{1i} + \dots + \rho_k x_{ki} + \rho_{11} x_{1i}^2 + \dots + \rho_{kk} x_{ki}^2 + \rho_{12} x_{1i} x_{2i} + \dots + \rho_{k-1,k} x_{k-1,i} x_{ki} + u_i$$

$$H_o : \rho_1 = \dots = \rho_k = \dots = \rho_{11} = \dots \rho_{kk} = \rho_{12} = \dots \rho_{k-1,k} = 0$$

$$LM = T * R^2 \approx \chi_{2k}^2$$

Aplicando la Heteroscedasticidad en EViews

En objet Ecuación 2 (es el nombre de la ecuación) se pulsa View/Residual Test/Specification White (no cross terms)

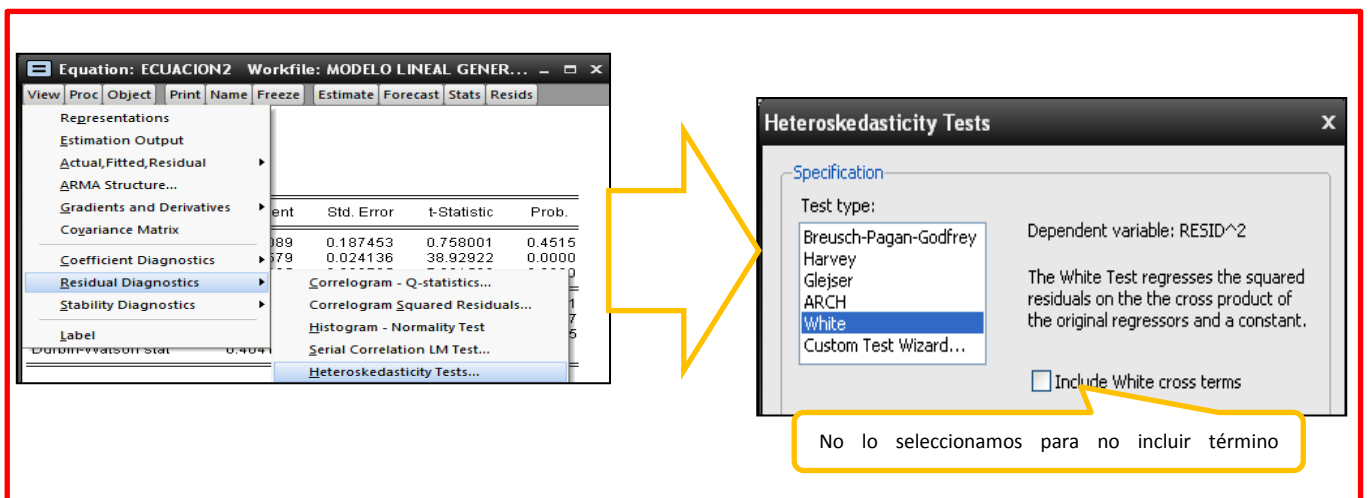


Gráfico N° 2.4 Residual Diagnostics>Heteroskedasticity Test

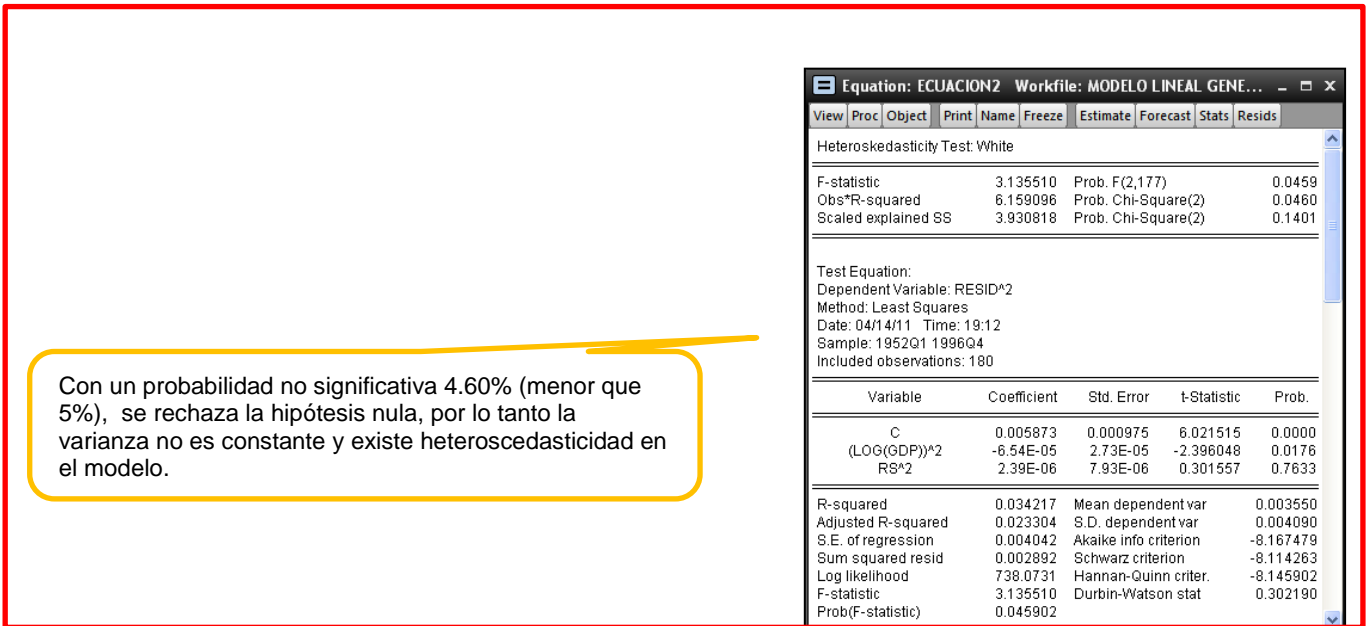


Gráfico N° 2.5 Prueba de Heteroscedasticidad de White

Formas de Corregir la Heteroscedasticidad

Para solucionar la heteroscedasticidad es necesario realizar Mínimos Cuadrados Generalizados (MCG).

Si se conoce la estructura de la varianza entonces se puede aproximar a $\sigma_i^2 = f(z_i)$

z_i : Vector de variables que incluye una o varias variables exógenas de la regresión.

f : Es una función cualquiera.

Las estructuras más habituales de la varianza son: $\sigma_i^2 = \sigma^2 x_{ji}$, $\sigma_i^2 = \alpha + \beta x_{ji}$ y $\sigma_i^2 = e^{(z_i \alpha)}$.

La matriz de varianza y covarianza resulta:

$$\Sigma = \begin{bmatrix} x_{j1} & 0 & \dots & 0 \\ 0 & x_{j2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_{jT} \end{bmatrix} \quad \text{y} \quad \Sigma = \begin{bmatrix} x_{j1}^2 & 0 & \dots & 0 \\ 0 & x_{j2}^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_{jT}^2 \end{bmatrix}$$

Por lo que MCG coincide con MCO utilizando como ponderador los valores $1/x_{jt}$ y $1/x_{jt}^2$ que son los inversos de los elementos de la diagonal de la matriz Σ .

Si la estructura de la varianza es $\sigma_i^2 = \sigma^2 x_{jt}$ el modelo puede transformarse:

$$\frac{y_i}{\sqrt{x_{jt}}} = \frac{\beta_1}{\sqrt{x_{jt}}} + \frac{\beta_2}{\sqrt{x_{jt}}} + \dots + \frac{\beta_k}{\sqrt{x_{jt}}} + \frac{\varepsilon_t}{\sqrt{x_{jt}}}$$

En general para resolver este problema es conveniente tomar logaritmos.

➤ Para detectar las formas funcionales más comunes de la varianza se puede seguir las formas:

$$\begin{aligned} |\varepsilon_t| &= \alpha + \beta \sqrt{x_{jt}} + u_t \\ |\varepsilon_t| &= \alpha + \beta \ln x_{jt} + u_t \\ |\varepsilon_t| &= \alpha + \frac{\beta}{x_{jt}} + u_t \end{aligned}$$

Se toma el que presenta R^2 más elevado.

Análisis del Tipo Box - Jenkins

Para explicar la raíz unitaria que a continuación se expone, se necesita de la metodología de Box – Jenkins. La descripción de los pasos de esta metodología no se hará mediante el esquema de etapas tan conocido, solo mencionare los pasos.

Paso 1º: Un examen visual a la trayectoria de la series estudiada, para identificar si es o no estacionaria en media. Si es existe un valor en torno al cual la seria va oscilando sin alejarse de forma permanece de dicho valor se puede decir que dicha serie presenta estacionalidad en media.

Paso 2º: Si los coeficientes de la Autocorrelación Simple (AC) no decaen o decrecen rápidamente entonces hay indicios que la serie es no estacionaria.

Paso 3º: Si el primer valor de la función de Autocorrelación Parcial Muestra (PAC) es significativo entonces existe indicios de no estacionalidad de la serie.

Todos estos paso ayudan a conocer si la serie es estacionaria. Si no lo fuera será es necesario aplicar la diferenciación (generalmente solo la $d = 1$ y $d = 2$) de la seria para hacerla estacionaria en media.

2.2.7.2 COLINEALIDAD

Prueba con matriz de correlaciones

El análisis de colinealidad permite determinar si cada regresor, inicialmente considerado, guarda independencia lineal o no con los demás regresores. El requisito fundamental para que un modelo sea apropiado para predicciones es la independencia lineal entre regresores. En sentido estricto, un regresor o variable explicativa será linealmente independiente con otro cuando el coeficiente de correlación entre ambos (correlación cruzada) es cercano a cero.

En términos prácticos cuando el coeficiente de correlación entre dos variables explicativas es mayor de 0.75, es indicativo de un alto grado de correlación y por tanto no sería posible estimar el modelo con la presencia de ambas variables. Para tal efecto, la verificación de colinealidad se realiza mediante el cálculo de la matriz de correlaciones con las variables explicativas que especifican a cada modelo.

2.2.7.3 ESPECIFICACIÓN FUNCIONAL

Prueba de Ramsey

La prueba Reset de Ramsey permite la comprobación de la correcta especificación polinómica (funcional) de un modelo estimado; es decir, que no se hayan omitido algunos otros regresores que pueden ser potencias y/o productos cruzados de los regresores ya incluidos en el modelo inicialmente especificado.

Para saber si nuestras variables regresoras cumplen bien con explicar el modelo, se aplica la prueba de Ramsey.

H 0: El modelo está bien especificado.

H 1: El modelo no esté bien especificado.

La alternativa para tratar la no linealidad consiste en transformar el modelo.

Lo principal es la forma en la que se encuentra los parámetros en la ecuación, pues mediante logaritmos o exponentes se puede convertir en lineales.

Algunas de las formas lineales más usuales son:

Tipo	Función	Forma Lineal
Inversa	$Y_t = \alpha + \beta \cdot \frac{1}{x_t} + \varepsilon_t$	$Y_t = \alpha + \beta \cdot x_t^* + \varepsilon_t$
Exponencial	$Y_t = \alpha e^{\beta x_t + \varepsilon_t}$	$\text{Log}(Y_t) = \text{Log}(\alpha) + \beta x_t + \varepsilon_t$
Crecimiento	$Y_t = e^{\alpha + \beta x_t + \varepsilon_t}$	$\text{Log}(Y_t) = \alpha + \beta x_t + \varepsilon_t$
Potencia	$Y_t = \alpha x_t^\beta \varepsilon_t$	$\text{Log}(Y_t) = \text{Log}(\alpha) + \beta(\text{Log}x_t) + \varepsilon_t$

Tabla N° 2.2 Formas Lineales de la Prueba de Ramsey

Para esta prueba utilizará el objeto resultados MCO y se da click en View/ Stability Diagnostics / Chow Ramsey RESET Test.

Y tomando una sola potencia para variables endógenas ajustada.

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 57.59% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

	Value	df	Probability
t-statistic	0.560483	174	0.5759
F-statistic	0.314141	(1, 174)	0.5759
Likelihood ratio	0.322877	1	0.5699

	Sum of Sq.	df	Mean Squares
Test SSR	5.84E-05	1	5.84E-05
Restricted SSR	0.032396	175	0.000185
Unrestricted SSR	0.032337	174	0.000186
Unrestricted SSR	0.032337	174	0.000186

	Value	df
Restricted LogL	517.2414	175
Unrestricted LogL	517.4029	174

Gráfico N° 2.6 Prueba de Reset Ramsey

2.2.7.4 ESTABILIDAD DE LOS PARÁMETROS

La prueba de residuos recursivos y la prueba de suma acumulada de los residuos normalizados al cuadrado $cusum_2$, permiten determinar la existencia de posibles quiebres estructurales en los modelos.

Un quiebre estructural es indicativo de que los parámetros de la ecuación de regresión no son constantes a lo largo de toda la muestra. Uno de los supuestos que garantiza la calidad del estimador de mínimos cuadrados ordinarios en el proceso de estimación de un determinado modelo, es precisamente que los parámetros sean constantes (estables); vale decir, que exista un único proceso generador de datos para toda la muestra en análisis.

2.2.7.5 CAUSALIDAD UNIDIRECCIONAL

Prueba de Granger.

El principio de exogeneidad indica que las variables explicativas en un determinado modelo no deben estar sometidas a algún grado de retroalimentación proveniente de los valores pasados de la variable dependiente. Es decir; para efectuar inferencias válidas sobre los parámetros estimados de la regresión, correcta especificación del modelo y consecuente uso como modelo de predicción, debe existir solamente una relación unidireccional entre variables explicativas y variable explicada.

2.3 MODELOS ESTOCÁSTICOS DE PREDICCIONES

2.3.1 MODELO DE SERIE TEMPORAL

El enfoque de análisis temporal de una serie descansa siempre, en mayor o menor medida, en la idea genérica de que una serie temporal de datos puede descomponerse siempre en una serie de componentes parciales que, agregados conforme a un esquema sumativo o multiplicativo, configuran el

aspecto global de la serie observada. Suele así afirmarse que cualquier serie de datos temporales viene a ser la agregación de cuatro patrones de evolución de sus datos: tendencia, ciclo, estacionalidad y componente errático o no sistemático. El análisis de series temporales tratará, a partir de los datos de una serie temporal, inferir las características de la estructura probabilística subyacente, del verdadero proceso estocástico. Si se logra entender qué características tiene este proceso (cuál es la esperanza de sus variables, su varianza y las relaciones entre variables separadas en el tiempo) y se observa además que estas características se mantienen en el tiempo, se podrá utilizar la metodología ARIMA para proyectar su valor en el futuro inmediato.

Ejemplo de serie compuesta por tendencia, Estacionalidad y componente aleatoria.




Gráfico N° 2.7

Ciclo: Patrón de evolución que revela cierta propensión de la serie a repetir a muy largo plazo una misma secuencia de comportamientos tendenciales. El ciclo muestra el comportamiento de corto plazo de la serie de tiempo, lo que dependerá de los factores no estructurales que se pueden presentar en el mercado.

En la economía existen dos tipos de ciclo:

- Regular cuyo comportamiento es uniforme y moderado, por lo que se puede predecir.
- Irregular cuyo comportamiento es totalmente errático e impredecible, por lo que es difícil de estimarlo.

Observando los ciclos de crecimiento intertrimestral de la economía americana podríamos señalar que, a principios de 2000, el ciclo económico de crecimiento no había terminado.

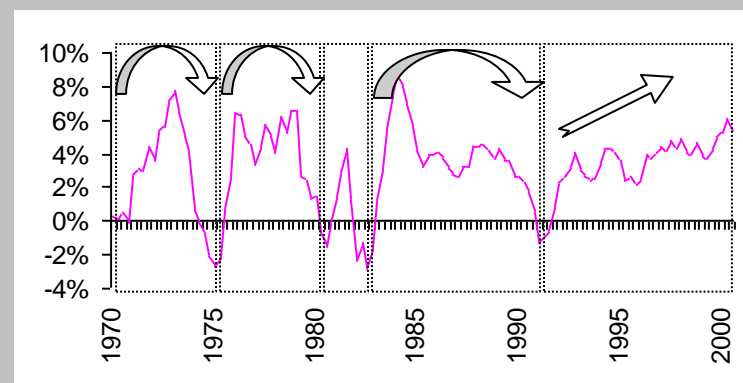


Gráfico N° 2.8 Serie de datos con ciclos

Componente tendencial: Generalmente asociado con el cambio en la media a lo largo del tiempo, se identifica la tendencia con el patrón de evolución sostenido a medio o largo plazo por encima de la existencia de movimientos rápidos a corto plazo.

Es un componente que refleja el comportamiento de mediano y largo plazo de la variable. Los factores que explican la tendencia de la serie de tiempo son aquellas variables importantes y relevantes que inciden de manera significativa en la serie de tiempo.

Existen dos tipos de tendencia esta son: Estocástica y determinística.

La tendencia es aleatoria o estocástica cuando la pendiente de la misma cambia en el tiempo. Y será determinística cuando la pendiente de la serie no varía.

La representación de los índices bursátiles DOW JONES, General de la Bolsa de Madrid y NIKKEI revelan que: en el caso del DOW JONES y la Bolsa de Madrid, la tendencia de la cotización de los índices ha sido claramente creciente a lo largo de los últimos 15 años y especialmente acelerada desde mediados de 1995.

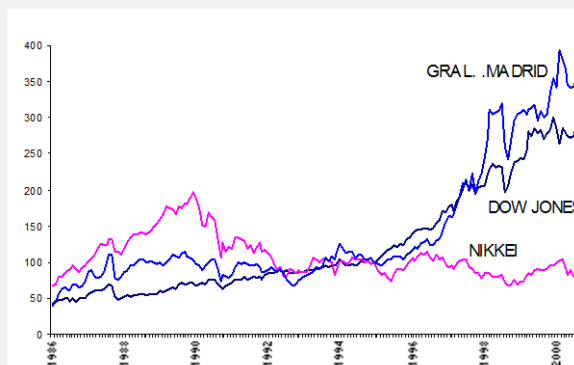


Gráfico N° 2.9 Serie de datos con componente tendencial

Estacionalidad: Patrón de evolución de la serie que se repite de forma más o menos invariable en momentos similares de espacio temporal mayor, generalmente un año.

La estacionalidad es importante cuando se trata de explicar un comportamiento de una variable endógena, porque una parte de la fluctuaciones que manifiestas las variables se debe a factores estacionales como por ejemplo: si se analiza el PBI mensual del PBI de cualquier país se verá el incremento en gran medida en el mes de diciembre, día de la madre, día del padre, fiestas patrias u otras fechas. Por lo que es necesario estacionalizar la serie para que aquellos períodos que tiene gran fluctuación.

Identificación de la Estacionalidad:

Una de las formas de identificar la estacionalidad es mediante el gráfico de barras, líneas apiladas, líneas separadas y correlograma que a continuación se pasa a explicar mediante el programa de cálculo EViews.

a) Gráficos de Barras

En esta parte del análisis me intereso en las observaciones picos de la serie, que son descritas por la gráfica y si estos picos se repiten en los meses posteriores se puede decir que existen pruebas de estacionalidad.

b) Líneas Separadas

Ahora interesa observar el comportamiento de cada mes, trimestre o bimestre según sea el caso. Si dicho comportamiento en la variable es diferente se puede decir que existe estacionalidad en dicha serie.

c) Correlograma

La función de Autocorrelación da una medida de la correlación que existe entre las observaciones continuas.

1) Función de Autocorrelación Simple (AC):

Estos coeficientes presentan una medida entre observaciones de series separadas por k períodos en el tiempo.

2) Función de Autocorrelación Parcial (PAC):

Esta función mide la correlación que hay entre t y $t-k$ quitando los efectos que son las observaciones intermedias entre los períodos de separación.




Gráfico N° 2.10 Función de Autocorrelación y Autocorrelación Parcial

Un correlograma está formado por dos columna la izquierda está referida a la autocorrelación simple y el de la derecha es la autocorrelación parcial. El número de rezagos que recomiendan muchos autores se debe considerar por lo menos 24 retardos si la serie analizada es mensual ,12 retados si es bimensual, 8 retardos sin la serie es trimestral, etc.

Observando la serie mensual de Contratos Registrados en el INEM de duración entre 1 y 3 meses puede comprobarse como la contratación temporal presenta, junto a una tendencia claramente creciente, una marcada estacionalidad, especialmente en el período estival.




Gráfico N° 2.11 Serie de datos con Estacionalidad

Ajuste estacional:

EViews tiene incorporado ratios y factores estacionales, como se pasa a explicar.

- a) **Generate by Equation:** Aunque este no es un filtro de estacionalidad. Luego, esta opción pide una serie para usar en la actualización de las series seleccionadas.
- b) **Seasonal Adjustment:** Esta opción crea una serie de ajuste estacional. Usa cuatro métodos que son: La razón con el promedio móvil y diferencia del promedio móvil, el método multiplicativo X-11, el método aditivo X-11 y el Census X-12.
- c) **Exponential Smoothing: (Suavización Exponencial):** Este Filtro crea una serie que ha sido suavizada. En EViews se puede encontrar formas simple, dobles y Holt – Winters de suavización exponencial.

Innovación, residuo o componente errática: Porción no sistemática del comportamiento temporal de una serie, o al menos movimiento que no puede catalogarse como estacional, tendencial y/o cíclico.

La idea básica del análisis de series consiste en que cada uno de estos componentes de las series puede ser analizado de forma separada para posteriormente, agregar los análisis parciales en un resultado conjunto.

En ocasiones, el análisis prioriza, se centra sólo en alguno de los componentes sistemáticos por separado (la tendencia, la estacionalidad, el ciclo), en otras ocasiones, como es el caso de la modelización ARIMA, lo que interesa es ir más allá de las componente cíclicas, tendenciales y estacionales, analizando la componente no sistemática, de carácter aparentemente aleatorio, para tratar de identificar algún patrón de interés en su evolución que ayude a entender la progresión de la serie completa.

Así pues, la aplicación de modelos ARIMA suele realizarse por descomposición, analizando en primer lugar la tendencia de la serie, pasando después a observar la estacionalidad y concentrándose después en la identificación del componente filtrado de tendencia y estacionalidad.

2.3.2 PROCESOS ESTOCÁSTICOS

En el análisis estocástico de series temporales, se define a un proceso estocástico como la familia de variables aleatorias de $\{X_t\}$, donde t es el tiempo, tal que para cada serie finita de elecciones de t (t_1, t_2, \dots, t_n), se define una distribución de probabilidad conjunta para las correspondientes variables aleatorias $X_{t_1}, X_{t_2}, \dots, X_{t_n}$.

Así, bajo el contexto de procesos estocásticos, una serie temporal X_t se define como el conjunto de valores observados de distintas variables aleatorias correspondientes a períodos de tiempo consecutivos; dichos períodos tienen la misma amplitud y la serie tiene un carácter discreto. Es decir, el valor observado de la serie en el instante t puede ser considerado como una muestra aleatoria de tamaño uno de la variable X_t del proceso

estocástico definida en dicho instante. Se puede decir que X_t y $X_{t'}$ están separadas por k retardos si $|t-t'|=k$.

Una forma de describir un proceso estocástico es especificando la distribución de probabilidad conjunta de $X_{t1}, X_{t2}, \dots, X_{tn}$ para cualquier conjunto (t_1, t_2, \dots, t_n) y cualquier valor de n , pero esto resulta complicado. Sin embargo, para muchos fines prácticos, se suele describir mediante sus momentos, entre los cuales se destacan los siguientes:

La media, de un proceso estocástico se define por:

$$\mu_t = E(X_t)$$

El subíndice t del que se ha dotado a la variable indica que la media será distinta para cada período de tiempo.

La función de autocovarianza (covarianzas entre variables referidas a momentos distintos en el tiempo), se expresa como:

$$\gamma_{t,t+k} \equiv \text{Cov}(X_t, X_{t+k}) \equiv E\{[X_t - E(X_t)][X_{t+k} - E(X_{t+k})]\}$$

$$k = 0, 1, 2, 3, \dots$$

A partir de esta función se obtienen:

La varianza del proceso (cuando $k=0$), dada por:

$$\gamma_{t,t} \equiv \text{var } X_t \equiv E(X_t - \mu_t)^2 = \sigma_t^2$$

La función de autocorrelación, definida por:

$$\rho_{t,t+k} = \frac{\gamma_{t,t+k}}{\sqrt{\gamma_{t,t}} \sqrt{\gamma_{t+k,t+k}}}$$

2.3.3 PROCESOS ESTOCÁSTICOS ESTACIONARIOS

La estacionariedad de un proceso estocástico se puede describir bajo dos sentidos, uno en el sentido estricto o fuerte y otro en el sentido amplio o débil.

La estacionariedad en el sentido estricto se da cuando su función de distribución conjunta es invariante respecto de un desplazamiento en el tiempo. Es decir, considerando que t_1, t_2, \dots, t_n corresponden a períodos sucesivos que se denomina como $t, t+1, \dots, t+k$, cuando:

$$F(X_t, X_{t+1}, \dots, X_{t+k}) = F(X_{t+m}, X_{t+1+m}, \dots, X_{t+k+m})$$

Para cualquier t, k y m . La estacionariedad en el sentido amplio se caracteriza mediante las siguientes propiedades:

Las esperanzas matemáticas de las variables aleatorias no dependen del tiempo; es decir son constantes:

$$\begin{array}{l} E(X_t) = E(X_{t+m}) \quad \forall m \\ \text{o bien} \quad \mu_t = \mu \quad \forall t \end{array}$$

Las varianzas tampoco dependen del tiempo y son finitas, es decir:

$$Var(X_t) = Var(X_{t+m}) < \infty \quad \forall m$$

O bien:

$$\sigma_t^2 = \sigma^2 \quad \forall t$$

Las covarianzas entre dos períodos de tiempo distintos solamente dependen del lapso de tiempo transcurrido entre estos dos períodos, es decir:

$$\text{Cov}(X_t, X_{t+m}) = \text{Cov}(X_{t+m}, X_{t+m}) \quad \forall m$$

O bien:

$$\gamma_{t, s} = \gamma_{|t-s|} \quad \forall t, s$$

2.3.4 PROCESOS ESTOCÁSTICOS NO ESTACIONARIOS

Para estas condiciones de estacionariedad, la autocorrelación de orden k (ρ_k) es la correlación separada k períodos de la misma serie temporal. Esto es:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\text{cov}(X_t, X_{t+k})}{\text{var}(X_t)}$$

Al conjunto de autocorrelaciones obtenidas para distintos valores de k se le denomina función de autocorrelación (FAC).

La mayoría de los procesos que representan sistemas económicos o energéticos no se ajustan a estas condiciones de estacionariedad, pero es posible eliminar sus tendencias y estabilizar sus varianzas para transformarlos en otros aproximadamente estacionarios. Una vez realizada

la transformación, los procesos estacionarios se modelizan, para fines de predicción.

2.3.5 PROCESO ESTOCÁSTICO “RUIDO – BLANCO”

Un ruido blanco es una sucesión de variables aleatorias (proceso estocástico) con esperanza nula, varianza constante, y covarianzas nulas para distintos valores de t . Este tipo de proceso, que sólo presenta varianza, que no presenta relación entre variables de distintos períodos, no podrá ser reproducido con un modelo ARIMA, es un proceso “vacío” de información de carácter autoproyectivo.

2.3.6 MODELOS ESTOCÁSTICOS ESTACIONARIOS LINEALES

Efectuar una predicción bajo el enfoque estocástico ARIMA, es inferir la distribución de probabilidad de una observación futura X_{t+1} dada una serie X_1, X_2, \dots, X_t de valores pasados. Para determinar las características del proceso estocástico subyacente a la serie temporal, se debe considerar un caso particular de proceso estocástico, es decir el proceso estocástico lineal discreto.

Un proceso estocástico es lineal discreto si cada observación X_t se puede expresar de la forma general:

$$X_t = \mu + u_t + \psi_1 u_{t-1} + \psi_2 u_{t-2} + \dots$$

Donde μ y ψ son parámetros desconocidos, y $u_t, u_{t-1}, u_{t-2}, \dots$ es una secuencia de perturbaciones aleatorias distribuidas idénticas e independientemente con media cero y varianza σ_u^2 , lo que se conoce como ruidos blancos. Los casos particulares del proceso estocástico lineal discreto son:

Modelo de medias móviles de orden q: MA (q)

Modelo autorregresivo de orden p: AR (p)

Modelo mixto autorregresivo- medias móviles de orden p, q: ARMA (p,q)

2.3.6.1 MODELO DE MEDIAS MÓVILES MA (Q)

Un modelo de los denominados de medias móviles es aquel que explica el valor de una determinada variable en un período t en función de un término independiente y una sucesión de términos de error, de innovaciones correspondientes a períodos precedentes, convenientemente ponderados. Estos modelos se denotan normalmente con las siglas **MA**, seguidos, como en el caso de los modelos autorregresivos, del orden entre paréntesis. Así, un modelo con q términos de error MA (q) respondería a la siguiente expresión:

$$X_t = \mu + u_t - \theta_1 u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q}$$

El signo negativo que van precedidos los coeficientes a estimar

$\theta_1, \theta_2, \dots, \theta_q$ de esta expresión se da por conveniencia notacional. El

parámetro μ es la esperanza matemática de X_t .

Este modelo se puede expresar más abreviadamente como:

$$X_t = \mu + \theta(L)u_t$$

Donde L es el operador de retardos y $\theta(L)$ es el operador polinomial de retardos, definido como:

$$\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q$$

Un modelo de medias móviles siempre es estacionario, y será invertible cuando pueda expresarse como un proceso autorregresivo de orden infinito. Para ello deberá cumplirse que las raíces de $\theta(L)=0$, caigan fuera del círculo unitario. Se dice que las raíces caen fuera del círculo unitario cuando, si éstas son reales, todas ellas son en valor absoluto mayores que la unidad, mientras que si son complejas ($a+bi$), entonces se cumple

que el módulo, definido como: $\sqrt{a^2 + b^2}$, es mayor que la unidad.

Como caso particular se tiene el Modelo MA (1), que viene definido por:

$$X_t = \mu + u_t - \theta_1 u_{t-1}$$

O bien:

$$X_t = \mu + \theta(L)u_t, \text{ siendo } \theta(L) = 1 - \theta_1 L$$

El modelo MA (1) será siempre estacionario. Mientras que, para que sea invertible deberá cumplirse que la raíz de la ecuación:

$$\theta(L) = 1 - \theta_1 L = 0$$

Caiga fuera del círculo unitario, es decir $|L| > 1$, que implica se cumpla que:

$|\theta_1| < 1$, para lo cual el modelo MA(1) puede escribirse como el modelo AR de orden infinito:

$$X_t = \pi_1 X_{t-1} + \pi_2 X_{t-2} + \pi_3 X_{t-3} + \dots + \delta + u_t$$

Donde:

$$\delta = \mu \frac{1}{1 - \theta_1}$$

La función de autocorrelación de MA (1) tendrá la forma:

$$\rho_k = \begin{cases} \frac{-\theta_1}{1 + \theta_1^2} & \text{para } k=1 \\ 0 & \text{para } k > 1 \end{cases}$$

2.3.6.2 MODELO AUTORREGRESIVO AR (P)

Los modelos ARIMA tratarán de expresar la evolución de una variable Y_t de un proceso estocástico en función del pasado de esa variable o de impactos aleatorios que esa variable sufrió en el pasado. Para ello, se

utilizarán dos tipos de formas funcionales lineales sencillas: los modelos AR (Modelos Autorregresivos), y los modelos MA (de Medias Móviles).

Un modelo AR (autorregresivo) como aquel en el que la variable endógena de un período t es explicada por las observaciones de ella misma correspondientes a períodos anteriores (parte sistemática) más un término de error ruido blanco (innovación).

Los modelos autorregresivos se abrevian con la palabra AR tras la que se indica el orden del modelo: AR (1), AR (2),....etc. El orden del modelo expresa el número de observaciones retasadas de las series temporales analizadas que intervienen en la ecuación. Así, por ejemplo, un modelo AR(1) tendría la siguiente expresión:

Un modelo autorregresivo de orden p se define como:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \delta + u_t$$

En forma abreviada se tiene:

$$\phi(L)X_t = \delta + u_t$$

Donde $\phi(L)$ es el operador polinomial de retardos:

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$$

A diferencia de los modelos de medias móviles que siempre son estacionarios, los modelos autorregresivos deben cumplir como condición de estacionariedad que las raíces del polinomio característico.

Esta forma funcional se acompaña de una serie de restricciones conectadas con importantes hipótesis analíticas:

- El proceso no debe ser anticipante (*hipótesis de recursividad temporal*); lo que quiere decir que los valores de una variable en un momento t no dependerán de los que esta misma tome en $t+j$.
- La correlación entre una variable y su pasado va reduciéndose a medida que se alejan más en el tiempo (*proceso ergódico*).

La magnitud de los coeficientes está limitada en valor absoluto: así, por ejemplo, en el caso de un AR(1), el coeficiente autorregresivo de un proceso estocástico estacionario ha de ser inferior a 1 en valor absoluto; en el caso de un AR(2), es la suma de los dos coeficientes la que no puede exceder la unidad. Estas restricciones expresadas en los coeficientes conectan con las propiedades de estacionariedad del proceso analizado o, dicho de otro modo: sólo los modelos cuyos coeficientes respetan una serie de condiciones (que dependen del orden “p” del modelo) representan procesos estocásticos estacionarios y, por tanto, tienen utilidad analítica.

2.3.6.3 MODELO MIXTO ARMA (P, Q)

Este modelo mixto autorregresivo (AR)-medias móviles (MA) de orden p , q , se define mediante la siguiente expresión:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \delta + u_t - \theta_1 u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q}$$

Utilizando los operadores polinomiales de retardos $\theta(L)$ y $\phi(L)$, la expresión anterior queda:

$$\phi(L)X_t = \delta + \theta(L)u_t$$

El modelo ARMA se dice que es estacionario cuando lo es su parte autorregresiva AR; esto es, cuando las raíces de la ecuación $\phi(L) = 0$ caen fuera del círculo unidad, y se puede afirmar que es invertible cuando lo es su parte MA; esto es, cuando las raíces de la ecuación $\theta(L) = 0$ caen fuera del círculo unidad. Adicionalmente a las condiciones de estacionariedad e invertibilidad también se supondrá que las raíces de $\phi(L) = 0$ y $\theta(L) = 0$ no son comunes.

Las funciones teóricas de autocorrelación (FAC) y de autocorrelación muestral (FAM) sirven como referencia para identificar las funciones de autocorrelación muestral y de autocorrelación parcial muestral de una serie temporal en estudio. Las características gráficas de las funciones teóricas de autocorrelación (FAC) y autocorrelación parcial (FACP), para diferentes tipos de modelos se muestran a continuación:

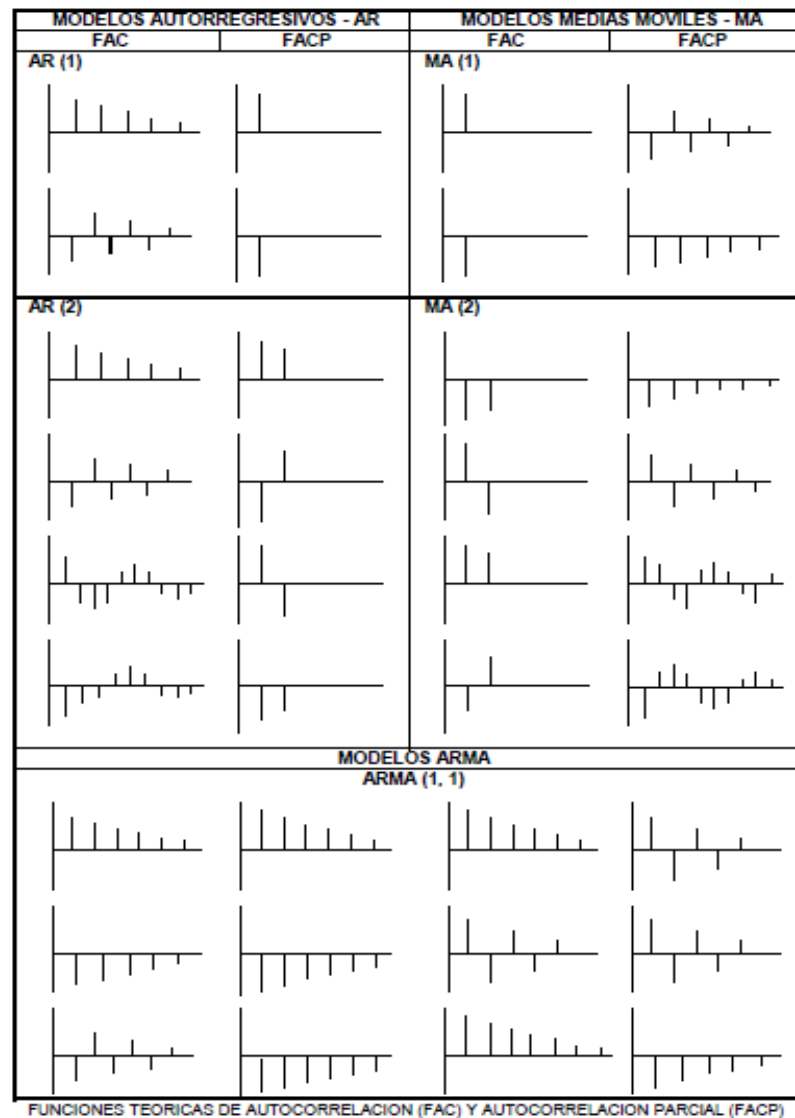


Tabla N° 2.3

2.3.7 MODELOS ARIMA

2.3.7.1 MODELOS LINEALES NO ESTACIONARIOS HOMOGÉNEOS

Se dice que un proceso estocástico no estacionario es homogéneo cuando al diferenciar en el proceso original, el proceso transformado resultante es estacionario, y el número de veces que debe diferenciarse

el proceso original para transformarse en estacionario constituye el grado u orden de homogeneidad.

Muchas series cronológicas, como las obtenidas en el campo energético se pueden convertir en aproximadamente estacionarias después de aplicar diferencias en una o más etapas; es decir:

Si la serie original, X_t , es homogénea de orden d , entonces.

$$\Delta^d X_t = (1-L)^d X_t = Z_t, \quad t=1, 2, \dots, T$$

La nueva serie es estacionaria.

A un proceso integrado X_t se le denomina proceso autorregresivo-medias móviles integrado, ARIMA (p, d, q), si tomando diferencias de orden d se obtiene un proceso estacionario Z_t del tipo ARMA (p, q).

El modelo ARIMA (p, d, q), se expresa de la siguiente forma:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q}$$

Abreviadamente se tiene.

$$\phi(L)Z_t = \theta(L)u_t, \text{ siendo } Z_t = \Delta^d X_t = (1-L)^d X_t$$

Quedando así:

$$\phi(L)(1-L)^d X_t = \theta(L)u_t$$

No se incluye el término constante δ dado que la media de la serie diferenciada Z_t es cero, como frecuentemente suele ocurrir. En caso de que este supuesto no pueda mantenerse, este parámetro deberá incluirse en la expresión del modelo ARIMA (p, d, q).

Al analizar la mayoría de las series temporales económicas, y en nuestro caso energético, se suele observar que éstas presentan una tendencia creciente o decreciente. La eliminación de esta tendencia (no estacionariedad en media) de la serie suele conseguirse mediante las diferenciaciones implícitas en los modelos ARIMA. Ahora bien, en ocasiones se observa también que existe una tendencia en la varianza, esto es, que la dispersión de las observaciones no es constante a lo largo del tiempo, la cual no se elimina mediante estas diferenciaciones. Cuando se presenta este hecho la transformación adecuada puede consistir en tomar logaritmos neperianos.

Esta posibilidad de transformar la serie se puede concretar de forma más general mediante la transformación Box-Cox. Así, el modelo ARIMA se puede expresar como:

$$\phi(L)\Delta^d X_t^{(\lambda)} = \delta + \theta(L)u_t$$

O bien:

$$\phi(L)(1-L)^d (X_t^{(\lambda)} - \mu) = \theta(L)u_t$$

Donde μ es la media de $X_t^{(\lambda)}$, siendo:

$$X_t^{(\lambda)} = \begin{cases} \frac{X_t^{(\lambda)} - 1}{\lambda} & \text{para } \lambda \neq 0 \\ \ln X_t & \text{para } \lambda = 0 \end{cases}$$

2.3.7.2 MODELOS ESTACIONALES NO ESTACIONARIOS HOMOGÉNEOS

Otra fuente de estacionariedad en muchas de las series reales del ámbito energético lo constituye la estacionalidad. Para desestacionalizar las series se proceden a la *diferenciación estacional*.

Los modelos estacionales no estacionarios pero homogéneos, ARIMA (P, D, Q), se expresan mediante:

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + u_t - \Theta_1 u_{t-1} - \dots - \Theta_q u_{t-q}$$

$$Z_t = \Delta_s^D X_t = (1 - L^s)^D X_t$$

La expresión resumida de ARIMA (P, D, Q) será:

$$\Phi_p(L^s)(1 - L^s)^D X_t = \delta + \Theta_q(L^s)u_t$$

Donde

$$\Phi_p(L^s) = 1 - \Phi_1 L^s - \Phi_2 L^{2s} - \dots - \Phi_p L^{ps}$$

$$\Theta_q(L^s) = 1 - \Theta_1 L^s - \Theta_2 L^{2s} - \dots - \Theta_q L^{qs}$$

2.3.8 ETAPAS PARA LA ELABORACIÓN DE UN MODELO ARIMA

Partiendo de una determinada serie temporal se trata de averiguar el modelo ARIMA (p,d,q) x ARIMA (P,D,Q) es susceptible de haber generado dicha serie, es decir, qué modelo representa adecuadamente el comportamiento de la misma, con el fin de utilizarlo para obtener predicciones de valores futuros de la serie en cuestión. Para ello se siguen cuatro etapas: identificación, estimación, validación, y predicción.

Identificación. Identificar una serie temporal consiste en inducir, a partir de los datos, la función de autocorrelación muestral y la función de autocorrelación parcial muestral, qué modelos ARIMA se adaptarían mejor a las características de la serie. Cuando se trata de una serie no estacionaria, primeramente se procede a estacionalizar la serie, tanto en media, es decir, identificación del valor d y D (estacionalidad), como en varianza, esto es identificar el valor de λ . Una vez que esta serie transformada es estacionaria (en media y en varianza) se deben de averiguar los posibles valores tanto de la parte regular del modelo (autorregresiva, p , y medias móviles, q) como de la parte estacional (autorregresiva, P , y medias móviles, Q).

Identificación del modelo Arima con Sucesos Externos.

Los sucesos externos se determinan una vez identificado el modelo ARIMA, generado, aparentemente sin intervenciones ni atípicos. Con la visualización del comportamiento de los residuos del modelo ARIMA base, se identifican los atípicos.

Las intervenciones se obtienen a partir de la visualización gráfica de la serie, identificando todos los valores extremos, secuenciales y puntuales, a los que posteriormente se les evalúa el grado de significancia estadística cuando se les somete a algún tipo de filtro (función impulso o escalón).

Estimación. Identificados los posibles modelos que han podido generar la serie temporal, se trata de cuantificar los parámetros de los mismos. Los dos problemas fundamentales a los que se enfrenta la estimación de los modelos ARIMA son el de los valores iniciales (de los parámetros, de la serie y de los ruidos) y el de no linealidad.

Se trata de estimar los parámetros β_i , $i=0, p+P+q+Q$, donde:

$$\begin{aligned} \beta_i &= \phi_i & i=1, \dots, p \\ \beta_i &= \Phi_{i-p} & i=p+1, \dots, p+P \\ \beta_i &= \theta_{i-(p+P)} & i=p+P, \dots, p+P+q \\ \beta_i &= \Theta_{i-(p+P+q)} & i=p+P+q+1, \dots, p+P+q+Q \\ \beta_i &= c & i=0 \end{aligned}$$

Si B_i es la estimación del parámetro β_i , la primera etapa en la validación del modelo consistirá en comprobar si los coeficientes B_i son significativamente distintos de cero. Para ello, sobre cada parámetro, se planteará la hipótesis nula, esto es $H_0: \beta_i=0$. Dicha hipótesis puede ser interpretada como que la variable asociada al parámetro β_i no mejora el ajuste con respecto al obtenido con las restantes variables incluidas en el modelo. Si el p -valor asociado al valor del estadístico de contraste t es menor que α , se rechazará la hipótesis nula al nivel de significación α .

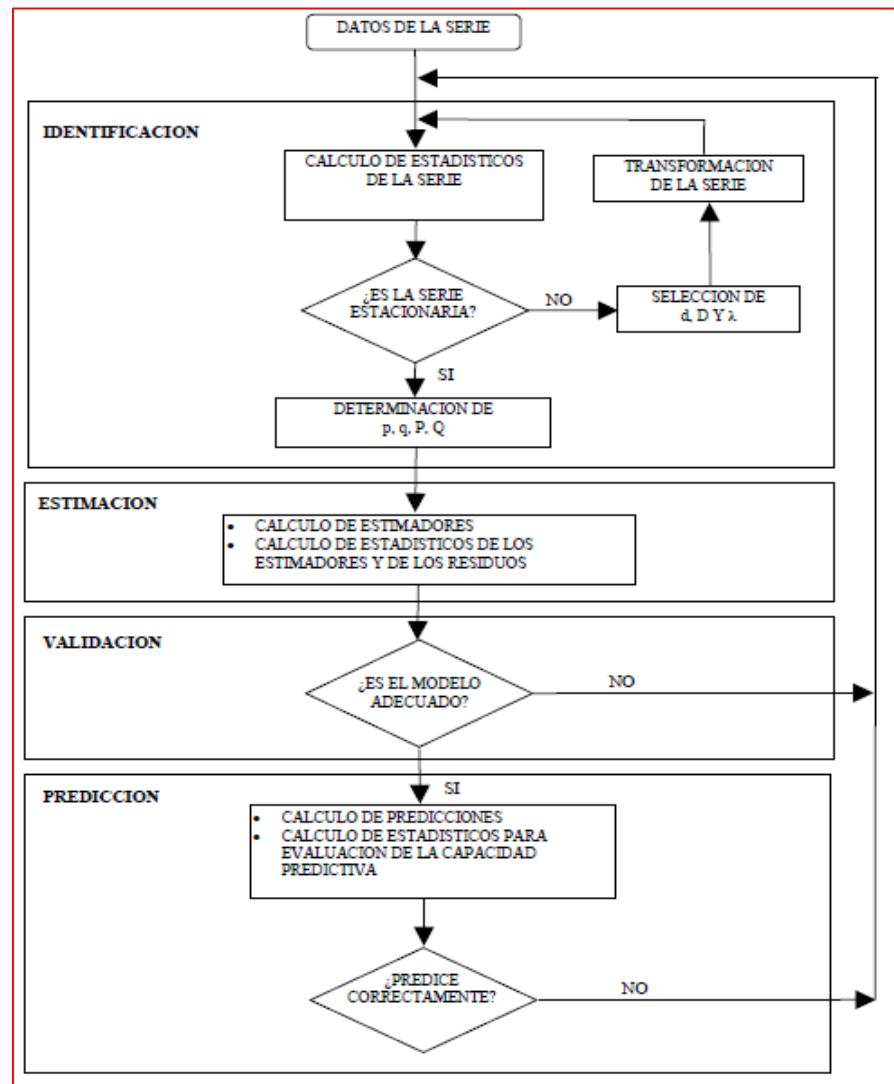
Estimación del modelo Arima con Sucesos Externos

Una vez comprobada la significancia de los sucesos externos seleccionados, se procede a estimar los coeficientes del modelo ARIMA de base, incluyendo dichos efectos externos.

Validación. La etapa de validación o chequeo se centra fundamentalmente en analizar si los residuos del modelo (\hat{u}_t) tienen un comportamiento similar a las perturbaciones del mismo (u_t); esto es, si puede afirmarse que son semejantes a un ruido blanco. Adicionalmente, se tratará de comprobar la calidad de las estimaciones, así como el cumplimiento de las condiciones de estacionariedad e invertibilidad que deben satisfacer los parámetros de estos modelos.

Predicción. Tras la validación, viene el fin básico de esta metodología, esto es, la obtención de predicciones de valores futuros de la serie temporal. Una vez obtenidas las predicciones del modelo se trata de volver a chequear la adecuación del mismo, pudiendo utilizar para ello métodos no paramétricos (como el error cuadrático medio) como paramétricos (estadísticos de contenido informativo, exactitud y corroboración).

A continuación se ha confeccionado un diagrama de flujo que resume el proceso a seguir para el cálculo de predicciones mediante modelos ARIMA.



Gráfica N° 2.12 Metodología de cálculo de Predicciones

2.3.9 PROCESO DE CÁLCULO Y ELEMENTOS DE PROGRAMACIÓN

Para el desarrollo cuantitativo de las predicciones de las variables energéticas a evaluar, han de tenerse en cuenta los siguientes puntos:

- Creación de una base de datos
- Elección de los modelos o técnicas de predicción
- Elección del programa o programas de cómputo

- Elaboración del modelo
- Cálculo numérico de las predicciones

Los elementos de programación pueden ser:

- Programas computacionales en donde se generen códigos propios de trabajo en predicciones. Entre los que se ha utilizado se tiene el E-Views.

2.4 PROGRAMA DE OPTIMIZACIÓN

2.4.1 ¿QUÉ ES EL PROGRAMA E-VIEWS?

El programa E-Views es la versión en entorno MS-Windows del antiguo Micro-TSP (Time Series Analysis) desarrollado por primera vez en 1981. Es uno de los más utilizados dentro del campo de la econometría y su manejo permite la estimación, resolución y uso de modelos econométricos de distinta naturaleza mediante la utilización de una amplia gama de procedimientos.

Su “puesta al día” en relación con los últimos avances de la econometría aplicada es notable y, para los que conocen cada una de las técnicas, su utilización es extremadamente intuitiva. Esta adecuación a la práctica profesional de la econometría se debe sin duda a sus autores que, desde las primeras versiones del TSP, diseñaron el programa de cara a su utilización real adaptándolo a sus propias necesidades del día a día.

2.4.2 CONCEPTOS BÁSICOS

Del mismo modo que el Word permite la creación de documentos, el Excel la creación de Hojas de Cálculo o el Corel Draw la creación de dibujos, los ficheros creados con E-Views reciben un nombre particular: Workfile o Ficheros de Trabajo.

Cada usuario definirá su propio Fichero de Trabajo en el que almacenará sus datos, estimará sus ecuaciones, realizará sus gráficos. Así, una vez abierto el programa E-Views, la primera operación consistirá siempre en crear un fichero de trabajo nuevo o abrir uno ya existente, previamente creado. Los Workfiles se almacenan en los discos con un nombre y una extensión como cualquier otro archivo creados con cualquier otro programa. Más adelante se analizarán las formas de guardar y recuperar ficheros así como sus extensiones.

El funcionamiento del programa E-Views está pensado alrededor del concepto de objeto. E-Views denomina objeto a todo aquello que puede crearse y almacenarse dentro de un fichero de trabajo: una serie de datos, una ecuación elaborada por el usuario, un modelo (conjunto de ecuaciones), un coeficiente de una ecuación, una matriz, un programa.

Por último, debe saberse que, en E-Views, un mismo objeto puede mostrarse en pantalla con distintos “aspectos”, de distintas formas: por ejemplo, para un objeto “serie de datos” pueden observarse sus valores, su representación gráfico, sus estadísticos básicos (media, varianza....), su histograma de frecuencias... etc. El

usuario puede cambiar fácilmente de una forma a otra de presentación para cada objeto utilizando lo que se denominan vistas o VIEWS del objeto.

El último concepto a conocer es el de procedimiento o PROCS. E-Views denomina procedimiento a cualquier operación que puede realizarse con el programa: estimar una ecuación, crear un grupo de series de datos, realizar un test para el contraste de una hipótesis. El resultado de ejecutar cualquier procedimiento supondrá la aparición de un nuevo objeto o la transformación de uno ya existente.

Conocer los distintos procedimientos de E-Views es, evidentemente, conocer las posibilidades de análisis de E-Views.

2.4.3 DESCRIPCIÓN DEL ENTORNO DE E-VIEWS

Antes de entrar en el manejo básico de E-Views, vamos a describir brevemente cada una de las partes que se observan en una sesión normal de la pantalla del programa, observando la forma en que podrán verse cada uno de los elementos que manejare habitualmente.

En la página siguiente puede observarse un ejemplo de la pantalla en una sesión habitual de E-Views:

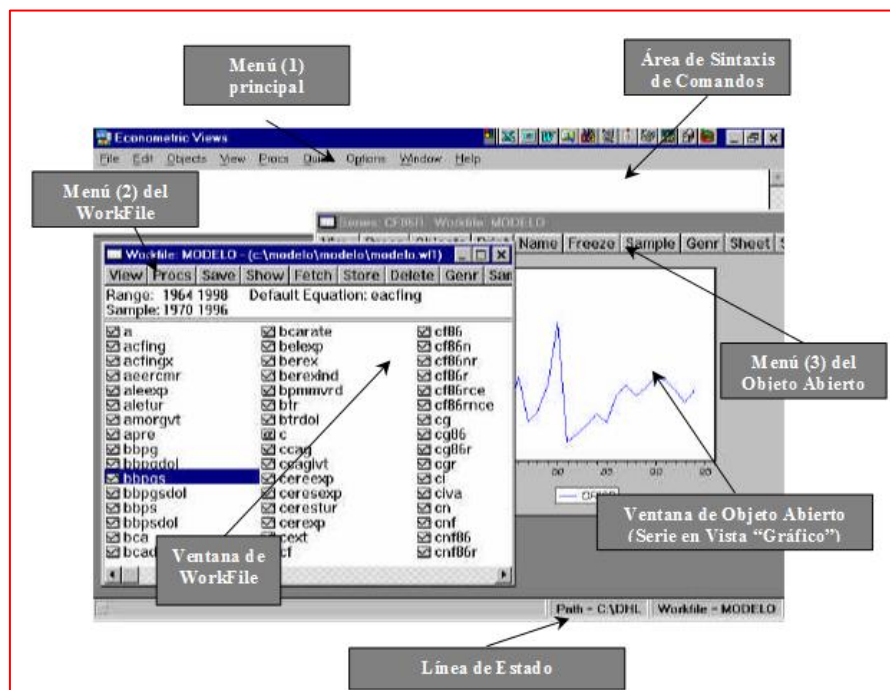


Gráfico N° 2.13 Ventana de Eviews

Para comprender de una forma sencilla la apariencia de la ilustración anterior debemos darnos cuenta de que al utilizar E-Views tendremos abiertas, la mayor parte del tiempo, 3 ventanas de forma simultánea:

La VENTANA del programa, que se abre al iniciar el E-Views.

La VENTANA del Workfile, que mostrará los objetos creados en el mismo.

La VENTANA del objeto (o las ventanas de los objetos) que se tienen abiertos en cada momento.

A partir de la ventana principal del workfile, cada uno de los objetos puede abrirse la ventana para cada uno de los objetos haciendo doble clic en el icono correspondiente. El tamaño de las ventanas puede modificarse, pueden

minimizarse las ventanas, moverse, cerrarse, según el procedimiento habitual de cualquier programa de MS-Windows.

Así pues, dado lo anterior, en un momento determinado se observa tres menús diferentes:

El menú principal que da entrada a todos los procedimientos generales.

El menú del workfile, que resume los principales procedimientos que afectan a los objetos de un fichero de trabajo.

El menú del objeto, que controla los procedimientos y vistas que afectan a cada objeto abierto.

Esta multiplicidad de menús implica que, en muchas ocasiones, se puede encontrar una misma operación o procedimiento en distintos lugares de los diferentes menús.

Además de lo anterior, la pantalla del E-Views mostrará:

El área de comandos, en el que puede utilizarse la sintaxis propia del antiguo TSP para MS-DOS, en lugar de los menús, para ejecutar determinados procedimientos.

La clásica línea de estado, en la que aparecerá información útil sobre el fichero abierto: principalmente el workfile en uso y el directorio en el que se localiza.

2.4.4 LOS MENÚS DE E-VIEWS

Sin perjuicio de dar posteriormente una descripción detallada de los procedimientos básicos que pueden realizarse con el programa E-Views, conviene dar una breve descripción de las principales opciones contenidas en los menús, uno a uno. Las entradas que aparecen inicialmente en el menú principal son 8, cada uno de ellos con una finalidad básica:

File Menu: controla operaciones relacionadas con los ficheros, datos y programas (abrir, guardar).

Edit Menu: contiene los ítems básicos de edición de cualquier programa en entorno Windows (Cortar, pegar, copiar).

Objects Menu: manipula los distintos objetos que se almacenan en un Workfile (crea, borra, renombra).

Proc and View Menus: estos dos menús se utilizan de forma diferente que el resto ya que se refieren siempre a la ventana activa en cada caso y por tanto, su contenido diferirá según el tipo de ventana en uso.

Quick Menu: da acceso directo a comandos que se utilizan con más frecuencia.

Options Menu: altera los parámetros de funcionamiento general del E-Views. Los cambios que se realicen con este menú permanecen aun saliendo del programa de modo que debe vigilarse su alteración.

Windows Menu: da acceso directo a las distintas ventanas que se tengan abiertas en el área de trabajo.

Help Menu: menú de ayuda clásico. La ayuda del E-views puede calificarse como de buena calidad en términos estadísticos y de manejo del programa por lo que es siempre un buen referente.

Se explicara con más detalle en las opciones básicas de aquellas entradas principales de mayor interés. Recordando una vez más que no se trata aquí de describir con detalle cada una de las opciones sino tan localizar, a modo de directorio de consulta rápida, alguno de los ítems contenidos en cada uno de ellos.

MENÚ FILE	
New	♦ Crea nuevos workfiles, ficheros de programa y ficheros de texto.
Open	♦ Abre un menú por el que se accede a los workfiles, programas o ficheros de texto previamente creados
Save	♦ Salva el workfile, programa o fichero de texto activo, si no se ha grabado nunca preguntará el nombre a utilizar.
Save as	♦ Salva el workfile, programa o fichero de texto activo preguntando por un nombre
Close	♦ Cierra la ventana activa. Si la ventana activa es un workfile, un programa o un fichero de texto este se cerrará, es decir, será borrado de la memoria RAM. Previamente se nos preguntará si deseamos guardar los últimos cambios.
Import	♦ Lee datos de un fichero externo. Los ficheros legibles son de los siguientes tipos: Banco de datos de E-Views, DRI Basic Economic database, texto, Lotus y Excel. Cuando se importan datos de estos formatos se abrirá un menú adicional en el que se nos preguntará el formato de los mismos.
Export	♦ Escribe datos desde un fichero de trabajo al formato Banco de datos EViews, texto, Lotus o Excel. En el formato de Banco de datos puede almacenarse cualquier tipo de objeto (en ficheros separados) pero en ficheros de texto o de hoja de cálculo sólo pueden almacenarse series de datos. Se abrirán en todos los casos menús adicionales para especificar el formato.
Print	♦ Imprime el contenido de la ventana activa. Si no hay ventana activada imprime el área de comandos.
Print Setup	♦ Controla las opciones de impresión. El menú que se abre permite, entre otras cosas, especificar si la impresión será enviada a la impresora o a un fichero de disco.
Exit	♦ Cierra todas las ventanas y sale del programa preguntando si deben grabarse los cambios realizados.

MENÚ EDIT	
Undo	♦ Deshace el efecto de la operación de edición más reciente
Cut	♦ Borra la selección y la coloca en el Clipboard de Windows
Copy	♦ Copia la selección en el Clipboard de Windows
Paste	♦ Coloca el material residente en el Clipboard de Windows en la zona seleccionada
Delete	♦ Borra la selección
Find	♦ Encuentra una cadena de caracteres en un texto
Replace	♦ Reemplaza determinadas cadenas de caracteres en un texto
Next	♦ Ejecuta la siguiente operación de búsqueda según la condición de búsqueda previa
Merge	♦ Hace aparecer en un fichero en el programa, modelo o sistema

MENÚ OBJECTS	
New Object	♦ Crea un nuevo objeto del que se nos preguntará el tipo y el nombre.
Fetch	♦ Es la operación contraria a Store y de efecto similar a Import del menú File. Su utilidad es recuperar un objeto guardado en formato Base de Datos E-Views (*.db*) de un disco.
Store	♦ Es la operación contraria a Fetch y de efecto similar a Export del menú File. Su utilidad es grabar un objeto en formato Base de Datos E-Views (*.db*) en un disco.

Tabla N° 2.4 Menús de Eviews

2.4.5 EL OBJETO PRINCIPAL: LA SERIE DE DATOS

Para el usuario no familiarizado con el manejo del programa E-Views ni con la práctica econométrica, puede resultarle difícil hacerse una idea clara de la naturaleza de cada uno de los objetos mencionados anteriormente. Por el

momento, basta con acercarse al más común y necesario de todos ellos: la serie de datos. Efectivamente, de todos los tipos de objetos que se agrupan en un fichero de trabajo, el más importante, sin duda, es la serie de datos. En definitiva, la práctica econométrica que me interesa desarrollar consiste en encontrar relaciones causales entre unas variables explicativas y otras explicadas; pues bien, cada una de esas “variables” se almacenarán en una serie temporal (valores de la variable a lo largo de una serie de años, meses, trimestres) o transversal (valores de la variable a lo “ancho” de un conjunto de individuos, países, provincias, Comunidades Autónomas).

	0	1	2	3	4
	Last updated: 04/16/97 - 15:44				
1960					6345.809
1965	6827.242	7470.836	7836.631	8437.910	9119.375
1970	9609.420	10356.32	11421.21	12287.83	12701.17
1975	12993.43	13887.16	14261.75	14567.73	14555.79
1980	14426.46	14454.54	14620.31	14881.17	15045.35
1985	15753.53	16492.11	17626.02	18626.47	19629.52
1990	20199.91	20792.52	21328.86	20845.81	21268.64
1995	21785.87	22384.77	NA	NA	

Gráfico N° 2.14 Serie de datos de una variable

Una vez introducidos los valores de cada una de las series de datos que se utilizarán, esta quedará almacenada como un objeto, admitiendo como ya se conoce distintas vistas: vistas de hoja de cálculo (como la que se muestra en la ilustración), vista de gráfico de barras o líneas, vista de histograma y estadísticos básicos, vista de tabla de frecuencias, vista de su correlograma, vista de su test de raíces unitarias o vista de su etiqueta.

Cada una de estas vistas es accesible utilizando el comando views bien del menú general bien de la barra de comandos propia de la ventana activa. Cuando se cambia de vista, no se crean objetos nuevos sino que se siempre observando el mismo objeto de diferentes maneras (salvo que el usuario lo solicite congelando la imagen con el comando “freeze”).

En la siguiente lustración se muestran para la serie de ejemplo cuatro vistas alternativas.

Diferentes vistas (Views) para una misma serie de datos

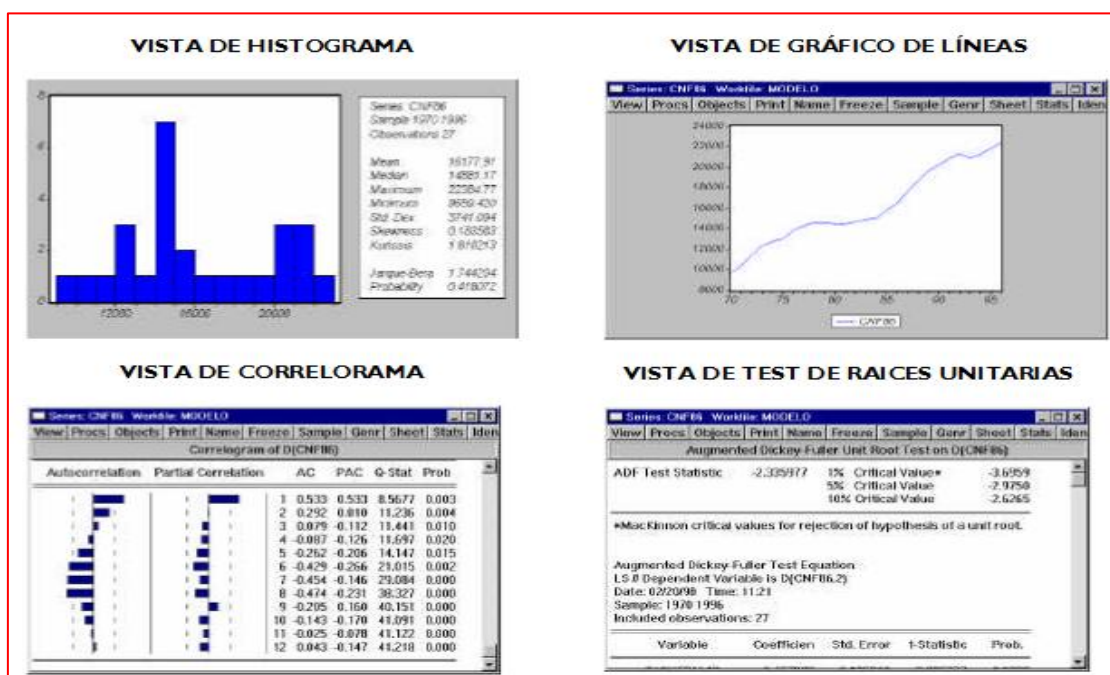


Gráfico N° 2.15

Cada una de las vistas de una serie de datos tiene, obviamente, una utilidad diferente y comprender cada una de ellas sólo es posible cuando se tiene cierto conocimiento sobre los procedimientos y técnicas de la práctica econométrica.

Una serie admite, además de distintas vistas, ser sometida a distintos procedimientos. Una vez más, el significado de cada uno de ellos requiere tener conocimientos de estadística y econometría lo cual se explicó al inicio del capítulo.

Con el marco teórico expuesto se comenzará a realizar los cálculos de la presente tesis los cuales se presentan en los siguientes capítulos.

CAPÍTULO III

EVALUACIÓN DEL ACTUAL MODELO

En el presente estudio se ha considerado el modelo econométrico de corrección de errores con período mensual, que se viene utilizando actualmente. Se propone estimar las ventas de Energía Eléctrica con el método econométrico para las series en frecuencia mensual.

Luego se procederá a estimar las ventas de energía eléctrica anuales con el modelo econométrico. A partir de los resultados del modelo en frecuencia mensual se tomarán estos datos para proyectar las ventas en frecuencia anual.

Finalmente, comenzamos a validar y contrastar los modelos para determinar si el modelo presenta un buen grado de bondad. Esto se verificará a través de los estadísticos ya mencionados en capítulos anteriores.

3.1 MÉTODO ECONOMETRICO

Los modelo de pronóstico causales (como por ejemplo el econométrico), parten del supuesto que el grado de las variables afectan al comportamiento del mercado permanece estable, para luego construir un modelo que relacione ese comportamiento con las variables que se estima son las causantes de los cambios que se observan en el mercado.

Se puede señalar tres etapas para el diseño de un modelo:

- La identificación de una o más variables respecto a las que se pueda presumir que influyen sobre la demanda, como por ejemplo el producto bruto interno, número de clientes, la tasa de natalidad, la población, tarifas, etc.
- La selección de la forma de la relación que vincule a las variables causales con el comportamiento del mercado, normalmente en la forma de una ecuación matemática de primer grado; y
- La validación del modelo de pronóstico, de manera que satisfaga tanto el sentido común como las pruebas estadísticas, a través de la representación adecuada del proceso que describa.

Es frecuente encontrar en los estudios empíricos y en la teoría macroeconómica la afirmación de que la demanda de un bien o servicio depende de muchas causas o factores que explicarían su comportamiento a través del tiempo en un momento específico de él.

Las causales explicativas se definen como variables independientes y la cantidad demandada, u otro elemento del mercado que se desea proyectar, se define como variable dependiente. La variable dependiente, en consecuencia, se explica por la

variable independiente. El análisis de regresión permite elaborar un modelo de pronóstico basado en estas variables, el cual puede tener desde una hasta “n” variables independientes.

De acuerdo con lo indicado, la proyección de las ventas de energía aplicando el método econométrico tomaría en cuenta las siguientes etapas generales:

- a) Selección de las variables independientes o explicativas para el modelo econométrico. Variables tales como las series de tiempo de Cantidad de usuarios, series de PBI, etc.
- b) Procesamiento de las variables de entrada para su uso como parte del modelo.
- c) Definición del modelo matemático para la realización de la proyección.
- d) Verificación de la validez de los modelos definidos, empleando para ello estadísticos de pruebas adecuados.
- e) Proyección definitiva de las ventas de energía globales.

Respecto a los criterios estadísticos, la construcción del modelo se basará en los indicadores estándares de correlación estadística, coeficiente de determinación, relevancia de las variables individualmente (t-student), además de las diversas pruebas estadísticas que evalúan el cumplimiento de los supuestos del modelo de regresión lineal, series no estacionarias, errores no autocorrelacionados, homocedasticidad, etc.

Dado el modelo lineal:

$$Y_i = B_0 + B_1 * X_i + u_i$$

Los supuestos del modelo de regresión lineal son:

$E(u_i|X_i) = 0$, la media de los errores es igual a cero para cada valor de X_i .

$Cov(u_i, u_j) = 0$, los errores no están correlacionados o son independientes.

$Var(u_i|X_i) = \sigma^2$, la varianza o dispersión de los errores es constante.

$Cov(u_i, X_j) = 0$, errores no correlacionados con la variable explicatoria X .

$u_i \sim N(0, \sigma^2)$, los errores presentan una distribución normal.

Las principales pruebas son las siguientes:

R^2 : Coeficiente de determinación

R^2_a : R^2 Ajustado.

T: t-student (prueba de significancia de la variable)

CUSUM 2: Estabilidad de los parámetros

DW: Durbin Watson (test de autocorrelación de primer orden)

ADF: Dick-Fuller Aumentado (test de estacionariedad)

3.2 PRESENTACIÓN Y EVALUACIÓN DE LOS DATOS UTILIZADOS

3.2.1 VARIABLES DEL MODELO ECONÓMICO

En el proceso de investigación y de la implementación empírica propiamente dicha, el primer paso llevado a cabo fue la recolección y evaluación de la información estadística disponible. Luego de realizado el análisis de los datos, las fuentes y las comparaciones respectivas, se ha llegado a la

conclusión que el sector eléctrico peruano no cuenta con un sistema uniforme de estadísticas y, que los datos disponibles (salvo los más recientes) son inconsistentes y de escasa confiabilidad. Esto hace ver la necesidad de realizar esfuerzos conducentes a la implementación de bases de datos de mejor calidad, con el propósito de evaluar diferentes aspectos de las ventas eléctricas. Entre las variables se tiene variables dependientes y variables independientes.

3.2.2 VARIABLES DEPENDIENTES

3.2.2.1 VENTAS DE ENERGÍA ELÉCTRICA (MWH)

Existen varias entidades gubernamentales que se encargan de recopilar dicha información, por lo que se tuvo especial consideración al momento de trabajar la serie.

Para el cálculo de las ventas de electricidad del departamento de Lima se obtuvo mediante la suma de las ventas de energía eléctrica registradas por las empresas Luz del Sur S.A.A.¹ y Edelnor S.A.A.² Luz del Sur elabora un registro total incluyendo a la empresa eléctrica Edecañete S.A.

La serie de ventas con frecuencia Anual se elaboró en base a la información desde el año 1994 provista por la Gerencia Adjunta de Regulación Tarifaria (GART)-OSINERGMIN.

En relación a los datos en frecuencia Mensual, ha sido posible encontrar información de las ventas mensuales de energía en GWh desde el año 1994 en base a la información provista por la GART-OSINERGMIN.

Esta información hace posible estimar modelos comparables con las proyecciones realizadas por las concesionarias para la demanda de electricidad del departamento de Lima.

Una característica de la serie de ventas mensual es el quiebre sufrido por la misma en 1997, año en el que tres grandes generadores que hasta aquel momento se encontraban aislados de los sistemas interconectados se incorporaron al Sistema Eléctrico Interconectado Nacional (SEIN) pudiendo reflejarse para el Departamento de Lima.

¹Volumen 9. Cálculo del peaje correspondiente al sistema eléctrico a remunerar de transmisión secundaria y complementaria de Luz del Sur. Período 2009-2014. Luz del Sur S.A.A.


²Estudio de Planeamiento del Sistema Eléctrico de Transmisión de Edelnor S.A. Proyección de la Demanda. Año 2012. Edelnor S.A.A. Lima, Perú.

HISTÓRICO DE VENTAS DE ENERGÍA ELÉCTRICA MWH (1994-2012)

Tabla N° 3.1

Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1994	416593	445946	467987	449613	476088	469737	475912	486538	470502	471438	478799	477847
1995	485140	440994	490697	455252	481840	466778	482037	488835	478171	485573	471648	482035
1996	502452	462298	465670	470332	484267	467613	492041	497553	484452	497079	494831	479467
1997	507661	485858	495821	531176	543733	521586	516438	546034	524519	550429	550842	527501
1998	565068	558655	568798	578604	575893	545620	550123	564793	560950	564754	557289	549373
1999	571292	548397	563439	583992	570625	545505	566415	566429	574023	569903	581798	578520
2000	587736	589225	605380	589671	594967	595236	578908	596136	606793	589950	610370	585516
2001	591397	595807	615775	587664	602903	589219	594605	589953	600874	594520	591609	594849
2002	620936	617630	626164	653549	638890	621379	632395	636256	631519	639547	635711	626336
2003	640537	641687	648915	634550	637572	628440	632597	620121	634493	658549	652415	633888
2004	656255	651647	654224	680401	651676	657561	674367	666033	677335	686846	696998	701139
2005	701448	693254	697789	728480	726471	706367	712412	698875	724163	725655	741644	751438
2006	755823	764364	766241	772403	753387	759015	760576	760985	786796	785979	802411	801932
2007	804634	824049	804428	829414	792853	811938	793293	802717	829335	822729	828390	833663
2008	852609	894280	871729	899768	868460	851106	842584	876876	878469	888416	879546	872681
2009	896889	907040	892969	920873	896184	858246	855755	899163	907666	908039	914790	919099
2010	931992	950537	965992	995395	948871	944477	930449	959064	975967	958235	982995	989662
2011	1011192	1017571	1022882	1047875	1017355	1007130	978847	995079	1028294	1015942	1039378	1059040
2012	1052605	1093615	1101591	1129758	1063367	1053295	1041041	1071809	1057867	1069200	1104700	1136500

Fuente: Osinergmin-GART³³En el anexo bibliográfico se detalla la fuente de los libros de la Gerencia de Fiscalización Eléctrica.



Gráfica N° 3.1 Evolución de las Ventas de Energía Eléctrica

3.2.3 VARIABLES INDEPENDIENTES

3.2.3.1 PRODUCTO BRUTO INTERNO (Soles constantes de 1994)

Si se desea tener un modelo que reproduzca correctamente el comportamiento de las ventas de electricidad, lo mejor sería tener una serie del PBI para el ámbito geográfico de dicho sistema, por lo que es necesario obtener el PBI departamental. Sin embargo, esta información dejó de publicarse el año 2000, no existiendo datos confiables para años recientes. Algunas instituciones⁴ han realizado estimaciones para dividir el PBI del Perú en 24 departamentos.

Estas estimaciones difieren considerablemente entre sí, aun para departamentos de los cuales se posee importante cantidad de información. Este factor, sumado al hecho de no poseer una serie extensa, llevó a la decisión de utilizar el PBI global de la economía peruana.

El indicador de actividad económica de mayor confiabilidad es el PBI con año base 1994, publicado por el Banco Central de Reserva del Perú (BCRP) en frecuencia mensual y en frecuencia anual.

⁴Tales como el Instituto Cuanto y Apoyo Consultoría. Esta última institución efectuó el cálculo del PBI departamental en las últimas fijaciones tarifarias.


Por ejemplo, el PBI para el departamento de Lima estimado por Apoyo para el 2000 superior en cuatro por ciento aproximadamente al calculado por Cuanto, mientras que el PBI de Arequipa para el mismo año es un 26 por ciento inferior.

HISTÓRICO DEL PRODUCTO BRUTO INTERNO (INDICE 1994=100) (1994-2012)

Tabla N° 3.2

Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1994	91,9	90,3	99,3	100,0	106,1	103,5	99,5	100,2	98,3	100,0	102,9	108,1
1995	105,2	101,4	108,1	109,1	121,2	113,4	110,8	110,2	102,8	107,2	106,3	107,6
1996	104,9	102,9	107,7	112,5	124,4	115,6	113,7	109,3	105,9	110,1	111,6	117,6
1997	113,7	109,0	111,3	125,2	130,2	123,6	119,4	116,0	116,4	119,2	116,0	128,0
1998	111,7	112,0	118,3	123,1	123,6	122,1	118,2	117,8	114,7	114,3	115,5	126,9
1999	110,2	109,8	117,4	119,7	128,9	124,9	120,7	114,6	115,9	119,3	121,8	128,1
2000	116,1	116,8	128,9	124,3	139,1	131,8	125,1	119,7	112,7	118,7	118,8	121,5
2001	112,8	112,9	120,7	125,8	137,7	127,1	127,0	121,6	115,5	123,9	121,8	129,9
2002	119,3	116,2	122,5	137,4	145,3	133,2	133,0	125,9	124,6	128,2	129,2	136,0
2003	127,2	123,8	130,9	142,9	149,2	142,9	136,9	128,9	127,9	134,3	130,3	138,5
2004	130,9	128,8	138,1	147,7	154,6	146,3	142,4	135,8	134,8	138,7	143,8	151,9
2005	138,3	139,2	144,3	157,5	165,5	156,3	150,8	145,9	144,2	148,0	155,5	163,9
2006	146,4	146,6	161,1	163,9	176,5	166,8	162,7	161,3	155,3	163,0	167,0	178,9
2007	161,1	159,3	172,8	176,8	193,1	178,8	178,3	173,0	171,1	180,6	181,3	197,0
2008	179,3	179,7	184,8	201,6	209,3	202,0	197,0	191,3	190,9	197,2	191,7	206,3
2009	184,7	179,9	189,6	198,1	210,4	197,1	194,6	190,3	191,0	200,4	198,9	216,5
2010	191,7	190,2	206,4	216,4	229,1	220,6	212,6	207,8	210,7	217,4	219,2	235,8
2011	211,3	206,0	222,9	233,3	246,1	232,6	226,4	223,8	223,1	229,0	230,5	249,9
2012	221,8	220,3	235,2	243,7	263,2	250,4	243,8	238,4	235,5	245,3	245,2	261,7

Fuente: Banco Central de Reserva del Perú. (BCRP)⁵⁵En el anexo bibliográfico se detalla la fuente.



Gráfica N° 3.2 Evolución del Producto Bruto Interno

3.2.3.2 TARIFA PROMEDIO DE ENERGÍA ELÉCTRICA (Ctm. Sol/kW.h)

Actualmente la GART publica información sobre los precios promedio de energía eléctrica por empresa eléctrica, dato que resulta de la división entre la facturación por las ventas finales de las empresas eléctricas en Nuevos Soles y el volumen de energía vendida en GWh. Además, se tomó el promedio de la tarifa entre las empresas Luz del Sur S.A.A. y Edelnor S.A.A.

De otro lado, la GART tienen series de precios promedio de electricidad con frecuencia mensual desde 1995. Esta serie se construye de la misma forma que la serie anual. La información sobre la tarifa promedio de electricidad se completó para el año 1994 utilizando la tarifa promedio anual reportada por la GART y una serie mensual de la tarifa promedio de electricidad publicada por el Banco Central de Reserva del Perú⁶.

⁶El Banco Central de Reserva publica en su boletín semanal la evolución mensual de la tarifa eléctrica promedio residencial e industrial. Ambas tarifas se promediaron utilizando pesos para estos dos sectores en función al nivel relativo de las ventas de electricidad al mercado residencial y las ventas al mercado industrial y comercial, información que se obtuvo de los anuarios de la GART.


HISTÓRICO DE LA TARIFA PROMEDIO DE ENERGÍA ELÉCTRICA (Ctm.Sol/kW.h) (1994-2012)

Tabla N° 3.3

Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2012	29.06	29.47	30.06	30.34	29.89	29.41	29.55	29.53	29.98	0.00	0.00	0.00
2011	27.93	27.92	27.50	28.04	27.76	27.34	28.06	28.36	28.46	28.61	28.49	28.59
2010	27.20	26.87	27.19	27.73	26.73	26.14	26.77	26.94	26.39	26.64	26.66	26.99
2009	28.13	27.96	28.80	28.91	29.39	29.27	29.07	28.79	27.87	27.38	26.76	26.81
2008	26.12	25.72	25.86	25.36	25.16	24.21	24.61	24.88	23.94	24.76	26.77	27.84
2007	26.29	26.09	26.07	26.33	25.46	25.51	25.72	26.29	26.35	26.12	25.74	26.13
2006	28.42	28.32	28.10	28.45	26.92	26.43	26.93	26.67	27.00	26.82	26.31	26.16
2005	29.06	28.28	28.28	28.43	27.55	27.81	28.41	28.32	28.59	28.81	28.11	28.04
2004	26.78	26.41	26.34	26.60	26.64	26.51	26.99	27.21	26.99	27.05	28.16	29.32
2003	27.69	27.36	27.52	27.29	27.31	27.18	27.09	27.02	26.88	26.70	26.29	26.39
2002	26.15	25.85	25.48	25.49	25.57	25.66	26.45	26.38	26.56	26.91	27.47	27.53
2001	27.85	27.70	28.00	28.25	27.60	27.80	27.95	27.95	28.00	27.45	26.55	26.10
2000	27.17	27.20	27.09	27.63	26.45	26.04	26.30	26.60	27.39	27.10	27.51	27.53
1999	22.71	22.88	23.10	23.57	23.64	25.00	24.88	25.19	26.19	27.20	26.53	26.20
1998	22.49	22.25	21.80	21.86	21.58	21.39	21.96	22.97	21.97	22.29	22.44	23.02
1997	24.52	23.45	24.79	23.43	23.12	23.00	22.99	22.83	22.79	22.74	22.01	21.92
1996	22.76	23.35	23.49	23.34	23.90	24.12	24.36	24.72	24.18	24.64	25.84	25.84
1995	22.36	22.88	22.93	22.80	23.11	23.17	23.40	23.97	23.95	24.29	24.78	24.72
1994	21.97	22.42	22.38	22.26	22.33	22.23	22.44	23.22	23.72	23.95	23.72	23.60

Fuente: GART-OSINERGMIN y BCRP⁷

⁷En el anexo bibliográfico se detalla la fuente.



Gráfica N° 3.3 Evolución de la Tarifa Promedio de Energía Eléctrica

3.2.3.3 NÚMERO DE CLIENTES DE ENERGÍA ELÉCTRICA

Con respecto al número de clientes para el departamento de Lima con frecuencia mensual se consideró la suma de los clientes de las empresas Luz del Sur S.A.A., Edelnor S.A.A. y Edecañete S.A.

La GART publica mensualmente información de las empresas eléctricas en el que se encuentra el número de clientes de electricidad que se construye a partir de la información de las concesionarias desde el año 1996.

Respecto a la serie de clientes de electricidad con frecuencia anual también es publicada por la GART⁸ para el periodo 1993-2012 considerando la suma de los clientes de las empresas eléctricas de Lima.

⁸ La GART publica en sus anuarios el número de clientes de electricidad por empresa eléctrica los cuales se detallan en la bibliografía.


HISTÓRICO DEL NÚMERO DE CLIENTES DE ENERGÍA ELÉCTRICA (1994-2012)

Tabla N° 3.4

Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1995												1179511
1996	1289889	1304992	1319769	1322088	1328625	1337780	1345638	1356956	1297922	1375330	1385645	1391881
1997	1402967	1380840	1415833	1413853	1421308	1425221	1435597	1432958	1412235	1436692	1441051	1444007
1998	1448395	1446477	1453427	1454418	1455442	1456036	1460455	1464540	1468226	1469069	1470091	1476242
1999	1481296	1485492	1493875	1499065	1497864	1499059	1503232	1505697	1509388	1513458	1511586	1519558
2000	1522198	1525676	1530172	1531626	1535208	1536960	1539314	1541980	1545555	1549817	1552195	1553820
2001	1520983	1526255	1529747	1532143	1533825	1536442	1538523	1539634	1542555	1544827	1546829	1549475
2002	1552921	1555531	1558582	1561003	1563190	1565225	1568179	1570772	1573212	1574506	1575139	1576406
2003	1579282	1581249	1583331	1585182	1587005	1588574	1589055	1590278	1592526	1594863	1597066	1599253
2004	1603149	1606273	1609086	1612130	1615347	1618821	1622772	1625743	1628508	1630899	1633225	1635922
2005	1638434	1638941	1639869	1641349	1643730	1646955	1650265	1653572	1657201	1660961	1663155	1666130
2006	1670053	1673472	1676933	1680788	1683995	1687300	1690824	1694398	1698161	1702127	1707128	1711704
2007	1716391	1721874	1725969	1729891	1736909	1742150	1746768	1751179	1755363	1759840	1762198	1767923
2008	1772897	1777723	1782322	1788887	1794253	1800224	1805845	1812801	1818411	1826033	1831330	1836047
2009	1842180	1847334	1852204	1857227	1861586	1865996	1870023	1873635	1877006	1882524	1894733	1900588
2010	1899528	1903211	1907276	1913401	1918333	1923429	1928375	1934198	1940294	1945843	1951374	1957824
2011	1965055	1971370	1977429	1983694	1989997	1997550	2003727	2011417	2017614	2024826	2031128	2038499
2012	2044700	2051500	2057500	2065800	2071300	2079300	2085900	2092900	2100900	2111200	2138900	2150700

Fuente: GART-OSINERGMIN⁹

⁹En el anexo bibliográfico se detalla la fuente.



Gráfica N° 3.4 Evolución del número de clientes de Energía Eléctrica

3.3 ESPECIFICACIÓN DEL MODELO ECONÓMICO MENSUAL

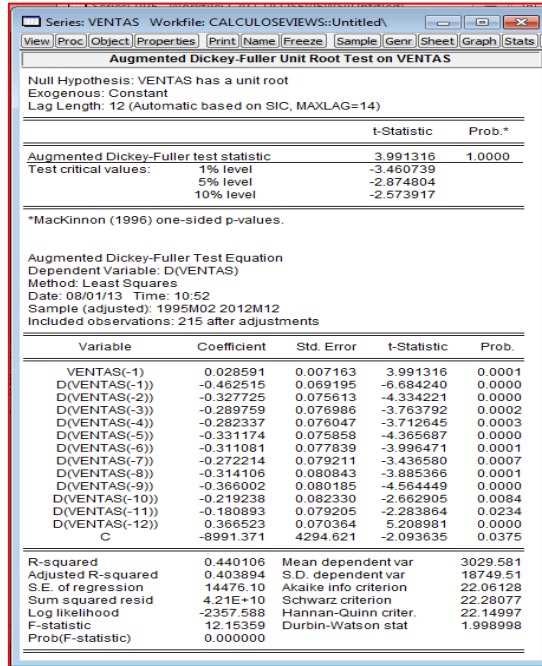
La especificación funcional del modelo se inicia considerando que las variables socioeconómicas explicativas de las ventas de Lima son:

- El PBI del departamento de Lima.
- El número de clientes de electricidad.
- La tarifa eléctrica promedio en Lima.

3.3.1 ANÁLISIS DE ESTACIONARIEDAD

Se analiza la estacionariedad en sus formas naturales (en niveles) o transformadas, mediante las pruebas de Dickey–Fuller Aumentado (ADF), explicadas en el capítulo anterior.

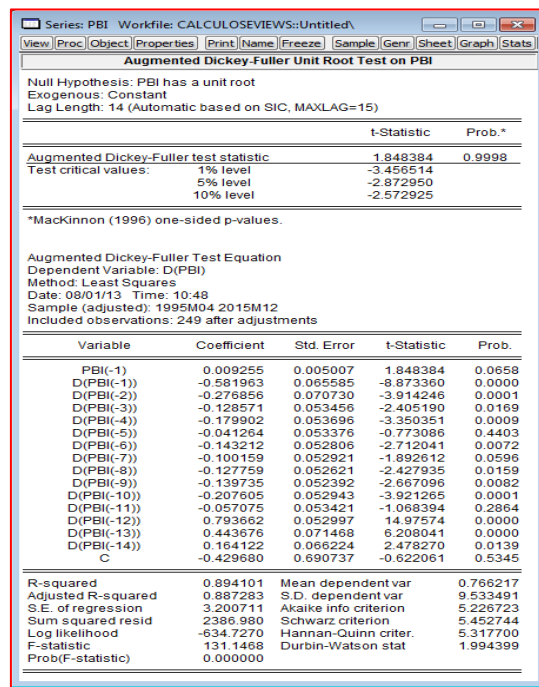
a. Análisis de la serie Ventas de Energía Eléctrica



Gráfica N° 3.5 Prueba Dickey-Fuller Aumentado-Ventas

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo no es estacionaria esto se debe porque la probabilidad es 1 (se acepta la hipótesis nula) y presenta raíz unitaria. Por lo que deberá aplicar una transformación a la siguiente serie Ventas de Energía Eléctrica.

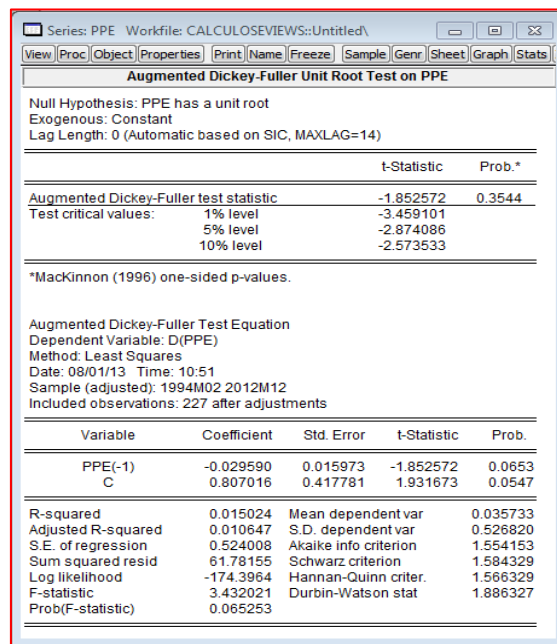
b. Análisis del Producto Bruto Interno (PBI)



Gráfica N° 3.6 Prueba Dickey Fuller Aumentado-PBI

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo no es estacionaria esto se debe porque la probabilidad es aproximadamente 1 (se acepta la hipótesis nula) y presenta raíz unitaria. Por lo que deberá aplicar una transformación a la siguiente serie PBI.

c. Análisis de la Tarifa eléctrica promedio de Lima



Gráfica N° 3.7 Prueba Dickey Fuller Aumentado-Tarifa

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo no es estacionaria esto se debe porque la probabilidad es aproximadamente 0.3544 (se acepta la hipótesis nula) y presenta raíz unitaria. Por lo que deberá aplicar una transformación a la siguiente serie Tarifa eléctrica promedio de Lima.

d. Análisis del número de clientes de electricidad en Lima

Series: USUARIOS Workfile: CALCULOSEVIEWS:Untitled

View Proc Object Properties Print Name Freeze Sample Genr Sheet Graph Stats

Augmented Dickey-Fuller Unit Root Test on USUARIOS

Null Hypothesis: USUARIOS has a unit root
Exogenous: Constant
Lag Length: 14 (Automatic based on SIC, MAXLAG=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	4.922215	1.0000
Test critical values:		
1% level	-3.462901	
5% level	-2.875752	
10% level	-2.574423	

*Mackinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(USUARIOS)
Method: Least Squares
Date: 08/01/13 Time: 10:55
Sample (adjusted): 1996M04 2012M12
Included observations: 201 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
USUARIOS(-1)	0.010975	0.002230	4.922215	0.0000
D(USUARIOS(-1))	-0.280293	0.072679	-3.856568	0.0002
D(USUARIOS(-2))	-0.038890	0.079224	-0.490888	0.6241
D(USUARIOS(-3))	0.010626	0.072398	0.146770	0.8835
D(USUARIOS(-4))	0.004336	0.008333	0.520332	0.6035
D(USUARIOS(-5))	0.007039	0.004385	1.605269	0.1101
D(USUARIOS(-6))	0.006149	0.004360	1.410445	0.1601
D(USUARIOS(-7))	0.008598	0.004316	1.992074	0.0478
D(USUARIOS(-8))	0.009109	0.004364	2.087135	0.0382
D(USUARIOS(-9))	-0.047872	0.004357	-10.99672	0.0000
D(USUARIOS(-10))	0.054492	0.005489	9.927828	0.0000
D(USUARIOS(-11))	0.017817	0.006708	2.655974	0.0086
D(USUARIOS(-12))	0.009909	0.006907	1.434587	0.1531
D(USUARIOS(-13))	0.006647	0.006820	0.974571	0.3310
D(USUARIOS(-14))	-0.015694	0.004296	-3.653503	0.0003
C	-13525.39	3528.298	-3.833404	0.0002

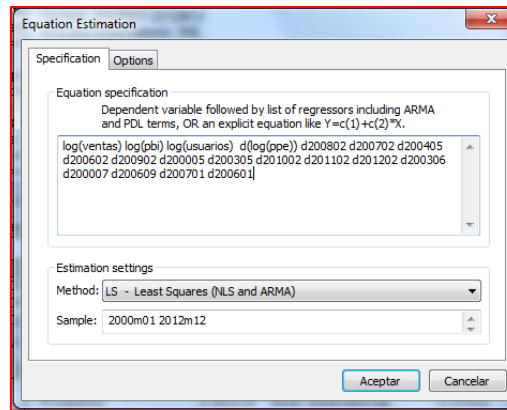
R-squared	0.698379	Mean dependent var	4133.985
Adjusted R-squared	0.673923	S.D. dependent var	8713.037
S.E. of regression	4975.417	Akaike info criterion	19.93866
Sum squared resid	4.58E+09	Schwarz criterion	20.20161
Log likelihood	-1987.835	Hannan-Quinn criter.	20.04506
F-statistic	28.55684	Durbin-Watson stat	1.746892
Prob(F-statistic)	0.000000		

Gráfica N° 3.8 Prueba Dickey Fuller Aumentado-Clientes

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo no es estacionaria esto se debe porque la probabilidad es 1 (se acepta la hipótesis nula) y presenta raíz unitaria. Por lo que deberá aplicar una transformación a la siguiente serie número de clientes de electricidad en Lima.

3.4 ESTIMACIÓN DE LOS PARÁMETROS MENSUALES

A continuación se realizará una regresión multivariada con la cual se busca obtener una mejor explicación. Correr la regresión multivariada. Seleccionar Quick / Estimate Equation del menú principal e ingresando la ecuación como se muestra en el siguiente gráfico:



Gráfica N° 3.9 Estimación de la ecuación MET_1_MENSUAL

El resultado de la regresión se presenta en el siguiente cuadro:

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.500690	0.011450	43.72861	0.0000
LOG(USUARIOS)	0.765677	0.004079	187.6979	0.0000
D(LOG(PPE))	0.288851	0.130812	2.208141	0.0289
D200802	0.090189	0.028589	3.154724	0.0020
D200702	0.091051	0.028526	3.191880	0.0018
D200405	-0.082432	0.028501	-2.892196	0.0044
D200602	0.078014	0.028533	2.734163	0.0071
D200902	0.071838	0.028522	2.518646	0.0129
D200005	-0.068527	0.029143	-2.351399	0.0201
D200305	-0.072713	0.028510	-2.550469	0.0118
D201002	0.069733	0.028577	2.440189	0.0159
D201102	0.067517	0.028565	2.363650	0.0195
D201202	0.071318	0.028662	2.488228	0.0140
D200306	-0.064787	0.028540	-2.270070	0.0248
D200007	-0.060262	0.028650	-2.103391	0.0372
D200609	0.062320	0.028542	2.183465	0.0307
D200701	0.060348	0.028503	2.117250	0.0360
D200601	0.064173	0.028570	2.246166	0.0263
R-squared	0.982234	Mean dependent var	13.55953	
Adjusted R-squared	0.980045	S.D. dependent var	0.201022	
S.E. of regression	0.028397	Akaike info criterion	-4.176923	
Sum squared resid	0.111279	Schwarz criterion	-3.825017	
Log likelihood	343.8000	Hannan-Quinn criter.	-4.033994	
Durbin-Watson stat	1.673450			

Gráfica N° 3.10 Resultados de la Regresión MET_1_MENSUAL

Se puede comprobar en la imagen que la información básica que suministra está dividida en tres grandes bloques:

Un primer bloque, que aparece en la parte superior, y donde se recogen las características generales de la estimación realizada, comenzando con la variable dependiente, el método de estimación utilizado, mínimos cuadrados ordinarios (Least Squares), la fecha en la que se ha realizado la estimación, el período muestral utilizado y el tamaño muestral real (Included Observations)

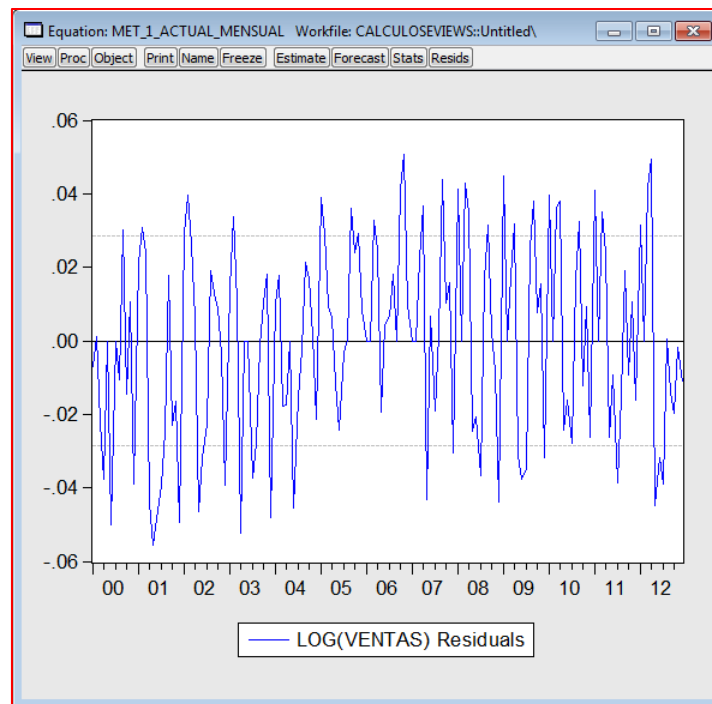
El segundo bloque recoge la información individual sobre cada una de las variables explicativas, incluyendo el nombre de la variable, el valor de coeficiente estimado (Coefficient), la desviación típica de dicho coeficiente estimado (Std. Error), el valor del estadístico t de Student (t-Statistic), y la probabilidad asociada a dicho estadístico (Prob.).

Finalmente, el tercer bloque recoge una serie de estadísticos conjuntos de la estimación realizada, comenzando, en la columna de la derecha, con el coeficiente de determinación y su equivalente corregido por los grados de libertad (R-squared y Adjusted R-squared), el valor estimado de la desviación típica del error, la suma cuadrática de residuos (Sum squared residual), el valor final del logaritmo de máxima verosimilitud (Log likelihood) y el estadístico de Durbin Watson (Durbin-Watson stat). En la columna de la izquierda aparece el valor medio y la desviación típica de la variable endógena (Mean y S.D. dependen var), los criterios de selección de Akaike y Schwartz (Akaike y Schwartz criterion) y los valores del estadístico de contraste de significación conjunta (F-statistic) y su correspondiente nivel de probabilidad asociado (Prob.).

A continuación realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente que, si bien el coeficiente asociado a la variable del PBI presenta un signo positivo (0.5) acorde con la teoría económica, también sucede lo mismo con la variable de tarifa promedio eléctrica (PPE), ya que presenta un signo positivo (0.28) y la variable usuarios (0.76). Además, como puede comprobarse por los valores del estadístico t (con valores de 43.72 para el PBI y 187.69 para la serie usuarios) ambas variables resultan significativas existiendo una probabilidad nula (Prob = 0.000) de rechazar la hipótesis nula siendo cierta.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 98.22% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin Watson (1.67), como es mayor a 1.53 el modelo parece no presentar problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Si errores positivos son seguidos de errores positivos y errores negativos por errores de igual signo, entonces estamos en presencia de autocorrelación positiva. Para ello se debe presionar: View y luego seleccionar Actual Fitted Residual / Residual Graph.



Gráfica N° 3.11 Evaluación de los residuos MET_1_MENSUAL

Se observa que el error residual se encuentra en un orden de ± 0.06 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

En términos generales, podríamos admitir que el modelo considerado está bien especificado, ya que los signos de los coeficientes no presentan problemas, presenta una buena representatividad global y no presenta indicios de autocorrelación residual.

Del Programa E-Views mostrará la especificación de la ecuación bajo tres formatos alternativos, como los que presentamos, comenzando con el comando de estimación, y siguiendo con la especificación algebraica genérica y la correspondiente una vez estimados los coeficientes.

Estimation Command:

=====

```
LS LOG(VENTAS) LOG(PBI) LOG(USUARIOS) D(LOG(PPE)) D200802 D200702 D200405
D200602 D200902 D200005 D200305 D201002 D201102 D201202 D200306 D200007 D200609
D200701 D200601
```

Estimation Equation:

=====

$$\begin{aligned} \text{LOG(VENTAS)} = & C(1)*\text{LOG(PBI)} + C(2)*\text{LOG(USUARIOS)} + C(3)*\text{D(LOG(PPE))} + C(4)*\text{D200802} + \\ & C(5)*\text{D200702} + C(6)*\text{D200405} + C(7)*\text{D200602} + C(8)*\text{D200902} + C(9)*\text{D200005} + C(10)*\text{D200305} \\ & + C(11)*\text{D201002} + C(12)*\text{D201102} + C(13)*\text{D201202} + C(14)*\text{D200306} + C(15)*\text{D200007} + \\ & C(16)*\text{D200609} + C(17)*\text{D200701} + C(18)*\text{D200601} \end{aligned}$$

LOG(VENTAS): Logaritmo de la serie Ventas de electricidad del departamento de Lima.

LOG(PBI): Logaritmo de la serie Producto Bruto Interno.

LOG(USUARIO): Logaritmo de la serie Usuario de electricidad.

D(LOG(PPE)): Primera diferencia en logaritmos de la tarifa promedio de electricidad.

D200802: Intervención de la variable dummy en el mes de febrero del 2008.

D200702: Intervención de la variable dummy en el mes de febrero del 2007.

D200405: Intervención de la variable dummy en el mes de mayo del 2004.

D201202: Intervención de la variable dummy en el mes de febrero del 2012.

Substituted Coefficients:

```

=====
LOG(VENTAS) = 0.5006904924*LOG(PBI) + 0.765677132471*LOG(USUARIOS) +
0.288850639914*D(LOG(PPE)) + 0.0901892746265*D200802 + 0.0910509111718*D200702 -
0.0824317704994*D200405 + 0.078013918312*D200602 + 0.0718378139544*D200902 -
0.0685272005561*D200005 - 0.0727131025523*D200305 + 0.0697334590534*D201002 +
0.0675172787877*D201102 + 0.0713180475571*D201202 - 0.0647874260535*D200306 -
0.0602624402348*D200007 + 0.0623201010072*D200609 + 0.0603475754794*D200701 +
0.0641731784804*D200601
    
```

3.5 CONTRASTE O VALIDACIÓN

3.5.1 PRUEBA DE HETEROSCEDASTICIDAD DE WHITE

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.039012	0.016547	2.357669	0.0198
(LOG(PBI))^2	0.000254	0.000109	2.329518	0.0213
(LOG(USUARIOS))^2	-0.000217	9.36E-05	-2.321838	0.0217
(D(LOG(PPE)))^2	-0.124342	0.094904	-1.310193	0.1923
D200802^2	-0.000836	0.000737	-1.135060	0.2583
D200702^2	-0.000743	0.000737	-1.006948	0.3157
D200405^2	-0.001071	0.000745	-1.436019	0.1533
D200602^2	-0.000714	0.000739	-0.966777	0.3354
D200902^2	-0.000622	0.000742	-0.838643	0.4031
D200005^2	-0.000880	0.000761	-1.156487	0.2495
D200305^2	-0.001090	0.000747	-1.458637	0.1470
D201002^2	-0.000569	0.000745	-0.763712	0.4464
D201102^2	-0.000581	0.000747	-0.777591	0.4382
D201202^2	-0.000488	0.000754	-0.647539	0.5184
D200306^2	-0.000972	0.000741	-1.311164	0.1920
D200007^2	-0.000827	0.000740	-1.117768	0.2656
D200609^2	-0.000752	0.000737	-1.020877	0.3091
D200701^2	-0.000796	0.000737	-1.080154	0.2820
D200601^2	-0.000703	0.000738	-0.951629	0.3430

R-squared	0.138499	Mean dependent var	0.000713
Adjusted R-squared	0.025309	S.D. dependent var	0.000743
S.E. of regression	0.000734	Akaike info criterion	-11.48305
Sum squared resid	7.38E-05	Schwarz criterion	-11.11159
Log likelihood	914.6780	Hannan-Quinn criter.	-11.33218
F-statistic	1.223597	Durbin-Watson stat	1.681873
Prob(F-statistic)	0.250796		

Gráfica N° 3.12 Prueba de Heteroscedasticidad MET_1_MENSUAL

Con un probabilidad significativa 25.08% (mayor que 5%), se acepta la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo es decir la serie es estacionaria.

3.5.2 COLINEALIDAD EN VARIABLES EXPLICATIVAS

El análisis de colinealidad permite determinar si cada regresor, inicialmente considerado, guarda independencia lineal o no con los demás regresores. El requisito fundamental para que un modelo sea apropiado para predicciones es la independencia lineal entre variables explicativas.

Correlation				
	LOG(VENTAS)	LOG(PBI)	LOG(USUA...	D(LOG(PPE))
LOG(VENTAS)	1.000000	0.971871	0.985354	0.051641
LOG(PBI)	0.971871	1.000000	0.968230	0.004154
LOG(USUA...	0.985354	0.968230	1.000000	0.054497
D(LOG(PPE))	0.051641	0.004154	0.054497	1.000000

Gráfica N° 3.13 Evaluación de la colinealidad

Se observa independencia lineal entre las variables explicativas. Inicialmente se perfila un modelo regresivo lineal, con las variables en niveles o transformadas, verificando el cumplimiento de los condicionantes estadísticos mediante pruebas estadísticas de significancia y corroboración. La transformación potencial se realiza con la finalidad de minimizar la variabilidad de la data histórica, cuando ésta tiene característica heteroscedástica. En situaciones muy frecuentes se aplica una transformación logarítmica, logrando resultados satisfactorios de estabilidad en varianza.


3.5.3 ESPECIFICACIÓN FUNCIONAL: PRUEBA DE RAMSEY

La prueba Reset de Ramsey permite la comprobación de la correcta especificación polinómica (funcional) de un modelo estimado; es decir, que no se hayan omitido algunos otros regresores que pueden ser potencias o productos cruzados de los regresores ya incluidos en el modelo inicialmente especificado.

Permite identificar si se está usando una forma lineal incorrecta y cualquier error de omisión o la presencia de correlaciones entre las variables explicativas y la perturbación.

Este comando se encuentra en Stability Test/ Ramsey RESET TEST/ clic y aparece el cuadro de diálogos “RESET Specification”, escribimos el número de potencias de la variable endógena ajustada a incluir empezando por el cuadrado; así, si indicamos 1 se añadirá el cuadrado de dicha variable; si ponemos 2 se incluirá el cuadrado y el cubo, etc. Si dejamos en blanco la celda el programa entiende que se añade la variable al cuadrado.

El resultado son las variables de F y χ^2 de razón de verosimilitud junto con la ecuación estimada. Así en Eviews hacemos view / Stability Test/ Ramsey RESET y escribimos en la celda en blanco 1, OK y aparece el cuadro:



Equation: MET_1_ACTUAL_MENSUAL Workfile: CALCUL...				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Ramsey RESET Test:				
F-statistic	16.25078	Prob. F(1,137)	0.2506	
Log likelihood ratio	17.48678	Prob. Chi-Square(1)	0.3972	
Test Equation:				
Dependent Variable: LOG(VENTAS)				
Method: Least Squares				
Date: 08/07/13 Time: 12:11				
Sample: 2000M01 2012M12				
Included observations: 156				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.022867	0.119028	0.192114	0.8479
LOG(USUARIOS)	0.622885	0.035632	17.48085	0.0000
D(LOG(PPE))	0.004198	0.142811	0.029399	0.9766
D200802	0.031542	0.030784	1.024626	0.3073
D200702	0.026983	0.031390	0.859601	0.3915
D200405	-0.012356	0.032151	-0.384324	0.7013
D200602	0.021363	0.030506	0.700292	0.4849
D200902	0.012227	0.030842	0.396424	0.6924
D200005	-0.009724	0.031266	-0.310990	0.7563
D200305	-0.008088	0.031447	-0.257189	0.7974
D201002	0.007796	0.031168	0.250121	0.8029
D201102	0.006185	0.031084	0.198988	0.8426
D201202	0.002985	0.032048	0.093137	0.9259
D200306	-0.012702	0.030007	-0.423288	0.6727
D200007	-0.018783	0.029069	-0.646145	0.5193
D200609	0.020607	0.028994	0.710749	0.4784
D200701	0.020678	0.028782	0.718449	0.4737
D200601	0.018798	0.029355	0.640381	0.5230
FITTED^2	0.024440	0.006063	4.031226	0.0001
R-squared	0.984118	Mean dependent var	13.55953	
Adjusted R-squared	0.982031	S.D. dependent var	0.201022	
S.E. of regression	0.026947	Akaike info criterion	-4.276198	
Sum squared resid	0.099479	Schwarz criterion	-3.904741	
Log likelihood	352.5434	Hannan-Quinn criter.	-4.125328	
Durbin-Watson stat	1.385724			

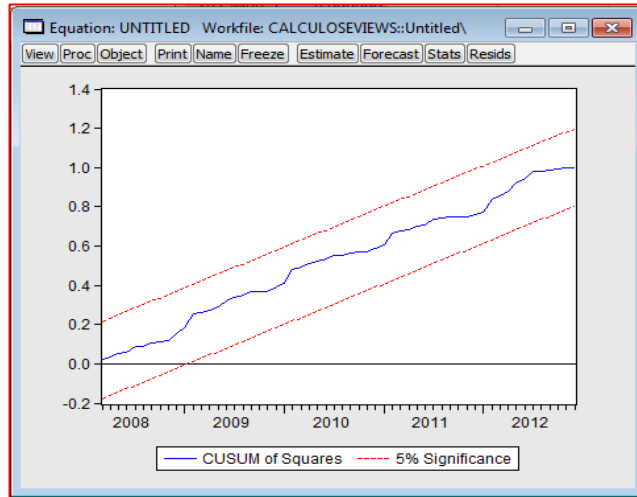
Gráfica N° 3.14 Prueba de Reset MET_1_MENSUAL

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 25,06% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

3.5.4 ESTABILIDAD DE LOS PARÁMETROS

La prueba de residuos recursivos y la prueba de suma acumulada de los residuos normalizados al cuadrado -cusum2-, permiten determinar la existencia de posibles quiebres estructurales en los modelos. Un quiebre estructural es indicativo de que los parámetros de la ecuación de regresión no son constantes a lo largo de toda la muestra. Uno de los supuestos que garantiza la calidad del estimador de mínimos cuadrados ordinarios en el

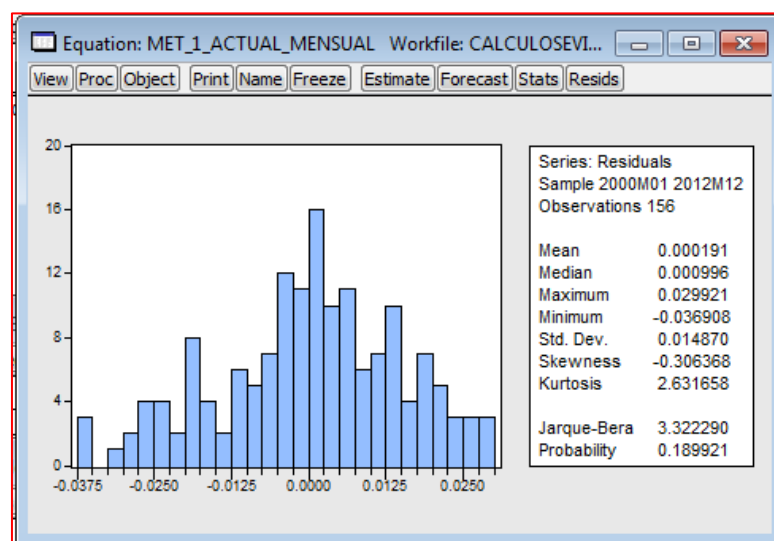
proceso de estimación de un determinado modelo, es precisamente que los parámetros sean constantes (estables); vale decir, que exista un único proceso generador de datos para toda la muestra en análisis.



Gráfica N° 3.15 Evaluación de la estabilidad de parámetros

Se observa que el gráfico no se sale de las bandas de confianza al 5% de significancia, donde comienza a presentarse ligeros quiebres estructurales, lo que se aprecia una estabilidad del modelo.

3.5.5 NORMALIDAD DEL RESIDUO



Gráfica N° 3.16 Evaluación de la Normalidad MET_1_MENSUAL

El test de Jarque-Bera, analiza la relación entre los coeficientes de apuntamiento y curtosis de los residuos de la ecuación y los correspondientes a los de una distribución normal, de forma tal que si estas relaciones son suficientemente diferentes se rechazaría la hipótesis nula de normalidad de los residuos.

Como en otras ocasiones el valor del contraste viene acompañado con el correspondiente nivel de probabilidad asociado al rechazo de la hipótesis nula siendo cierta, de forma tal que si dicho valor de probabilidad fuera inferior al 5%, rechazaríamos la hipótesis nula, con el 95% de confianza, y deberíamos admitir la no normalidad del residuo.

En este caso la probabilidad es de 18.99%, por lo que debemos asumir la hipótesis nula y afirmar que la distribución de residuos es normal.

3.6 ESTIMACIÓN DEL MODELO DE CORRECCIÓN DE ERROR MENSUAL

Siguiendo la metodología de estimación en dos etapas propuesta por Engle y Granger, se debe verificar que el residuo de la expresión anterior sea estacionario para verificar la presencia de cointegración. Una vez determinada la estacionariedad de los residuos se procede a estimar un modelo de corrección de errores, determinado por un modelo de rezagos distribuidos de la forma:

Estimación de los parámetros

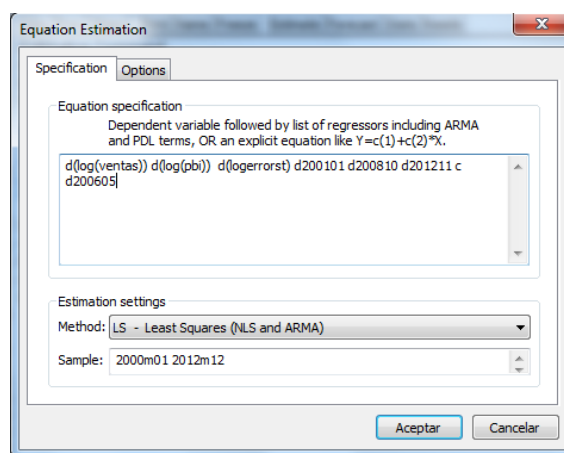
Estimation Equation:

=====

$$D(\text{LOG}(\text{VENTAS})) = C(1)*D(\text{LOG}(\text{PBI})) + C(2)*D(\text{LOGERRORST}) + C(3)*D200101 + C(4)*D200810 + C(5)*D201211 + C(6) + C(7)*D200605$$

$$\begin{aligned} \text{Logerrorst} = & \log(\text{ventas}) - 0.5006904924 * \text{LOG}(\text{PBI}) - 0.765677132471 * \text{LOG}(\text{USUARIOS}) - \\ & 0.288850639914 * \text{D}(\text{LOG}(\text{PPE})) - 0.0901892746265 * \text{D}200802 - 0.0910509111718 * \text{D}200702 + \\ & 0.0824317704994 * \text{D}200405 - 0.078013918312 * \text{D}200602 - 0.0718378139544 * \text{D}200902 \\ & + 0.0685272005561 * \text{D}200005 + 0.0727131025523 * \text{D}200305 - 0.0697334590534 * \text{D}201002 - \\ & 0.0675172787877 * \text{D}201102 - 0.0713180475571 * \text{D}201202 + 0.0647874260535 * \text{D}200306 \\ & + 0.0602624402348 * \text{D}200007 - 0.0623201010072 * \text{D}200609 - 0.0603475754794 * \text{D}200701 - \\ & 0.0641731784804 * \text{D}200601 \end{aligned}$$

Ingresando la ecuación como se muestra en el siguiente gráfico:



Gráfica N° 3.17 Estimación de la ecuación

El resultado de la regresión se presenta en el siguiente cuadro:


Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.344007	0.005781	59.50648	0.0000
D(LOGERRORST)	0.994047	0.010631	93.50231	0.0000
D200101	-0.018568	0.002948	-6.298593	0.0000
D200810	0.010954	0.002920	3.751530	0.0003
D201211	0.011261	0.002923	3.852578	0.0002
C	0.001910	0.000239	7.990997	0.0000
D200605	-0.008454	0.002940	-2.875602	0.0046
R-squared	0.983747	Mean dependent var		0.004254
Adjusted R-squared	0.983088	S.D. dependent var		0.022357
S.E. of regression	0.002908	Akaike info criterion		-8.798931
Sum squared resid	0.001251	Schwarz criterion		-8.661486
Log likelihood	688.9171	Hannan-Quinn criter.		-8.743104
F-statistic	1492.973	Durbin-Watson stat		2.437318
Prob(F-statistic)	0.000000			

Gráfica N° 3.18 Resultados de la Regresión ECONOMETRICST

De la misma manera realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente que, si bien el coeficiente asociado a la variable del PBI presenta un signo positivo (0.34) acorde con la teoría económica. Además puede apreciarse la inserción de la variable dummy d200101 para el mes de enero del 2001, d200810 para el mes de octubre del 2008, d201211 para el mes de noviembre del 2012 y d200605 para el mes de mayo del 2006. Como puede verse, todas las variables tienen el signo esperado y son significativas al 5%.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 98.37% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin Watson (2.43), como es menor a 2.46 el modelo parece no presentar problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Si errores positivos son seguidos de errores positivos y errores negativos por errores de igual signo, entonces estamos en presencia de autocorrelación positiva. Para ello se debe presionar: View y luego seleccionar Actual Fitted Residual / Residual Graph.



Gráfica N° 3.19 Evaluación de los residuos ECONOMETRICST

Se observa que el error residual se encuentra en un orden de +/- 0.008 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

Estimation Command:

```
=====
LS D(LOG(VENTAS)) D(LOG(PBI)) D(LOGERRORST) D200101 D200810 D201211 C D200605
```

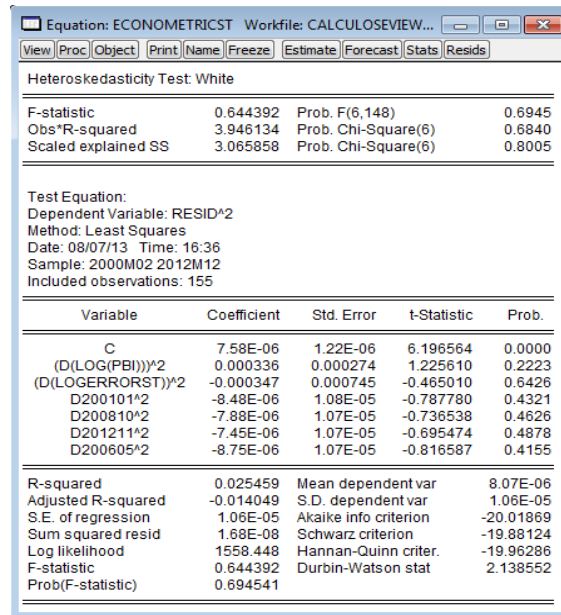
Estimation Equation:

```
=====
D(LOG(VENTAS)) = C(1)*D(LOG(PBI)) + C(2)*D(LOGERRORST) + C(3)*D200101 + C(4)*D200810
+ C(5)*D201211 + C(6) + C(7)*D200605
```

Substituted Coefficients:

```
=====
D(LOG(VENTAS)) = 0.344007209909*D(LOG(PBI)) + 0.994046983538*D(LOGERRORST) -
0.0185684154836*D200101 + 0.0109535902163*D200810 + 0.0112610213602*D201211 +
0.00190967351864 - 0.00845425074748*D200605
```

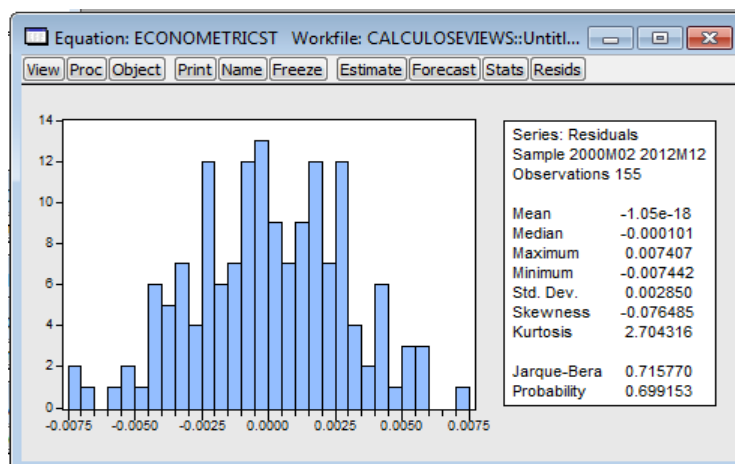
Prueba de Heteroscedasticidad de WHITE



Gráfica N° 3.20 Prueba de Heteroscedasticidad ECONOMETRICST

Con un probabilidad significativa 69.45% (mayor que 5%), no se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo.

Normalidad del Residuo.

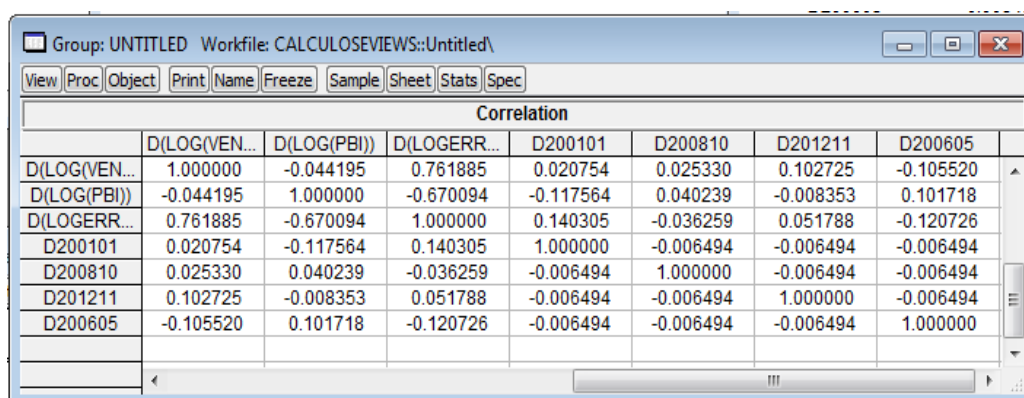


Gráfica N° 3.21 Evaluación de la Normalidad ECONOMETRICST

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 69.91%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

Colinealidad en variables explicativas.

Con el análisis de colinealidad determinaremos si cada regresor, inicialmente considerado, guarda independencia lineal o no con los demás regresores. El requisito fundamental para que un modelo sea apropiado para predicciones es la independencia lineal entre variables explicativas.



Correlation							
	D(LOG(VEN...	D(LOG(PBI))	D(LOGERR...	D200101	D200810	D201211	D200605
D(LOG(VEN...	1.000000	-0.044195	0.761885	0.020754	0.025330	0.102725	-0.105520
D(LOG(PBI))	-0.044195	1.000000	-0.670094	-0.117564	0.040239	-0.008353	0.101718
D(LOGERR...	0.761885	-0.670094	1.000000	0.140305	-0.036259	0.051788	-0.120726
D200101	0.020754	-0.117564	0.140305	1.000000	-0.006494	-0.006494	-0.006494
D200810	0.025330	0.040239	-0.036259	-0.006494	1.000000	-0.006494	-0.006494
D201211	0.102725	-0.008353	0.051788	-0.006494	-0.006494	1.000000	-0.006494
D200605	-0.105520	0.101718	-0.120726	-0.006494	-0.006494	-0.006494	1.000000

Gráfica N° 3.22 Evaluación de la colinealidad

De la misma manera se observa independencia lineal entre las variables explicativas. Si existe causalidad entre ambas variables, las correlaciones cruzadas no deberían perder significancia.

Especificación funcional: Prueba de Ramsey.

A continuación se comprueba si se está usando una forma lineal incorrecta y cualquier error de omisión o la presencia de correlaciones entre las variables explicativas y la perturbación.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.344332	0.005831	59.04992	0.0000
D(LOGERRORST)	0.994249	0.010666	93.22015	0.0000
D200101	-0.018636	0.002958	-6.299101	0.0000
D200810	0.010870	0.002932	3.707751	0.0003
D201211	0.011372	0.002939	3.869939	0.0002
C	0.002011	0.000312	6.444059	0.0000
D200605	-0.008445	0.002947	-2.865004	0.0048
FITTED^2	-0.202614	0.400914	-0.505380	0.6140

R-squared	0.983775	Mean dependent var	0.004254
Adjusted R-squared	0.983002	S.D. dependent var	0.022357
S.E. of regression	0.002915	Akaike info criterion	-8.787763
Sum squared resid	0.001249	Schwarz criterion	-8.630683
Log likelihood	689.0517	Hannan-Quinn criter.	-8.723961
F-statistic	1273.290	Durbin-Watson stat	2.437501
Prob(F-statistic)	0.000000		

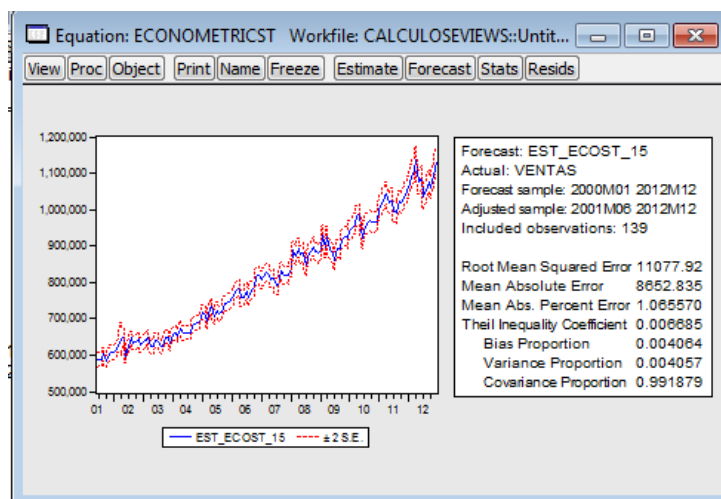
Gráfica N° 3.23 Prueba de Reset ECONOMETRICST

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 61.40% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

Una vez realizadas las operaciones descritas, ya estaríamos en condiciones de resolver el modelo y utilizarlo para obtener predicciones. La realización de predicciones con modelos multiecuacionales consiste en la obtención de una solución del modelo para un período futuro extramuestral. Para poder realizar esta predicción será necesario, por tanto, alimentar el modelo con valores futuros de todas las variables exógenas incluidas en el mismo.

3.7 PROYECCIONES ECONÓMICAS MENSUALES

Predicciones de la Variable Dependiente (Forecast Estatic)




Gráfica N° 3.24 Forecast Estatic- Variable mensual Ventas

Se puede cuantificar los resultados del diagrama de predicción realización mediante el coeficiente de desigualdad o de Theil, y que Eviews muestra de forma automática si seleccionamos la opción de evaluación de la predicción (Forecast Evaluation), donde además del valor total de dicho estadístico (Theil Inequality Coefficient), se muestran, en porcentajes sobre el total, el Error Sistemático (Bias proportion), el Error de Dispersión (Variance Proportion) y el Error de Correlación (Covariance Proportion).

Este es una representación de una predicción estática desde el período 2000:M01 hasta 12012:M12, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.006685, esto da indicciones de una buena predicción.

Predicciones de la Variable Dependiente (Forecast Dynamic)




Gráfica N° 3.25 Forecast Dinamic- Variable mensual Ventas

Este es una representación de una predicción dinámica desde el período 2012:M01 hasta 12015:M12, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.013717, esto da indicciones de una buena predicción.

Proyección de las Ventas de Energía Eléctrica:

Año	Proyección VENTAS ENERGÍA Econométrico (2013-2015)
2013M01	1167957
2013M02	1174432
2013M03	1164222
2013M04	1176913
2013M05	1165191
2013M06	1155269
2013M07	1146644
2013M08	1162104
2013M09	1171299
2013M10	1184898
2013M11	1187083
2013M12	1202067
2014M01	1197461
2014M02	1205041
2014M03	1206250
2014M04	1199618
2014M05	1191843
2014M06	1196050
2014M07	1197142
2014M08	1204995
2014M09	1203611
2014M10	1210566
2014M11	1210727
2014M12	1212880
2015M01	1225835
2015M02	1253019
2015M03	1278708
2015M04	1308968
2015M05	1315128
2015M06	1330195
2015M07	1334843
2015M08	1349032
2015M09	1363821
2015M10	1371502
2015M11	1378042
2015M12	1383296

Tabla N° 3.5



Gráfica N° 3.26 Evolución de la Proyección de Ventas

3.8 RESULTADOS DE LA EVALUACIÓN DEL MODELO ACTUAL MENSUAL

Se observa los resultados de las proyecciones de las ventas de energía eléctrica para el departamento de Lima con el modelo Econométrico mensual. En la tabla se muestra los resultados en frecuencia mensual desde el 2013 al 2015. En la gráfica N° 3.26 se muestra el gráfico de las proyecciones mensuales hasta diciembre de 2015 y en la curva de abajo se observa las ventas de energía eléctrica actuales. Para el cálculo de las ventas de energía se utilizó el modelo de corrección de errores en frecuencia mensual.

3.9 ESPECIFICACIÓN DEL MODELO ECONÓMICO ANUAL

De las ventas de energía eléctrica en series mensuales se calculó las ventas anuales para el período 2013-2015, las que se añadirán a las series anuales y se determinara las ventas de energía eléctrica anuales para el período 2016-2018 a partir de un modelo econométrico de corrección de errores (MCE), utilizando variables explicativas en series anuales tales como: PBI, Población y Tarifa.

Con las variables antes mencionadas se ha construido el siguiente modelo econométrico considerando los supuestos estadísticos correspondientes.

$$\ln(\text{ventas}) = c_0 + m_1 \cdot \ln(\text{clientes}) + m_2 \cdot \ln(\text{PBI}) + m_3 \cdot \ln(\text{Tarifa})$$

$$\ln(\text{error}) = \ln(\text{ventas}) - (c_0 + m_1 \cdot \ln(\text{clientes}) + m_2 \cdot \ln(\text{PBI}) + m_3 \cdot \ln(\text{Tarifa}))$$

3.10 ESTIMACIÓN DE LOS PARÁMETROS ANUALES

A continuación se realizará una regresión multivariada con la cual se busca obtener una mejor explicación.

El resultado de la regresión se presenta en el siguiente cuadro:


Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.560792	0.024056	23.31230	0.0000
LOG(USUARIOS)	0.671027	0.017727	37.85424	0.0000
LOG(PPE)	-0.103610	0.040894	-2.533625	0.0229
D1997	-0.081177	0.016099	-5.042428	0.0001
D96	-0.097829	0.016167	-6.051283	0.0000
D2006	0.032877	0.015514	2.119231	0.0512
D99	-0.030677	0.016204	-1.893218	0.0778
R-squared	0.998342	Mean dependent var	15.98908	
Adjusted R-squared	0.997679	S.D. dependent var	0.312738	
S.E. of regression	0.015066	Akaike info criterion	-5.299424	
Sum squared resid	0.003405	Schwarz criterion	-4.952274	
Log likelihood	65.29366	Hannan-Quinn criter.	-5.217646	
Durbin-Watson stat	1.612299			

Gráfica N° 3.27 Resultados de la Regresión EC3_ECONOMETRIC

De la misma manera realizaremos un análisis de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.57) acorde con la teoría económica. Además puede apreciarse el inserción de las variables dummy para los años 1996, 1997, 1999 y 2006. Como puede verse, todas las variables tienen el signo esperado y son significativas al 5%.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 99.83% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin Watson (1.61), como es mayor a 1.53 el modelo parece no presentar problemas de autocorrelación en los residuos.

Observando el gráfico de los residuos a lo largo del tiempo.



Gráfica N° 3.28 Evaluación de los residuos EC3_ECONOMETRIC

Se observa que el error residual se encuentra en un orden de +/- 0.03 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

Estimation Command:

```
=====
LS LOG(VENTAS) LOG(PBI) LOG(USUARIOS) LOG(PPE) D1997 D96 D2006 D99
```

Estimation Equation:

```
=====
LOG(VENTAS) = C(1)*LOG(PBI) + C(2)*LOG(USUARIOS) + C(3)*LOG(PPE) + C(4)*D1997 +
C(5)*D96 + C(6)*D2006 + C(7)*D99
```

Substituted Coefficients:

```
=====
LOG(VENTAS) = 0.560792250099*LOG(PBI) + 0.671027078745*LOG(USUARIOS) -
0.103610496842*LOG(PPE) - 0.0811770930638*D1997 - 0.0978291117989*D96 +
0.0328773298682*D2006 - 0.0306772913623*D99
```

3.11 CONTRASTE O VALIDACIÓN DEL MODELO ACTUAL ANUAL (MAA)

3.11.1 PRUEBA DE HETEROSCEDASTICIDAD DE WHITE DEL (MAA)

Equation: EC3_ECONOMETRIC Workfile: SERIE_ECONOM...

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Heteroskedasticity Test: White

F-statistic	1.385802	Prob. F(7,14)	0.2851
Obs*R-squared	9.004558	Prob. Chi-Square(7)	0.2523
Scaled explained SS	1.994751	Prob. Chi-Square(7)	0.9601

Test Equation:
 Dependent Variable: RESID^2
 Method: Least Squares
 Date: 08/07/13 Time: 17:33
 Sample: 1994 2015
 Included observations: 22


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.006269	0.003149	1.990969	0.0664
(LOG(PBI))^2	3.03E-05	1.65E-05	1.840428	0.0870
(LOG(USUARIOS))^2	-5.44E-05	2.90E-05	-1.877279	0.0815
(LOG(PPE))^2	6.84E-05	7.91E-05	0.864187	0.4020
D1997^2	-0.000125	0.000127	-0.987268	0.3403
D96^2	-0.000155	0.000126	-1.233893	0.2376
D2006^2	-0.000156	0.000121	-1.289951	0.2180
D99^2	-7.77E-05	0.000131	-0.594060	0.5619

R-squared	0.409298	Mean dependent var	0.000116
Adjusted R-squared	0.113947	S.D. dependent var	0.000124
S.E. of regression	0.000117	Akaike info criterion	-14.99033
Sum squared resid	1.92E-07	Schwarz criterion	-14.59358
Log likelihood	172.8936	Hannan-Quinn criter.	-14.89687
F-statistic	1.385802	Durbin-Watson stat	2.173521
Prob(F-statistic)	0.285129		

Gráfica N° 3.29 Prueba de Heteroscedasticidad EC3_ECONOMETRIC

Con un probabilidad significativa 28.51% (mayor que 5%), No se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo.

3.11.2 NORMALIDAD DEL RESIDUO DEL (MAA)



Gráfica N° 3.30 Evaluación de la Normalidad EC3_ECONOMETRIC

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 63.61%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

Como en otras ocasiones el valor del contraste viene acompañado con el correspondiente nivel de probabilidad asociado al rechazo de la hipótesis nula siendo cierta, de forma tal que si dicho valor de probabilidad fuera inferior al 5%, rechazaríamos la hipótesis nula, con el 95% de confianza, y deberíamos admitir la no normalidad del residuo.

3.11.3 COLINEALIDAD EN VARIABLES EXPLICATIVAS DEL (MAA)

Con el análisis de colinealidad determinaremos si cada regresor, inicialmente considerado, guarda independencia lineal o no con los demás regresores. El requisito fundamental para que un modelo sea apropiado para predicciones es la independencia lineal entre variables explicativas.

	LOG(VENTAS)	LOG(PBI)	LOG(USUA...)	LOG(PPE)	D1997	D96	D2006	D99
LOG(VENTAS)	1.000000	0.993961	0.978379	0.827165	-0.237655	-0.297133	0.038000	-0.181159
LOG(PBI)	0.993961	1.000000	0.967993	0.799346	-0.198612	-0.243898	0.013805	-0.196910
LOG(USUA...)	0.978379	0.967993	1.000000	0.886472	-0.183945	-0.225209	0.006927	-0.126709
LOG(PPE)	0.827165	0.799346	0.886472	1.000000	-0.221742	-0.144981	0.051517	-0.107874
D1997	-0.237655	-0.198612	-0.183945	-0.221742	1.000000	-0.047619	-0.047619	-0.047619
D96	-0.297133	-0.243898	-0.225209	-0.144981	-0.047619	1.000000	-0.047619	-0.047619
D2006	0.038000	0.013805	0.006927	0.051517	-0.047619	-0.047619	1.000000	-0.047619
D99	-0.181159	-0.196910	-0.126709	-0.107874	-0.047619	-0.047619	-0.047619	1.000000

Gráfica N° 3.31 Evaluación de la colinealidad

De la misma manera se observa independencia lineal entre las variables explicativas. Si existe causalidad entre ambas variables, las correlaciones cruzadas no deberían perder significancia.

3.11.4 ESPECIFICACIÓN FUNCIONAL: PRUEBA DE RAMSEY DEL (MAA)

A continuación se comprueba si se está usando una forma lineal incorrecta y cualquier error de omisión o la presencia de correlaciones entre las variables explicativas y la perturbación.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	1.840384	0.933161	1.972203	0.0702
LOG(USUARIOS)	1.276401	0.638385	1.999421	0.0669
LOG(PPE)	-0.019276	0.058037	-0.332134	0.7451
D1997	-0.209267	0.105143	-1.990304	0.0680
D96	-0.268999	0.133748	-2.011233	0.0655
D2006	0.078545	0.040454	1.941586	0.0742
D99	-0.058722	0.032321	-1.816826	0.0924
C	-9.857356	8.944960	-1.102001	0.2904
FITTED^2	-0.056305	0.043988	-1.279999	0.2229

R-squared	0.998894	Mean dependent var	15.98908
Adjusted R-squared	0.998213	S.D. dependent var	0.312738
S.E. of regression	0.013220	Akaike info criterion	-5.522109
Sum squared resid	0.002272	Schwarz criterion	-5.075774
Log likelihood	69.74320	Hannan-Quinn criter.	-5.416966
F-statistic	1467.436	Durbin-Watson stat	1.962370
Prob(F-statistic)	0.000000		

Gráfica N° 3.32 Prueba de Ramsey EC3_ECONOMETRIC

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 22.29% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

3.12 ESTIMACIÓN DEL MODELO DE CORRECCIÓN DE ERRORES ANUAL

Una vez realizadas las operaciones descritas, ya estaríamos en condiciones de resolver el modelo de corrección de errores y utilizarlo para obtener predicciones.

Estimación de los parámetros anuales

Estimation Command:

=====

LS D(LOG(VENTAS2)) D(LOG(PBI)) D(LOGERROR2) D98 D2013

Estimation Equation:

=====

$D(\text{LOG}(\text{VENTAS2})) = C(1)*D(\text{LOG}(\text{PBI})) + C(2)*D(\text{LOGERROR2}) + C(3)*D98 + C(4)*D2013$

Obteniendo la siguiente ecuación:

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.869403	0.056186	15.47360	0.0000
D(LOGERROR2)	1.179003	0.227570	5.180842	0.0001
D98	0.104811	0.015654	6.695635	0.0000
D2013	0.050877	0.014494	3.510146	0.0027


R-squared	0.757443	Mean dependent var	0.049781
Adjusted R-squared	0.714639	S.D. dependent var	0.026912
S.E. of regression	0.014376	Akaike info criterion	-5.476853
Sum squared resid	0.003513	Schwarz criterion	-5.277896
Log likelihood	61.50695	Hannan-Quinn criter.	-5.433674
Durbin-Watson stat	1.670993		

Gráfica N° 3.33 Resultados de la Regresión EC3_ECONOMETRIC2

De la misma manera realizaremos un análisis de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.86) acorde con la teoría económica. Además puede apreciarse el inserción de las variables dummy para los años 1998 y 2013. Como puede verse, todas las variables tienen el signo esperado y son significativas al 5%.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 75.74% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin Watson (1.67), como es mayor a 1.53 el modelo parece no presentar problemas de autocorrelación en los residuos.

Observando el gráfico de los residuos a lo largo del tiempo.



Gráfica N° 3.34 Evaluación de los residuos EC3_ECONOMETRIC2

Se observa que el error residual se encuentra en un orden de +/- 0.04 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

Estimation Command:

=====

LS D(LOG(VENTAS2)) D(LOG(PBI)) D(LOGERROR2) D98 D2013

Estimation Equation:

=====

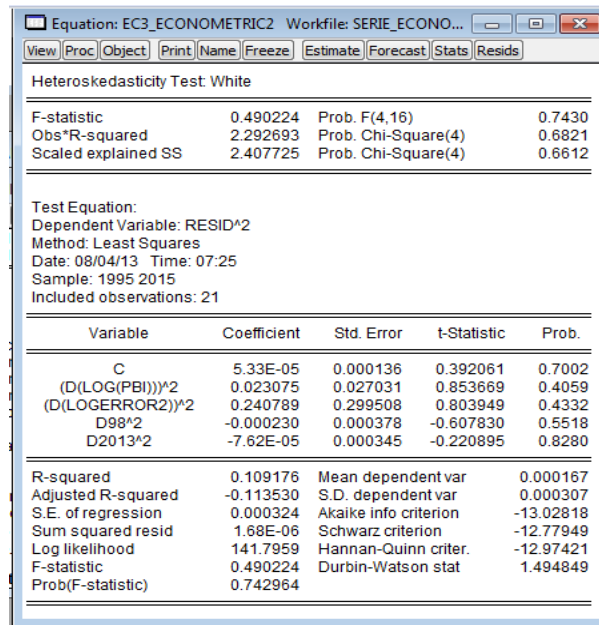
$D(\text{LOG}(\text{VENTAS2})) = C(1)*D(\text{LOG}(\text{PBI})) + C(2)*D(\text{LOGERROR2}) + C(3)*D98 + C(4)*D2013$

Substituted Coefficients:

=====

$D(\text{LOG}(\text{VENTAS2})) = 0.869402839948*D(\text{LOG}(\text{PBI})) + 1.1790031044*D(\text{LOGERROR2}) + 0.104810900771*D98 + 0.0508766132697*D2013$

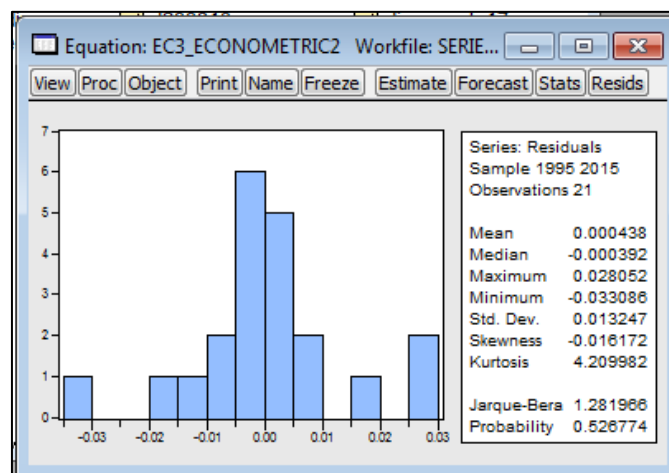
Prueba de Heteroscedasticidad de WHITE



Gráfica N° 3.35 Prueba de Heteroscedasticidad EC3_ECONOMETRIC2

Con un probabilidad significativa 74.30% (mayor que 5%), No se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo.

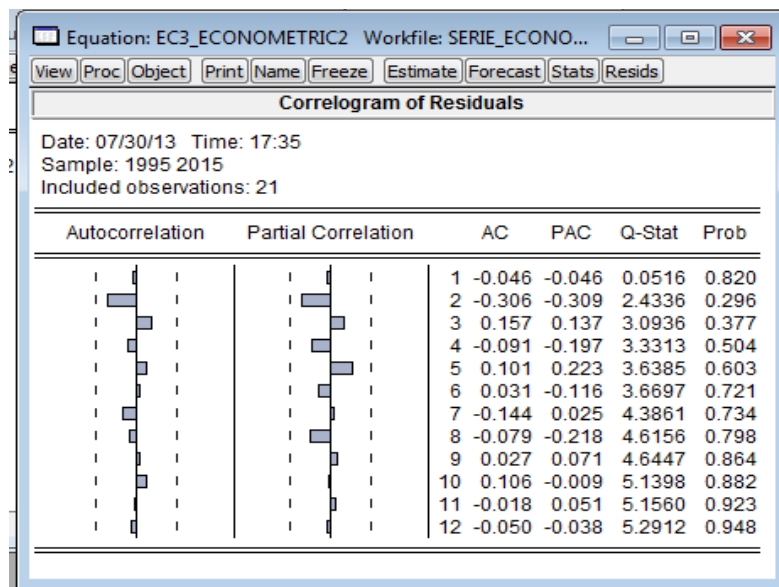
Normalidad del Residuo



Gráfica N° 3.36 Evaluación de la Normalidad EC3_ECONOMETRIC2

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 52.67%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

Como en otras ocasiones el valor del contraste viene acompañado con el correspondiente nivel de probabilidad asociado al rechazo de la hipótesis nula siendo cierta, de forma tal que si dicho valor de probabilidad fuera inferior al 5%, rechazaríamos la hipótesis nula, con el 95% de confianza, y deberíamos admitir la no normalidad del residuo.

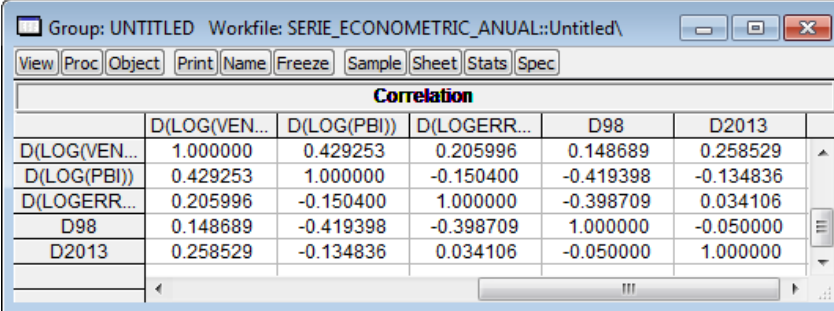


Gráfica N° 3.37 Correlograma- EC3_ECONOMETRIC2

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

Colinealidad en variables explicativas

Con el análisis de colinealidad determinaremos si cada regresor, inicialmente considerado, guarda independencia lineal o no con los demás regresores. El requisito fundamental para que un modelo sea apropiado para predicciones es la independencia lineal entre variables explicativas.



	D(LOG(VEN...	D(LOG(PBI))	D(LOGERR...	D98	D2013
D(LOG(VEN...	1.000000	0.429253	0.205996	0.148689	0.258529
D(LOG(PBI))	0.429253	1.000000	-0.150400	-0.419398	-0.134836
D(LOGERR...	0.205996	-0.150400	1.000000	-0.398709	0.034106
D98	0.148689	-0.419398	-0.398709	1.000000	-0.050000
D2013	0.258529	-0.134836	0.034106	-0.050000	1.000000

Gráfica N° 3.38 Evaluación de la colinealidad

De la misma manera se observa independencia lineal entre las variables explicativas. Si existe causalidad entre ambas variables, las correlaciones cruzadas no deberían perder significancia.

Especificación funcional: Prueba de Ramsey

A continuación se comprueba si se está usando una forma lineal incorrecta y cualquier error de omisión o la presencia de correlaciones entre las variables explicativas y la perturbación.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.965547	0.282495	3.417927	0.0035
D(LOG(ERROR2))	1.350594	0.546077	2.473269	0.0250
D98	0.118071	0.041390	2.852667	0.0115
D2013	0.058905	0.027473	2.144072	0.0477
FITTED^2	-1.767791	5.084685	-0.347670	0.7326

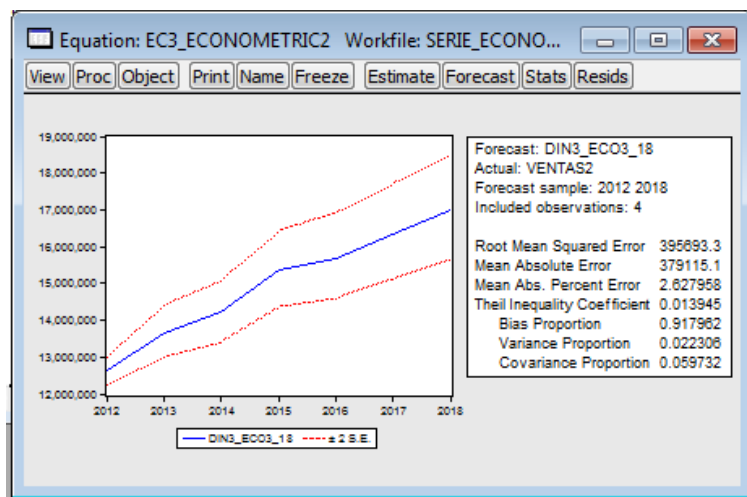
R-squared	0.759262	Mean dependent var	0.049781
Adjusted R-squared	0.699077	S.D. dependent var	0.026912
S.E. of regression	0.014763	Akaike info criterion	-5.389141
Sum squared resid	0.003487	Schwarz criterion	-5.140445
Log likelihood	61.58598	Hannan-Quinn criter.	-5.335167
Durbin-Watson stat	1.651653		

Gráfica N° 3.39 Prueba de Ramsey EC3_ECONOMETRIC2

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 73.26% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

3.13 PROYECCIONES ECONOMÉTRICAS ANUALES

Una vez realizadas las operaciones descritas, ya estaríamos en condiciones de resolver el modelo de corrección de errores y utilizarlo para obtener predicciones.




Gráfica N° 3.40 Proyección de la Variable Anual Ventas

Este es una representación de una predicción dinámica desde el período 2012 hasta 2018, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.013945, esto da indicaciones de una buena predicción.

A continuación se Observa las proyecciones anuales:

Tabla N° 3.6 Resultados de la Proyección Anual

	DATOS ANUALES			
	VENTAS	PBI	TARIFA	CLIENTES
	MWh	(Mio. S/.)	ctm. Sol/kW.h	
1,994	5,587,000	98,577	18.47	1,169,518
1,995	5,708,999	107,064	21.80	1,179,511
1,996	5,798,055	109,760	24.21	1,391,881
1,997	6,301,598	117,294	23.13	1,444,007
1,998	6,739,920	116,522	22.17	1,476,242
1,999	6,820,338	117,587	24.75	1,519,558
2,000	7,129,888	121,057	27.00	1,553,820
2,001	7,149,175	121,317	27.60	1,549,475
2,002	7,580,312	127,402	26.29	1,576,406
2,003	7,663,766	132,545	27.06	1,599,253
2,004	8,054,482	139,141	27.08	1,635,922
2,005	8,607,996	148,640	28.31	1,666,130
2,006	9,269,914	160,145	27.21	1,711,704
2,007	9,777,443	174,407	26.01	1,767,923
2,008	10,476,525	191,505	25.44	1,836,047
2,009	10,776,712	193,155	28.26	1,900,588
2,010	11,533,637	210,143	26.85	1,957,824
2,011	12,240,585	227,908	28.09	2,038,499
2,012	12,975,348	242,041	29.70	2,150,700
2,013	14,058,078	249,589	31.33	2,192,743
2,014	14,436,182	260,224	31.03	2,273,976
2,015	15,892,388	272,323	33.53	2,348,387
2,016	15,694,441	284,801	34.52	2,375,967
2,017	16,338,734	298,290	35.11	2,389,063
2,018	16,990,453	312,016	35.17	2,441,674



Gráfica N° 3.41 Resultados de las Proyección de las Ventas de Energía Eléctrica

3.14 RESULTADOS DE LA EVALUACIÓN DEL MODELO ACTUAL ANUAL

Se observa los resultados de las proyecciones de las ventas de energía eléctrica para el departamento de Lima con el modelo Econométrico anual. En la tabla se muestra los resultados en frecuencia anual desde el 2016 al 2018. En la gráfica N° 3.41 se muestra el gráfico de las proyecciones anuales hasta el 2018. Para el cálculo de las ventas de energía se utilizó el modelo de corrección de errores con frecuencia anual.

CAPÍTULO IV

PROPUESTA DE ALTERNATIVA

En la presente documento se propone estimar las ventas de Energía Eléctrica con el método Arima y un método econométrico propuesto para las series en frecuencia mensual, a diferencia del anterior método en el método Econométrico se añadirá entre las variables Econométricas la variable Temperatura, variable que relaciona los niveles de frío y calor y que inciden en la demanda de energía eléctrica mediante la utilización de aparatos de calefacción y frío.

Luego se procederá a estimar las ventas de energía eléctrica anuales con el modelo Arima-Econométrico. A partir de los resultados del modelo Arima en frecuencia mensual se tomaran estos datos para proyectar las ventas en frecuencia anual. Asimismo también se proyectara con el modelo Econométrico mensual propuesto en frecuencia Anual.

Finalmente, comenzamos a validar y contrastar los modelos para escoger el modelo que presente un mejor grado de bondad. Esto se verificará a través de los estadísticos ya mencionados en capítulos anteriores.

4.1 MODELO ARIMA

La determinación de predicciones mediante análisis cuantitativo univariante de series temporales se fundamenta en el uso de los datos históricos de la variable en estudio, con los que, utilizando el tratamiento estadístico matemático apropiado, se elabora un modelo tal que describa su comportamiento temporal de la forma lo más aproximada posible.

La metodología ARIMA (Autoregressive – Moving Average) está basada en que la serie temporal en estudio, luego de una transformación apropiada debe aproximarse al comportamiento de un proceso estocástico estacionario lineal, y a partir de ello explicar y pronosticar a dicha variable.

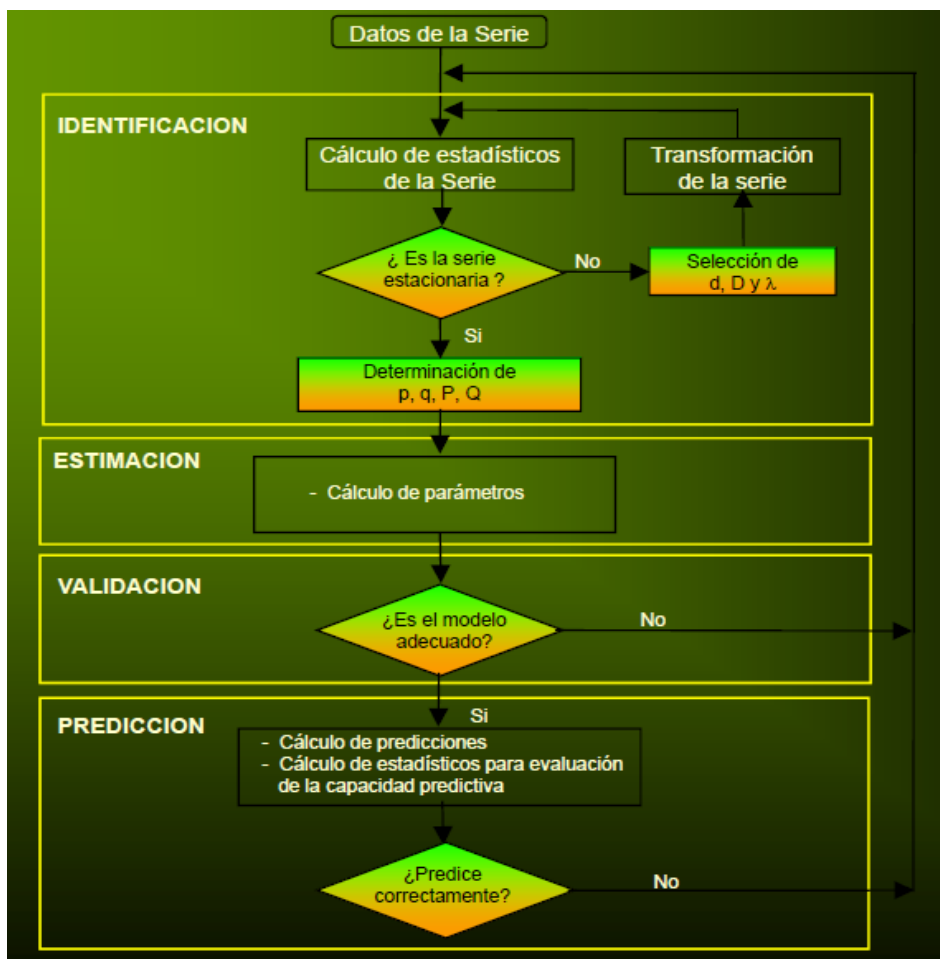
Así; un modelo ARIMA parte de un proceso estocástico no estacionario lineal homogenizado (integrado); ello quiere decir, que luego de practicarle diferenciaciones regulares y estacionales, queda como resultante un proceso estacionario del tipo ARMA. Un modelo ARMA (Autoregressive – Moving Average), viene a ser un proceso estocástico estacionario lineal, resultante de la combinación de dos procesos estocásticos estacionarios lineales, uno autorregresivo y otro de medias móviles.

La importancia de la metodología ARIMA estriba en la calidad de predicciones que se logran, ello debido a la exhaustiva exploración de todos los patrones de comportamiento evolutivo que puede tener una serie temporal (tendencia, ciclaje, estacionalidad, irregularidad).

4.2 PROCEDIMIENTOS DE CÁLCULO CON EL MODELO ARIMA

El proceso de cálculo se realiza bajo la forma siguiente:

- Identificación de modelos ARIMA tentativos
- Estimación y ajuste de los modelos ARIMA tentativos
- Evaluación y elección de modelos ARIMA tentativos
- Identificación de intervenciones y atípicos
- Identificación de modelos ARIMA con intervención y atípicos
- Estimación y ajuste de modelos ARIMA con intervención y atípicos
- Evaluación y elección de modelos ARIMA con intervención y atípicos
- Cálculo de predicciones



Gráfica N° 4.1 Procedimiento de Cálculo del Modelo Arima

4.2.1 IDENTIFICACIÓN: ESTABILIDAD EN VARIANZA

Cualquier serie histórica, en niveles como tal, a lo largo de su evolución histórica puede presentar una variabilidad no constante, esto es que la varianza sea dependiente del tiempo (exista heteroscedasticidad). En muchos casos la variabilidad no aumenta con el tiempo sino con el nivel de la serie. Por tanto, se tendrá que efectuar una transformación de la variable para de esta forma estabilizar la varianza.

En el objetivo de identificar si la varianza es constante en una serie natural, se procede a evaluar el comportamiento variabilidad-nivel, para ello se agrupa las observaciones de la serie por periodos de tiempo con el mismo número de observaciones (agrupando en años cuando se tienen observaciones mensuales). Luego, dependiendo del grado de complejidad de la serie, se puede realizar, bien una visualización gráfica y a partir de ello determinar si es necesario practicar una transformación logarítmica para alcanzar la estabilidad en varianza, o en el caso más amplio efectuar una prueba de comprobación de la hipótesis de que los grupos conformados procedan de poblaciones con varianza común (Prueba de Levene).

4.2.2 IDENTIFICACIÓN: ESTABILIDAD EN MEDIA Y DE ESTACIONALIDAD

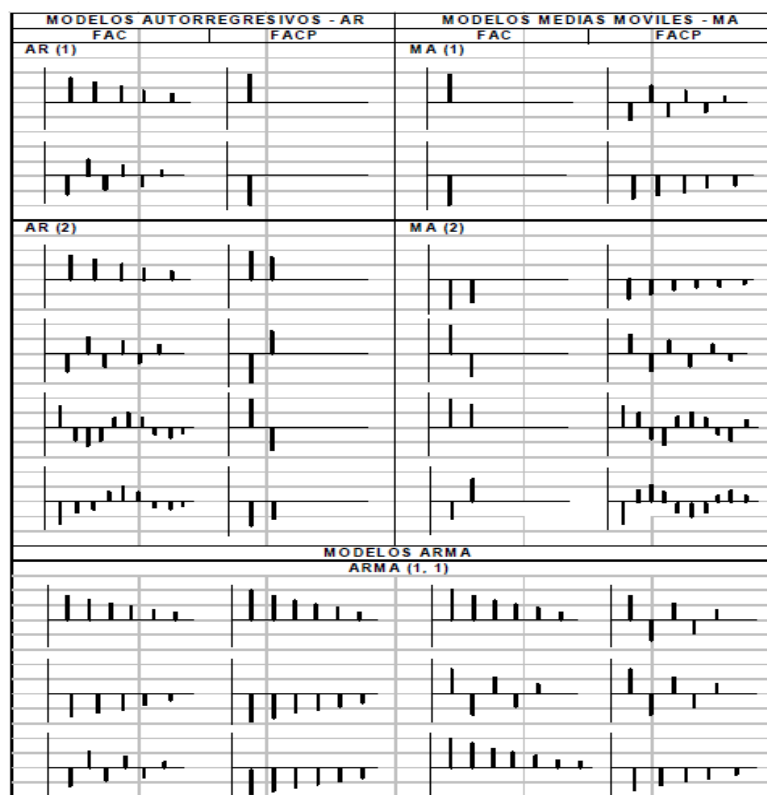
Para estabilizar la media de la serie en estudio puede ser necesario aplicar diferencias regulares (de orden d) y estacionales (de orden D). Las órdenes de diferenciación se determinan luego del análisis de estabilidad en varianza, tomando como referencia:

- El comportamiento gráfico de la serie.
- El comportamiento de las funciones de autocorrelación simple (FAC) y parcial (FACP).

- El uso de estadísticos de medición de error para elegir el mejor arreglo, dentro de un juego de posibilidades.
- El contraste de raíces unitarias para verificar la estacionariedad de la serie.

4.2.3 IDENTIFICACIÓN: DETERMINACIÓN DE ORDENES AR Y MA

La identificación de las órdenes autorregresivas y de medias móviles de la parte regular del modelo, (p, q) , se realiza a partir de las funciones FAC y FACP muestrales, las mismas que se comparan con el comportamiento de los retardos típicos de las FAC y FACP teóricas. La identificación de los parámetros autorregresivos y de medias móviles de la parte estacional (P, Q) se realiza a partir de las funciones FAC y FACP muestrales para la serie diferenciada estacionalmente, considerando exclusivamente los retardos estacionales $s, 2s, 3s, \dots$, y teniendo como patrón de comportamiento a las FAC y FACP teóricas.



Gráfica N° 4.2 Cuadro de Identificación de los modelos Autorregresivos y de Medias Móviles

4.2.4 ESTIMACIÓN Y AJUSTE DE MODELOS

La estimación de los parámetros del modelo tentativo, generalmente se realiza por los métodos máxima verosimilitud condicional y máxima verosimilitud exacta. En base a ello es importante señalar que los distintos programas que se utilizan, pueden proporcionar valores diferentes de los parámetros calculados para un mismo modelo ARIMA; pues además se suma la diferencia de algoritmos utilizados por cada programa.

Por tanto, es esta etapa la que influye en la elección del programa informático apropiado para alcanzar estimaciones más refinadas. No obstante, en muchas series reales la diferencia de resultados estimados entre uno y otro programa son relativamente pequeños.

4.2.5 IDENTIFICACIÓN Y ESTIMACIÓN DE INTERVENCIONES Y ATÍPICOS

Se procede a Identificar por su inicio como por su efecto:

De acuerdo a su influencia sobre la serie se aplica una variable ficticia o artificial (impulso o escalón), acompañada de un factor de filtrado típico para cada caso

Posteriormente se procede a estimar los coeficientes de filtrado utilizando métodos de máxima verosimilitud o mínimos cuadrados, ello mediante el programa informático o la elaboración de programas estructurados que pueden realizarse en cualquier lenguaje de programación.

La validación o chequeo se realiza con la demostración de la significancia de sus parámetros de filtrado, ello mediante los estadísticos de error y de contraste.

Entre las pruebas estadísticas realizadas se tienen:

Pruebas de estadísticos descriptivos: (desviación estándar) para la elección de las órdenes de diferenciación regular y/o estacional, en la búsqueda de estabilidad en medias

Pruebas de contraste t-student: para la significancia de los coeficientes estimados, tanto de las partes autorregresivas y medias móviles del modelo, como de los efectos externos (intervenciones y atípicos)

Prueba de incorrelación de residuos: (o ausencia de autocorrelación de los residuos) para verificar que estos residuos se asemejan al comportamiento de un ruido blanco

Prueba de normalidad de residuos: para verificar que el comportamiento de los residuos cumplen con la hipótesis de normalidad.

La capacidad predictiva del modelo ARIMA seleccionado, se comprueba con el cálculo de predicciones en base a un horizonte histórico muestral con n observaciones menos que el horizonte histórico real de la serie.

4.2.6 VALIDACIÓN DEL MODELO SELECCIONADO

La validación del mejor modelo ARIMA calculados, consiste en comprobar si se satisface la hipótesis relativa a que los residuos del modelo $\{u_t\}$ obedecen al comportamiento de un ruido blanco. El inconveniente radica en que, dado que los coeficientes del modelo son estimaciones de los verdaderos parámetros a partir de la muestra observada, los verdaderos errores son desconocidos. En consecuencia, la comprobación de las hipótesis de proceso de ruido blanco se realizará sobre una estimación de los mismos.

4.3 ESTIMACIÓN DE LA SERIE VENTAS DE ENERGÍA ELÉCTRICA MENSUAL CON EL MODELO ARIMA (MAM)

4.3.1 IDENTIFICACIÓN DEL MODELO

Estimation Command:

```

=====
LS(DERIV=AA) D(LOG(VENTAS_SA)) D9704 D200204 D9503 D9504 D199402 D9603
D(D200802) D9710 D9502 MA(3) D(D200304) D(D200104) MA(23) MA(6) D9801 MA(2) MA(19)
D201211 MA(1) MA(24) MA(21)
    
```

Estimation Equation:

```

=====
D(LOG(VENTAS_SA)) = C(1)*D9704 + C(2)*D200204 + C(3)*D9503 + C(4)*D9504 +
C(5)*D199402 + C(6)*D9603 + C(7)*D(D200802) + C(8)*D9710 + C(9)*D9502 +
C(10)*D(D200304) + C(11)*D(D200104) + C(12)*D9801 + C(13)*D201211 +
[MA(3)=C(14),MA(23)=C(15),MA(6)=C(16),MA(2)=C(17),MA(19)=C(18),MA(1)=C(19),MA(24)=C(
20),MA(21)=C(21),BACKCAST=1994M02,ESTSMPL="1994M02 2012M12"]
    
```

D(LOG(VENTAS_SA)): Primera diferencia del Logaritmo de la serie ventas de energía eléctrica desestacionalizado.

D199402: Intervención en la serie en el mes de Febrero del año 1994. Variable dummy.

D9502: Intervención en la serie en el mes de Febrero del año 1995. Variable dummy.

D9504: Intervención en la serie en el mes de Abril del año 1995. Variable dummy.

D9503: Intervención en la serie en el mes de Marzo del año 1995. Variable dummy.

D9603: Intervención en la serie en el mes de Marzo del año 1996. Variable dummy.

D9704: Intervención en la serie en el mes de Abril del año 1997. Variable dummy.

D9710: Intervención en la serie en el mes de Abril del año 1997. Variable dummy.

D200204: Intervención en la serie en el mes de Abril del año 2002. Variable dummy.

D(D200802): Primera diferencia de la Variable dummy en el mes de febrero del año 2008.

D(D200304): Primera diferencia de la Variable dummy en el mes de Abril del año 2003.

D(D200104): Primera diferencia de la Variable dummy en el mes de Abril del año 2001.

MA(1): Variable de medias móviles de orden 1, para corrección de la autocorrelación de la serie.

MA(2): Variable de medias móviles de orden 2, para corrección de la autocorrelación de la serie.

MA(3): Variable de medias móviles de orden 3, para corrección de la autocorrelación de la serie.

MA(6): Variable de medias móviles de orden 6, para corrección de la autocorrelación de la serie.

MA(23): Variable de medias móviles de orden 23, para corrección de la autocorrelación de la serie.

MA(12): Variable de medias móviles de orden 12, para corrección de la autocorrelación de la serie.

MA(21): Variable de medias móviles de orden 21, para corrección de la autocorrelación de la serie.

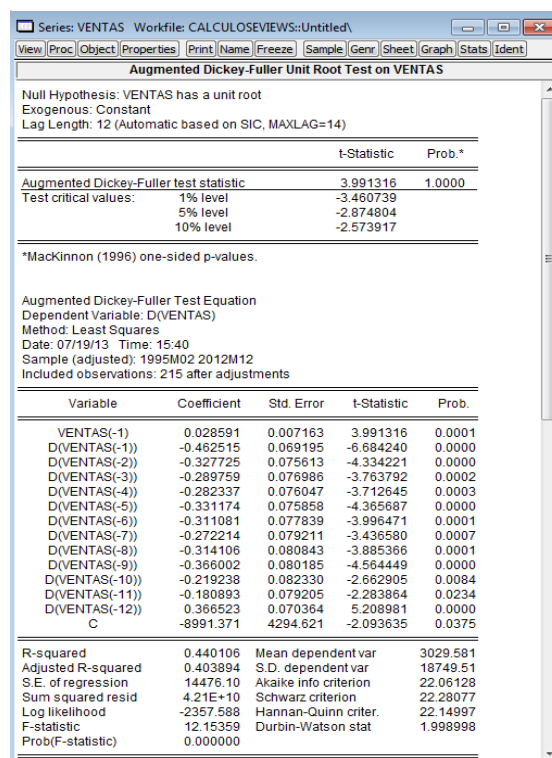
Substituted Coefficients:

=====

$$\begin{aligned}
 D(\text{LOG}(\text{VENTAS_SA})) &= 0.0658436184505 * D9704 + 0.0349389886749 * D200204 + \\
 &0.0584332196373 * D9503 - 0.0433157532412 * D9504 + 0.141403663301 * D199402 - \\
 &0.0339823325503 * D9603 + 0.0234123651285 * D(D200802) + 0.0410518150583 * D9710 - \\
 &0.0372918466881 * D9502 - 0.0348468668046 * D(D200304) - 0.0321822729892 * D(D200104) + \\
 &0.0240736374744 * D9801 + 0.0303501475599 * D201211 +
 \end{aligned}$$

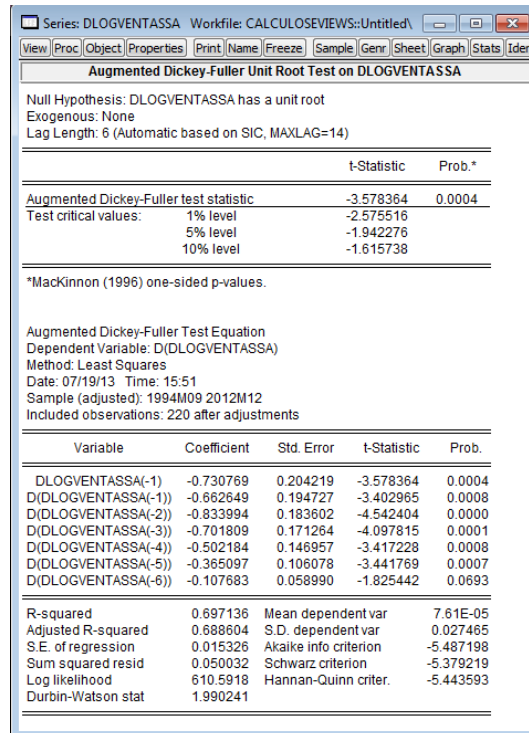
[MA(3)=0.198414071108,MA(23)=0.415447958499,MA(6)=0.191916169286,MA(2)=-0.184607898814,MA(19)=0.347151253316,MA(1)=-0.27651522425,MA(24)=-0.210718022832,MA(21)=-0.246783477994,BACKCAST=1994M02,ESTSMPL="1994M02 2012M12"]

4.3.1.1 PRUEBA DE RAÍZ UNITARIA



Gráfica N° 4.3 Prueba Dickey-Fuller Aumentado-ventas

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo no es estacionaria esto se debe porque la probabilidad es aproximadamente 1 (se acepta la hipótesis nula) y presenta raíz unitaria. Por lo que deberá aplicar una transformación a la serie ventas.



Gráfica N° 4.4 Prueba Dickey-Fuller Aumentado-DLOGVENTASSA

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo es estacionaria esto se debe porque la probabilidad es aproximadamente 0 (se rechaza la hipótesis nula) y no presenta raíz unitaria.

4.3.2 ESTIMACIÓN Y AJUSTE DE MODELOS

Estimando el modelo ARIMA se obtiene el siguiente resultado de la regresión:

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D9704	0.065844	0.010405	6.328341	0.0000
D200204	0.034939	0.009766	3.577564	0.0004
D9503	0.058433	0.014017	4.168645	0.0000
D9504	-0.043316	0.013734	-3.153817	0.0019
D199402	0.141404	0.015365	9.203074	0.0000
D9603	-0.033982	0.010899	-3.117922	0.0021
D(D200802)	0.023412	0.007573	3.091406	0.0023
D9710	0.041052	0.010487	3.914435	0.0001
D9502	-0.037292	0.013802	-2.701834	0.0075
D(D200304)	-0.034847	0.007649	-4.555968	0.0000
D(D200104)	-0.032182	0.007787	-4.132782	0.0001
D9801	0.024074	0.009943	2.421167	0.0163
D201211	0.030350	0.010957	2.770010	0.0061
MA(3)	0.198414	0.061970	3.201763	0.0016
MA(23)	0.415448	0.067553	6.149980	0.0000
MA(6)	0.191916	0.060718	3.160764	0.0018
MA(2)	-0.184608	0.064634	-2.856223	0.0047
MA(19)	0.347151	0.061383	5.655533	0.0000
MA(1)	-0.276515	0.066041	-4.187003	0.0000
MA(24)	-0.210718	0.067880	-3.104288	0.0022
MA(21)	-0.246783	0.067322	-3.665711	0.0003

R-squared	0.655064	Mean dependent var	0.004544
Adjusted R-squared	0.621575	S.D. dependent var	0.018866
S.E. of regression	0.011606	Akaike info criterion	-5.986648
Sum squared resid	0.027748	Schwarz criterion	-5.669803
Log likelihood	700.4846	Hannan-Quinn criter.	-5.858797
Durbin-Watson stat	2.095364		

Inverted MA Roots	93+ .16i	.93- .16i	.86+ .45i	.86- .45i
	.67- .57i	.67+ .57i	.58+ .71i	.58- .71i
	.57	.36+ .91i	.36- .91i	.08- .99i
	.08+ .99i	-.21+ .97i	-.21- .97i	-.48+ .84i
	-.48- .84i	-.69- .66i	-.69+ .66i	-.83- .48i
	-.83+ .48i	-.94+ .27i	-.94- .27i	-.98

Gráfica N° 4.5 Resultados de la Regresión ECUACION_3_ARIMA


De la misma manera realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente que la mayoría de variables tiene un coeficiente cercano a cero. Además puede apreciarse que se añadió las variable dummy d9704 para el mes de abril de 1997, d200204 para el mes de abril del 2002, etc. Con el fin de obtener un buen ajuste en el modelo.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 65.5% de la varianza de la variable endógena, resultado que

inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin Watson (2.09), como es próximo a 2 el modelo no presenta problemas de autocorrelación en los residuos.

Como puede verse, todas las variables tienen el signo esperado y son significativas al 5%. En este caso no es tan importante tomar en cuenta el R^2 ajustado, sin embargo este indicador es de mucha importancia en regresiones multivariadas, ya que se pueden estar incluyendo algunas variables que no son relevantes y por lo tanto se pierden grados de libertad.

Observando el gráfico de los residuos a lo largo del tiempo.



Gráfica N° 4.6 Evaluación de los residuos ECUACION_3_ARIMA

Se observa que el error residual se encuentra en un orden de ± 0.03 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

4.3.3 CONTRASTE O VALIDACIÓN DEL MODELO ARIMA


4.3.3.1 PRUEBA DE HETEROSCEDASTICIDAD DE WHITE DEL (MAM)

Equation: ECUACION_3_ARIMA Workfile: CALCULOSEVI...				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Heteroskedasticity Test: White				
F-statistic	0.637612	Prob. F(21,205)	0.8876	
Obs*R-squared	13.91775	Prob. Chi-Square(21)	0.8731	
Scaled explained SS	10.68385	Prob. Chi-Square(21)	0.9686	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 08/08/13 Time: 10:43				
Sample: 1994M02 2012M12				
Included observations: 227				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000143	1.67E-05	8.538505	0.0000
GRADF_01^2	-0.000105	0.000225	-0.468356	0.6400
GRADF_02^2	-0.000139	0.000192	-0.721813	0.4712
GRADF_03^2	-0.000198	0.000337	-0.588768	0.5567
GRADF_04^2	-0.000154	0.000344	-0.447647	0.6549
GRADF_05^2	-0.000384	0.000506	-0.757464	0.4496
GRADF_06^2	-0.000181	0.000242	-0.745635	0.4567
GRADF_07^2	-9.44E-05	0.000163	-0.579259	0.5631
GRADF_08^2	-2.76E-05	0.000215	-0.128754	0.8977
GRADF_09^2	-0.000282	0.000335	-0.842384	0.4006
GRADF_10^2	-0.000142	0.000172	-0.827748	0.4088
GRADF_11^2	-0.000243	0.000177	-1.377059	0.1700
GRADF_12^2	-0.000294	0.000219	-1.341891	0.1811
GRADF_13^2	-0.000133	0.000180	-0.739045	0.4607
GRADF_14^2	-0.001097	0.001950	-0.562572	0.5743
GRADF_15^2	6.86E-07	0.000246	0.002787	0.9978
GRADF_16^2	4.38E-05	0.000253	0.173634	0.8623
GRADF_17^2	0.000117	0.000279	0.419606	0.6752
GRADF_18^2	0.000146	0.000250	0.583121	0.5605
GRADF_19^2	-0.003997	0.001814	-2.203116	0.0287
GRADF_20^2	-0.014856	0.043320	-0.342926	0.7320
GRADF_21^2	-0.000205	0.000249	-0.822926	0.4115
R-squared	0.061312	Mean dependent var	0.000122	
Adjusted R-squared	-0.034847	S.D. dependent var	0.000167	
S.E. of regression	0.000170	Akaike info criterion	-14.42779	
Sum squared resid	5.94E-06	Schwarz criterion	-14.09586	
Log likelihood	1659.555	Hannan-Quinn criter.	-14.29385	
F-statistic	0.637612	Durbin-Watson stat	2.081902	
Prob(F-statistic)	0.887619			

Gráfica N° 4.7 Prueba de Heteroscedasticidad ECUACION_3_ARIMA

Con un probabilidad significativa 88.76% (mayor que 5%), No se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo.

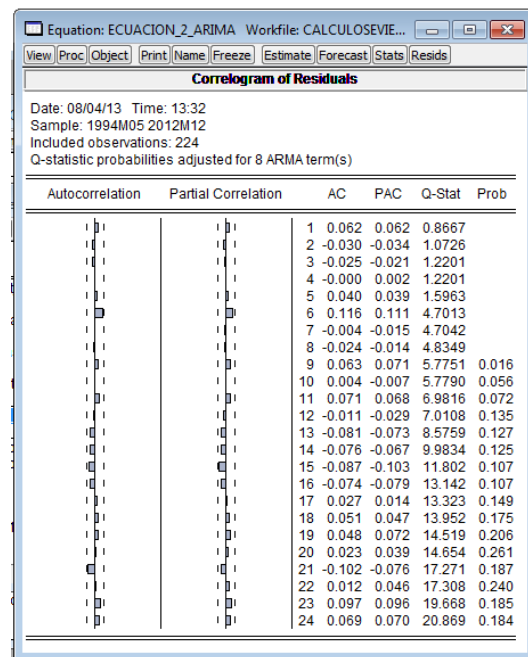
4.3.3.2 NORMALIDAD DEL RESIDUO DEL (MAM)



Gráfica N° 4.8 Evaluación de la Normalidad ECUACION_3_ARIMA

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 89.98%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

Como en otras ocasiones el valor del contraste viene acompañado con el correspondiente nivel de probabilidad asociado al rechazo de la hipótesis nula siendo cierta, de forma tal que si dicho valor de probabilidad fuera inferior al 5%, rechazaríamos la hipótesis nula, con el 95% de confianza, y deberíamos admitir la no normalidad del residuo.



Gráfica N° 4.9 Correlograma-ECUACION_2_ARIMA

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

4.3.3.3 ESPECIFICACIÓN FUNCIONAL: PRUEBA DE RAMSEY DEL (MAM)

A continuación se comprueba si se está usando una forma lineal incorrecta y cualquier error de omisión o la presencia de correlaciones entre las variables explicativas y la perturbación.

Equation: ECUACION_3_ARIMA Workfile: CALCULOSEVIE...				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Ramsey RESET Test				
F-statistic	0.430405	Prob. F(1,205)	0.5125	
Log likelihood ratio	0.476095	Prob. Chi-Square(1)	0.4902	
WARNING: the MA backcasts differ for the original and test equation. Under the null hypothesis, the impact of this difference vanishes asymptotically.				
Test Equation: Dependent Variable: D(LOG(VENTAS_SA)) Method: Least Squares Date: 08/08/13 Time: 10:52 Sample: 1994M02 2012M12 Included observations: 227 Failure to improve SSR after 18 iterations MA Backcast: 1992M02 1994M01				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
D9704	0.059846	0.018023	3.320478	0.0011
D200204	0.032265	0.011311	2.852539	0.0048
D9503	0.053845	0.017710	3.040396	0.0027
D9504	-0.046542	0.015736	-2.957782	0.0035
D199402	0.117232	0.058933	1.989249	0.0480
D9603	-0.035561	0.011280	-3.152696	0.0019
D(D200802)	0.023184	0.007577	3.059694	0.0025
D9710	0.039412	0.011007	3.580689	0.0004
D9502	-0.038332	0.014080	-2.722369	0.0070
D(D200304)	-0.034809	0.007661	-4.543977	0.0000
D(D200104)	-0.033233	0.008106	-4.099791	0.0001
D9801	0.022905	0.010411	2.200102	0.0289
D201211	0.029736	0.011117	2.674729	0.0081
FITTED^2	1.173242	2.839700	0.413157	0.6799
MA(3)	0.200830	0.062496	3.213463	0.0015
MA(23)	0.412613	0.067860	6.080343	0.0000
MA(6)	0.190797	0.061182	3.118498	0.0021
MA(2)	-0.182812	0.065193	-2.804156	0.0055
MA(19)	0.346752	0.062052	5.588050	0.0000
MA(1)	-0.278775	0.066593	-4.186246	0.0000
MA(24)	-0.214077	0.068249	-3.136728	0.0020
MA(21)	-0.250753	0.067604	-3.709125	0.0003
R-squared	0.655787	Mean dependent var	0.004544	
Adjusted R-squared	0.620526	S.D. dependent var	0.018866	
S.E. of regression	0.011622	Akaike info criterion	-5.979935	
Sum squared resid	0.027690	Schwarz criterion	-5.648002	
Log likelihood	700.7226	Hannan-Quinn criter.	-5.845995	
Durbin-Watson stat	2.093101			
Inverted MA Roots	.93-.17i	.93+.17i	.86-.45i	.86+.45i
	.67-.57i	.67+.57i	.58-.71i	.58+.71i
	.58	.36+.91i	.36-.91i	.08-.99i
	.08+.99i	-.21+.97i	-.21-.97i	-.48+.84i
	-.48-.84i	-.69+.66i	-.69-.66i	-.83+.48i
	-.83-.48i	-.94-.27i	-.94+.27i	-.98


Gráfica N° 4.10 Prueba de Ramsey ECUACION_2_ARIMA

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 51.25% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

Luego de realizadas las operaciones descritas, ya estaríamos en condiciones de resolver el modelo ARIMA y utilizarlo para obtener predicciones en orden mensual.

4.3.4 PROYECCIÓN DEL MODELO ARIMA MENSUAL


FORECAST ESTATIC CÁLCULO ARIMA



Gráfica N° 4.11 Forecast Estatic ECUACION_2_ARIMA

Este es una representación de una predicción estática desde el período 1994:M01 hasta 2012:M12, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.006196, esto da indicciones de una buena predicción.

FORECAST DINAMIC



Gráfica N° 4.12 Forecast Dinamic ECUACION_2_ARIMA

Este es una representación de una predicción dinámica desde el período 2012:M01 hasta 2015:M12, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser próximo a 0, en este caso es 0.00788, esto da indicaciones de una buena predicción.

A Continuación se aprecia las proyecciones de las ventas mensuales del período 2013-2015.

Tabla N° 4.1 Proyección de Ventas de Energía con el Modelo Arima

Año	Proyección VENTAS ENERGÍA ARIMA (2013- 2015)
2013M01	1095716
2013M02	1105836
2013M03	1109404
2013M04	1112841
2013M05	1114932
2013M06	1121695
2013M07	1131783
2013M08	1130979
2013M09	1128497
2013M10	1145085
2013M11	1140486
2013M12	1146084
2014M01	1153680
2014M02	1157613
2014M03	1160960
2014M04	1167145
2014M05	1172004
2014M06	1176301
2014M07	1181430
2014M08	1186579
2014M09	1191308
2014M10	1196279
2014M11	1201383
2014M12	1206357
2015M01	1211362
2015M02	1216464
2015M03	1221550
2015M04	1226640
2015M05	1231780
2015M06	1236941
2015M07	1242112
2015M08	1247313
2015M09	1252541
2015M10	1257787
2015M11	1263057
2015M12	1268354

4.3.5 RESULTADOS DE LA ESTIMACIÓN DEL MODELO ARIMA MENSUAL

Se observa los resultados de las proyecciones de las ventas de energía eléctrica para el departamento de Lima con el modelo Arima mensual. En la tabla se muestra los resultados en frecuencia mensual desde el 2013 al 2015. En la gráfica N° 4.12 se muestra el gráfico de las proyecciones mensuales hasta el 2015. Para el cálculo de las ventas de energía se utilizó el modelo Arima con frecuencia mensual.

4.4 ESTIMACIÓN DE LA SERIE VENTAS DE ENERGÍA ELÉCTRICA CON EL MODELO ECONÓMICO PROPUESTO MENSUAL (MEPM)

En el capítulo anterior se pronosticó las ventas de energía eléctrica para el departamento de Lima con la metodología como se calcula actualmente, en este documento se propone ingresar la variable temperatura y pronosticar la variable ventas de energía eléctrica.

4.4.1 VARIABLE DE TEMPERATURA PROMEDIO EN LIMA

Lima tiene un clima tibio sin excesivo calor tropical ni fríos extremos que requieran tener calefacción en casa, a excepción de muy pocos inviernos. La temperatura promedio anual es de 18,5 a 19 °C. Los veranos, de diciembre a abril, tienen temperaturas que oscilan entre los 29 a 30 °C durante el día y 21 a 22 °C en las noches.

Los inviernos van de junio a mediados de septiembre, con temperaturas que oscilan entre los 19 y 12 °C, siendo 8,8 °C la temperatura más baja comprobada históricamente. Los meses de primavera y otoño (septiembre,

octubre y mayo), tienen temperaturas templadas que oscilan entre los 23 y 17 °C.

El SENAHMI es el Servicio Nacional de Meteorología e Hidrología del Perú que cuenta con históricos mensuales de temperatura promedio de Lima de sus estaciones meteorológicas. La serie mensual se construye a partir del promedio diario para el período 1996-2012.

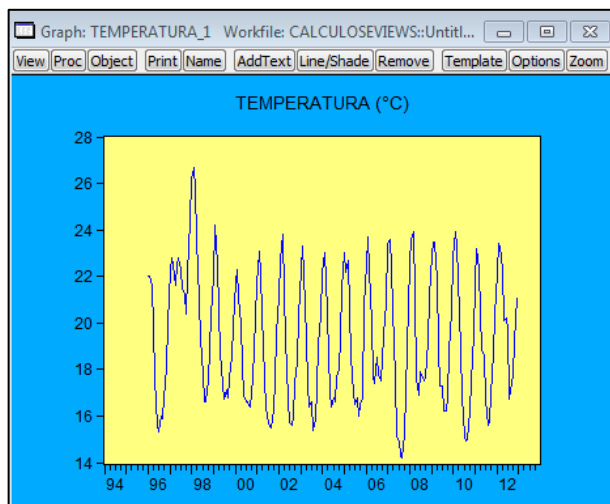
Respecto a la serie Anual de la temperatura promedio de Lima se tiene información en el SENAHMI de la temperatura, para este documento se tomó desde el año 1994.

HISTÓRICO DE LA TEMPERATURA PROMEDIO DE LIMA (°C) (1994-2012)

Tabla N° 4.2

Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1996	22	22	21,6	19,8	17,6	15,6	15,3	16	15,9	16,8	18,1	20
1997	22,3	22,8	22,5	21,6	22,5	22,8	22,3	21,5	21,2	20,4	22,1	24,4
1998	26,2	26,7	25,8	23,6	21	19,3	17,8	16,6	16,6	17,5	18,9	20,3
1999	22	24,2	22,5	20,6	18,7	17,4	16,7	17,1	16,8	17,6	18,5	19,9
2000	21,8	22,3	21,1	20	18,2	16,9	16,6	16,6	16,4	17	17,6	20,2
2001	21,7	23,1	22,2	20,4	17,6	16,4	15,7	15,6	15,5	16,3	17,5	19,6
2002	21,1	22,7	23,8	21,3	19,3	16,7	15,7	15,6	16	17,4	18,3	20,3
2003	22,3	23,3	22,1	19,3	17,4	16,4	16,6	15,4	15,9	17,2	19,1	20,3
2004	22,2	23	21,9	20,4	17	16,4	16,8	16,6	17,7	18	19,4	21,5
2005	23	22,2	22,7	20,6	18,6	17	16,5	16,8	16	16,5	16,8	20,8
2006	22,5	23,7	22,3	20	17,7	17,4	18,5	17,8	17,5	18,4	19,5	20,9
2007	23,4	23,6	22,4	20,6	17,6	15,1	14,9	14,3	14,2	15,2	17	18,9
2008	22,6	23,6	23,9	21,2	17,6	16,9	17,9	17,7	17,5	17,6	19,2	21,1
2009	22,9	23,5	23,5	21,9	19	17,3	17,3	16,2	16,2	16,8	18,8	20,5
2010	22,82	23,92	23,36	21,88	18,89	16,83	15,17	14,91	15	16,22	17,5	19,5
2011	21,76	23,21	22,35	20,46	18,89	18,66	16,74	15,61	15,78	16,9	18,7	20,3
2012	22,2	23,4	23,3	22,3	20,1	20,2	19,7	16,7	17,4	17,8	19,2	21,1

Fuente: Senahmi¹¹En el anexo bibliográfico se detalla la fuente.

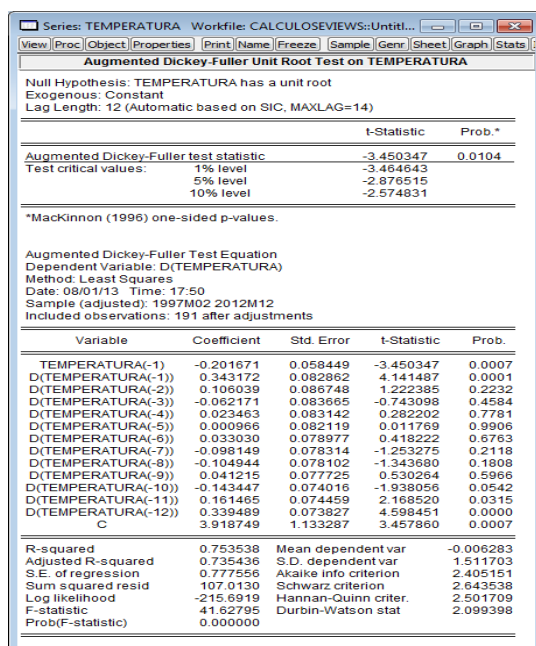


Gráfica N° 4.13 Evolución de la variable Temperatura

4.4.2 ESPECIFICACIÓN DEL MODELO ECONÓMTRICO MENSUAL

4.4.2.1 ANÁLISIS DE ESTACIONARIEDAD

Análisis de Dickey Fuller Aumentado de la serie mensual Temperatura



Gráfica N° 4.14 Prueba Dickey-Fuller Aumentado-Temperatura

Se observa que mediante la prueba de Dickey-Fuller la serie de tiempo no es estacionaria esto se debe porque la probabilidad es aproximadamente 0 (se rechaza la hipótesis nula) y presenta raíz unitaria. Por lo que deberá aplicar una transformación a la siguiente serie temperatura.

4.4.3 ESTIMACIÓN DE LOS PARÁMETROS MENSUALES

Ecuación del modelo econométrico:

Con las variables antes mencionadas se ha construido el siguiente modelo econométrico considerando los supuestos estadísticos correspondientes.

Estimation Command:

```
=====
LS LOG(VENTAS) LOG(PBI) LOG(USUARIOS) LOG(TEMPERATURA) LOG(PPE) D200609
D200509 D200709 D201207
```

Estimation Equation:

```
=====
LOG(VENTAS) = C(1)*LOG(PBI) + C(2)*LOG(USUARIOS) + C(3)*LOG(TEMPERATURA) +
C(4)*LOG(PPE) + C(5)*D200609 + C(6)*D200509 + C(7)*D200709 + C(8)*D201207
```

Log(PBI): Logaritmo de la serie histórica del Producto Bruto Interno (PBI).

Log(USUARIOS): Logaritmo de la serie histórica Usuarios.

Log(PPE): Logaritmo de la serie histórica del precio promedio de electricidad.

Log(Ventas): Logaritmo de la serie Ventas de electricidad.

Log(Temperatura): Logaritmo de la serie histórica de la temperatura.

Equation: EQ01IMPORTANT_ECONO Workfile: CALCULO...

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: LOG(VENTAS)
Method: Least Squares
Date: 08/08/13 Time: 14:40
Sample: 2000M01 2012M12
Included observations: 156

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.218761	0.038771	5.642317	0.0000
LOG(USUARIOS)	1.508534	0.095356	15.81996	0.0000
LOG(TEMPERATURA)	0.113712	0.015466	7.352557	0.0000
LOG(PPE)	-0.215886	0.053998	-3.998043	0.0001
D200609	0.067482	0.026199	2.575747	0.0110
D200509	0.060138	0.026478	2.271243	0.0246
D200709	0.067451	0.026569	2.538672	0.0122
C	-8.849423	1.102892	-8.023837	0.0000

R-squared	0.983950	Mean dependent var	13.55953
Adjusted R-squared	0.983191	S.D. dependent var	0.201022
S.E. of regression	0.026062	Akaike info criterion	-4.406737
Sum squared resid	0.100528	Schwarz criterion	-4.250334
Log likelihood	351.7255	Hannan-Quinn criter.	-4.343213
F-statistic	1296.189	Durbin-Watson stat	1.941520
Prob(F-statistic)	0.000000		


Gráfica N° 4.15 Resultados de la Regresión EQ01IMPORTANT

A continuación realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.2) acorde con la teoría económica, el coeficiente asociado a los usuarios (1.5) y el coeficiente asociado a la temperatura (0.11) también son positivos. Además puede comprobarse el valor estadístico t que todos son mayores a 2, probabilidad nula (Prob. = 0.000) de rechazar la hipótesis nula siendo cierta.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 98.2% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de

Durbin Watson (1.94), como es mayor a 1.53 el modelo no presenta problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Para ello se debe presionar: View y luego seleccionar Actual Fitted Residual / Residual Graph.



Gráfica N° 4.16 Evaluación de los residuos EQ01IMPORTANT

Se observa que el error residual se encuentra en un orden de ± 0.06 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

En términos generales, podríamos admitir que el modelo considerado está bien especificado, ya que los signos de los coeficientes no presentan problemas, presenta una buena representatividad global y no presenta indicios de autocorrelación residual.

Substituted Coefficients:

=====

$$\text{LOG(VENTAS)} = 0.21876066048 * \text{LOG(PBI)} + 1.50853437219 * \text{LOG(USUARIOS)} +$$

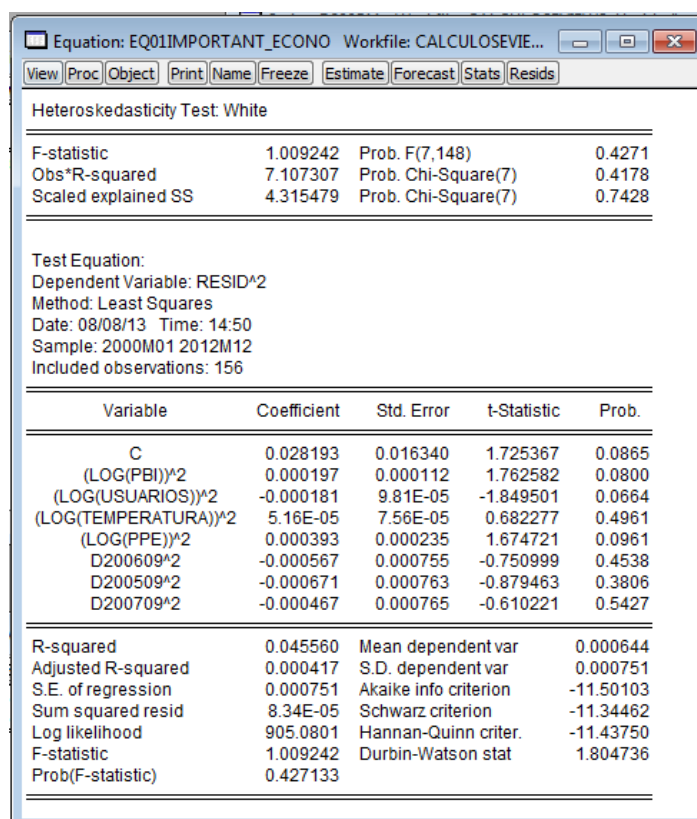
$$0.113712421225 * \text{LOG(TEMPERATURA)} - 0.2158860832 * \text{LOG(PPE)} +$$

$$0.0674821188898 * \text{D200609} + 0.0601376284396 * \text{D200509} + 0.0674505990467 * \text{D200709} -$$

$$8.84942298874$$

4.4.4 CONTRASTE O VALIDACIÓN DEL MODELO ECONOMÉTRICO PROPUESTO

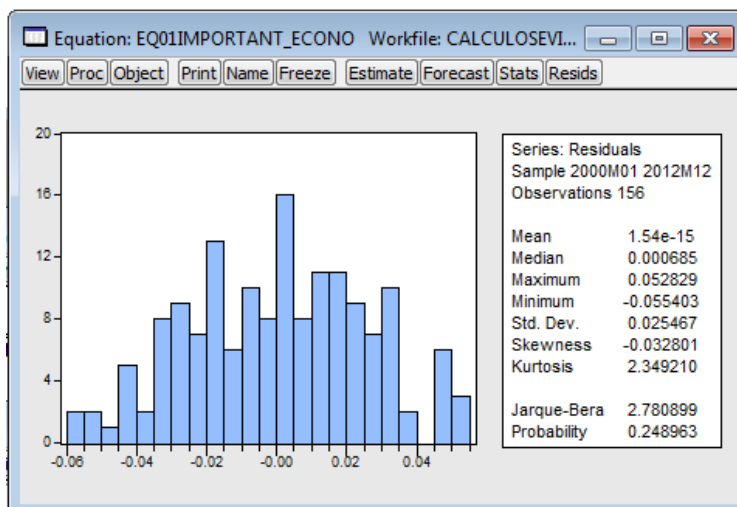
4.4.4.1 PRUEBA DE HETEROSCEDASTICIDAD DE WHITE DEL (MEPM)



Gráfica N° 4.17 Prueba de Heteroscedasticidad EQ01IMPORTANT

Con un probabilidad significativa 42.71% (mayor que 5%), se acepta la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo es decir la serie es estacionaria.

4.4.4.2 NORMALIDAD DEL RESIDUO DEL (MEPM)



Gráfica N° 4.18 Evaluación de la Normalidad EQ01IMPORTANT

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 24.89%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

4.4.4.3 COLINEALIDAD EN VARIABLES EXPLICATIVAS DEL (MEPM)

El análisis de colinealidad permite determinar si cada regresor, inicialmente considerado, guarda independencia lineal o no con los demás regresores. El requisito fundamental para que un modelo sea apropiado para predicciones es la independencia lineal entre variables explicativas.

	LOG(VENTAS)	LOG(PBI)	LOG(USUA...)	LOG(TEMPE...)	LOG(PPE)	D200609	D200509	D200709
LOG(VENTAS)	1.000000	0.968759	0.988890	-0.025297	0.622340	0.030580	0.006164	0.046078
LOG(PBI)	0.968759	1.000000	0.961868	-0.073301	0.556546	0.004928	-0.015424	0.031519
LOG(USUA...)	0.988890	0.961868	1.000000	-0.064812	0.659730	0.014929	0.000786	0.034118
LOG(TEMPE...)	-0.025297	-0.073301	-0.064812	1.000000	-0.137773	-0.044583	-0.088486	-0.146957
LOG(PPE)	0.622340	0.556546	0.659730	-0.137773	1.000000	0.021815	0.072231	0.000304
D200609	0.030580	0.004928	0.014929	-0.044583	0.021815	1.000000	-0.004926	-0.004926
D200509	0.006164	-0.015424	0.000786	-0.088486	0.072231	-0.004926	1.000000	-0.004926
D200709	0.046078	0.031519	0.034118	-0.146957	0.000304	-0.004926	-0.004926	1.000000

Gráfica N° 4.19 Evaluación de la colinealidad

Se observa independencia lineal entre las variables explicativas.

Inicialmente se perfila un modelo regresivo lineal, con las variables en niveles o transformadas, verificando el cumplimiento de los condicionantes estadísticos mediante pruebas estadísticas de significancia y corroboración. La transformación potencial se realiza con la finalidad de minimizar la variabilidad de la data histórica, cuando ésta tiene característica heteroscedástica. En situaciones muy frecuentes se aplica una transformación logarítmica, logrando resultados satisfactorios de estabilidad en varianza.

4.4.4.4 ESPECIFICACIÓN FUNCIONAL: PRUEBA DE RAMSEY DEL (MEPM)

La prueba Reset de Ramsey permite la comprobación de la correcta especificación polinómica (funcional) de un modelo estimado; es decir, que no se hayan omitido algunos otros regresores que pueden ser potencias o productos cruzados de los regresores ya incluidos en el modelo inicialmente especificado.


Equation: EQ01IMPORTANT_ECONO Workfile: CALCULOSEVI...				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Ramsey RESET Test				
F-statistic	0.505721	Prob. F(1,143)	0.4782	
Log likelihood ratio	0.550722	Prob. Chi-Square(1)	0.4580	
Test Equation:				
Dependent Variable: LOG(VENTAS)				
Method: Least Squares				
Date: 08/08/13 Time: 14:56				
Sample: 2000M01 2012M12				
Included observations: 156				
Convergence achieved after 18 iterations				
MA Backcast: 1998M01 1999M12				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	-0.101075	0.030704	-3.291870	0.0013
LOG(USUARIOS)	0.250924	0.072599	3.456290	0.0007
LOG(TEMPERATURA)	0.022777	0.011823	1.926580	0.0560
LOG(PPE)	-0.054238	0.020152	-2.691480	0.0080
D200609	0.028335	0.014888	1.903209	0.0590
D200509	0.026638	0.017250	1.544180	0.1248
D200709	0.038100	0.017379	2.192391	0.0300
C	-2.971663	0.852051	-3.487660	0.0006
FITTED^2	-3.974648	3.824948	-1.039138	0.3005
R-squared	0.440882	Mean dependent var	0.004328	
Adjusted R-squared	0.393963	S.D. dependent var	0.022304	
S.E. of regression	0.017364	Akaike info criterion	-5.189234	
Sum squared resid	0.043113	Schwarz criterion	-4.935079	
Log likelihood	417.7602	Hannan-Quinn criter.	-5.086007	
F-statistic	9.396681	Durbin-Watson stat	2.167709	
Prob(F-statistic)	0.000000			

Gráfica N° 4.20 Prueba de Ramsey EQ01IMPORTANT

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 47.82% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

4.4.4.5 ESTABILIDAD DE LOS PARÁMETROS

La prueba de suma acumulada de los residuos normalizados al cuadrado -cusum2-, permiten determinar la existencia de posibles quiebres estructurales en los modelos. Un quiebre estructural es indicativo de que los parámetros de la ecuación de regresión no son constantes a lo largo de toda la muestra.



Gráfica N° 4.21 Prueba de Cusum-EQ01IMPORTANT

Se observa que el gráfico no se sale de las bandas de confianza al 5% de significancia, donde comienza a presentarse ligeros quiebres estructurales, lo que se aprecia una estabilidad del modelo.

Siguiendo la metodología de estimación en dos etapas propuesta por Engle y Granger, se debe verificar que el residuo de la expresión anterior sea estacionario para verificar la presencia de cointegración. Una vez determinada la estacionariedad de los residuos se procede a estimar un modelo de corrección de errores, determinado por un modelo de rezagos distribuidos de la forma:

Cálculo del error:

$$\begin{aligned}
 \text{LOG(ERROR)} = & \text{LOG(VENTAS)} & -0.21876066048 * \text{LOG(PBI)} & - \\
 & 1.50853437219 * \text{LOG(USUARIOS)} & -0.113712421225 * \text{LOG(TEMPERATURA)} & + \\
 & 0.2158860832 * \text{LOG(PPE)} & - 0.0674821188898 * \text{D200609} & - 0.0601376284396 * \text{D200509} & - \\
 & 0.0674505990467 * \text{D200709} & + 8.84942298874 & &
 \end{aligned}$$

Log(PBI): Logaritmo de la serie histórica del Producto Bruto Interno (PBI).

Log(USUARIOS): Logaritmo de la serie histórica Usuarios.

Log(PPE): Logaritmo de la serie histórica del precio promedio de electricidad.

Log(Ventas): Logaritmo de la serie Ventas de electricidad.

Log(Temperatura): Logaritmo de la serie histórica de la temperatura.

Log(Error): Logaritmo Natural de las diferencia de logaritmo de Ventas reales y logaritmo de Ventas estimadas.

Equation: EQ02IMPORTANT Workfile: CALCULOSEVIEWS:...

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: D(LOG(VENTAS))
 Method: Least Squares
 Date: 08/08/13 Time: 16:37
 Sample: 2000M01 2012M12
 Included observations: 156
 Convergence achieved after 5 iterations
 MA Backcast: 1998M01 1999M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.085703	0.043634	1.964137	0.0514
LOGERROR3	-0.380482	0.064917	-5.861046	0.0000
D0204	0.060977	0.014633	4.167129	0.0001
D0705	-0.039220	0.012232	-3.206206	0.0016
MA(12)	0.721741	0.058137	12.41439	0.0000
MA(24)	0.561485	2.29E-06	244718.2	0.0000

R-squared	0.492846	Mean dependent var	0.004328
Adjusted R-squared	0.475940	S.D. dependent var	0.022304
S.E. of regression	0.016147	Akaike info criterion	-5.376521
Sum squared resid	0.039107	Schwarz criterion	-5.259219
Log likelihood	425.3687	Hannan-Quinn criter.	-5.328878
Durbin-Watson stat	2.005976		


Inverted MA Roots				
.96-.17i	.96+.17i	.92-.34i	.92+.34i	
.75-.63i	.75+.63i	.63+.75i	.63-.75i	
.34+.92i	.34-.92i	.17+.96i	.17-.96i	
-.17+.96i	-.17-.96i	-.34+.92i	-.34-.92i	
-.63+.75i	-.63-.75i	-.75+.63i	-.75-.63i	
-.92+.34i	-.92-.34i	-.96+.17i	-.96-.17i	

Gráfica N° 4.22 Resultados de la Regresión EQ02IMPORTANT

A continuación realizaremos un análisis conjunto, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 49.28% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin

Watson (2), como es mayor a 1.53 el modelo parece no presentar problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo:



Gráfica N° 4.23 Evaluación de los residuos EQ02IMPORTANT

Se observa que el error residual se encuentra en un orden de ± 0.04 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

4.4.5 ESTIMACIÓN DEL MODELO DE CORRECCIÓN DE ERRORES MENSUAL

Del Programa E-Views mostrará la especificación de la ecuación bajo tres formatos alternativos, como los que presentamos, comenzando con el comando de estimación, y siguiendo con la especificación algebraica genérica y la correspondiente una vez estimados los coeficientes.

Estimation Command:

=====

LS(DERIV=AA) D(LOG(VENTAS)) D(LOG(PBI)) LOGERROR3 D0204 D0705 MA(12) MA(24)

Estimation Equation:

=====

D(LOG(VENTAS)) = C(1)*D(LOG(PBI)) + C(2)*LOGERROR3 + C(3)*D0204 + C(4)*D0705 +

[MA(12)=C(5),MA(24)=C(6),BACKCAST=2000M01,ESTSMPL="2000M01 2012M12"]

Substituted Coefficients:

=====

D(LOG(VENTAS)) = 0.0857034945186*D(LOG(PBI)) - 0.380481775958*LOGERROR3 +

0.0609766985823*D0204 - 0.0392195701596*D0705 +

[MA(12)=0.721740773357,MA(24)=0.561484561183,BACKCAST=2000M01,ESTSMPL="2000M0

1 2012M12"]

D (Log (PBI)): Primera diferencia del logaritmo de la serie histórica del Producto Bruto Interno (PBI).

Log (Error): Logaritmo Natural de las diferencia de logaritmo de Ventas reales y logaritmo de Ventas estimadas.

D (Log (Ventas)): Primera diferencia del logaritmo de las Ventas.

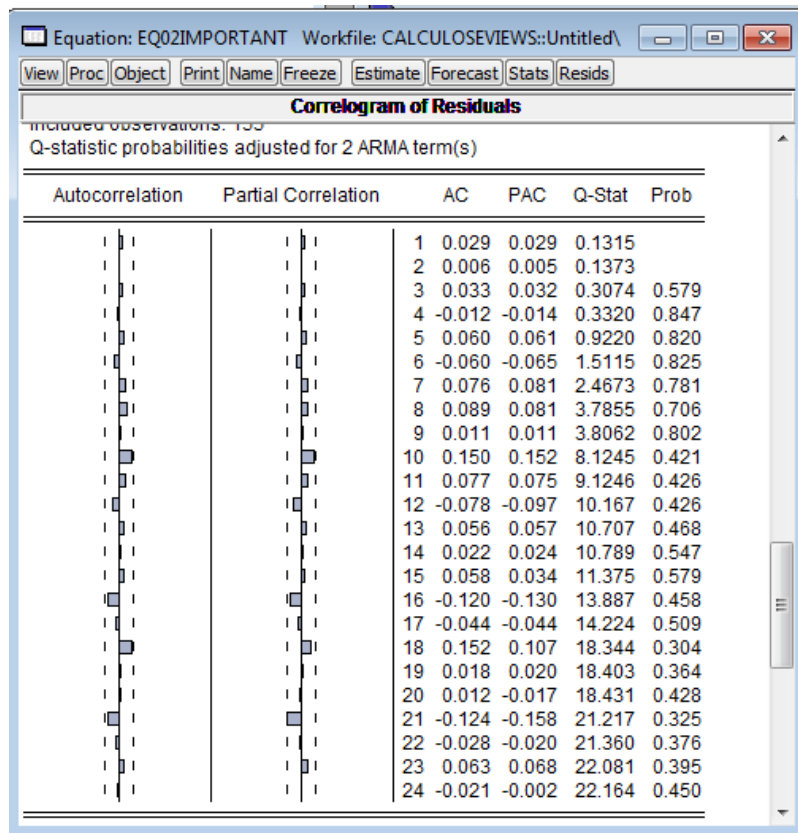
D0204: Intervención en la serie en el mes de Abril del año 2002. Variable dummy.

D0705: Intervención en la serie en el mes de Mayo del año 2005. Variable dummy.

MA (12): Variable de medias móviles de orden 12, para corrección de la autocorrelación de la serie.

MA (24): Variable de medias móviles de orden 24, para corrección de la autocorrelación de la serie.

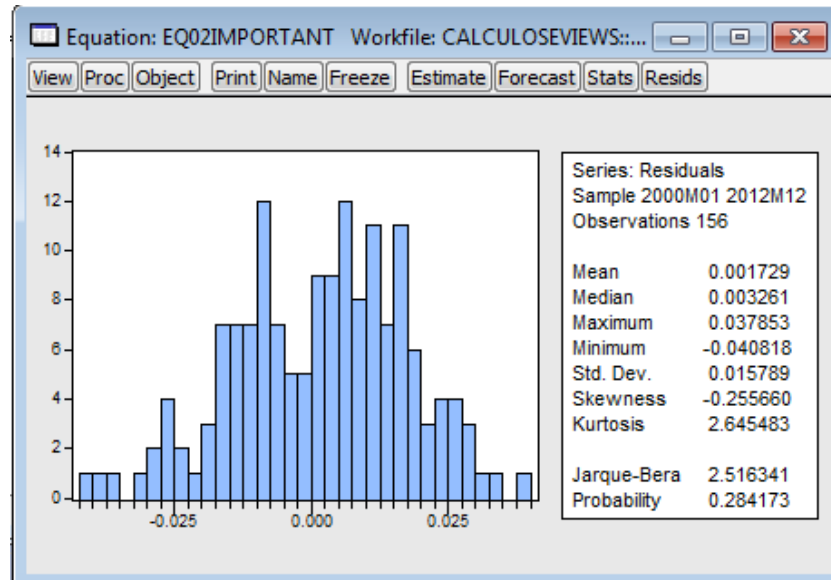
Correlograma de Residuos



Gráfica N° 4.24 Correlograma-EQ02IMPORTANT

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

Normalidad del Residuo



Gráfica N° 4.25 Evaluación de la Normalidad EQ02IMPORTANT

El test de Jarque-Bera presenta una probabilidad de 28.41% por lo que no rechazamos la hipótesis la nula por ser mayor a 5% y deberíamos admitir la normalidad del residuo. Este test analiza la relación entre los coeficientes de apuntamiento y curtosis de los residuos de la ecuación y los correspondientes a los de una distribución normal.

Prueba de Heteroscedasticidad de WHITE

Heteroskedasticity Test: White

F-statistic	0.487524	Prob. F(6,149)	0.8169
Obs*R-squared	3.003601	Prob. Chi-Square(6)	0.8084
Scaled explained SS	2.143755	Prob. Chi-Square(6)	0.9060

Test Equation:
 Dependent Variable: RESID^2
 Method: Least Squares
 Date: 08/08/13 Time: 17:06
 Sample: 2000M01 2012M12
 Included observations: 156

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000239	4.09E-05	5.849747	0.0000
GRADF_01^2	-0.009707	0.019052	-0.509493	0.6112
GRADF_02^2	0.066660	0.048169	1.383887	0.1685
GRADF_03^2	-0.000269	0.000421	-0.637500	0.5248
GRADF_04^2	-0.000122	0.000284	-0.428479	0.6689
GRADF_05^2	-0.012437	0.031893	-0.389971	0.6971
GRADF_06^2	0.006342	0.041429	0.153073	0.8785

R-squared	0.019254	Mean dependent var	0.000251
Adjusted R-squared	-0.020239	S.D. dependent var	0.000312
S.E. of regression	0.000316	Akaike info criterion	-13.24013
Sum squared resid	1.48E-05	Schwarz criterion	-13.10328
Log likelihood	1039.730	Hannan-Quinn criter.	-13.18454
F-statistic	0.487524	Durbin-Watson stat	2.041633
Prob(F-statistic)	0.816904		

Gráfica N° 4.26 Prueba de Heteroscedasticidad EQ02IMPORTANT

Con un probabilidad significativa 81.69% (mayor que 5%), se acepta la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo es decir la serie es estacionaria.

Especificación funcional: Prueba de Ramsey

Permite identificar si se está usando una forma lineal incorrecta y cualquier error de omisión o la presencia de correlaciones entre las variables explicativas y la perturbación.

Ramsey RESET Test				
F-statistic	0.305293	Prob. F(1,148)	0.5814	
Log likelihood ratio	0.321464	Prob. Chi-Square(1)	0.5707	
WARNING: the MA backcasts differ for the original and test equation. Under the null hypothesis, the impact of this difference vanishes asymptotically.				
Test Equation:				
Dependent Variable: D(LOG(VENTAS))				
Method: Least Squares				
Date: 08/08/13 Time: 17:07				
Sample: 2000M01 2012M12				
Included observations: 156				
Convergence achieved after 13 iterations				
MA Backcast: 1998M01 1999M12				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.096101	0.044017	2.183291	0.0306
LOGERROR3	-0.424782	0.061897	-6.862719	0.0000
D0204	0.061427	0.017656	3.479100	0.0007
D0705	-0.048451	0.010582	-4.578503	0.0000
C	0.003883	0.003344	1.161011	0.2475
FITTED^2	-0.450260	2.624847	-0.171538	0.8640
MA(12)	0.896502	0.002714	330.3268	0.0000
MA(24)	0.878063	0.024421	35.95465	0.0000
R-squared	0.570693	Mean dependent var	0.004328	
Adjusted R-squared	0.550388	S.D. dependent var	0.022304	
S.E. of regression	0.014956	Akaike info criterion	-5.517523	
Sum squared resid	0.033104	Schwarz criterion	-5.361121	
Log likelihood	438.3668	Hannan-Quinn criter.	-5.453999	
F-statistic	28.10594	Durbin-Watson stat	1.911651	
Prob(F-statistic)	0.000000			
Inverted MA Roots	.98+.17i	.98-.17i	.93-.34i	.93+.34i
	.76+.64i	.76-.64i	.64-.76i	.64+.76i
	.34+.93i	.34-.93i	.17+.98i	.17-.98i
	-.17+.98i	-.17-.98i	-.34+.93i	-.34-.93i
	-.64+.76i	-.64-.76i	-.76+.64i	-.76-.64i
	-.93+.34i	-.93-.34i	-.98+.17i	-.98-.17i

Gráfica N° 4.27 Prueba de Ramsey EQ02IMPORTANT

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 58.14% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

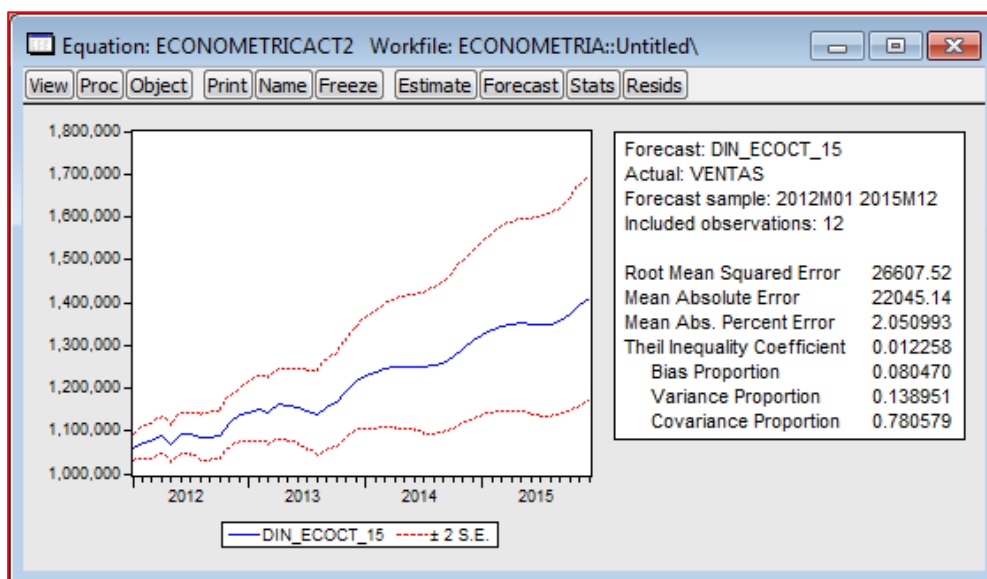
4.4.6 PROYECCIÓN ECONOMÉTRICA PROPUESTA MENSUAL

Una vez determinada los parámetros se procede a proyectar la variable ventas de energía eléctrica para el modelo con la variable temperatura para el período 2013-2015 en frecuencia mensual.

PROYECCIÓN ECONOMÉTRICA MENSUAL CON TEMPERATURA

Tabla N° 4.3

Año	Proyección Ventas de Energía Eléctrica Modelo Econométrico 2013-2015 (MWh)
2013M01	1143002
2013M02	1149314
2013M03	1144146
2013M04	1161460
2013M05	1157474
2013M06	1154640
2013M07	1145083
2013M08	1139212
2013M09	1156175
2013M10	1168482
2013M11	1191653
2013M12	1215836
2014M01	1228097
2014M02	1236140
2014M03	1244702
2014M04	1247755
2014M05	1250657
2014M06	1249514
2014M07	1248056
2014M08	1251877
2014M09	1259707
2014M10	1274290
2014M11	1291908
2014M12	1309561
2015M01	1324474
2015M02	1337408
2015M03	1344539
2015M04	1347921
2015M05	1351040
2015M06	1347748
2015M07	1348875
2015M08	1348529
2015M09	1357939
2015M10	1373278
2015M11	1393275
2015M12	1410587



Gráfica N° 4.28 Gráfica de la proyección de la variable ventas de energía eléctrica en el departamento de Lima para el período 2013-2015

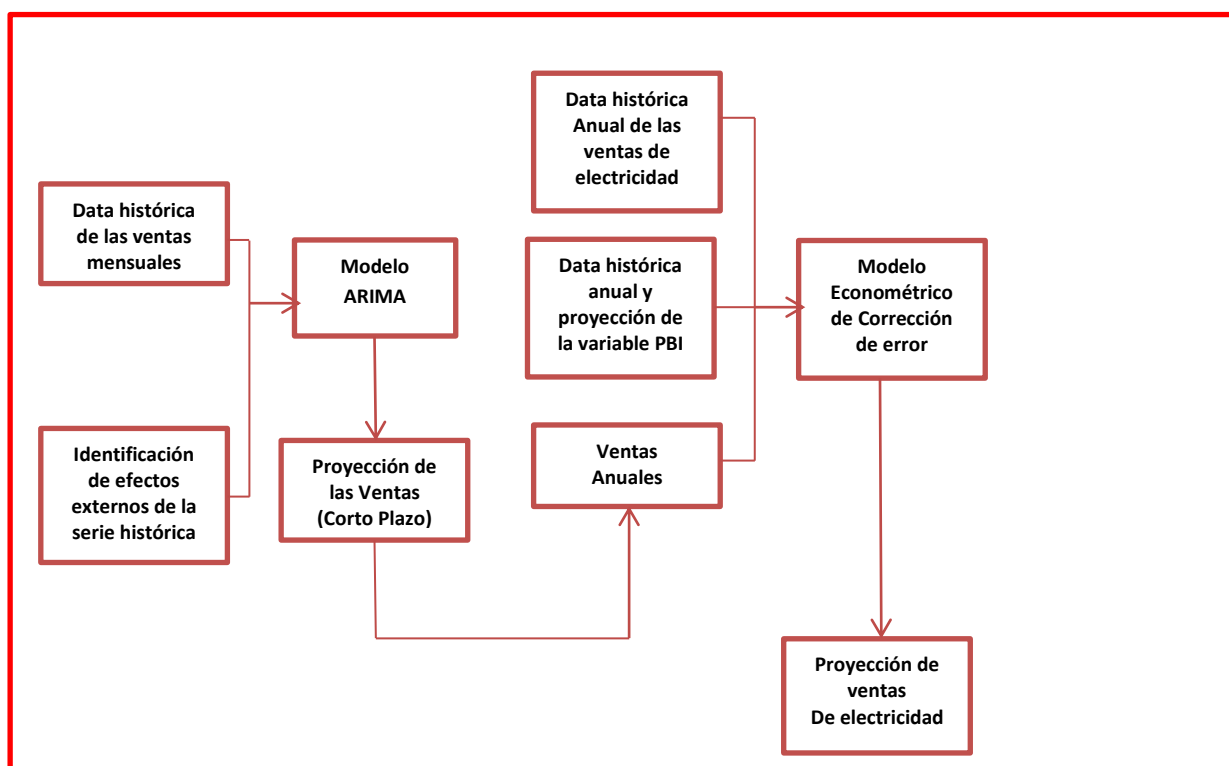
Este es una representación de una predicción dinámica desde el período 2013-2015, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.012258, esto da indicaciones de una buena predicción.

4.4.7 RESULTADOS DE LA ESTIMACIÓN DEL MODELO ECONOMÉTRICO PROPUESTO MENSUAL

Se observa los resultados de las proyecciones de las ventas de energía eléctrica para el departamento de Lima con el modelo Econométrico de Corrección de errores con la adición de la variable temperatura. En la tabla se muestra los resultados en frecuencia mensual desde el 2013 al 2015. En la gráfica N° 4.28 se muestra el gráfico de las proyecciones mensuales hasta el 2015. Para el cálculo de las ventas de energía se utilizó el modelo de corrección de errores con frecuencia mensual.

4.5 OPTIMIZACIÓN DEL MODELO ARIMA-ECONOMÉTRICO (MAE) PARA PROYECTAR LAS VENTAS DE ENERGÍA ELÉCTRICA ANUALES

A continuación se proyectara la variable ventas de energía eléctrica en frecuencia anual para el período 2016-2018, ingresando los resultados obtenidos en la proyección mensual con el modelo ARIMA del período 2013-2015 y se comienza a proyectar de acuerdo al modelo Arima-Económico.

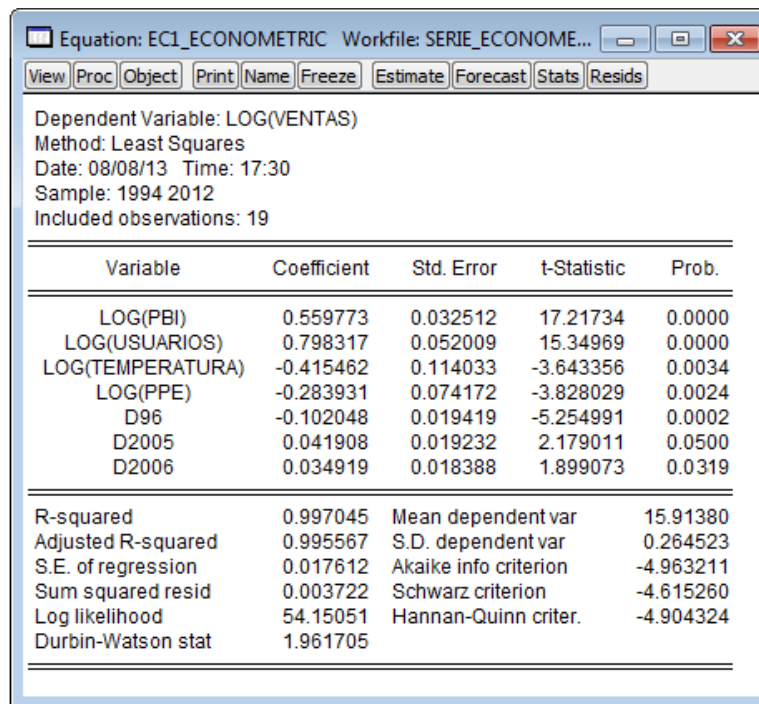


Gráfica N° 4.29 Procedimiento de cálculo del Modelo Arima-Económico

4.5.1 ESTIMACIÓN DEL MODELO ECONÓMICO PROPUESTO

A continuación se realizará una regresión multivariada con la cual se busca obtener una mejor explicación.

El resultado de la regresión se presenta en el siguiente cuadro:



Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.559773	0.032512	17.21734	0.0000
LOG(USUARIOS)	0.798317	0.052009	15.34969	0.0000
LOG(TEMPERATURA)	-0.415462	0.114033	-3.643356	0.0034
LOG(PPE)	-0.283931	0.074172	-3.828029	0.0024
D96	-0.102048	0.019419	-5.254991	0.0002
D2005	0.041908	0.019232	2.179011	0.0500
D2006	0.034919	0.018388	1.899073	0.0319


R-squared	0.997045	Mean dependent var	15.91380
Adjusted R-squared	0.995567	S.D. dependent var	0.264523
S.E. of regression	0.017612	Akaike info criterion	-4.963211
Sum squared resid	0.003722	Schwarz criterion	-4.615260
Log likelihood	54.15051	Hannan-Quinn criter.	-4.904324
Durbin-Watson stat	1.961705		

Gráfica N° 4.30 Resultados de la Regresión EC1_ECONOMETRIC

A continuación realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.55) acorde con la teoría económica, significa que, Si el PBI aumenta en 1% las ventas de energía eléctrica aumentan en 0.55%. En el caso de la tarifa eléctrica, si la tarifa promedio eléctrica aumenta en un punto porcentual las ventas de energía eléctrica disminuyen en 0.28%.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 99.7% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si se observa el valor del estadístico de Durbin Watson (1.96), como es mayor a 1.53 el modelo parece no presentar problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Si errores positivos son seguidos de errores positivos y errores negativos por errores de igual signo, entonces estamos en presencia de autocorrelación positiva. Observando el gráfico a continuación:



Gráfica N° 4.31 Evaluación de los residuos EC1_ECONOMETRIC

Se observa que el error residual se encuentra en un orden de ± 0.03 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

En términos generales, podríamos admitir que el modelo considerado está bien especificado, ya que los signos de los coeficientes no presentan problemas, presenta una buena representatividad global y no presenta indicios de autocorrelación residual.

Del Programa E-Views mostrará la especificación de la ecuación bajo tres formatos alternativos, como los que presentamos, comenzando con el comando de estimación, y siguiendo con la especificación algebraica genérica y la correspondiente una vez estimados los coeficientes.

Estimation Command:

```
=====
LS LOG(VENTAS) LOG(PBI) LOG(USUARIOS) LOG(TEMPERATURA) LOG(PPE) D96 D2005
D2006
```

Estimation Equation:

```
=====
LOG(VENTAS) = C(1)*LOG(PBI) + C(2)*LOG(USUARIOS) + C(3)*LOG(TEMPERATURA) +
C(4)*LOG(PPE) + C(5)*D96 + C(6)*D2005 + C(7)*D2006
```


Substituted Coefficients:

```
=====
LOG(VENTAS) = 0.559772511553*LOG(PBI) + 0.798317183131*LOG(USUARIOS) -
0.415462466152*LOG(TEMPERATURA) - 0.283931344122*LOG(PPE) - 0.102048307171*D96 +
0.0419077135278*D2005 + 0.0349194759298*D2006
```

4.5.2 CONTRASTE O VALIDACIÓN DEL MODELO ARIMA-ECONOMÉTRICO (MAE)

A continuación se validará con las siguientes pruebas:

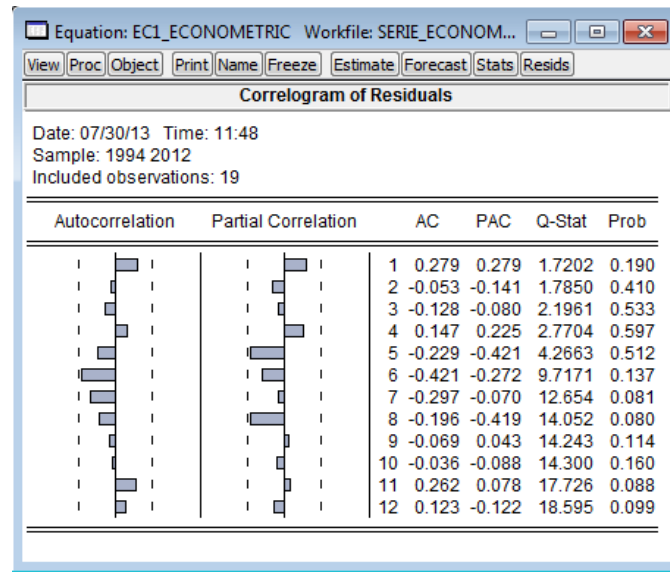
4.5.2.1 NORMALIDAD DEL RESIDUO DEL (MAE)



Gráfica N° 4.32 Evaluación de la Normalidad EC1_ECONOMETRIC

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 24.89%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

4.5.2.2 CORRELOGRAMA DE RESIDUOS DEL (MAE)



Gráfica N° 4.33 Correlograma-EC1_ECONOMETRIC

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

4.5.2.3 PRUEBA DE HETEROSCEDASTICIDAD DE WHITE DEL (MAE)

Equation: EC1_ECONOMETRIC Workfile: SERIE_ECONOMETRIC_A...									
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Heteroskedasticity Test: White									
F-statistic	0.820247	Prob. F(7,11)	0.5902						
Obs*R-squared	6.516225	Prob. Chi-Square(7)	0.4809						
Scaled explained SS	1.705958	Prob. Chi-Square(7)	0.9743						
Test Equation:									
Dependent Variable: RESID^2									
Method: Least Squares									
Date: 08/17/13 Time: 12:19									
Sample: 1994 2012									
Included observations: 19									
Variable	Coefficient	Std. Error	t-Statistic	Prob.					
C	0.000479	0.006620	0.072368	0.9436					
(LOG(PBI))^2	3.46E-05	3.36E-05	1.028893	0.3256					
(LOG(USUARIOS))^2	-3.54E-05	6.43E-05	-0.550498	0.5930					
(LOG(TEMPERATURA))^2	0.000208	0.000260	0.799678	0.4408					
(LOG(PPE))^2	2.62E-05	0.000214	0.122474	0.9047					
D96^2	-7.98E-05	0.000265	-0.301443	0.7687					
D2005^2	-0.000224	0.000270	-0.827213	0.4257					
D2006^2	-0.000232	0.000252	-0.920116	0.3772					
R-squared	0.342959	Mean dependent var	0.000196						
Adjusted R-squared	-0.075158	S.D. dependent var	0.000231						
S.E. of regression	0.000239	Akaike info criterion	-13.54384						
Sum squared resid	6.29E-07	Schwarz criterion	-13.14619						
Log likelihood	136.6665	Hannan-Quinn criter.	-13.47654						
F-statistic	0.820247	Durbin-Watson stat	1.978619						
Prob(F-statistic)	0.590211								

Gráfica N° 4.34 Prueba de Heteroscedasticidad EC1_ECONOMETRIC

Con un probabilidad significativa 59.02% (mayor que 5%), no se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo es decir la serie es estacionaria.

4.5.2.4 ESPECIFICACIÓN FUNCIONAL: PRUEBA DE RAMSEY DEL (MAE)

La prueba Reset de Ramsey permite la comprobación de la correcta especificación polinómica (funcional) de un modelo estimado; A continuación se muestra el siguiente gráfico:


Equation: EC1_ECONOMETRIC Workfile: SERIE_ECONOMETRIC_A...									
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Ramsey RESET Test									
Equation: EC1_ECONOMETRIC									
Specification: LOG(VENTAS) LOG(PBI) LOG(USUARIOS)									
LOG(TEMPERATURA) LOG(PPE) D96 D2005 D2006									
Omitted Variables: Squares of fitted values									
		Value	df	Probability					
t-statistic		2.120244	11	0.0575					
F-statistic		4.495437	(1, 11)	0.0575					
Likelihood ratio		6.510356	1	0.0107					
F-test summary:									
		Sum of Sq	df	Mean Squares					
Test SSR		0.001080	1	0.001080					
Restricted SSR		0.003722	12	0.000310					
Unrestricted SSR		0.002642	11	0.000240					
Unrestricted SSR		0.002642	11	0.000240					
LR test summary:									
		Value	df						
Restricted LogL		54.15051	12						
Unrestricted LogL		57.40568	11						
Unrestricted Test Equation:									
Dependent Variable: LOG(VENTAS)									
Method: Least Squares									
Date: 08/17/13 Time: 12:20									
Sample: 1994 2012									
Included observations: 19									
	Variable	Coefficient	Std. Error	t-Statistic	Prob.				
	LOG(PBI)	0.782987	0.109096	7.177024	0.0000				
	LOG(USUARIOS)	0.747265	0.051716	14.44948	0.0000				
	LOG(TEMPERATURA)	-0.507292	0.109298	-4.641372	0.0007				
	LOG(PPE)	-0.229375	0.070161	-3.269287	0.0075				
	D96	-0.126344	0.021115	-6.079229	0.0001				
	D2005	0.042347	0.016926	2.501885	0.0294				
	D2006	0.037909	0.016243	2.333927	0.0396				
	FITTED^2	-0.007210	0.003401	-2.120244	0.0575				
	R-squared	0.997902	Mean dependent var	15.91380					
	Adjusted R-squared	0.996567	S.D. dependent var	0.264523					
	S.E. of regression	0.015498	Akaike info criterion	-5.200598					
	Sum squared resid	0.002642	Schwarz criterion	-4.802940					
	Log likelihood	57.40568	Hannan-Quinn criter.	-5.133299					
	Durbin-Watson stat	2.509382							

Gráfica N° 4.35 Prueba de Ramsey EC1_ECONOMETRIC

Notemos que, la probabilidad asociada al F estadístico del test de Ramsey RESET es igual a 5.75% ($p > 5\%$, por lo no se rechaza la hipótesis nula). Por lo tanto no se puede rechazar la hipótesis nula de que el modelo está bien especificado. Es decir que las variables regresoras cumplen con el objetivo de explicar bien el modelo.

4.5.2.5 ESTABILIDAD DE LOS PARÁMETROS DEL (MAE)

Utilizando la prueba de cusum permite determinar la existencia de posibles quiebres estructurales en los modelos.



Gráfica N° 4.36 Prueba de Cusum-EC1_ECONOMETRIC

Se observa que el gráfico no se sale de las bandas de confianza al 5% de significancia, donde comienza a presentarse ligeros quiebres estructurales, lo que se aprecia una estabilidad del modelo.

4.5.3 ESTIMACIÓN DEL MODELO DE CORRECCIÓN DE ERRORES ANUAL

Siguiendo la metodología de estimación en dos etapas propuesta por Engle y Granger, se debe verificar que el residuo de la expresión anterior sea estacionario para verificar la presencia de cointegración. Una vez determinada la estacionariedad de los residuos se procede a estimar un modelo de corrección de errores, determinado por un modelo de rezagos distribuidos de la forma:

Estimation Command:

=====

LS(DERIV=AA) D(LOG(VENTAS)) D(LOG(PBI)) LOGERROR D98 D2002 AR(2) MA(1) MA(5)

Estimation Equation:

=====

D(LOG(VENTAS)) = C(1)*D(LOG(PBI)) + C(2)*LOGERROR + C(3)*D98 + C(4)*D2002 +
[AR(2)=C(5),MA(1)=C(6),MA(5)=C(7),BACKCAST=1997,ESTSMPL="1997 2014"]

El resultado de la regresión se presenta en el siguiente cuadro:

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.865749	0.006599	131.2038	0.0000
LOGERROR	-0.175130	0.050057	-3.498583	0.0050
D98	0.062732	0.017515	3.581692	0.0043
D2002	0.018576	0.004332	4.288122	0.0013
AR(2)	-0.735754	0.201636	-3.648915	0.0038
MA(1)	-1.040459	0.298170	-3.489477	0.0051
MA(5)	0.324351	0.133879	2.422724	0.0338
R-squared	0.929482	Mean dependent var		0.049570
Adjusted R-squared	0.891017	S.D. dependent var		0.023056
S.E. of regression	0.007612	Akaike info criterion		-6.633008
Sum squared resid	0.000637	Schwarz criterion		-6.286752
Log likelihood	66.69707	Hannan-Quinn criter.		-6.585264
Durbin-Watson stat	2.451211			
Inverted MA Roots	.95-.31i	.95+.31i	-.10-.70i	-.10+.70i
	-.66			


Gráfica N° 4.37 Resultados de la Regresión EC2_ECONOMETRIC

A continuación realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.86) acorde con la teoría económica, significa que, Si el PBI aumenta en 1% las ventas de energía eléctrica aumentan en 0.86%. Obsérvese que se añadió las variables dummy para los años 1998 y 2002.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 92.94% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si Se observa el valor del estadístico de Durbin Watson (2.45), como es mayor a 1.53 y menor a 2.46 el modelo parece no presentar problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Observando el gráfico a continuación:

Observando el gráfico de los residuos a lo largo del tiempo. Existen errores positivos que son seguidos de errores positivos y errores negativos por errores de igual signo, entonces estamos en presencia de autocorrelación positiva.



Gráfica N° 4.38 Evaluación de los residuos EC2_ECONOMETRIC

Se observa que el error residual se encuentra en un orden de +/- 0.04 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.


Prueba de Heteroscedasticidad de WHITE

Heteroskedasticity Test: White				
F-statistic	2.365029	Prob. F(7,10)	0.1051	
Obs*R-squared	11.22167	Prob. Chi-Square(7)	0.1292	
Scaled explained SS	145.2095	Prob. Chi-Square(7)	0.0000	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 08/17/13 Time: 12:48				
Sample: 1997 2014				
Included observations: 18				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.45E-05	0.000214	0.114768	0.9109
GRADF_01^2	0.000618	0.000486	1.271599	0.2323
GRADF_02^2	0.007023	0.006473	1.084884	0.3034
GRADF_03^2	0.003236	0.004720	0.685695	0.5085
GRADF_04^2	-0.000182	0.000188	-0.967598	0.3561
GRADF_05^2	-1.097742	0.600856	-1.826964	0.0977
GRADF_06^2	0.023190	0.008492	2.730916	0.0212
GRADF_07^2	-0.002621	0.001372	-1.911262	0.0850
R-squared	0.623426	Mean dependent var	0.000304	
Adjusted R-squared	0.359824	S.D. dependent var	0.000303	
S.E. of regression	0.000243	Akaike info criterion	-13.50877	
Sum squared resid	5.89E-07	Schwarz criterion	-13.11305	
Log likelihood	129.5789	Hannan-Quinn criter.	-13.45420	
F-statistic	2.365029	Durbin-Watson stat	2.700809	
Prob(F-statistic)	0.105125			

Gráfica N° 4.39 Prueba de Heteroscedasticidad EC2_ECONOMETRIC

Con un probabilidad significativa 10.51% (mayor que 5%), no se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo es decir la serie es estacionaria.

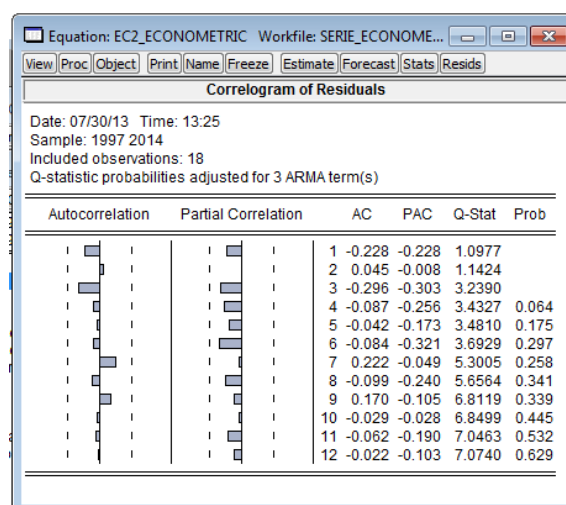
Normalidad del Residuo



Gráfica N° 4.40 Evaluación de la Normalidad EC2_ECONOMETRIC

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 76.96%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

Correlograma de residuos




Gráfica N° 4.41 Correlograma-EC2_ECONOMETRIC

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

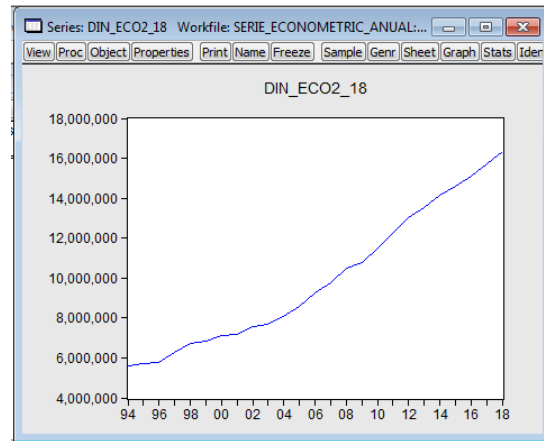
Una vez realizadas las operaciones descritas, ya estaríamos en condiciones de resolver el modelo y utilizarlo para obtener predicciones. La realización de predicciones con modelos multiecuacionales consiste en la obtención de una solución del modelo para un período futuro extramuestral. Para poder realizar esta predicción será necesario, por tanto, alimentar el modelo con valores futuros de todas las variables exógenas incluidas en el mismo.

4.5.4 PROYECCIÓN DEL MODELO ARIMA-ECONOMÉTRICO ANUAL



Gráfica N° 4.42 Proyecciones Dinámicas Período 2012-2018

Proyecciones Dinámicas Período 2012-2018



Gráfica N° 4.43 Proyección de las Ventas de Energía Eléctrica Período 2012-2018

Este es una representación de una predicción dinámica desde el período 2013-2015, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.005445, esto da indicciones de una buena predicción.

Datos Calculados de la Proyección Econométrica Período 2016-2018

Tabla N° 4.4

DATOS ANUALES					
	VENTAS	PBI	TARIFA	CLIENTES	T
	MWh	(Mio. S/.)	ctm. Sol/kW.h		(°C)
1,994	5,587,000	98,577	18.47	1,169,518	19.6
1,995	5,708,999	107,064	21.80	1,179,511	19.3
1,996	5,798,055	109,760	24.21	1,391,881	18.4
1,997	6,301,598	117,294	23.13	1,444,007	22.2
1,998	6,739,920	116,522	22.17	1,476,242	20.8
1,999	6,820,338	117,587	24.75	1,519,558	19.3
2,000	7,129,888	121,057	27.00	1,553,820	18.7
2,001	7,149,175	121,317	27.60	1,549,475	18.4
2,002	7,580,312	127,402	26.29	1,576,406	19
2,003	7,663,766	132,545	27.06	1,599,253	18.7
2,004	8,054,482	139,141	27.08	1,635,922	19.2
2,005	8,607,996	148,640	28.31	1,666,130	18.9
2,006	9,269,914	160,145	27.21	1,711,704	19.7
2,007	9,777,443	174,407	26.01	1,767,923	18.6
2,008	10,476,525	191,505	25.44	1,836,047	19.7
2,009	10,776,712	193,155	28.26	1,900,588	19.9
2,010	11,533,637	210,143	26.85	1,957,824	19.3
2,011	12,240,585	227,908	28.09	2,038,499	19.4
2,012	12,975,348	242,041	29.70	2,150,700	20.3
2,013	13,483,338	249,589	31.33	2,192,743	19.76
2,014	14,151,039	260,224	31.03	2,273,976	18.05
2,015	14,875,900	272,323	33.53	2,348,387	19.46
2,016	15,090,430	284,801	34.52	2,375,967	18.79
2,017	15,740,461	298,290	35.11	2,389,063	19.03
2,018	16,328,784	312,016	35.17	2,441,674	18.14

4.6 OPTIMIZACIÓN DEL MODELO ECONÓMETRICO PROPUESTO PARA PROYECTAR LAS VENTAS DE ENERGÍA ELÉCTRICA ANUALES (MEPA)

4.6.1 ESTIMANDO DE LA ECUACIÓN DE COINTEGRACIÓN

Estimation Command:

=====

LS LOG(VENTAS1) LOG(PBI) LOG(USUARIOS) LOG(TEMPERATURA) LOG(PPE) D96 D2015

Estimation Equation:

=====

LOG(VENTAS1) = C(1)*LOG(PBI) + C(2)*LOG(USUARIOS) + C(3)*LOG(TEMPERATURA) +
C(4)*LOG(PPE) + C(5)*D96 + C(6)*D2015

Substituted Coefficients:

=====

$$\text{LOG(VENTAS1)} = 0.568941309762 \cdot \text{LOG(PBI)} + 0.769342013979 \cdot \text{LOG(USUARIOS)} - 0.383421921605 \cdot \text{LOG(TEMPERATURA)} - 0.217490094627 \cdot \text{LOG(PPE)} - 0.103620280831 \cdot \text{D96} + 0.102031371568 \cdot \text{D2015}$$

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.568941	0.034508	16.48702	0.0000
LOG(USUARIOS)	0.769342	0.053212	14.45815	0.0000
LOG(TEMPERATURA)	-0.383422	0.114366	-3.352597	0.0040
LOG(PPE)	-0.217490	0.074867	-2.905004	0.0103
D96	-0.103620	0.021797	-4.753837	0.0002
D2015	0.102031	0.023484	4.344811	0.0005

R-squared	0.997177	Mean dependent var	15.99759
Adjusted R-squared	0.996295	S.D. dependent var	0.327326
S.E. of regression	0.019924	Akaike info criterion	-4.766782
Sum squared resid	0.006351	Schwarz criterion	-4.469225
Log likelihood	58.43461	Hannan-Quinn criter.	-4.696687
Durbin-Watson stat	1.720321		


Gráfica N° 4.44 Resultados de la Regresión EC1_ECONOMETRIC2

A continuación realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.56) acorde con la teoría económica, significa que, Si el PBI aumenta en 1% las ventas de energía eléctrica aumentan en 0.56%. Obsérvese que se añadió la variable dummy para los años 1996 y 2015.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 99.71% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si Se observa el valor del estadístico de

Durbin Watson (1.72), como es mayor a 1.53 y menor a 2.46 el modelo parece no presentar problemas de autocorrelación en los residuos.

Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Observando el gráfico a continuación:



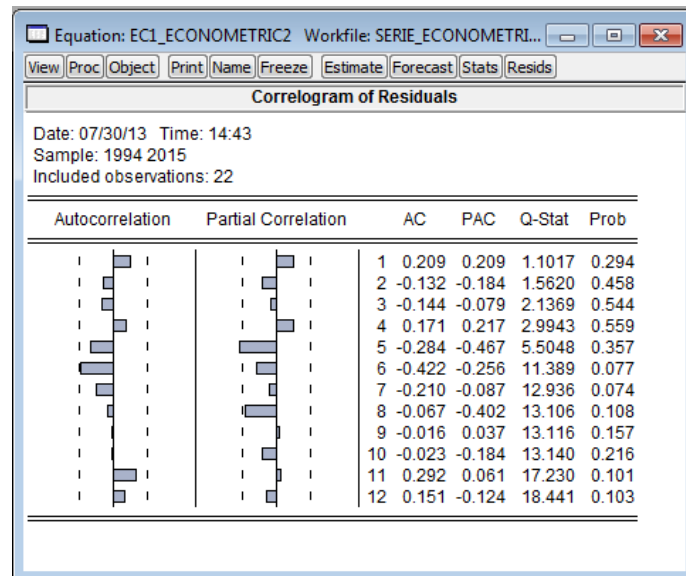
Gráfica N° 4.45 Evaluación de los residuos EC1_ECONOMETRIC2

Se observa que el error residual se encuentra en un orden de ± 0.04 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.

4.6.2 CONTRASTE O VALIDACIÓN DEL MODELO ECONÓMICO ANUAL PROPUESTO

A Continuación se realizarán las pruebas estadísticas de validación.


4.6.2.1 CORRELOGRAMA DE RESIDUOS DEL (MEPA)



Gráfica N° 4.46 Correlograma- EC1_ECONOMETRIC2

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

4.6.2.2 NORMALIDAD DEL RESIDUO DEL (MEPA)



Gráfica N° 4.47 Evaluación de la Normalidad EC1_ECONOMETRIC2

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 69.91%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

4.6.2.3 PRUEBA DE HETEROSCEDASTICIDAD DE WHITE DEL (MEPA)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.005068	0.009776	0.518413	0.6117
(LOG(PBI))^2	4.69E-05	5.09E-05	0.922098	0.3711
(LOG(USUARIOS))^2	-7.15E-05	9.30E-05	-0.769664	0.4535
(LOG(TEMPERATURA))^2	0.000237	0.000363	0.651998	0.5243
(LOG(PPE))^2	0.000111	0.000291	0.381127	0.7085
D96^2	-0.000201	0.000412	-0.489273	0.6317
D2015^2	-0.000471	0.000456	-1.033530	0.3177

R-squared	0.147659	Mean dependent var	0.000289
Adjusted R-squared	-0.193277	S.D. dependent var	0.000343
S.E. of regression	0.000375	Akaike info criterion	-12.68581
Sum squared resid	2.11E-06	Schwarz criterion	-12.33866
Log likelihood	146.5440	Hannan-Quinn criter.	-12.60404
F-statistic	0.433100	Durbin-Watson stat	2.290940
Prob(F-statistic)	0.845538		

Gráfica N° 4.48 Prueba de Heteroscedasticidad EC1_ECONOMETRIC2

Con un probabilidad significativa 84.55% (mayor que 5%), no se rechaza la hipótesis nula, por lo tanto la varianza es constante y existe homocedasticidad en el modelo.

4.6.3 ESTIMACIÓN DEL MODELO DE CORRECCIÓN DE ERRORES ANUAL

Siguiendo la metodología de estimación en dos etapas propuesta por Engle y Granger, se debe verificar que el residuo de la expresión anterior sea estacionario para verificar la presencia de cointegración. Una vez determinada la estacionariedad de los residuos se procede a estimar un modelo de

corrección de errores, determinado por un modelo de rezagos distribuidos de la forma:

Estimation Command:

=====

LS(DERIV=AA) D(LOG(VENTAS1)) D(LOG(PBI)) D(LOGERROR1) D2014 MA(6)

Estimation Equation:

=====

D(LOG(VENTAS1)) = C(1)*D(LOG(PBI)) + C(2)*D(LOGERROR1) + C(3)*D2014 + [MA(6)=C(4),BACKCAST=1995,ESTSMPL="1995 2015"]

Substituted Coefficients:

=====

D(LOG(VENTAS1)) = 0.943530748095*D(LOG(PBI)) + 0.671411997861*D(LOGERROR1) + 0.0505400947477*D2014 + [MA(6)=-0.935715813295,BACKCAST=1995,ESTSMPL="1995 2015"]

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LOG(PBI))	0.943531	0.047369	19.91877	0.0000
D(LOGERROR1)	0.671412	0.165520	4.056370	0.0008
D2014	0.050540	0.012384	4.080955	0.0008
MA(6)	-0.935716	0.033407	-28.00982	0.0000

R-squared	0.778035	Mean dependent var	0.050945
Adjusted R-squared	0.738864	S.D. dependent var	0.025414
S.E. of regression	0.012987	Akaike info criterion	-5.680087
Sum squared resid	0.002867	Schwarz criterion	-5.481130
Log likelihood	63.64091	Hannan-Quinn criter.	-5.636908
Durbin-Watson stat	2.352170		

Inverted MA Roots				
.99	.49-.86i	.49+.86i	-.49-.86i	
	-.49+.86i	-.99		


Gráfica N° 4.49 Resultados de la Regresión EC2_ECONOMETRIC2

A continuación realizaremos un análisis individual de los coeficientes estimados, comprobando inicialmente el coeficiente asociado a la variable del PBI presenta un signo positivo (0.94) acorde con la teoría económica, significa

que, Si el PBI aumenta en 1% las ventas de energía eléctrica aumentan en 0.94%.

El paso siguiente consistiría en la evaluación de los resultados conjuntos, comenzando con la evaluación general de la capacidad explicativa del modelo que, de acuerdo con los estadísticos R^2 y R^2 corregido sería capaz de explicar en torno al 77.8% de la varianza de la variable endógena, resultado que inicialmente, sería satisfactorio teniendo en cuenta las características de la variable endógena. Adicionalmente, y si Se observa el valor del estadístico de Durbin Watson (2.35), como es mayor a 1.53 y menor a 2.46 el modelo parece no presentar problemas de autocorrelación en los residuos.

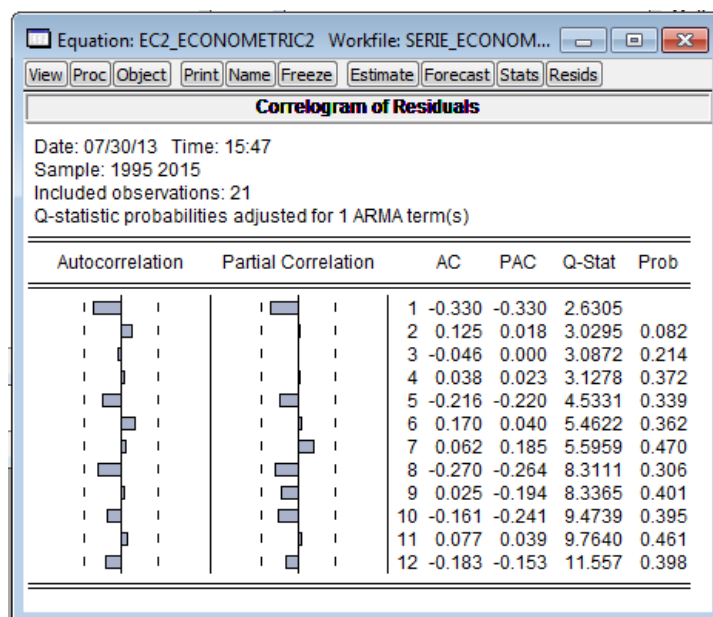
Otra forma de determinar si existe autocorrelación es ver el gráfico de los residuos a lo largo del tiempo. Observando el gráfico a continuación:



Gráfica N° 4.50 Evaluación de los residuos EC2_ECONOMETRIC2

Se observa que el error residual se encuentra en un orden de +/- 0.008 lo que es buen índice para confirmar que el modelo no presenta autocorrelación de los residuos.


Correlograma de Residuos



Gráfica N° 4.51 Correlograma- EC2_ECONOMETRIC2

Como se aprecia en el correlograma la función de correlación parcial y de autocorrelación no superan el 5%. Observándose que los errores no siguen un proceso autorregresivo. Por lo que existe homocedasticidad en el modelo.

Normalidad del Residuo



Gráfica N° 4.52 Evaluación de la Normalidad EC2_ECONOMETRIC2

El test de Jarque-Bera, analiza la relación entre los coeficientes de apuntamiento y curtosis de los residuos de la ecuación y los correspondientes a los de una distribución normal, de forma tal que si estas


relaciones son suficientemente diferentes se rechazaría la hipótesis nula de normalidad de los residuos.

Nótese el valor del estadístico de Jarque-Bera, para contrastar la normalidad de la serie y su correspondiente nivel de probabilidad es de 69.39%, en este caso no se rechaza la hipótesis nula (existe homocedasticidad en el modelo).

4.6.4 PROYECCIÓN DEL MODELO ECONÓMICO

Una vez realizadas las operaciones descritas, ya estaríamos en condiciones de resolver el modelo y utilizarlo para obtener predicciones. La realización de predicciones con modelos multiecuacionales consiste en la obtención de una solución del modelo para un período futuro extramuestral. Para poder realizar esta predicción será necesario, por tanto, alimentar el modelo con valores futuros de todas las variables exógenas incluidas en el mismo.

Proyecciones Dinámicas Período 2016-2018




Gráfica N° 4.53 Proyecciones de las Ventas Anuales Período 2016-2018

Este es una representación de una predicción dinámica desde el período 2013-2015, sin embargo debemos verificar el valor del coeficiente de Theil que debe ser cercano a 0, en este caso es 0.004145, esto da indicciones de una buena predicción.

Tabla N° 4.5 Proyecciones Anuales de las Ventas de Energía Eléctrica Modelo Arima-Econométrico

	DATOS ANUALES				
	VENTAS MWh	PBI (Mio. S/.)	TARIFA ctm. Sol/kW.h	CLIENTES	T (°C)
1,994	5,587,000	98,577	18.47	1,169,518	19.6
1,995	5,708,999	107,064	21.80	1,179,511	19.3
1,996	5,798,055	109,760	24.21	1,391,881	18.4
1,997	6,301,598	117,294	23.13	1,444,007	22.2
1,998	6,739,920	116,522	22.17	1,476,242	20.8
1,999	6,820,338	117,587	24.75	1,519,558	19.3
2,000	7,129,888	121,057	27.00	1,553,820	18.7
2,001	7,149,175	121,317	27.60	1,549,475	18.4
2,002	7,580,312	127,402	26.29	1,576,406	19
2,003	7,663,766	132,545	27.06	1,599,253	18.7
2,004	8,054,482	139,141	27.08	1,635,922	19.2
2,005	8,607,996	148,640	28.31	1,666,130	18.9
2,006	9,269,914	160,145	27.21	1,711,704	19.7
2,007	9,777,443	174,407	26.01	1,767,923	18.6
2,008	10,476,525	191,505	25.44	1,836,047	19.7
2,009	10,776,712	193,155	28.26	1,900,588	19.9
2,010	11,533,637	210,143	26.85	1,957,824	19.3
2,011	12,240,585	227,908	28.09	2,038,499	19.4
2,012	12,975,348	242,041	29.70	2,150,700	20.3
2,013	13,926,478	249,589	31.33	2,192,743	19.76
2,014	15,092,265	260,224	31.03	2,273,976	18.05
2,015	16,285,613	272,323	33.53	2,348,387	19.46
2,016	16,660,072	284,801	34.52	2,375,967	18.79
2,017	17,462,268	298,290	35.11	2,389,063	19.03
2,018	18,219,460	312,016	35.17	2,441,674	18.14



Gráfica N° 4.54 Evolución de las Ventas de Energía Eléctrica Período 1994-2018

4.6.5 RESULTADOS DE LA ESTIMACIÓN DEL MODELO ARIMA-ECONOMÉTRICO ANUAL

Se observa los resultados de las proyecciones de las ventas de energía eléctrica para el departamento de Lima con el modelo Arima-Económico con la adición de la variable temperatura. En la tabla se muestra los resultados en frecuencia anual desde el 2016 al 2018. En la gráfica N° 4.54 se muestra el gráfico de las proyecciones anuales hasta el 2018.

Para el cálculo de las ventas de energía se utilizó el modelo Arima con frecuencia mensual, con estas proyecciones se procedieron a ingresar el modelo econométrico de corrección de errores en frecuencia anual obteniendo los resultados mostrados.

CAPÍTULO V

ANÁLISIS COMPARATIVO DE RESULTADOS Y CONTRASTACIÓN DE LAS HIPÓTESIS

De lo hasta aquí desarrollado a lo largo de la presente investigación, con la información expuesta y la información estadística presentada en los anteriores capítulos y de los resultados obtenidos de la proyección de ventas de energía eléctrica, cuyo modelos aplicados se han detallado; se procederá a verificar y contrastar la hipótesis. Para lo cual se recopilará los resultados obtenidos que permitirán aceptar o rechazar las hipótesis.

5.1 ANÁLISIS COMPARATIVO DE RESULTADOS

En esta sección se presenta un análisis comparativo de la calidad predictiva de los modelos estimados en los capítulos anteriores y se muestran las proyecciones de cada modelo estimado, período de proyección similar al realizado en un proceso de fijación tarifaria. En los cuadros siguientes N° 5.1 y N° 5.2 se presenta un resumen de los resultados de los modelos desarrollados a lo largo del presente documento.

Proyección de las Ventas de Energía Eléctrica (MWh)
Mensual (2013-2015)
CUADRO N° 5.1

Serie Mensual- Año	Modelo Actual Econométrico	Modelo Econométrico Propuesto	Modelo ARIMA
2013M01	1167957	1143002	1095716
2013M02	1174432	1149314	1105836
2013M03	1164222	1144146	1109404
2013M04	1176913	1161460	1112841
2013M05	1165191	1157474	1114932
2013M06	1155269	1154640	1121695
2013M07	1146644	1145083	1131783
2013M08	1162104	1139212	1130979
2013M09	1171299	1156175	1128497
2013M10	1184898	1168482	1145085
2013M11	1187083	1191653	1140486
2013M12	1202067	1215836	1146084
2014M01	1197461	1228097	1153680
2014M02	1205041	1236140	1157613
2014M03	1206250	1244702	1160960
2014M04	1199618	1247755	1167145
2014M05	1191843	1250657	1172004
2014M06	1196050	1249514	1176301
2014M07	1197142	1248056	1181430
2014M08	1204995	1251877	1186579
2014M09	1203611	1259707	1191308
2014M10	1210566	1274290	1196279
2014M11	1210727	1291908	1201383
2014M12	1212880	1309561	1206357
2015M01	1225835	1324474	1211362
2015M02	1253019	1337408	1216464
2015M03	1278708	1344539	1221550
2015M04	1308968	1347921	1226640
2015M05	1315128	1351040	1231780
2015M06	1330195	1347748	1236941
2015M07	1334843	1348875	1242112
2015M08	1349032	1348529	1247313
2015M09	1363821	1357939	1252541
2015M10	1371502	1373278	1257787
2015M11	1378042	1393275	1263057
2015M12	1383296	1410587	1268354

En el cuadro N° 5.1 se muestran las proyecciones de ventas de energía eléctrica para el departamento de Lima, en la segunda columna se muestran los resultados calculado con el modelo Actual (Modelo Econométrico de Corrección de Errores), en la tercera columna se muestra los resultados con el modelo Econométrico Propuesto en el cual se agregó la variable temperatura obteniendo proyecciones más elevadas para los últimos meses del año 2015 y en la cuarta columna se realizó con el modelo Arima todos estos resultados en frecuencia mensual.

Luego de realizar las proyecciones de las ventas de energía eléctrica se procede a evaluar la calidad de predicción con este fin se verificará las hipótesis mencionadas en el presente documento (Cuadro N° 5.3).

Proyección de las Ventas de Energía Eléctrica (MWh)
Anual (2016-2018)
CUADRO N° 5.2

Año	Modelo Actual Econométrico	Modelo Econométrico Propuesto	Modelo ARIMA Econométrico
1,994	5,587,000	5,587,000	5,587,000
1,995	5,708,999	5,708,999	5,708,999
1,996	5,798,055	5,798,055	5,798,055
1,997	6,301,598	6,301,598	6,301,598
1,998	6,739,920	6,739,920	6,739,920
1,999	6,820,338	6,820,338	6,820,338
2,000	7,129,888	7,129,888	7,129,888
2,001	7,149,175	7,149,175	7,149,175
2,002	7,580,312	7,580,312	7,580,312
2,003	7,663,766	7,663,766	7,663,766
2,004	8,054,482	8,054,482	8,054,482
2,005	8,607,996	8,607,996	8,607,996
2,006	9,269,914	9,269,914	9,269,914
2,007	9,777,443	9,777,443	9,777,443
2,008	10,476,525	10,476,525	10,476,525
2,009	10,776,712	10,776,712	10,776,712
2,010	11,533,637	11,533,637	11,533,637
2,011	12,240,585	12,240,585	12,240,585
2,012	12,975,348	12,975,348	12,975,348
2,013	14,058,078	13,926,478	13,483,338
2,014	14,436,182	15,092,265	14,151,039
2,015	15,892,388	16,285,613	14,875,900
2,016	15,694,441	16,660,072	15,090,430
2,017	16,338,734	17,462,268	15,740,461
2,018	16,990,453	18,219,460	16,328,784

En el cuadro N° 5.2 se muestran las proyecciones de ventas de energía eléctrica para el departamento de Lima, en la segunda columna se muestran los resultados calculado con el modelo Actual (Modelo Econométrico de Corrección de Errores), en la tercera columna se muestra los resultados con el modelo Econométrico Propuesto en el cual se agregó la variable temperatura obteniendo proyecciones más elevadas para los últimos años y en la cuarta columna se realizó con el modelo Arima, todas estas series en frecuencia anual.

Luego de realizar las proyecciones de las ventas de energía eléctrica se procede a evaluar la calidad de predicción con este fin se verificará las hipótesis mencionadas en el presente documento (Cuadro N° 5.4).

5.1.1 INDICADORES DE CALIDAD DE PREDICCIÓN

En esta sección se procederá a comparar la calidad de predicción de los modelos con los resultados del modelo Econométrico actualmente calculado. Se consideró comparar los estadísticos de los residuos de las predicciones en la muestra. Los cuadros siguientes resumen los principales estadísticos de los residuos de las estimaciones realizadas, mostrando los modelos con datos anuales y los resultados de modelos econométricos con datos mensuales.

Es necesario precisar las bondades de ajuste de los mismos utilizando estadísticos específicos para estos fines. Entre estos estadísticos destacan: la raíz cuadrada del error cuadrático promedio (RCECM), el promedio del valor absoluto de los errores (PVAE), el promedio del valor absoluto de los errores como porcentaje de los valores observados (PVAEPA) y el Coeficiente de

Desigualdad de Theil (TIC). El resultado de estas pruebas se muestra en los siguientes Cuadros (Cuadros N° 5.3 y Cuadros N° 5.4):

Evaluación de la calidad predictiva en frecuencia mensual

CUADRO N° 5.3

	Modelo Actual Econométrico	Modelo ARIMA	Modelo Econométrico Propuesto
Root Mean Squared Error	30029.8	16978.33	26607.52
Mean Absolute Error	25902.1	13481.31	22045.14
Mean Abs. Percent Error	2.415934	1.231869	2.050993
Theil Inequality Coefficient	0.013717	0.00788	0.012258
Bias Proportion	0.743987	0.254209	0.08047
Variance Proportion	0.014249	0.178005	0.138951
Covariance Proportion	0.241764	0.567787	0.780579

En el cuadro N° 5.3 se muestra los resultados de la evaluación de la calidad predictiva, en la segunda columna se muestran los resultados calculados con el modelo Actual (Modelo Econométrico de Corrección de Errores), en la tercera columna se muestra los resultados con el modelo Arima y en la cuarta columna se realizó con el modelo Econométrico Propuesto.

Se observa que el modelo Arima presenta la menor raíz cuadrada del error cuadrático promedio con este indicador se puede decir que el modelo Arima es un buen modelo y tiene mejor calidad predictiva que los otros dos modelos.

Evaluando el coeficiente de Theil se aprecia que el modelo Arima, presenta el menor coeficiente lo que quiere decir que el modelo Arima en frecuencia mensual es el mejor modelo para proyectar las Ventas de Energía Eléctrica.

Evaluación de la calidad predictiva en frecuencia anual

CUADRO N° 5.4

	Modelo Actual Econométrico	Modelo ARIMA-Econométrico	Modelo Econométrico Propuesto
Root Mean Squared Error	395693.3	150885.3	120862
Mean Absolute Error	379115.1	86399.79	85200.2
Mean Abs. Percent Error	2.627958	0.589898	0.559944
Theil Inequality Coefficient	0.013945	0.005445	0.004145
Bias Proportion	0.917962	0.178457	0.496937
Variance Proportion	0.022306	0.532088	0.186043
Covariance Proportion	0.059732	0.289455	0.31702

En el cuadro N° 5.4 se muestra los resultados de la evaluación de la calidad predictiva, en la segunda columna se muestran los resultados calculados con el modelo Actual (Modelo Econométrico de Corrección de Errores), en la tercera columna se muestra los resultados con el modelo Arima y en la cuarta columna se realizó con el modelo Econométrico Propuesto.

Se observa que el modelo Econométrico Propuesto presenta la menor raíz cuadrada del error cuadrático promedio con este indicador se puede decir que el modelo es un buen modelo y tiene mejor calidad predictiva que los otros dos modelos.

Evaluando el coeficiente de Theil se aprecia que el modelo Econométrico Propuesto, presenta el menor coeficiente. En conclusión el modelo Econométrico Propuesto presenta la mejor bondad predictiva para proyectar las Ventas de Energía Eléctrica.

5.2 CONTRASTACIÓN DE LAS HIPÓTESIS

De acuerdo con los resultados obtenidos en los cálculos de la proyección de las ventas de energía eléctrica para el departamento de Lima se puede demostrar las hipótesis de la tesis a través de los resultados. Se corrobora lo siguiente:

5.2.1 CONTRASTACIÓN DE LAS HIPÓTESIS ESPECIFICAS

H1: “La evaluación del actual método de corrección de error presenta ciertas carencias en comparación con el modelo Arima – Econométrico” fue contrastada con los resultados de los cuadros N° 5.3 y 5.4 en el cual se verifica que el modelo actual en comparación con el modelo Arima-Econométrico presenta un mayor coeficiente Theil, con lo que se puede afirmar que el modelo Arima-Econométrico presenta una mejor bondad predictiva.

H2: “En la medida que se optimice el modelo Arima – Econométrico contribuirá con un mejor grado de proyección a las ventas de energía eléctrica actual del departamento de Lima mediante una estimación más precisa.” Fue contrastada al calcular el indicador de calidad predictiva se obtuvo que el modelo Arima tiene un buen grado de bondad en comparación con el actual modelo pero menor que el modelo econométrico propuesto en frecuencia mensual. Es por esta razón que, para los cálculos en frecuencia anual, se utilizó el modelo econométrico propuesto por su mejor grado de bondad. En resumen, el modelo Arima- Econométrico presenta buenos resultados en comparación al modelo actual para proyectar las ventas de energía eléctrica con lo que se valida la hipótesis.

H3: “La intervención de la temperatura en el actual método de Corrección de error influirá positivamente en la proyección de las ventas de energía eléctrica.” Será contrastada a continuación con la validación de la intervención de la variable temperatura en el actual modelo. Para lo cual se presenta los contrastes básicos ofrecidos por Eviews para detectar la posible presencia de

una especificación errónea en el modelo, y que, se puede deber a tres causas fundamentalmente:

- Omisión de variables relevantes.
- Inclusión de variables irrelevantes.
- Forma funcional incorrecta.

Una primera aproximación al análisis de una especificación errónea se puede realizarlo analizando los resultados básicos de la estimación. Así, un elevado coeficiente de autocorrelación en los residuos (Durbin-Watson próximo a cero) puede ser un primer indicio de una omisión de variables relevantes, mientras que un contraste t, poco significativo puede indicarnos la presencia de una variable irrelevante.

Adicionalmente Eviews proporciona, dentro del menú de visualización (View) en la ecuación, una serie de contrastes directos (Coefficient tests) para la determinación de la existencia de variables omitidas (Omitted variables) o variables redundantes (Redundant variables).

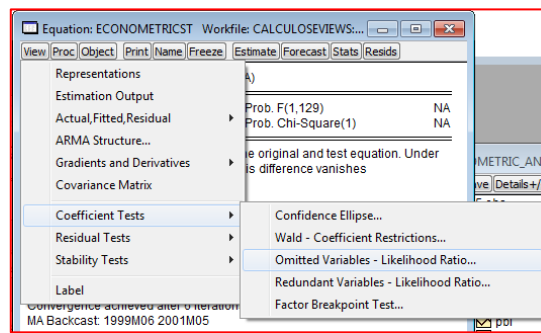
Ambos contrastes están basados en el Ratio de Verosimilitud, cuya idea básica consiste en comparar los resultados obtenidos en dos modelos alternativos, uno restringido y otros sin restringir, de forma tal que si la diferencia entre ambos modelos es suficientemente amplia, admitiremos como válido el modelo sin restringir.

Para realizar el contraste de variables omitidas partiremos de la variable temperatura no considera para el cálculo de la proyección de las ventas de energía eléctrica y que depende, como se calculó en la metodología propuesta.

Para contrastar la posible omisión de alguna variable relevante, como la variable temperatura promedio en el departamento de Lima, accederemos al menú del objeto ecuación y seleccionaremos consecutivamente las siguientes opciones:

View ->Coefficient tests ->Omitted variables

Apareciendo a continuación una ventana como la que se muestra:



Gráfica N° 5.1 Ventana Omitted variables en Eviews

Sobre dicha ventana incluiremos el nombre de la variable (serie) de la que pretendemos contrastar su omisión, en este caso la variable log(temperatura), obteniéndose unos resultados como los que se muestran en la tabla que presentamos a continuación:

Equation: ECONOMETRICST Workfile: CALCULOSEVIEWS::Untitled

Omitted Variables: LOG(TEMPERATURA)

F-statistic	-25.07547	Prob. F(1,129)	0.0013
Log likelihood ratio	-30.04450	Prob. Chi-Square(1)	0.0008

WARNING: the MA backcasts differ for the original and test equation. Under the null hypothesis, the impact of this difference vanishes asymptotically.

Test Equation:
 Dependent Variable: D(LOG(VENTAS))
 Method: Least Squares
 Date: 09/06/13 Time: 15:14
 Sample: 2001M06 2012M12
 Included observations: 139
 Convergence achieved after 6 iterations
 MA Backcast: 1999M06 2001M05

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	-0.041676	0.011848	-3.517691	0.0006
LOGERRORST	0.354037	0.059615	5.938744	0.0000
D0204	0.054571	0.018724	2.914467	0.0042
C	0.339422	0.084940	3.996043	0.0001
LOG(TEMPERATURA)	-0.021472	0.014022	-1.531332	0.1281
AR(10)	0.151480	0.083776	1.808147	0.0729
AR(1)	-0.158627	0.085355	-1.858430	0.0654
AR(17)	-0.055797	0.084456	-0.660667	0.5100
MA(12)	0.576625	0.010341	55.76046	0.0000
MA(24)	0.351591	0.072395	4.856546	0.0000

R-squared	0.528473	Mean dependent var	0.004561
Adjusted R-squared	0.495576	S.D. dependent var	0.021815
S.E. of regression	0.015494	Akaike info criterion	-5.427523
Sum squared resid	0.030968	Schwarz criterion	-5.216410
Log likelihood	387.2129	Hannan-Quinn criter.	-5.341732
F-statistic	16.06437	Durbin-Watson stat	2.061140
Prob(F-statistic)	0.000000		

Inverted AR Roots	82-.12i	82+.12i	.72-.48i	.72+.48i
	.48+.64i	.48-.64i	.24+.84i	.24-.84i
	-.12-.81i	-.12+.81i	-.35+.78i	-.35-.78i
	-.67-.55i	-.67+.55i	-.75-.31i	-.75+.31i
	.90			
Inverted MA Roots	94+.17i	94-.17i	.90-.33i	.90+.33i
	.73+.61i	.73-.61i	.61+.73i	.61-.73i
	.33-.90i	.33+.90i	.17-.94i	.17+.94i
	-.17-.94i	-.17+.94i	-.33-.90i	-.33+.90i
	-.61-.73i	-.61+.73i	-.73-.61i	-.73+.61i
	-.90-.33i	-.90+.33i	-.94-.17i	-.94+.17i

Gráfica N° 5.2 Prueba de Omisión de la Variable Temperatura

En la parte superior de la tabla aparece la hipótesis nula que estamos contrastando, en este caso la omisión de la variable log (temperatura). A continuación aparecen los resultados de dos test alternativos, tipo F, y tipo Ratio de verosimilitud, junto con los niveles de probabilidad asociados al rechazo de la hipótesis nula siendo cierta.

Teniendo en cuenta que la hipótesis nula a contrastar es la irrelevancia de la nueva variable sobre nuestra ecuación estimada (su coeficiente no es estadísticamente distinto de cero) y con los niveles habituales de significatividad con los que normalmente trabajamos (95%) rechazaríamos la hipótesis nula, si el nivel de probabilidad asociado es inferior a 0.05. En este caso, tendríamos una probabilidad del 0.13% y el 0.08%, respectivamente, de no rechazar dicha hipótesis nula siendo cierta, por lo que admitiremos como no válida dicha hipótesis nula y diremos que la variable log(temperatura) ha sido

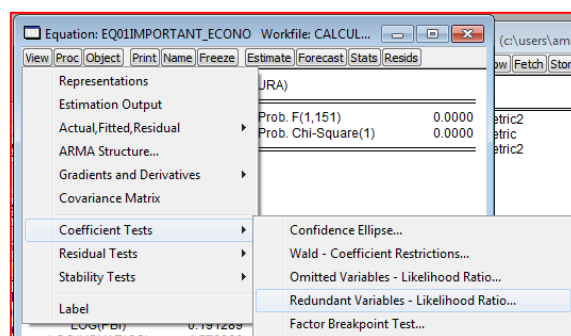
omitida de la ecuación, es decir tenemos que incluirla en nuestra especificación.

En la parte inferior de la tabla se presentan los resultados de la estimación alternativa calculada para contrastar la irrelevancia de la posible variable omitida, y que, como vemos, es un modelo similar al original pero que incluye esa nueva variable como una explicativa adicional.

Si este modelo alternativo fuera claramente superior al original, deberíamos rechazar la hipótesis nula y admitir por parto que habíamos omitido la variable analizada, lo que se observa claramente.

Para contrastar la posible inclusión de variables irrelevantes, el procedimiento a seguir es similar al anterior, pero optando, en este caso por la contratación de variables redundantes.

View ->Coefficient tests ->Reduntant variables



Gráfica N° 5.3 Ventana Reduntant variables en Eviews

A continuación, el programa mostrará una ventana similar a la anterior donde se debe incluir la variable cuya irrelevancia contrastare, y que lógicamente, debe ser alguna de las variables incluidas en la especificación original.

Para este caso, y teniendo en cuenta que la probabilidad asociada al estadístico T de la variable de log (temperatura) está cercana al nivel de

significatividad (0%), contrastare su inclusión dentro del modelo, obteniéndose unos resultados como los que presento en la tabla que aparece a continuación:

Redundant Variables: LOG(TEMPERATURA)				
F-statistic	41.15545	Prob. F(1,151)	0.0000	
Log likelihood ratio	37.59988	Prob. Chi-Square(1)	0.0000	
Test Equation:				
Dependent Variable: LOG(VENTAS)				
Method: Least Squares				
Date: 08/06/13 Time: 15:24				
Sample: 2000M01 2012M12				
Included observations: 156				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PBI)	0.191289	0.045476	4.206381	0.0000
LOG(USUARIOS)	1.572366	0.111858	14.05686	0.0000
LOG(PPE)	-0.172029	0.062734	-2.742207	0.0068
C	-9.435335	1.295820	-7.281364	0.0000
R-squared	0.977133	Mean dependent var	13.55953	
Adjusted R-squared	0.976681	S.D. dependent var	0.201022	
S.E. of regression	0.030697	Akaike info criterion	-4.103998	
Sum squared resid	0.143230	Schwarz criterion	-4.025797	
Log likelihood	324.1119	Hannan-Quinn criter.	-4.072236	
F-statistic	2165.000	Durbin-Watson stat	0.732566	
Prob(F-statistic)	0.000000			

Gráfica N° 5.4 Prueba de Redundancia de la Variable Temperatura

Como puede comprobarse el resultado obtenido tiene una estructura similar al anterior, con una primera parte donde se recoge la hipótesis a contrastar, en nuestro caso que la variable log (temperatura) es irrelevante, junto con los estadísticos F y ratio de verosimilitud y sus respectivas probabilidades asociadas.

La hipótesis nula contrastada es similar al caso anterior, es decir, que el coeficiente asociado a la variable irrelevante no es estadísticamente distinto de cero, rechazándose dicha hipótesis nula si el nivel de probabilidad es inferior al 5%.

Nótese que el contraste F aplicado es el que como contraste de un subconjunto de parámetros, de forma tal que, si se ha seleccionado una única variable (este contraste, al igual que el anterior, puede aplicarse sobre varias series a la vez),

el valor del estadístico F parcial calculado coincide exactamente con el estadístico t individual, con lo que no aportaría ninguna información adicional.

Luego de determinar que la variable temperatura influye positivamente en la proyección de las ventas de energía eléctrica. El cual se verificó mediante el coeficiente de Theil al presentar un menor coeficiente que el modelo actual y esto se interpreta en el modelo econométrico propuesto presentando un mejor grado de bondad. De lo mencionado se verifica la presente hipótesis.

H4: “El manejo del programa Eviews como herramienta de cálculo facilitará los cálculos para la proyección de las ventas de energía eléctrica”. Queda contrastada, por todo lo aludido se han verificado las hipótesis con el programa Eviews por su facilidad entre otras, como herramienta de cálculo para la proyección de las ventas de energía eléctrica. Y también se verifica la presente hipótesis.

Habiendo sido contrastadas las hipótesis específicas H1, H2, H3 y H4 queda contrastada la Hipótesis General “La optimización de un modelo Arima – Econométrico permitirá una mejor proyección de las ventas de energía eléctrica”.

CONCLUSIONES

1. Con la evaluación del actual método de corrección de error se concluyó que el actual método presenta un menor grado de bondad en comparación con el modelo Arima – Econométrico. Esto se verificó con la evaluación del coeficiente de Theil, el cual era menor en la evaluación del modelo Arima - Econométrico.
2. Al optimizar el modelo Arima-Econométrico se logró un mejor grado de bondad en comparación al actual método de corrección de error de las proyecciones de las ventas de energía eléctrica del departamento de Lima.
3. Con la intervención de la temperatura en el actual método de Corrección de error se comprobó que los resultados de las proyecciones de las ventas de energía eléctrica mejoran sustancialmente.
4. Utilizando el programa E-views como herramienta de cálculo por su facilidad en los cálculos econométricos para la proyección de las ventas de energía eléctrica.

Asimismo, se contrastaron las hipótesis Específicas utilizando los indicadores de calidad de predicción con el manejo del programa Eviews.

5. Al ser contrastadas las hipótesis específicas y la hipótesis general, se ha logrado el Objetivo General de la tesis “Lograr la Optimización de un modelo Arima - Econométrico para proyectar las ventas de energía eléctrica en el departamento de Lima”.

RECOMENDACIONES

1. Se recomienda contar con una serie de datos para las series para el departamento de Lima, muchas de estas series son confidenciales por algunas empresas y dificultan la investigación.
2. El programa E-views que se utilizó es una versión educativa. Actualmente existen versiones más avanzadas del programa E-views, las cuales requieren de licencias.
3. Como agenda de investigación se recomienda continuar analizando formas funcionales que puedan mejorar la aproximación de las ventas de energía eléctrica.

BIBLIOGRAFÍA

1. Informe COES/DP-01-2013. “Informe de Diagnóstico de las Condiciones Operativas del SEIN 2015-2024” Comité de Operación Económica del sistema eléctrico. Año 2013.
2. Modelos Energéticos Periodo Académico. 2013-I. Dr. Salome Gonzáles Chávez. UNI. Lima, Perú.
3. Estimación de la Demanda Agregada de Electricidad Documento de Trabajo N° 4. Oficina de Estudio Económicos. Osinergmin. Enero 2004.
4. Plan Referencial de Electricidad 2001-2010 MINEM Oficina Técnica de Energía. Lima, Perú.
5. Resultados de escenarios Tendenciales del 2011 al 2016 – CEPLAN. Lima, Perú Año 2010.
6. Anuario Estadístico 2011. OSINERGMIN-Gerencia Adjunta de Regulación Tarifaria. Lima, Perú. (Anuarios desde el año 1994 al 2011).

7. Memoria Anual 2000. Comisión de Tarifas de Energía. Lima, Perú. (Memorias desde el año 1994 al 2000).
8. Informe de Situación de las Tarifas eléctricas 1993 al 2000. Comisión de Tarifas de Energía. Lima, Perú.
9. Tarifas y Mercado Eléctrico. Organismo Supervisor de la Inversión en Energía y Minas. (Boletines mensuales desde el mes de Enero 2003 a Mayo 2013). Lima, Perú.
10. Reporte de Inflación. Panorama actual y proyecciones macroeconómicas 2013-2014. Marzo 2013. Banco Central de Reserva del Perú.
11. Proyección de la demanda global del sistema eléctrico interconectado nacional y representación en barras para la simulación con el modelo PERSEO. Anexo B. Proyecciones de la Demanda Eléctrica Período 2012-2014. Año 2012. Lima, Perú.
12. <http://www.coes.org.pe/wcoes/coes/infoperativa/estudios/ppt/default.aspx>
13. <http://www2.osinerg.gob.pe/procreg/tarifasbarra/PrcdmntoFiccionPrciosBrraPrdoMyo2012Abril2014/SbcmteGnrdrCOES/Anexo-B.pdf>
14. http://www.econometricos.com.ar/wp-content/uploads/2008/09/capitulo-2_partea.pdf

APÉNDICE A