



MSC Management Science Consulting

**MODELOS DE PROYECCIÓN DE CONSUMO DE CORTO Y
LARGO PLAZO DE LOS COMBUSTIBLES AFECTOS AL
IMPUESTO ESPECÍFICO DE LA LEY 18.502**

INFORME FINAL

Preparado para la Comisión Nacional de Energía



Jefe del Estudio: Claudio Araya Sassi

25 de Febrero de 2013

INDICE

	Página
1 INTRODUCCIÓN.....	10
1.1 OBJETIVO GENERAL.....	10
1.2 OBJETIVOS ESPECÍFICOS	10
2 CAPÍTULO 1: ANTECEDENTES	11
2.1 MODELOS ESTRUCTURALES DE DEMANDA POR COMBUSTIBLES	11
2.2 TEORÍA DE CORRELACIÓN SERIAL.....	12
2.2.1 Modelo Autorregresivo de Primer Orden.....	13
2.2.2 Modelos Autorregresivos de Orden más Alto	13
2.2.3 Teoría ARIMA	14
2.2.4 Principios de Modelamiento ARIMA	14
2.3 TEORÍA DE SERIES DE TIEMPO.....	15
2.3.1 No Estacionariedad de Series de Tiempo	15
2.3.2 Regresión Espuria	16
2.3.3 Cointegración.....	16
3 CAPÍTULO 2: METODOLOGÍA.....	18
3.1 SERIES DE TIEMPO DE VARIABLES RELEVANTES Y FUENTES DE INFORMACIÓN.....	18
3.1.1 Consideraciones sobre algunas variables.....	18
3.1.2 Prueba de Raíz Unitaria de Dickey-Fuller Aumentada (ADF)	20
3.2 MODELOS ARIMA Y DE SERIES DE TIEMPO.....	22
3.2.1 Modelo ARIMA General Multiplicativo Estacional	22
3.2.2 Muestras de Estimación	24
3.2.3 Ajustes Preliminares de las Series	24
3.2.4 Estimación de Modelos ARIMA	26
3.3 MODELOS ESTRUCTURALES DE CONSUMO.....	29
3.3.1 Especificación de Modelos Estructurales	29
3.3.2 Muestras de Estimación	30
3.3.3 Ajustes Preliminares de las Series	30
3.3.4 Verificación de Cointegración.....	31
3.3.5 Tests de Especificación y Diagnóstico de Modelos Estructurales	33
3.3.6 Estimación de Modelos Estructurales	34
3.4 PRONÓSTICOS.....	35
3.4.1 Tipos de Pronósticos	35
3.4.2 Límites de Confianza de Pronósticos Ex Ante	35
3.4.3 Medidas de Evaluación de Pronósticos Ex Post	36
3.4.4 Pronósticos Ex ante Modelos ARIMA.....	37
3.4.5 Pronósticos Ex ante Modelos Estructurales	37
3.4.6 Pronósticos Ex ante Modelos ARIMA CNE	38
3.4.7 Evaluación de Pronósticos Ex Post Modelos ARIMA.....	38
3.4.8 Evaluación de Pronósticos Ex Post Modelos Estructurales	39
3.4.9 Evaluación de Pronósticos Ex Post Modelos ARIMA CNE	39
3.5 METODOLOGÍA COMPLEMENTARIA	40
3.5.1 Definición de Metodología Complementaria.....	40
3.5.2 Metodología Complementaria Indirecta.....	41
3.5.3 Metodología Complementaria Directa	42
3.5.4 Verificación y Aplicación de Metodología Complementaria	43

3.5.5	Empalme entre meses de pronósticos semanales.....	44
4	CAPÍTULO 3: RESULTADOS	45
4.1	ANÁLISIS DESCRIPTIVO DE SERIES DE TIEMPO	45
4.1.1	Consumo Nacional de Gasolina Automotriz.....	45
4.1.2	Consumo Nacional de Diesel Vehicular	46
4.1.3	Consumo Nacional de GLP Vehicular	47
4.1.4	Consumo Nacional de GNC Vehicular	48
4.1.5	Precios de Gasolina Automotriz	49
4.1.6	Precios de Diesel Vehicular	49
4.1.7	Precios de GLP Vehicular	50
4.1.8	Precios de GNC Vehicular	51
4.1.9	Índice Mensual de Actividad Económica IMACEC	52
4.2	PRUEBA DE RAÍZ UNITARIA DE DICKEY-FULLER AUMENTADA (ADF)	53
4.3	MODELOS ARIMA Y DE SERIES DE TIEMPO.....	54
4.3.1	Modelo ARIMA de consumo nacional de gasolina automotriz	54
4.3.2	Modelo ARIMA de consumo nacional de diesel vehicular	61
4.3.3	Modelo ARIMA de consumo nacional de gas natural comprimido vehicular	68
4.3.4	Modelo ARIMA de consumo nacional de gas licuado de petróleo vehicular	75
4.3.5	Modelo ARIMA de Precios de Gasolina Automotriz País.....	79
4.3.6	Modelo ARIMA de Precios de Diesel Vehicular País	85
4.3.7	Modelo ARIMA de Índice Mensual de Actividad Económica IMACEC.....	91
4.4	MODELOS ESTRUCTURALES	97
4.4.1	Modelo Estructural de Consumo Nacional de Gasolina Automotriz.....	97
4.4.2	Modelo Estructural de Consumo Nacional de Diesel Vehicular	102
4.4.3	Modelo Estructural de Consumo Nacional de GNC Vehicular	107
4.4.4	Modelo Estructural de Consumo Nacional de GLP Vehicular	112
4.5	EVALUACIÓN DE PRONÓSTICOS MENSUALES EX POST	116
4.5.1	Evaluación de Pronósticos de Corto Plazo	116
4.5.2	Evaluación de Pronósticos de Largo Plazo	116
4.6	METODOLOGÍA COMPLEMENTARIA	117
4.6.1	Metodología Complementaria Indirecta.....	117
4.6.2	Metodología Complementaria Directa	119
4.7	ANÁLISIS COMPARATIVO DE MODELOS ARIMA UTILIZADOS POR LA CNE.....	122
4.7.1	Modelo ARIMA de Consumo Nacional de Gasolina Automotriz	122
4.7.2	Modelo ARIMA de Consumo Nacional de Diesel Vehicular	128
4.7.3	Comparación de Desempeño de Pronósticos Ex Post entre Modelos.....	133
4.8	PROGRAMA MODELOS DESARROLLADO EN EIEWS 7 PARA LA CNE	134
4.9	PROPUESTA DE SOFTWARE.....	136
4.9.1	Precios de Licencias de EIEWS	136
5	CONCLUSIONES y RECOMENDACIONES	137
5.1	CONCLUSIONES	137
5.2	RECOMENDACIONES	139
6	REFERENCIAS	140
7	ANEXOS.....	142
7.1	ANEXO 1: PRUEBAS ADF CONSUMO DE GASOLINA AUTOMOTRIZ.....	142
7.2	ANEXO 2: PRUEBAS ADF CONSUMO DE DIESEL VEHICULAR.....	144
7.3	ANEXO 3: PRUEBAS ADF CONSUMO DE GLP VEHICULAR.....	146

7.4	ANEXO 4: PRUEBAS ADF CONSUMO DE GNC VEHICULAR	148
7.5	ANEXO 5: TESTS DE COINTEGRACIÓN DE ENGLE-GRANGER.....	150
7.6	ANEXO 6: ARCHIVO DE ESPECIFICACIÓN DE CONSUMO DE GASOLINA X-12 ARIMA UTILIZADO POR LA CNE.....	154
7.7	ANEXO 7: ARCHIVO DE ESPECIFICACIÓN DE CONSUMO DE DIESEL X-12 ARIMA UTILIZADO POR LA CNE... ..	155
7.8	ANEXO 8: ARCHIVO DE ESPECIFICACIÓN DE CONSUMOS DE COMBUSTIBLES X-12 ARIMA UTILIZADO EN EL PRESENTE ESTUDIO	156
7.9	ANEXO 9: PRONÓSTICOS MENSUALES DE MODELOS ARIMA Y ESTRUCTURALES	157
7.10	ANEXO 10: PRONÓSTICOS SEMANALES DE CONSUMO MODELOS ARIMA Y ESTRUCTURALES.....	158

INDICE DE FIGURAS

Figura 1.	Tipos de pronósticos.....	35
Figura 2.	Consumo Nacional de Gasolina Automotriz.	45
Figura 3.	Histograma de Consumo Nacional de Gasolina Automotriz.	45
Figura 4.	Consumo Nacional de Diesel Vehicular.	46
Figura 5.	Histograma de Consumo Nacional de Diesel Vehicular.....	46
Figura 6.	Consumo Nacional de GLP Vehicular.	47
Figura 7.	Histograma de Consumo Nacional de GLP Vehicular.	47
Figura 8.	Consumo Nacional de GNC Vehicular.	48
Figura 9.	Histograma de Consumo Nacional de GNC Vehicular.....	48
Figura 10.	Precios de gasolina automotriz.....	49
Figura 11.	Histogramas de precios de gasolina automotriz.....	49
Figura 12.	Precios de diesel vehicular.	50
Figura 13.	Histograma de precios de diesel vehicular.	50
Figura 14.	Precios e histograma de GLP Vehicular.....	51
Figura 15.	Precios de GNC vehicular.	51
Figura 16.	Histograma de precios de GNC vehicular.	51
Figura 17.	Índice Mensual de Actividad Económica, IMACEC.	52
Figura 18.	Histograma de IMACEC.	52
Figura 19.	Ajuste de modelo ARIMA Consumo de gasolina automotriz.....	56
Figura 20.	Autocorrelación muestral de los residuales de modelo ARIMA CGAS.	57
Figura 21.	Autocorrelación parcial muestral de los residuales de modelo ARIMA CGAS.	58
Figura 22.	Histograma y estadísticas descriptivas de residuales modelo ARIMA CGAS.	58
Figura 23.	Pronósticos mensuales ex ante consumo de gasolina automotriz.....	59
Figura 24.	Pronósticos semanales modelo ARIMA consumo de gasolina automotriz.	60
Figura 25.	Ajuste de modelo ARIMA Consumo Diesel Vehicular.	63
Figura 26.	Autocorrelación muestral de los residuales de modelo ARIMA CDIESEL.	64
Figura 27.	Autocorrelación parcial muestral de los residuales de modelo ARIMA CDIESEL.	65
Figura 28.	Histograma y estadísticas descriptivas de residuales modelo ARIMA CDIESEL.	65
Figura 29.	Pronósticos mensuales ex ante consumo de diesel vehicular.	66
Figura 30.	Pronósticos semanales modelo ARIMA consumo de diésel vehicular.....	67
Figura 31.	Ajuste de modelo ARIMA Consumo GNC Vehicular.	70
Figura 32.	Autocorrelación muestral de los residuales de modelo ARIMA CGNC.....	71
Figura 33.	Autocorrelación parcial muestral de los residuales de modelo ARIMA CDIESEL.	72
Figura 34.	Histograma y estadísticas descriptivas de residuales modelo ARIMA CGNC.	72
Figura 35.	Pronósticos mensuales ex ante consumo de GNC vehicular.	73
Figura 36.	Pronósticos semanales modelo ARIMA consumo de GNC vehicular.	74
Figura 37.	Ajuste de modelo ARIMA Consumo GLP Vehicular.	76
Figura 38.	Correlograma de los residuales de modelo ARIMA CGLP.	76
Figura 39.	Histograma y estadísticas descriptivas de residuales modelo ARIMA CGLP.....	77
Figura 40.	Pronósticos mensuales ex ante consumo de GLP vehicular.	77
Figura 41.	Pronósticos semanales modelo ARIMA consumo de GLP vehicular.....	78
Figura 42.	Ajuste de modelo ARIMA de PGASPAIS.	80
Figura 43.	Autocorrelación muestral de los residuales de modelo ARIMA PGASPAIS.	81
Figura 44.	Autocorrelación parcial muestral de residuales de modelo ARIMA PGASPAIS.	82
Figura 45.	Histograma y estadísticas descriptivas residuales modelo ARIMA PGASPAIS.	83
Figura 46.	Pronósticos mensuales ex ante Precios Gasolina País.	84
Figura 47.	Ajuste de modelo ARIMA de PDIESELPAIS.....	86
Figura 48.	Autocorrelación muestral de los residuales de modelo ARIMA PDIESELPAIS.....	87
Figura 49.	Autocorrelación parcial muestral de residuales de modelo ARIMA PDIESELPAIS.....	88
Figura 50.	Histograma y estadísticas descriptivas residuales modelo ARIMA PDIESELPAIS.....	89
Figura 51.	Pronósticos mensuales ex ante Precios Diesel País.	90
Figura 52.	Ajuste de modelo ARIMA de IMACEC.	92

Figura 53.	Autocorrelación muestral de los residuales de modelo ARIMA IMACEC.	93
Figura 54.	Autocorrelación parcial muestral de residuales de modelo ARIMA IMACEC.	94
Figura 55.	Histograma y estadísticas descriptivas residuales modelo ARIMA IMACEC.	95
Figura 56.	Pronósticos mensuales ex ante IMACEC.....	96
Figura 57.	Ajuste de modelo estructural de consumo nacional de gasolina automotriz.	99
Figura 58.	Correlograma de residuales de modelo estructural de CGAS.	99
Figura 59.	Histograma y estadísticas descriptivas de residuales modelo CGAS.....	100
Figura 60.	Pronósticos mensuales ex ante modelo estructural de CGAS.....	100
Figura 61.	Pronósticos semanales modelo estructural de CGAS.	101
Figura 62.	Ajuste de modelo estructural de consumo nacional de diesel vehicular.	104
Figura 63.	Correlograma de residuales de modelo estructural de CDIESEL.	104
Figura 64.	Histograma y estadísticas descriptivas de residuales modelo CDIESEL.....	105
Figura 65.	Pronósticos mensuales ex ante modelo estructural de CDIESEL.	105
Figura 66.	Pronósticos semanales modelo estructural de CDIESEL.	106
Figura 67.	Ajuste de modelo estructural de consumo nacional de GNC vehicular.	109
Figura 68.	Correlograma de residuales de modelo estructural de CGNC.	109
Figura 69.	Histograma y estadísticas descriptivas de residuales modelo CGNC.	110
Figura 70.	Pronósticos mensuales ex ante modelo estructural de CGNC.	110
Figura 71.	Pronósticos semanales modelo estructural de CGNC.	111
Figura 72.	Ajuste de modelo estructural de consumo nacional de GLP vehicular.	113
Figura 73.	Correlograma de residuales de modelo estructural de CGLP.....	114
Figura 74.	Histograma y estadísticas descriptivas de residuales modelo CGLP.	114
Figura 75.	Pronósticos mensuales ex ante modelo estructural de CGLP.	115
Figura 76.	Pronósticos semanales modelo estructural de CGLP.	115
Figura 77.	Ajuste de modelo ARIMA CNE de CGAS.....	123
Figura 78.	Autocorrelación muestral de los residuales de modelo ARIMA CNE de CGAS.	124
Figura 79.	Autocorrelación parcial muestral residuales de modelo ARIMA CNE de CGAS.	125
Figura 80.	Histograma y estadísticas descriptivas residuales modelo ARIMA CNE de CGAS.....	126
Figura 81.	Pronósticos mensuales ex ante modelo ARIMA CNE de CGAS.	127
Figura 82.	Ajuste de modelo ARIMA CNE de CDIESEL.	129
Figura 83.	Autocorrelación muestral de los residuales de modelo ARIMA CNE de CGAS.	130
Figura 84.	Autocorrelación parcial muestral residuales de modelo ARIMA CNE de CGAS.	131
Figura 85.	Estadísticas descriptivas residuales modelo ARIMA CNE de CDIESEL.	131
Figura 86.	Pronósticos mensuales ex ante modelo ARIMA CNE de CDIESEL.	133
Figura 87.	Archivos necesarios y generados por el programa MODELOS en Eviews	135
Figura 88.	Software Eviews 7.	136
Figura 89.	Precios de Software Eviews 7.	136

INDICE DE TABLAS

Tabla 1.	Lista de series de tiempo de variables relevantes utilizadas en el estudio.	18
Tabla 2.	Lista de variables utilizadas para la estimación de modelos ARIMA.	24
Tabla 3.	Muestras de estimación de modelos estructurales.	30
Tabla 4.	Lista de variables pronosticadas y muestras de pronóstico ex ante.	37
Tabla 5.	Lista de modelos estructurales y muestras de pronóstico ex ante.	37
Tabla 6.	Lista de variables pronosticadas y muestras de pronóstico ex ante.	38
Tabla 7.	Muestras de estimación de modelos ARIMA de variables para pronósticos ex post.	38
Tabla 8.	Lista de variables pronosticadas y muestras de pronóstico ex post.	38
Tabla 9.	Muestras de estimación de modelos estructurales para pronósticos ex post.	39
Tabla 10.	Lista de variables pronosticadas y muestras de pronóstico ex post.	39
Tabla 11.	Muestras de estimación de modelos ARIMA CNE para pronósticos ex post.	39
Tabla 12.	Lista de variables pronosticadas y muestras de pronóstico ex post.	40
Tabla 13.	Pruebas de Raíz Unitaria de Dickey-Fuller Aumentada (ADF).	53
Tabla 14.	Selección de transformación automática de CGAS.	54
Tabla 15.	Outliers identificados automáticamente de CGAS.	54
Tabla 16.	Cinco mejores modelos ARIMA de CGAS.	55
Tabla 17.	Parámetros estimados del modelo ARIMA de CGAS.	55
Tabla 18.	Autocorrelación muestral de los residuales de modelo ARIMA CGAS.	56
Tabla 19.	Autocorrelación parcial muestral de los residuales de modelo ARIMA CGAS.	57
Tabla 20.	Estadísticos de normalidad de residuales de modelo ARIMA de CGAS.	59
Tabla 21.	Selección de transformación automática de CDIESEL.	61
Tabla 22.	Outliers identificados automáticamente de CDIESEL.	61
Tabla 23.	Cinco mejores modelos ARIMA de CDIESEL.	62
Tabla 24.	Parámetros estimados del modelo ARIMA de CDIESEL.	62
Tabla 25.	Autocorrelación muestral de los residuales de modelo ARIMA CDIESEL.	63
Tabla 26.	Autocorrelación parcial muestral de los residuales de modelo ARIMA CDIESEL.	64
Tabla 27.	Estadísticos de normalidad de residuales de modelo ARIMA de CDIESEL.	66
Tabla 28.	Selección de transformación automática de CGNC.	68
Tabla 29.	Outliers identificados automáticamente de CGNC.	68
Tabla 30.	Cinco mejores modelos ARIMA de CGNC.	69
Tabla 31.	Parámetros estimados del modelo ARIMA de CGNC.	69
Tabla 32.	Autocorrelación muestral de los residuales de modelo ARIMA CDIESEL.	70
Tabla 33.	Autocorrelación parcial muestral de los residuos de modelo ARIMA CGNC.	71
Tabla 34.	Estadísticos de normalidad de residuales de modelo ARIMA de CGNC.	73
Tabla 35.	Modelo AR(2) de CGLP.	75
Tabla 36.	Selección de transformación automática de PGASPAIS.	79
Tabla 37.	Outliers identificados automáticamente de PGASPAIS.	79
Tabla 38.	Cinco mejores modelos ARIMA de PGASPAIS.	80
Tabla 39.	Parámetros estimados del modelo ARIMA de PGASPAIS.	80
Tabla 40.	Autocorrelación muestral de los residuales de modelo ARIMA PGASPAIS.	81
Tabla 41.	Autocorrelación parcial muestral de los residuales de modelo ARIMA PGASPAIS.	82
Tabla 42.	Estadísticos de normalidad de residuales de modelo ARIMA de PGASPAIS.	83
Tabla 43.	Selección de transformación automática de PDIESELPAIS.	85
Tabla 44.	Outliers identificados automáticamente de PDIESELPAIS.	85
Tabla 45.	Cinco mejores modelos ARIMA de PDIESELPAIS.	86
Tabla 46.	Parámetros estimados del modelo ARIMA de PDIESELPAIS.	86
Tabla 47.	Autocorrelación muestral de los residuales de modelo ARIMA PDIESELPAIS.	87
Tabla 48.	Autocorrelación parcial muestral de los residuales de modelo ARIMA PDIESELPAIS.	88
Tabla 49.	Estadísticos de normalidad de residuales de modelo ARIMA de PDIESELPAIS.	89
Tabla 50.	Selección de transformación automática de IMACEC.	91
Tabla 51.	Outliers identificados automáticamente de IMACEC.	91
Tabla 52.	Cinco mejores modelos ARIMA de IMACEC.	92

Tabla 53.	Parámetros estimados del modelo ARIMA de IMACEC.....	92
Tabla 54.	Autocorrelación muestral de los residuales de modelo ARIMA IMACEC.	93
Tabla 55.	Autocorrelación parcial muestral de los residuales de modelo ARIMA IMACEC.....	94
Tabla 56.	Estadísticos de normalidad de residuales de modelo ARIMA de IMACEC.	95
Tabla 57.	Regresión de Cointegración de Consumo de Gasolina Automotriz.	97
Tabla 58.	Test de Engle-Granger de cointegración.....	97
Tabla 59.	Estimación Modelo Estructural de Consumo de Gasolina Automotriz.	98
Tabla 60.	Regresión de Cointegración de Consumo de Diesel Vehicular.	102
Tabla 61.	Test de Engle-Granger de modelo estructural Consumo de Diesel Vehicular.....	102
Tabla 62.	Estimación Modelo Estructural de Consumo de Diesel Vehicular.	103
Tabla 63.	Regresión de Cointegración de Consumo de GNC Vehicular.	107
Tabla 64.	Test de Engle-Granger de modelo estructural Consumo de GNC Vehicular.....	107
Tabla 65.	Estimación Modelo Estructural de Consumo de GNC Vehicular.	108
Tabla 66.	Regresión de Cointegración de Consumo de GLP Vehicular.	112
Tabla 67.	Test de Engle-Granger de modelo estructural Consumo de GLP Vehicular.	112
Tabla 68.	Estimación Modelo Estructural de Consumo de GLP Vehicular.	113
Tabla 69.	Índices de evaluación de pronósticos de corto plazo de modelos.	116
Tabla 70.	Índices de evaluación de pronósticos de largo plazo de modelos.	116
Tabla 71.	Modelo estimado para PEAJEGAS.	117
Tabla 72.	Modelo estimado para PEAJEDIESEL.....	118
Tabla 73.	Modelo estimado para CGAS, incluyendo FDSLARGO.....	119
Tabla 74.	Modelo estimado para CDIESEL, incluyendo FDSLARGO.	120
Tabla 75.	Outliers identificados automáticamente de modelo ARIMA CNE de CGAS.	122
Tabla 76.	Parámetros estimados del modelo ARIMA CNE de CGAS.....	123
Tabla 77.	Autocorrelación muestral de los residuales de modelo ARIMA CNE de CGAS.	124
Tabla 78.	Autocorrelación parcial muestral de los residuales de modelo ARIMA CNE de CGAS.	125
Tabla 79.	Estadísticos de normalidad de residuales de modelo ARIMA CNE de CGAS.....	126
Tabla 80.	Outliers identificados automáticamente de modelo ARIMA CNE de CDIESEL.	128
Tabla 81.	Parámetros estimados del modelo ARIMA CNE de CDIESEL.	129
Tabla 82.	Autocorrelación muestral de los residuales de modelo ARIMA CNE de CDIESEL.	129
Tabla 83.	Autocorrelación parcial muestral de residuales de modelo ARIMA CNE de CDIESEL.	130
Tabla 84.	Estadísticos de normalidad de residuales de modelo ARIMA CNE de CDIESEL.	132
Tabla 85.	Comparación de Índices de evaluación de pronósticos de corto plazo de modelos.....	133
Tabla 86.	Comparación de Índices de evaluación de pronósticos de largo plazo de modelos.....	134

ACRÓNIMOS

Acrónimo	Descripción
CNE	Comisión Nacional de Energía
SEC	Superintendencia de Energía y Combustibles
SERNAC	Servicio Nacional del Consumidor
BCENTRAL	Banco Central de Chile
INE	Instituto Nacional de Estadísticas
IMACEC	Índice Mensual de Actividad Económica
SEPCO	Seguro de Protección del Contribuyente ante Variaciones en los Precios de Combustibles
RM	Región Metropolitana
EViews	Software econométrico “Econometric Views”
OLS	Ordinary Least Squares (Mínimos Cuadrados Ordinarios)
RMSE	Root Mean Square Error (Raíz del Error Cuadrático Medio)
MAE	Mean Absolute Error (Error Absoluto Medio)
MAPE	Mean Absolute Percentage Error (Error Porcentual Absoluto Medio)
THEIL	Theil Inequality Coefficient (Coeficiente de Desigualdad de Theil)
FMOLS	Fully Modified Least Squares (Mínimos Cuadrados Totalmente Modificados)
ARIMA	AutoRegressive Integrated Moving Average
ARMA	AutoRegressive Moving Average
SOLS	Static Ordinary Least Squares (Mínimos Cuadrados Ordinarios Estáticos)
ACF	AutoCorrelation Function (Función de autocorrelación)
PCF	Partial Correlation Function (Función de Autocorrelación Parcial)
GLP	Gas Licuado de Petróleo
GNC	Gas Natural Comprimido
ADF	Argumented Dickey-Fuller (Dickey-Fuller Aumentada)
B	Backward shift operator (Operador de rezago)
i.i.d.	Independiente e idénticamente distribuida
AIC	Akaike Information Criterion
BIC	Bayesian information Criterion (Criterio de Información Bayesiano)
lom	Lengh-of-month (Largo del mes)
AO	Additive Outlier
LS	Level Shift (outlier de cambio de regimen)
TRAMO	Time series Regression with ARIMA noise, Missing observations, and Outliers
CGAS	Consumo Nacional de Gasolina Automotriz
CDIESEL	Consumo Nacional de Diesel Vehicular
CGLP	Consumo Nacional de Gas Licuado de Petróleo Vehicular
CGNC	Consumo Nacional de Gas Natural Comprimido Vehicular
PGASRM	Precio Gasolina Automotriz Región Metropolitana
PGASPAIS	Precio Gasolina Automotriz Promedio País
PDIESELRM	Precio Diesel Vehicular Región Metropolitana
PDIESELPAIS	Precio Diesel Vehicular Promedio País

1 INTRODUCCIÓN

La Comisión Nacional de Energía (CNE) requiere para el cumplimiento de sus funciones en la implementación del Seguro de Protección del Contribuyente ante Variaciones en los Precios de Combustibles (SEPCO), entregar al Ministerio de Hacienda antecedentes para la creación de la fórmula para estimar el número de opciones a comprar y/o vender respecto a las variables de cantidades físicas de los combustibles afectos al impuesto específico. Adicionalmente, deberá informar las correspondientes proyecciones conforme a lo regulado por los decretos supremos que constituirán el sistema de seguros.

1.1 Objetivo General

El objetivo general del estudio es recomendar una metodología y/o modelo de proyección de corto y largo plazo de consumos de los combustibles gasolina automotriz, petróleo diésel y del gas licuado de petróleo y gas natural comprimido, que sirva de insumo para los cálculos que debe realizar la CNE en caso de implementación del SEPCO.

1.2 Objetivos Específicos

- Proponer una metodología y/o modelo de proyección semanal de corto plazo de consumo de combustibles.
- Proponer una metodología y/o modelo de proyección semanal y mensual de largo plazo de consumo de combustibles.

2 CAPITULO 1: ANTECEDENTES

2.1 Modelos Estructurales de Demanda por Combustibles

La teoría económica tradicional y hallazgos empíricos han demostrado que el ingreso y el precio juegan un rol importante en la determinación de la demanda por combustibles; el ingreso tiene un impacto positivo sobre la cantidad demandada, mientras que el precio posee un efecto negativo.

En la literatura académica se estimó la función de demanda con la siguiente especificación:

$$D_t = \alpha_0 + \beta_0 P_t + \gamma_0 Y_t + \delta_0 D_{t-1} + \varepsilon_t \quad (1)$$

Donde:

D_t : es la (log de) demanda per cápita en el periodo t (y análogamente para D_{t-1})

P_t : es el (log de) precio del combustible

Y_t : es el (log de) ingreso per cápita

$\alpha_0, \beta_0, \gamma_0, \delta_0$: parámetros

ε_t : término de error aleatorio o estocástico.

La ecuación (1) se deriva de suponer una estructura de rezagos geométricos de Koyck. Esta estructura implica que los efectos de la variable explicatoria sobre la variable dependiente no se agotan en un solo período, operando además en forma rezagada en los siguientes períodos; específicamente, Koyck supone que los efectos rezagados van decreciendo geométricamente en el tiempo.

Además de la simplicidad econométrica de esta ecuación, una de las características atractivas es que los parámetros (para el modelo log-lineal) pueden ser interpretados de la siguiente manera:

β_0 : elasticidad de corto plazo de la demanda.

$\beta_0 / (1 - \delta_0)$: elasticidad de largo plazo de la demanda.

γ_0 : elasticidad de corto plazo del Ingreso.

$\gamma_0 / (1 - \delta_0)$: elasticidad de largo plazo del ingreso.

La elasticidad mide la variación porcentual de la variable dependiente ante un cambio de un 1% en una variable independiente (Pyndick y Rubinfeld, 2001). Pueden observarse dos características importantes del modelo log-lineal: el modelo supone que la elasticidad entre la variable independiente y la dependiente, permanece constante a través del tiempo de aquí su nombre alterno “modelo de elasticidad constante” (Gujarati, 2001).

Existen varias racionalizaciones del modelo de Koyck, siendo las más importantes el Modelo de Expectativas Adaptativas y el Modelo de Ajuste Parcial. La primera, se basa

en la hipótesis de expectativas adaptativas o de aprendizaje por error: implica que los agentes económicos adaptan sus expectativas a la luz de la experiencia pasada y que, en particular, ellos aprenden de sus errores. La segunda racionalización, se ilustra considerando el modelo de acelerador flexible de la teoría económica, que supone que hay un nivel de stock de capital de equilibrio óptimo deseado, bajo condiciones dadas de tecnología, tasa de interés, etc., pero el ajuste hacia dicho stock de capital óptimo ocurre en el tiempo, demorándose más de un período. Por último, existe una combinación de los dos modelos anteriores basada en la célebre hipótesis del ingreso permanente de Milton Friedman, que plantea que el consumo permanente o de largo plazo es una función del ingreso permanente o de largo plazo.

La ecuación (1) es una versión dinámica del siguiente modelo estático simple (Atkins y Tayyebi, 2004):

$$D_t = \alpha_0 + \beta_0 P_t + \gamma_0 Y_t + \varepsilon_t \quad (2)$$

La ecuación (2) es teóricamente cuestionable, ya que es un poco ingenuo pensar que existe un ajuste instantáneo en este mercado. De haber efectos rezagados, la ecuación (2) adolece de error de especificación. Incluso la ecuación (1) podría ser sólo un caso especial de una especificación más general de estructuras de rezagos.

2.2 Teoría de Correlación Serial

Un hallazgo común en las regresiones de series de tiempo es que los residuales están correlacionados con sus propios valores rezagados. Esta correlación serial viola los supuestos estándar de la teoría de regresión de que las perturbaciones no están correlacionadas con otras perturbaciones. Los problemas primarios asociados con la correlación serial son:

- MCO no es el más eficiente entre los estimadores lineales. Además, puesto que los residuales previos ayudan a predecir los residuales actuales, podemos tomar ventaja de esta información para formar una mejor predicción de la variable dependiente.
- Los errores estándar calculados usando la fórmula de MCO de los libros de texto no son correctos, y son generalmente subestimados.
- Si existen variables dependientes rezagadas en el lado derecho, los estimados MCO son sesgados e inconsistentes.

En general, estaremos preocupados con especificaciones de la forma:

$$y_t = x_t' \beta + u_t \quad (3)$$

$$u_t = z_{t-1}' \gamma + \epsilon_t \quad (4)$$

Donde:

x_t es un vector de variables exploratorias observadas en el tiempo t ,
 z_{t-1} es un vector de variables conocidas en el periodo previo,
 β y γ son vectores de parámetros,
 u_t es un término de perturbación, y
 ϵ_t es la innovación en la perturbación

El vector z_{t-1} puede contener valores rezagados de u , valores rezagados de ϵ , o ambos. La perturbación u_t es llamado residual incondicional. Es el residual basado en el componente estructural ($x_t'\beta$) el cual no utiliza la información contenida en z_{t-1} . La innovación ϵ_t es también conocida como *error de pronóstico un período adelante* o *error de predicción*. Es la diferencia entre el valor actual de la variable dependiente y un pronóstico hecho sobre la base de las variables independientes y los errores de pronóstico pasados.

2.2.1 Modelo Autorregresivo de Primer Orden

El modelo más simple y más comúnmente usado de correlación serial es el modelo autorregresivo de primer orden, o AR(1). El modelo AR(1) es especificado como:

$$y_t = x_t'\beta + u_t \quad (5)$$

$$u_t = \rho u_{t-1} + \epsilon_t \quad (6)$$

El parámetro ρ es el coeficiente de correlación serial de primer orden. En efecto, el modelo AR(1) incorpora el residual desde la observación pasada dentro del modelo de regresión para la observación actual.

2.2.2 Modelos Autorregresivos de Orden más Alto

Más generalmente, una regresión con un proceso autorregresivo de orden p , error AR(p) está dado por:

$$y_t = x_t'\beta + u_t \quad (7)$$

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \epsilon_t \quad (8)$$

Las autocorrelaciones de un proceso estacionario AR(p) gradualmente decaen a cero, mientras que las autocorrelaciones parciales para rezagos más grandes que p son cero.

2.2.3 Teoría ARIMA

Los modelos ARIMA (autorregresive integrated moving average) son generalizaciones del modelo AR simple que usa tres herramientas para el modelamiento de la correlación serial en la perturbación:

- Cada término AR corresponde al uso de un valor rezagado del residual en la ecuación de pronóstico para el residual no condicional. Un modelo autorregresivo de orden p , $AR(p)$ tiene la forma:

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \epsilon_t \quad (9)$$

- Término de orden de integración. Cada orden de integración corresponde a la diferenciación de las series que están siendo pronosticadas.
- Un modelo de pronóstico de promedios móviles usa los valores rezagados del error de pronóstico para mejorar el pronóstico actual. Un modelo $MA(q)$ tiene la forma:

$$u_t = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (10)$$

Las especificaciones autorregresivas y de promedios móviles pueden ser combinadas para formar una especificación $ARMA(p, q)$

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (11)$$

2.2.4 Principios de Modelamiento ARIMA

El primer paso en formar un modelo ARIMA para una serie de residuales es mirar en sus propiedades de autocorrelación.

Esta fase del procedimiento del modelamiento ARIMA es llamado *identificación*. La naturaleza de la correlación entre los valores actuales de los residuales y sus valores pasados provee una guía en la selección de una especificación ARIMA.

Las autocorrelaciones son fácil de interpretar-cada una es el coeficiente de correlación del valor actual de la serie con la serie rezagada un cierto número de periodos. Las autocorrelaciones parciales son un poco más complicadas; ellas miden la correlación de las series actual y rezagada después de tomar en cuenta el poder predictivo de todos los valores de las series con rezagos más pequeños. La autocorrelación parcial para el rezago 6, por ejemplo, mide el poder predictivo sumado de u_{t-6} cuando $u_1, \dots, u_{t-5}$ están ya en el modelo de predicción. De hecho, la autocorrelación parcial es

precisamente el coeficiente de regresión de u_{t-6} en una regresión donde los rezagos más tempranos son también usados como predictores de u_t .

Si se sospecha que existe una relación entre un rezago distribuido entre la variable dependiente (lado izquierdo) y algún otro predictor, se puede mirar en sus correlaciones cruzadas antes de realizar la estimación.

El próximo paso es decidir qué tipo de modelo ARIMA usar. Si la función de autocorrelación decae suavemente a una tasa geométrica, y las autocorrelaciones parciales son cero después de un rezago, entonces es apropiado un modelo autorregresivo de primer orden. Alternativamente, si las autocorrelaciones fueron cero después de un rezago y las autocorrelaciones parciales declinan geométricamente, un proceso de promedios móviles de primer orden parecería apropiado. Si las autocorrelaciones parecen tener un patrón estacional, esto sugeriría la presencia de una estructura ARMA estacional.

2.3 Teoría de Series de Tiempo

2.3.1 No Estacionariedad de Series de Tiempo

Toda la teoría de regresión esta basada en series de tiempo estacionarias. Una serie se dice estacionaria si la media y autocovarianza de esta no depende del tiempo. Un ejemplo común de una serie no estacionaria es la caminata aleatoria:

$$y_t = y_{t-1} + \varepsilon_t \quad (12)$$

Donde:

ε_t : término estacionario de perturbación aleatoria

La serie y tiene un valor de pronóstico constante, condicional en t , y la varianza se incrementa sobre el tiempo. La caminata aleatoria es una serie estacionaria de diferencia donde la primera diferencia de y es estacionaria:

$$y_t - y_{t-1} = \varepsilon_t \quad (13)$$

Una serie estacionaria de diferencia se dice que está integrada y es denotada como $I(d)$, donde d es el orden de integración. El orden de integración es el número de raíces unitarias contenidas en las series, o el número de operaciones de diferenciación que toma hacer la serie estacionaria. Para la caminata aleatoria de arriba, existe una raíz unitaria, así que es una serie $I(1)$. Similarmente, una serie estacionaria es $I(0)$.

Los procedimientos estándar de inferencia no se aplican a regresiones que contienen una variable dependiente integrada o regresores integrados. Por lo tanto, es importante

chequear si una serie es estacionaria o no antes de usarla en una regresión. El método formal para probar la estacionariedad de una serie es la Prueba de Raíz Unitaria.

2.3.2 Regresión Espuria

Al efectuar la regresión de una variable de serie de tiempo sobre otra variable de serie de tiempo, con frecuencia se obtiene un R^2 muy elevado aunque no haya una relación significativa entre las dos. Esta situación ejemplifica el problema de **regresión espuria**. Este problema surge porque si las dos series de tiempo involucradas presentan **tendencias** fuertes (movimientos sostenidos hacia arriba o hacia abajo), el alto R^2 observado se debe a la presencia de la tendencia y no a la verdadera relación entre las dos. Por consiguiente, es muy importante averiguar si la relación entre las variables económicas es verdadera o es espuria. Por ejemplo, cuando se efectúa una regresión entre dos series de tiempo, puede haberse efectuado una regresión de una serie de tiempo no estacionaria sobre otra igualmente no estacionaria (caminata aleatoria). En ese caso, los procedimientos estándar de pruebas t y F no son válidos. En este sentido, la regresión es espuria.

2.3.3 Cointegración

Debido a que muchas series de tiempo económicas parecen seguir caminatas aleatorias, esto sugiere que se desee, de manera típica diferenciar una variable antes de usarla en una regresión. Aunque esto es aceptable, la diferenciación puede dar como resultado una pérdida de información acerca de la relación a largo plazo entre dos variables. La mayor parte de la teoría económica se postula con base en relaciones de largo plazo entre las variables en niveles, es decir, no en forma de primera diferencia. Así, la hipótesis del ingreso permanente de Milton Friedman postula que el nivel del consumo permanente es función del nivel del ingreso permanente; la relación no está planteada en términos de las primeras diferencias de estas variables.

El hallazgo que muchas series de tiempo macroeconómicas pueden contener una raíz unitaria ha motivado el desarrollo de la teoría de análisis de series de tiempo no estacionarias. Engle y Granger (1987) señalan, que una combinación lineal de dos o más series no estacionarias puede ser estacionaria. Si tal combinación lineal estacionaria existe, las series de tiempo no estacionarias se dice que están **cointegradas**. La combinación lineal estacionaria es llamada la **ecuación de cointegración** y puede ser interpretada como la relación de equilibrio de largo plazo entre las variables.

Suponga la siguiente regresión entre 2 variables:

$$y_t = \beta_1 + \beta_2 x_t + u_t \quad (14)$$

Donde:

y_t : variable dependiente

x_t : variable independiente o explicatorio

β_1, β_2 : parámetros estimados

u_t : error aleatorio

Además, suponga que se ha determinado que ambas variables son procesos no estacionarios $I(1)$ o caminatas aleatorias. A pesar de esto, la combinación de estas dos variables podría ser estacionaria. Más específicamente, si se escribe (14) como:

$$u_t = y_t - \beta_1 - \beta_2 x_t \quad (15)$$

y se encuentra que u_t [es decir, la combinación lineal $(y_t - \beta_1 - \beta_2 x_t)$] es $I(0)$ o estacionaria, entonces se dice que las variables x_t e y_t están cointegradas; es decir, están sobre la misma longitud de onda. Intuitivamente se observa que cuando u_t en (15) es $I(0)$, las “tendencias” en x_t e y_t se cancelan. Y estas estarán en la misma longitud de onda si son integradas del mismo orden. Así, si una serie Y es $I(1)$ y otra serie X es también $I(1)$, ellas pueden estar cointegradas. En general, si Y es $I(d)$ y X es también $I(d)$, donde d es el mismo valor, estas dos series pueden estar cointegradas. Si ese es el caso, la regresión de las dos variables en niveles, como en (14), es significativa (es decir, no es espuria); y no se pierde información valiosa de largo plazo, lo cual sucedería si se utilizaran sus primeras diferencias.

En resumen, siempre y cuando se verifique que los residuales de las regresiones como (14) son $I(0)$ o estacionarios, la metodología tradicional de regresión (incluyendo las pruebas t y F) es aplicable a las series de tiempo. La contribución valiosa de los conceptos de estacionariedad, raíz unitaria y cointegración, es que obliga a determinar si los residuales de la regresión son estacionarios.

En el lenguaje de la teoría de la cointegración una regresión tal como (14) se conoce como **regresión cointegrada** y el parámetro β_2 es conocido como **parámetro cointegrado**.

3 CAPITULO 2: METODOLOGÍA

3.1 Series de Tiempo de Variables Relevantes y Fuentes de Información

Se construyó una base de datos Excel “**BDModelos**” con un set de datos de frecuencia mensual, excepto para una sola variable, esto es, para Fin de Semanas Largos (FDSESLARGO), la cual se incorpora en frecuencia mensual y semanal. Se consideraron inicialmente las variables más relevantes que empírica y teóricamente influyen en el comportamiento del consumo de los diferentes combustibles. A continuación, se detallan las series utilizadas, el periodo de la muestra histórica, la frecuencia, la fuente de información, la unidad en que se expresan y el acrónimo utilizado.

Variable	Muestra Histórica		Frecuencia	Fuente	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	01-1988	11-2012	M	CNE	m ³	CGAS
Consumo Nacional de Diesel Vehicular	01-1998	11-2012	M	CNE	m ³	CDIESEL
Consumo Nacional de Gas Licuado de Petróleo (*)	01-2011	11-2012	M	CNE	m ³	CGLP
Consumo Nacional de Gas Natural Comprimido (*)	01-2001	11-2012	M	SEC	Mm ³	CGNC
Precio de Gasolina Automotriz 95 octanos RM	01-2003	11-2012	M	SERNAC	\$/litro	PGASRM
Precio de Gasolina Automotriz 95 octanos PAÍS	01-2003	11-2012	M	SERNAC	\$/litro	PGASPAIS
Precio de Diesel Vehicular RM	01-2003	11-2012	M	SERNAC	\$/litro	PDIESELRM
Precio de Diesel Vehicular PAÍS	01-2003	11-2012	M	SERNAC	\$/litro	PDIESELPAIS
Precio de Gas Licuado de Petróleo	01-2011	11-2012	M	CNE	\$/litro	PGLP
Precio de Gas Natural Comprimido RM	01-2011	11-2012	M	CNE	\$/m ³	PGNCRM
Precio de Gas Natural Comprimido XII Región	01-2008	11-2012	M	CNE	\$/m ³	PGNCR12
Índice Mensual de Actividad Económica IMACEC	01-2003	11-2012	M	BCENTRAL	-	IMACEC
Vehículos a Gasolina Controlados en Plazas de Peaje	01-2003	11-2012	M	INE	N°	PEAJEGAS
Vehículos a Diesel Controlados en Plazas de Peaje	01-2003	11-2012	M	INE	N°	PEAJEDIESEL
Vehículos Totales Controlados en Plazas de Peaje	01-2003	11-2012	M	INE	N°	PEAJETOT
Fines de Semana Largos	01-2003	12-2020	S, M	GOOGLE	N°	FDSESLARGO

Tabla 1. Lista de series de tiempo de variables relevantes utilizadas en el estudio.

Notas: S = frecuencia semanal; M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

(*) Combustibles de uso vehicular.

3.1.1 Consideraciones sobre algunas variables

3.1.1.1 Consumo Nacional de Gas Natural Comprimido (CGNC)¹

Corresponde al consumo total nacional obtenido de los Informes Estadísticos Anuales de la SEC y caratulado como “Estaciones de Servicio GNC” en el título de la hoja 47² “Gas Natural Distribuido por regiones y tipo de consumidor (Mm3)”.

¹ http://www.sec.cl/portal/page?_pageid=33,3429539&_dad=portal&_schema=PORTAL

² El número de hoja Excel del respectivo Informe Estadístico puede cambiar de un año a otro.

3.1.1.2 Precio de Gasolina Automotriz 95 octanos RM (PGASRM)³

Se consideró el precio de la gasolina de 95 octanos de la encuesta semanal del SERNAC en las estaciones de servicio de la Región Metropolitana, como representativo de los precios promedios de las diferentes calidades presentes en el mercado, esto es, 93 y 97 octanos, puesto que el precio de paridad calculado para la gasolina de 95 octanos es el promedio de los precios de dichas calidades. El precio mensual se calculó como el promedio simple de los precios de cada una de las semanas del mes respectivo.

3.1.1.3 Precio de Diesel Vehicular RM (PDIESELRM)⁴

Al igual que el precio anterior, la fuente de información es la encuesta semanal del SERNAC o sondeo semanal en las estaciones de servicio de la Región Metropolitana. Análogamente, el precio mensual se calculó como el promedio simple de los precios de cada una de las semanas del mes respectivo.

3.1.1.4 Precio de Gasolina Automotriz 95 octanos País (PGASPAIS)⁵

Corresponde al promedio nacional mensual, calculado como la suma de los precios de cada región dividido por el número de regiones del país para cada mes. Estos datos se encuentran en el sitio de la CNE caratulados con el nombre de “Precio Mensual Regional de Combustibles Líquidos (SERNAC)”.

3.1.1.5 Precio de Diésel Vehicular País (PDIESELPAIS)⁶

El cálculo y fuente de información de esta variable es análogo a la anterior.

3.1.1.6 Índice Mensual de Actividad Económica (IMACEC)⁷

Este índice se consideró como una variable representativa del crecimiento económico mensual del país y por ende del ingreso. Corresponde a la “serie original” ubicada en “Base de Datos Estadísticos\Cuentas Nacionales\PIB gasto e ingreso\Empalmes con series referencia 2008\Imacec\Índice” de la página web del Banco Central de Chile.

3.1.1.7 Vehículos a Gasolina Controlados en Plazas de Peaje (PEAJEGAS)⁸

³ <http://www.sernac.cl/category/estudios/sondeos-de-precios/>

⁴ <http://www.sernac.cl/category/estudios/sondeos-de-precios/>

⁵ <http://www.cne.cl/estadisticas/energia/hidrocarburos>

⁶ <http://www.cne.cl/estadisticas/energia/hidrocarburos>

⁷ <http://si3.bcentral.cl/Siete/secure/cuadros/arboles.aspx>

⁸

http://www.inec.cl/canales/chile_estadistico/estadisticas_economicas/transporte_y_comunicaciones/transporte_y_comunicaciones.php

Corresponde al total nacional y se calculó como la suma del número de los siguientes vehículos:

- i) Autos y Camionetas;
- ii) Autos y Camionetas con carro, de uno o más ejes; y
- iii) Motos y similares.

Se consideró esta variable con miras a cuantificar el efecto de los fines de semana largos en la variación del consumo de la gasolina automotriz.

La fuente de información de estos datos corresponde a la página web del INE:

“Productos estadísticos\Económicas\Transporte y Comunicaciones\Estadística Mensual\ Transporte y Comunicaciones”.

3.1.1.8 Vehículos a Diésel Controlados en Plazas de Peaje (PEAJEDIESEL)⁹

Corresponde al total nacional y se calculó como la suma del número de los siguientes vehículos:

- i) Camiones de dos ejes;
- ii) Camiones y Buses de Tres y más ejes; y
- iii) Buses de dos ejes.

Análogamente, se consideró esta variable con miras a cuantificar el efecto de los fines de semana largos en la variación del consumo del diésel vehicular.

3.1.1.9 Vehículos Totales Controlados en Plazas de Peaje (PEAJETOT)

Se calculó como la suma de PEAJEGAS Y PEAJEDIESEL.

3.1.1.10 Fines de Semana Largos (FDSSLARGO)

Corresponde a una variable dicótoma¹⁰ o dummy que toma los valores de 1 si existe presencia de fin de semana largo y 0 si no existe. Estos datos fueron obtenidos de los calendarios de Google¹¹.

3.1.2 Prueba de Raíz Unitaria de Dickey-Fuller Aumentada (ADF)

⁹

http://www.ine.cl/canales/chile_estadistico/estadisticas_economicas/transporte_y_comunicaciones/transporte_y_comunicaciones.php

¹⁰ Otros nombres para esta variable son variables indicadoras, variables binarias, variables categóricas y variables cualitativas.

¹¹ [Google Calendar](#)

Se realizaron pruebas de raíces unitarias de Dickey-Fuller Aumentada a cada una de las series relevantes con el objetivo de verificar la propiedad de estacionariedad en cada una de ellas y poseer información para la toma de decisiones en la formulación de los modelos de series de tiempo y estructurales de consumo de los diferentes combustibles.

La prueba de Dickey-Fuller Aumentada para raíz unitaria se basa en la siguiente regresión:

$$\Delta y_t = \alpha_0 + \alpha_1 t + \beta_1 y_{t-1} + \beta_2 \Delta y_{t-1} + \dots + \beta_p \Delta y_{t-p} + v_t \quad (16)$$

Donde:

$$\beta_1 = \rho - 1$$

p : rezago del término de diferencia de la variable dependiente y

Las hipótesis nula y alternativa pueden ser escritas como:

$$H_0 : \beta_1 = 0 \quad (17)$$

$$H_1 : \beta_1 < 0 \quad (18)$$

y evaluada usando el t -**ratio** convencional para β_1 :

$$t_{\beta_1} = \hat{\beta}_1 / (se(\hat{\beta}_1)) \quad (19)$$

Donde:

$\hat{\beta}_1$: es el estimado de β_1 y;

$se(\hat{\beta}_1)$: es el coeficiente de error estándar

Dickey y Fuller demostraron que bajo la hipótesis nula de una raíz unitaria, este estadístico no sigue la distribución t de Student convencional, y ellos derivaron resultados asintóticos y simularon valores críticos para varios test y tamaños de muestra. Más recientemente, McKinnon (1991,1996) implementa un set de simulaciones mucho más grande que esas tabuladas por Dickey y Fuller. Además, McKinnon estima superficies de respuesta para los resultados de la simulación, permitiendo el cálculo de los valores críticos de Dickey-Fuller y p -values para muestras de tamaño arbitrario. Eviews utiliza los cálculos de valores críticos más recientes de

McKinnon para construir los resultados del test. Asimismo, la selección de p está basada en el criterio de información de Schwartz (SIC; Schwartz Information Criterion).

3.2 Modelos ARIMA y de Series de Tiempo

3.2.1 Modelo ARIMA General Multiplicativo Estacional¹²

Antes de definir el modelo ARIMA estacional es necesario definir algunos operadores que conforman dicho modelo:

- **Backward shift operator B (Operador de rezago)**¹³

Este operador se define de la siguiente forma:

$$B^m z_t = z_{t-m} \quad (20)$$

Es decir este operador produce un rezago de m periodos de tiempo respecto de la serie o variable z .

- **Operador de diferencia ∇**

Este operador corresponde a la primera diferencia de la serie z respecto de su rezago, y se define de la siguiente forma:

$$\nabla z_t = z_t - z_{t-1} \quad (21)$$

Este operador puede escribirse en términos de B de la siguiente forma:

$$\nabla z_t = z_t - z_{t-1} = (1 - B)z_t \quad (22)$$

- **Operador B con rezago estacional**

La característica principal de las series de tiempo estacionales con periodo s radica en que las observaciones que están en intervalos s son similares¹⁴. Por lo tanto, uno esperaría que la operación $B^s z_t = z_{t-s}$ desempeñe un papel relevante en el análisis de series estacionales y, adicionalmente, ya que se espera la presencia de no estacionariedad en las series $z_t, z_{t-s}, z_{t-2s}, \dots$, la operación se puede simplificar de la siguiente forma:

¹² Sección basada en Box, G., G. Jenkins and G. Reinsel (2008) y en X-12-ARIMA Reference Manual, Version 0.3, U.S. Census Bureau (2011).

¹³ Operador de rezagos símil de L (Lag operator) utilizado en el resto de la literatura de series de tiempo y software Eviews.

¹⁴ En este estudio que se estimaron modelos de frecuencia mensual, s correspondió a 12, esto es, se verificaría la hipótesis que por ejemplo el consumo del mes de junio de un año dado posee una correlación con el consumo del mismo mes del año anterior.

$$\nabla_s z_t = z_t - z_{t-s} = (1 - B^s)z_t \quad (23)$$

- **Operador autorregresivo no estacional (AR)**

$$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \quad (24)$$

- **Operador autorregresivo estacional¹⁵**

$$\Phi(B^s) = (1 - \Phi_1 B - \dots - \Phi_p B^{ps}) \quad (25)$$

- **Operador de medias móviles no estacional (MA)**

$$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q) \quad (26)$$

- **Operador de medias móviles estacional¹⁶**

$$\Theta(B^s) = (1 - \Theta_1 B - \dots - \Theta_Q B^{Qs}) \quad (27)$$

Finalmente, un modelo ARIMA general multiplicativo estacional para una serie de tiempo z_t puede ser escrito como:

$$\phi(B)\Phi(B^s)(1 - B)^d(1 - B^s)^D z_t = \theta(B)\Theta(B^s)a_t \quad (28)$$

Donde:

a_t ¹⁷: es una serie de “shocks” independientes. Estos shocks son aleatorios generados desde una distribución fija, usualmente asumida normal y que tiene media cero y varianza σ_a^2 . Tal secuencia de variables aleatorias independientes (i.i.d) $a_t, a_{t-1}, a_{t-2}, \dots$ se conoce como un proceso de *ruido blanco*.

El proceso multiplicativo resultante se dice entonces que es de orden:

$$(p \ d \ q)(P \ D \ Q)_s \quad (29)$$

y el modelo ARIMA se conoce como:

$$ARIMA(p \ d \ q)(P \ D \ Q)_s^{18} \quad (30)$$

Donde:

¹⁵ También conocido en la literatura como SAR, Seasonal AR.

¹⁶ También conocido en la literatura como SMA, Seasonal MA.

¹⁷ También conocido en la literatura con la notación de ε_t .

¹⁸ Por su simplicidad y representatividad se utilizó esta notación del modelo ARIMA en el presente estudio.

p : es el orden AR no estacional

d : es el número de diferencias no estacionales

q : es el orden MA no estacional

P : es el orden AR estacional

D : es el número de diferencias estacionales

Q : es el orden MA estacional

s : es el periodo estacional, para frecuencia trimestral $s = 4$, para frecuencia mensual $s = 12$

3.2.2 Muestras de Estimación

Para llevar a cabo la estimación de los modelos ARIMA se consideraron las muestras de estimación de las series de tiempo que poseían más de 36 datos, ya que este es el mínimo de observaciones que el software X12 ARIMA necesita para poder ejecutar una estimación. Debido a lo anterior, no se pudo estimar el modelo ARIMA de la serie de Consumo de GLP (CGLP) mediante dicho software, las cuales poseían apenas 23 observaciones. No obstante, se estimó un modelo de CGLP ARIMA mediante el software Eviews.

Se estimaron modelos ARIMA adicionalmente para los precios de gasolina y diésel y para el IMACEC, con el objetivo de generar pronósticos para que a su vez sirvieran de input de los modelos estructurales que se detallan más adelante, puesto que algunas de estas variables corresponden a variables exógenas en dichos modelos.

Variable	Muestra de Estimación		Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	01-2006	11-2012	M ³	CGAS
Consumo Nacional de Diesel Vehicular	01-2005	11-2012	M ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	01-2002	11-2012	MM ³	CGNC
Consumo Nacional de GLP	01-2011	11-2012	M ³	CGLP
Precio de Gasolina Automotriz 95 octanos PAÍS	01-2003	11-2012	\$/litro	PGASPAIS
Precio de Diesel Vehicular PAÍS	01-2003	11-2012	\$/litro	PDIESELPAIS
Índice Mensual de Actividad Económica IMACEC	01-2003	11-2012	-	IMACEC

Tabla 2. Lista de variables utilizadas para la estimación de modelos ARIMA.

3.2.3 Ajustes Preliminares de las Series

3.2.3.1 Transformación de los Datos

Para datos estacionales se debe tener especial cuidado en la selección de una apropiada transformación de los datos (Box, et. al. 2008). Respecto a este tema el programa X-12-ARIMA en su módulo regARIMA posee cuatro diferentes tipos de funciones de transformación (transform):

- i) Logarítmica (log)¹⁹
- ii) Raíz cuadrada (square root)
- iii) Inversa (inverse) y
- iv) Logística (logistic)

Estas pueden ser directamente elegidas sin ningún test de bondad de ajuste comparativo, sin embargo el software permite ejecutar una selección basada en el Criterio de Información de Akaike (AIC) para decidir entre una transformación logarítmica versus no transformación (function=auto). Este último método se utilizó para verificar si era conveniente transformar o no la serie original.

Por otro lado, los datos se pueden ajustar por el largo del mes (lengh-of-month) de la siguiente forma:

$$Y_{ta} = \frac{(30,4375 * Y_t)}{m_t} \quad (31)$$

Donde:

Y_{ta} : Serie ajustada por el largo del mes

Y_t : Serie original a ajustar

m_t : Número de días en el mes t

30,4375: promedio del largo del mes en el año²⁰

3.2.3.2 Identificación de Valores Atípicos (Outliers)

Se detectaron los valores atípicos en cada una de las series a través de la función **outlier** del software X12-ARIMA, que selecciona los valores atípicos en forma automática. Se seleccionaron los siguientes tipos de outlier a detectar:

- i) AO: outlier aditivo en t_0 : $aodate_0$ (additive outlier)

Los AOs afectan solamente una observación en la serie de tiempo de la siguiente forma:

$$AO_t^{(t_0)} = \begin{cases} 1 & \text{para } t = t_0 \\ 0 & \text{para } t \neq t_0 \end{cases} \quad (date_0 \text{ es la fecha correspondiente al punto de tiempo } t_0) \quad (32)$$

En otras palabras corresponde a una variable dicotómica o dummy para puntos específicos atípicos.

- ii) LS: cambio estructural en t_0 : $lsdate_0$ (Level shift)

¹⁹ Corresponde a logaritmo natural.

²⁰ Corresponde a la sumatoria de número de días en el año (365,25) dividido por 12 meses.

Los LSs aumentan o disminuyen todas las observaciones por alguna cantidad constante desde un cierto punto en el tiempo en adelante y están definidos de la siguiente forma:

$$LS_t^{(t_0)} = \begin{cases} -1 & \text{para } t < t_0 \\ 0 & \text{para } t \geq t_0 \end{cases} \quad (33)$$

3.2.4 Estimación de Modelos ARIMA

Los modelos ARIMA se estimaron mediante el software X12 ARIMA²¹ versión 0.3 de la Oficina del Censo de Estados Unidos, el cual es llamado y ejecutado a través de funciones especiales dentro del software Eviews. Se optó por la utilización de este software para la estimación de los modelos ARIMA en vez de hacerlo en forma interna en el software Eviews, debido a que el primero incorpora un módulo de selección automática del modelo (AUTOMDL) la cual permite ir variando en el tiempo la selección del mejor ajuste de los diferentes modelos de consumo de combustibles ante la incorporación de nuevos datos en forma mensual por parte de la CNE y obtener por ende pronósticos que mantendrán o mejoraran su exactitud en el tiempo.

Se utilizó la función AUTOMDL, la cual es un procedimiento de selección automática del modelo $ARIMA(p\ d\ q)(P\ D\ Q)_s$, implementado en la versión 0.3 de X12 ARIMA y está basado en el programa de modelamiento de series de tiempo TRAMO (Time series Regression with ARIMA noise, Missing observations, and Outliers) desarrollado por Gómez y Maravall (1996). Es muy similar al procedimiento de TRAMO pero contiene modificaciones para hacer uso de los diferentes procedimientos de estimación de modelos del programa, opciones de modelo de regARIMA, transformación y procedimientos de identificación de outlier y diagnósticos del modelo. Este procedimiento puede ser resumido en cinco etapas o pasos:

3.2.4.1 Estimación del modelo por defecto

Se estima un modelo por defecto, identificación de outlier inicial y se realizan test de regresores y por último se generan diagnósticos de los residuales. El modelo por defecto es un modelo “airline”²²: $ARIMA(0\ 1\ 1)(0\ 1\ 1)_s$ para series mensuales y trimestrales. Este modelo por defecto es utilizado para desarrollar una serie de tareas. Se chequea la significancia de los regresores (diversos efectos incluidos en el programa) mediante un test AIC y se chequea la significancia de incluir una constante en el modelo regARIMA. Se utiliza un estadístico t para la media de los residuales del modelo, y se chequea frente a un valor crítico de 1,96. Una vez que lo anterior se ha realizado, se realiza la identificación automática de los autlier, si es que esta especificación ha sido utilizada.

²¹ <http://www.census.gov/srd/www/x12a/>

²² Se refiere al modelo de ejemplo del total de pasajeros transportados por aerolíneas internacionales que se expone extensamente en Box et. al. (2008).

Después de que la sección de regresión del modelo por defecto ha terminado, el programa genera diagnóstico de los residuales para este modelo:

- El estadístico Q de Ljung-Box para los residuales del modelo (con un rezago de 24 para las series mensuales y de 16 para las series trimestrales).
- El coeficiente de confianza para este estadístico: se define como 1 menos el p-value del estadístico Q de Ljung-Box.
- Un t-value para los residuales del modelo regARIMA
- Un estimado del error estándar de los residuales

Estos diagnósticos son luego contrastados con los del modelo seleccionado por el procedimiento de identificación automática del modelo. Dicho modelo seleccionado debe mostrar una mejora sobre el modelo por defecto en estos diagnósticos de los residuales, de lo contrario el programa aceptará el modelo por defecto.

3.2.4.2 Identificación de órdenes de diferenciación

Se realizan test de raíz unitaria empíricos para determinar los órdenes de diferenciación necesarios por el modelo, ajustando diferentes modelos ARMA a las series linealizadas (algunas veces diferenciadas). La estimación de estos modelos es realizada usando una técnica llamada método Hannan-Rissanen²³.

Paso 1: Se ajusta un modelo $ARIMA(2\ 0\ 0)(1\ 0\ 0)_s$ para series lineales usando el método Hannan-Rissanen, y se visualiza las raíces reales AR del modelo estimado. El programa considera la existencia de una raíz unitaria si el módulo de la raíz es menor a 1,042, y entonces el orden de diferenciación que corresponde a la raíz (estacional o no estacional) se incrementa en uno, esto es, se verifica la existencia de una raíz unitaria y por ende se concluye que la serie era no estacionaria y se necesitaba una diferenciación o integración para hacerla estacionaria para la componente estacional o no estacional.

Paso 2: si se verificó una diferenciación en el paso 1, la serie linealizada es diferenciada al comienzo del paso 2. Un modelo $ARMA(1\ 1)(1\ 1)_s$ es ajustado a la serie resultante, y se verifican los parámetros AR para visualizar si son cercanos a 1. Si se encuentra un coeficiente AR que cumple el criterio, el programa chequea si existe un factor común para los correspondientes polinomios AR y MA del modelo ARMA que pueden cancelarse. Si no se cancelan, el orden de diferenciación cambia y este proceso se repite hasta que las diferenciaciones son encontradas.

²³ Hannan y Rissanen (1982), Gómez y Maravall (2001).

3.2.4.3 Identificación de órdenes de modelos ARMA

Una vez que el orden de diferenciación se encontró en la etapa anterior, el programa encuentra los órdenes del modelo ARMA. Para cumplir con lo anterior se comparan los valores del BIC: Criterio de Información Bayesiano²⁴ (Schwarz, 1978) de un número de modelos, hasta el máximo orden para los polinomios regulares y estacionales del modelo ARMA especificados por el usuario.

Se utilizó el máximo de órdenes disponibles que trae el programa, esto es, un orden máximo de 3 para el polinomio AR y un máximo de 2 para el polinomio MA.

Por último se seleccionó el modelo con el menor BIC, sin embargo se pueden visualizar en los resultados los mejores cinco modelos mediante la tabla *bestfivemdl* que se incorporó dentro de la función *print* en el archivo de especificación de X-12-ARIMA.

El BIC puede ser expresado de la siguiente forma:

$$BIC_N = -2\widehat{L}_N + n_p \log N \quad (34)$$

Donde:

$\widehat{L}_N$: máximo valor de la función de verosimilitud logarítmica evaluada sobre N observaciones,

n_p : número de parámetros estimados en el modelo, incluyendo las varianzas de ruido blanco, y

N : número de observaciones que quedan después de la aplicación de las operaciones de diferenciación estacional y no estacional del modelo.

3.2.4.4 Comparación del modelo identificado con el modelo por defecto

Si el modelo identificado en forma automática en la etapa anterior no corresponde al modelo por defecto, los diagnósticos de los residuales son comparados entre ellos.

El modelo por defecto será preferido sobre el modelo identificado automáticamente si:

- El número de outliers automáticamente identificados por el modelo por defecto es menor o igual al número de outliers automáticamente identificados por el modelo automáticamente identificado, **Y**
- $Q_A < 0,95$ y $Q_D < 0,75$ y $RSE_D < RSE_A$, **0**
- $Q_A > 0,95$ y $Q_D < 0,95$ (solo para el primer paso), **0**
- $Q_A < 0,95$ y $Q_D < 0,75$ y $Q_D < Q_A$ y $RSE_D < RSE_A * 1,013$, **0**

²⁴ BIC, Bayesian information Criterion.

- $Q_A \geq 0,95$ y $Q_D < 0,95$ y $RSE_D < RSE_A * 1,013$, **0**
- El modelo automático es $(1\ 0\ 1)(0\ 1\ 1)_s$ o $(1\ 0\ 0)(0\ 1\ 1)_s$ y $\phi_1 \geq 0,82$, **0**
- El modelo automático es $(0\ 1\ 1)(1\ 0\ 1)_s$ o $(0\ 1\ 1)(1\ 0\ 0)_s$ y $\Phi_1 \geq 0,65$.

Donde:

Q_A : Coeficiente de confianza del estadístico Q de Ljung-Box para el modelo identificado automáticamente (con un rezago de 24 para series mensuales).

Q_D : Coeficiente de confianza del estadístico Q de Ljung-Box para el modelo por defecto.

RSE_A : Error estándar residual para el modelo identificado automáticamente.

RSE_D : Error estándar residual para el modelo por defecto.

3.2.4.5 Chequeo final del modelo

Una vez que el modelo es seleccionado, se lleva a cabo una serie de test para verificar que el modelo sea adecuado.

- Verificación de raíces unitarias en el polinomio AR, para visualizar si el orden de diferenciación regular o estacional debiera ser corregido. El programa detecta la presencia de una raíz unitaria si el módulo de una raíz AR dada es menor o igual que 1,05. Si se detecta una raíz unitaria, el programa entonces reduce el orden del polinomio AR a uno adecuado, y aumenta el orden de diferenciación a uno apropiado. Luego, se estima el modelo actualizado, y se generan los nuevos diagnósticos del modelo.
- Para el polinomio MA se realiza un procedimiento análogo.

3.3 Modelos Estructurales de Consumo

3.3.1 Especificación de Modelos Estructurales

Los modelos estructurales de consumo de todos los combustibles se especificaron de la siguiente forma:

$$\log(C_t) = \alpha_0 + \beta_0 \log(P_t) + \gamma_0 \log(IMACEC_t) + \delta_0 \log(C_{t-1}) + \sum_{i=2}^{12} \omega_i D_i + \lambda_i AO_i + \varepsilon_t \quad (41)$$

Donde:

C_t : es el consumo nacional del combustible en el mes t
 C_{t-1} : es el consumo nacional del combustible en el mes $t - 1$
 P_t : es el precio nominal del combustible en el mes t
 $IMACEC_t$: es el Índice Mensual de Actividad Económica en el mes t
 D_i : Variables dicotómicas o dummy estacionales con $i = 2, \dots, 12$
 AO_i : outliers aditivos
 $\alpha_0, \beta_0, \gamma_0, \delta_0, \omega_i, \lambda_i$: parámetros a estimar
 ε_t : término de error aleatorio o estocástico en el mes t
 $\log$: operador de logaritmo natural

3.3.2 Muestras de Estimación

Con el objetivo de incorporar la totalidad de la información de la variable IMACEC, la cual tenía una data histórica desde enero de 2003 hasta noviembre de 2012, los modelos estructurales de consumo se estimaron con esa muestra, excepto para aquellos modelos en los cuales existiera otra variable que pudiese limitar la muestra de estimación de un modelo en particular o que económicamente tuviese que restringirse en modelo en particular. Respecto a esto último, el modelo estructural de consumo de GLP posee una muestra de estimación más pequeña dada la disponibilidad de datos de consumo de este combustible.

Modelo Estructural	Muestra de Estimación		Frecuencia	Unidad
Consumo de Gasolina Automotriz con precios País	01-2006	11-2012	M	m ³
Consumo de Diesel Vehicular con precios País	01-2003	11-2012	M	m ³
Consumo de Gas Licuado de Petróleo	01-2011	11-2012	M	m ³
Consumo de Gas Natural Comprimido	01-2003	11-2012	M	Mm ³

Tabla 3. Muestras de estimación de modelos estructurales.

Notas: M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

3.3.3 Ajustes Preliminares de las Series

3.3.3.1 Transformación de los Datos

Los datos se transformaron en forma logarítmica, tanto de la variable independiente como de las variables exógenas o independientes. La justificación de dicha transformación radica en que se obtiene un mejor ajuste en las funciones de demanda o consumo, se minimizan los problemas de autocorrelación de los residuos y permite interpretar los parámetros estimados como elasticidad precio e ingreso de corto y largo plazo.

3.3.3.2 Identificación de Valores Atípicos (Outliers)

Se utilizaron los valores atípicos aditivos de las series de consumo de combustibles detectados por el software X12-ARIMA, que selecciona los valores atípicos en forma automática. Se utilizaron los siguientes tipos de outlier:

i) AO: outlier aditivo en t_0 : $aodate_0$ (additive outlier)

Los AOs afectan solamente una observación en la serie de tiempo de la siguiente forma:

$$AO_t^{(t_0)} = \begin{cases} 1 & \text{para } t = t_0 \\ 0 & \text{para } t \neq t_0 \end{cases} \quad (\text{date}_0 \text{ es la fecha correspondiente al punto de tiempo } t_0) \quad (42)$$

En otras palabras corresponde a una variable dicótoma o dummy para puntos específicos atípicos.

3.3.4 Verificación de Cointegración²⁵

Se verificó la existencia de cointegración entre el consumo de combustible y las variables explicatorias o exógenas como el precio e IMACEC, puesto que se desea evitar la estimación de una regresión espuria e inferir erróneamente sobre los parámetros estimados y sus respectivos test de significancia, obteniéndose resultados por ende que no son adecuados para realizar pronósticos. Para ello, se estimaron regresiones de cointegración mediante el método de estimación de Fully Modified OLS (FMOLS), solamente para desarrollar posteriormente el test de cointegración de Engel y Granger (1987).

3.3.4.1 Método de estimación FMOLS

Phillips y Hansen (1990) presentaron un estimador que emplea una corrección semiparamétrica para eliminar los problemas causados por la correlación de largo plazo entre la ecuación de cointegración y las innovaciones de los regresores estocásticos. El estimador resultante FMOLS es asintóticamente insesgado y posee una mezcla eficiente asintóticamente normal que permite los test de Wald usando inferencia estadística asintótica Chi-cuadrado.

3.3.4.2 Test de Cointegración de Engel-Granger

El test de Engel-Granger es un test de cointegración basado en los residuales resultantes de la estimación de la regresión y es simplemente un test de raíz unitaria obtenido desde la ecuación de estimación de SOLS (Static Ordinary Least Squares):

²⁵ Sección basada en EViews 7 User's Guide II (2010).

$$y_t = X_t' \beta + D_{1t}' \gamma_1 + u_{1t} \quad (43)$$

Donde:

(y_t, X_t') : vector de procesos de series de tiempo de $n+1$ dimensiones
 $D_t = (D_{1t}', D_{2t}')'$ son regresores de tendencia determinísticos y los n regresores estocásticos X_t son gobernados por el sistema de ecuaciones:

$$X_t = \Gamma_{21}' D_{1t} + \Gamma_{21}' D_{2t} + \epsilon_{2t} \quad (44)$$

$$\Delta \epsilon_{2t} = u_{2t} \quad (45)$$

Bajo el supuesto de que las series *no están cointegradas*, todas las combinaciones lineales de (y_t, X_t') , incluyendo los residuales desde SOLS, son raíces unitarias no estacionarias. Por lo tanto, un test de hipótesis nula de no cointegración frente a la alternativa de cointegración corresponde al test de raíz unitaria de la hipótesis nula de no estacionariedad frente a la alternativa de estacionariedad.

Engel y Granger utilizan un test paramétrico para cuantificar la correlación serial en la serie de residuales, esto es, utilizan la aproximación de Dickey-Fuller Aumentada (ADF).

El test Engle-Granger estima una regresión aumentada de p -rezagos de la forma:

$$\Delta \hat{u}_{1t} = (\rho - 1) \hat{u}_{1t-1} + \sum_{j=1}^p \delta_j \Delta \hat{u}_{1t-j} + v_t \quad (46)$$

Se consideran los dos test estadísticos ADF estándar, uno basado en el estadístico- t para testear la hipótesis nula de no estacionariedad ($\rho = 1$) y el otro basado directamente en el coeficiente de autocorrelación normalizado $\hat{\rho} = 1$:

$$\hat{t} = \frac{\hat{\rho} - 1}{se(\hat{\rho})} \quad (47)$$

$$\hat{z} = \frac{T(\hat{\rho} - 1)}{(1 - \sum_j \hat{\delta}_j)} \quad (48)$$

Donde:

$se(\hat{\rho})$: es el estimador OLS usual del error estándar del estimado $\hat{\rho}$

$$se(\hat{\rho}) = \hat{s}_v \left(\sum_t \hat{u}_{1t-1}^2 \right)^{-1/2} \quad (49)$$

3.3.5 Tests de Especificación y Diagnóstico de Modelos Estructurales

3.3.5.1 Significancia de Parámetros y Bondad de Ajuste

- La selección de los modelos se realizó de acuerdo a la significancia de los parámetros ($p < 0.05$) y coeficiente de determinación ajustado (R^2 ajustado).

3.3.5.2 Autocorrelación

Un rasgo común en las regresiones de series de tiempo es que los residuos están correlacionados con sus propios valores rezagados. Esta correlación serial viola el supuesto estándar de la teoría de regresión de que las perturbaciones no están correlacionadas con otras perturbaciones. Los problemas primarios con la correlación serial son:

- Los estimadores MCO (mínimos cuadrados ordinarios) no son los más eficientes entre los estimadores lineales.
- Los errores estándar de los estimadores calculados usando MCO no son los correctos, y generalmente son subestimados.
- Si existen variables dependientes rezagadas en el lado derecho de la ecuación, los estimadores MCO son sesgados e inconsistentes.

3.3.5.3 Detección de Autocorrelación

La autocorrelación se detectó en primera instancia con el estadígrafo Durbin-Watson, y se verificó en segunda instancia con el Correlograma de Residuos.

En el caso de modelos con variables dependientes rezagadas en el lado derecho de la ecuación se aplicó la Prueba de Autocorrelación Breush-Godfrey (LM Test). Este test es alternativo al estadístico Q (Correlograma de residuos) para prueba de correlación serial.

El LM Test pertenece a la clase de tests asintóticos (muestras grandes) conocidos como Tests de Multiplicadores de Lagrange (Eviews, 2010). Al contrario del estadígrafo Durbin-Watson para errores AR(1) (autorregresivos de primer orden), el LM Test puede ser usado para testear órdenes más altas de autocorrelación y es aplicable si existen o no variables dependientes rezagadas.

La hipótesis nula del LM Test es que no existe correlación serial hasta el rezago de orden p , donde p es un entero pre-especificado. Además en los resultados de dicho test se observa una regresión de los residuales sobre los regresores originales X y los residuales rezagados hasta el orden p . Eviews reporta dos test estadísticos desde esta prueba de regresión. El estadístico F es un test de variable omitida para la significancia global de todos los residuos rezagados. El estadígrafo Breush-Godfrey LM Test es $Obs \cdot R\text{-squared}$, el cual es calculado como el número de observaciones por el R^2 desde el test de regresión. Bajo las condiciones generales totales, el estadístico LM Test está asintóticamente distribuido como un $\chi^2(p)$.

3.3.5.4 Corrección por Autocorrelación.

Se eliminó la autocorrelación mediante técnicas que estiman, en primer lugar, el coeficiente de autocorrelación de primer orden de los residuos (ρ) y luego estiman la ecuación definitiva mediante una regresión lineal con variables transformadas: la variable X^* es igual a $X(t) - \rho * X(t-1)$, donde X es la variable del modelo original.

En el modelo de dos variables independientes, además del rezago de la variable dependiente, se realizó la siguiente corrección por autocorrelación:

$$\ln(Y_t) = \alpha_0 + \beta_0 \ln(X_{1t}) + \gamma_0 \ln(X_{2t}) + \delta_0 \ln(Y_{t-1}) + \mu_t \quad (50)$$

$$\mu_t = \rho \mu_{t-1} + \varepsilon_t \quad (51)$$

realizando una diferenciación generalizada y sustituyendo queda:

$$\begin{aligned} \ln(Y_t) = & \alpha_0(1-\rho) + \rho \ln Y_{t-1} + \beta_0(\ln X_{1t} - \rho \ln X_{1t-1}) + \\ & \gamma_0(\ln X_{2t} - \rho \ln X_{2t-1}) + \delta_0(\ln Y_{t-1} - \rho \ln Y_{t-2}) + v_t \end{aligned} \quad (52)$$

Cabe destacar que el valor AR(1) que arroja Eviews en el resultado de la regresión corresponde a ρ .

3.3.6 Estimación de Modelos Estructurales

Una vez verificada la existencia de cointegración en cada uno de los modelos estructurales de consumo se procedió a estimarlos mediante mínimos cuadrados ordinarios (OLS), puesto que es bien conocido que si las series que participan en la regresión están cointegradas, la estimación de OLS del vector de cointegración β es consistente y converge a una tasa más rápida que la estándar (Hamilton, 1994).

3.4 Pronósticos

3.4.1 Tipos de Pronósticos

Es de suma utilidad distinguir entre el pronóstico ex post y el ex ante. En un pronóstico ex post, las observaciones en las variables endógenas y en las variables explicativas o independientes exógenas ya se conocen con certeza en el periodo pronosticado. De este modo, los pronósticos ex post pueden verificarse contra los datos históricos existentes y proporcionan un medio para evaluar un modelo de pronóstico.

Un pronóstico ex ante también predice valores de la variable dependiente fuera del periodo de estimación original (muestra de estimación), pero usa variables explicativas, que pueden conocerse o no conocerse aún con certeza. La distinción entre el pronóstico ex post y ex ante puede apreciarse en la siguiente figura.




Figura 1. Tipos de pronósticos.

3.4.2 Límites de Confianza de Pronósticos Ex Ante

Se estimaron límites o bandas de confianza al 95% en función del error estándar del pronóstico (fse, por sus siglas en inglés), los cuales fueron calculados como:

$$\text{Límite Superior} = \hat{y}_t + 2 * fse \quad (35)$$

$$\text{Límite Inferior} = \hat{y}_t - 2 * fse \quad (36)$$

Si hipotéticamente se realizan muchos pronósticos, el valor actual de la variable dependiente caerá dentro de estas bandas el 95% de las veces.

3.4.3 Medidas de Evaluación de Pronósticos Ex Post

Para seleccionar modelos competitivos en su especificación se utilizaron las medidas de evaluación de pronósticos que se detallan más adelante.

Suponga que la muestra de pronóstico es $t = T+1, \dots, T+k$ y que, en el tiempo t , los valores reales y ajustados de la variable dependiente son, respectivamente, S_t y $\hat{S}_t$. Las medidas de evaluación de pronóstico se pueden definir como:

a) Root Mean Square Error (Raíz del Error Cuadrático Medio):

$$RMSE = \sqrt{\frac{\sum_{t=T+1}^{T+k} (\hat{S}_t - S_t)^2}{k}} \quad (37)$$

b) Mean Absolute Error (Error Absoluto Medio):

$$MAE = \frac{\sum_{t=T+1}^{T+k} |\hat{S}_t - S_t|}{k} \quad (38)$$

c) Mean Absolute Percentage Error (Error Porcentual Absoluto Medio):

$$MAPE = 100 \frac{\sum_{t=T+1}^{T+k} \left(\frac{|\hat{S}_t - S_t|}{S_t} \right)}{k} \quad (39)$$

d) Theil Inequality Coefficient (Coeficiente de Desigualdad de Theil):

$$Theil = \frac{\sqrt{\frac{\sum_{t=T+1}^{T+k} (\hat{S}_t - S_t)^2}{k}}}{\sqrt{\frac{\sum_{t=T+1}^{T+k} \hat{S}_t^2}{k}} + \sqrt{\frac{\sum_{t=T+1}^{T+k} S_t^2}{k}}} \quad (40)$$

Mientras RMSE y MAE son dependientes de la escala de la variable dependiente y deben ser utilizados como medidas relativas para comparar pronósticos para las mismas series a través de diferentes modelos. Mientras más pequeño es el error, mejor es la capacidad de pronóstico de ese modelo de acuerdo a ese criterio. MAPE y Theil son a escala invariante. Además, Theil va entre el rango de 0 a 1, con cero indicando ajuste perfecto.

La evaluación de los pronósticos ex post se dividió en evaluación de corto plazo y evaluación de largo plazo, aplicando las medidas de evaluación para 2 y 18 meses respectivamente, con el objetivo de seleccionar modelos competitivos entre los modelos ARIMA y los modelos estructurales que tengan un mejor desempeño de pronósticos en forma diferenciada para ambos periodos de tiempo.

3.4.4 Pronósticos Ex ante Modelos ARIMA

Con los modelos ARIMA estimados se realizaron pronósticos ex ante (fuera de muestra) mensuales y semanales para los modelos de consumo de gasolina, diesel, GLP y GNC y sólo mensual para el resto de las series de precios e IMACEC, con una muestra de pronóstico para todos los modelos de 24 meses, esto es, desde diciembre de 2012 hasta noviembre del 2014²⁶.

Variable	Muestra Pronóstico (*)		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	12-2012	11-2014	M, S	m ³	CGAS
Consumo Nacional de Diesel Vehicular	12-2012	11-2014	M, S	m ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	12-2012	11-2014	M, S	Mm ³	CGNC
Consumo Nacional de Gas Licuado de Petróleo	12-2012	11-2014	M, S	m ³	CGLP
Precio de Gasolina Automotriz 95 octanos PAÍS	12-2012	11-2014	M	\$/litro	PGASPAIS
Precio de Diesel Vehicular PAÍS	12-2012	11-2014	M	\$/litro	PDIESELPAIS
Índice Mensual de Actividad Económica IMACEC	12-2012	11-2014	M	-	IMACEC

Tabla 4. Lista de variables pronosticadas y muestras de pronóstico ex ante.

Notas: S = frecuencia semanal; M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

(*) Muestra de pronóstico ex ante.

3.4.5 Pronósticos Ex ante Modelos Estructurales

Con los modelos estructurales estimados se realizaron pronósticos ex ante mensuales y semanales para los modelos de consumo de gasolina, diesel, GLP y GNC, con una muestra de pronóstico para todos los modelos de 24 meses, esto es, desde diciembre de 2012 hasta noviembre del 2014²⁷.

Modelo Estructural	Muestra Pronóstico (*)		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	12-2012	11-2014	M, S	m ³	CGAS
Consumo Nacional de Diesel Vehicular	12-2012	11-2014	M, S	m ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	12-2012	11-2014	M, S	Mm ³	CGNC
Consumo Nacional de Gas Licuado de Petróleo	12-2012	11-2014	M, S	m ³	CGLP

Tabla 5. Lista de modelos estructurales y muestras de pronóstico ex ante.

Notas: S = frecuencia semanal; M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

(*) Muestra de pronóstico ex ante.

²⁶ Esta muestra queda fija en cuanto al número de meses, sin embargo cada vez que se adicione un dato mensual a la BDModelos.xls el programa MODELOS desarrollado en Eviews modificará la fecha de la primera observación a pronosticar.

²⁷ Idem anterior.

3.4.6 Pronósticos Ex ante Modelos ARIMA CNE

Con los modelos ARIMA estimados de la CNE se realizaron pronósticos ex ante (fuera de muestra) mensuales y semanales para los modelos de consumo de gasolina y diesel para muestra de pronóstico de 24 meses, esto es, desde diciembre de 2012 hasta noviembre del 2014²⁸.

Variable	Muestra Pronóstico (*)		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	12-2012	11-2014	M, S	m ³	CGAS
Consumo Nacional de Diesel Vehicular	12-2012	11-2014	M, S	m ³	CDIESEL

Tabla 6. Lista de variables pronosticadas y muestras de pronóstico ex ante.

Notas: S = frecuencia semanal; M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

(*) Muestra de pronóstico ex ante.

3.4.7 Evaluación de Pronósticos Ex Post Modelos ARIMA

Para realizar la evaluación de pronósticos ex post de los diferentes modelos ARIMA, estos se reestimaron con las muestras de estimación respectivas de cada una de las series de tiempo restándoles los últimos 18 meses de dicho periodo, tal como se aprecia en la siguiente tabla.

Variable	Muestra de Estimación		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	01-2006	05-2011	M	m ³	CGAS
Consumo Nacional de Diesel Vehicular	01-2005	05-2011	M	m ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	01-2002	05-2011	M	Mm ³	CGNC
Consumo Nacional de Gas Licuado de Petróleo	01-2011	05-2011	M	m ³	CGLP

Tabla 7. Muestras de estimación de modelos ARIMA de variables para pronósticos ex post.

Notas: S = frecuencia semanal; M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

Con los modelos ARIMA reestimados se procedió a evaluar los pronósticos ex post. La evaluación de pronósticos se realizó para una muestra de pronósticos (ex post) de 18 meses desde junio de 2011 a noviembre de 2012, elección basada en la longitud del periodo establecido para la operación de los contratos de seguros en el SEPCO²⁹.

Variable	Muestra Pronóstico (*)		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	06-2011	11-2012	M	m ³	CGAS
Consumo Nacional de Diesel Vehicular	06-2011	11-2012	M	m ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	06-2011	11-2012	M	Mm ³	CGNC
Consumo Nacional de Gas Licuado de Petróleo	06-2011	11-2012	M	m ³	CGLP

Tabla 8. Lista de variables pronosticadas y muestras de pronóstico ex post.

²⁸ Esta muestra queda fija en cuanto al número de meses, sin embargo cada vez que se adicione un dato mensual a la BDModelos.xls el programa MODELOS desarrollado en Eviews modificará la fecha de la primera observación a pronosticar.

²⁹ Estipulada en el Título III de la Ley N° 20.493, la cual señala textualmente: "En cada uno de estos contratos, la diferencia máxima entre la fecha de contratación y la última fecha de ejercicio será de dieciocho meses. Del mismo modo, en cada contrato la diferencia mínima entre la fecha de contratación y la primera fecha de ejercicio será de dos meses".

Notas: M = frecuencia mensual; Mm³ = Miles de metros cúbicos.
(*) Muestra de pronóstico ex post.

3.4.8 Evaluación de Pronósticos Ex Post Modelos Estructurales

Para realizar la evaluación de pronósticos ex post de los diferentes modelos estructurales, estos se reestimaron con las muestras de estimación respectivas de cada una de las series de tiempo restándoles los últimos 18 meses de dicho periodo, tal como se aprecia en la siguiente tabla.

Modelo Estructural	Muestra de Estimación		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	01-2006	05-2011	M	m ³	CGAS
Consumo Nacional de Diesel Vehicular	01-2003	05-2011	M	m ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	01-2003	05-2011	M	Mm ³	CGNC
Consumo Nacional de Gas Licuado de Petróleo	01-2011	05-2011	M	m ³	CGLP

Tabla 9. Muestras de estimación de modelos estructurales para pronósticos ex post.

Notas: S = frecuencia semanal; M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

Con los modelos estructurales reestimados se procedió a evaluar los pronósticos ex post. La evaluación de pronósticos se realizó para una muestra de pronósticos (ex post) de 18 meses desde junio de 2011 a noviembre de 2012.

Modelo Estructural	Muestra Pronóstico (*)		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	06-2011	11-2012	M	m ³	CGAS
Consumo Nacional de Diesel Vehicular	06-2011	11-2012	M	m ³	CDIESEL
Consumo Nacional de Gas Natural Comprimido	06-2011	11-2012	M	Mm ³	CGNC
Consumo Nacional de Gas Licuado de Petróleo	06-2011	11-2012	M	m ³	CGLP

Tabla 10. Lista de variables pronosticadas y muestras de pronóstico ex post.

Notas: M = frecuencia mensual; Mm³ = Miles de metros cúbicos.
(*) Muestra de pronóstico ex post.

3.4.9 Evaluación de Pronósticos Ex Post Modelos ARIMA CNE

Para realizar la evaluación de pronósticos ex post de los diferentes modelos ARIMA que utiliza actualmente la CNE, estos se reestimaron con las muestras de estimación respectivas de cada una de las series de tiempo restándoles los últimos 18 meses de dicho periodo, tal como se aprecia en la siguiente tabla.

Variable	Muestra de Estimación		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	01-1988	05-2011	M	m ³	CGAS
Consumo Nacional de Diesel Vehicular	01-1998	05-2011	M	m ³	CDIESEL

Tabla 11. Muestras de estimación de modelos ARIMA CNE para pronósticos ex post.

Notas: S = frecuencia semanal; M = frecuencia mensual.

Con los modelos ARIMA reestimados se procedió a evaluar los pronósticos ex post. La evaluación de pronósticos se realizó para una muestra de pronósticos (ex post) de 18 meses desde junio de 2011 a noviembre de 2012, elección basada en la longitud del periodo establecido para la operación de los contratos de seguros en el SEPCO³⁰.

Variable	Muestra Pronóstico (*)		Frecuencia	Unidad	Acrónimo
Consumo Nacional de Gasolina Automotriz	06-2011	11-2012	M	m ³	CGAS
Consumo Nacional de Diesel Vehicular	06-2011	11-2012	M	m ³	CDIESEL

Tabla 12. Lista de variables pronosticadas y muestras de pronóstico ex post.

Notas: M = frecuencia mensual; Mm³ = Miles de metros cúbicos.

(*) Muestra de pronóstico ex post.

3.5 Metodología Complementaria

3.5.1 Definición de Metodología Complementaria

Se cuantificó el efecto semanal en el consumo de gasolina y diesel que tienen los “fines de semana largos”, con miras a corregir la proporcionalidad que se asume al pasar de pronósticos mensuales estimados a pronósticos semanales calculados.

La hipótesis plausible o válida detrás de esta metodología corresponde a la variación en el consumo de gasolina y diésel en forma diferenciada, debido al comportamiento que tienen los conductores de los vehículos que utilizan dichos combustibles ante la presencia de un fin de semana largo. Esto se fundamenta en forma intuitiva principalmente en la decisión de los conductores de aprovechar estos feriados largos para salir de la ciudad hacia destinos turísticos cercanos. Un ejemplo de aquello es la masiva salida de Santiago de vehículos en feriados emblemáticos como Semana Santa, Fiestas Patrias, Día de Todos los Santos, entre otros.

Se consideró como fin de semana los días sábado y domingo. Asimismo, se consideró como fines de semana largos aquellos en los cuales existía un feriado los días viernes, lunes o en algunos casos, más de un día feriado adyacente al fin de semana, como por ejemplo jueves y viernes o lunes y martes.

Se definió la variable Fin de Semana Largo (FDSLARGO) de la siguiente forma:

$$FDSLARGO_t^{(t_0)} = \begin{cases} 1 & \text{para } t = t_0 \\ 0 & \text{para } t \neq t_0 \end{cases} \quad (53)$$

Donde:

t_0 : es el mes (semana) donde se presenta un fin de semana largo.

³⁰ Estipulada en el Título III de la Ley N° 20.493, la cual señala textualmente: “En cada uno de estos contratos, la diferencia máxima entre la fecha de contratación y la última fecha de ejercicio será de dieciocho meses. Del mismo modo, en cada contrato la diferencia mínima entre la fecha de contratación y la primera fecha de ejercicio será de dos meses”.

t : es el mes o semana dependiendo de la frecuencia de la variable.

En otras palabras FDSLARGO corresponde a una variable dicotóma o dummy que toma los valores de 1 si existe presencia de fin de semana largo y 0 si no existe.

Se cuantificó el efecto de los fines de semana largo en la variación de consumo mensual de los combustibles gasolina automotriz y diésel vehicular mediante dos metodologías; una indirecta y otra directa, con el objetivo de contrastar las hipótesis de significancia estadística del efecto de la variable FDSLARGO en la variación de consumo mensual y su comparación entre ambas metodologías, puesto que no existen datos semanales de consumo con los cuales se puedan verificar dichas hipótesis.

La metodología indirecta se utilizó sólo para validar los signos de los coeficientes estimados que acompañan a la variable FDSLARGO en su inclusión en los modelos estructurales que conforman la metodología directa.

Cabe destacar, que la metodología directa es la que realmente se utiliza para cuantificar el efecto de los fines de semana largos en la variación de los consumos de combustibles gasolina y diésel.

3.5.2 Metodología Complementaria Indirecta

Se consideró la variable Vehículos a Gasolina Controlados en Plazas de Peaje PEAJEGAS³¹ y Vehículos a Diesel Controlados en Plazas de Peaje PEAJEDIESEL³² como variables proxy³³ del efecto de los fines de semana largos en la variación de consumo mensual de gasolina y diésel, respectivamente. Cada una de las dos variables se detendencializó y se desestacionalizó, incorporando adicionalmente la variable FDSLARGO como variable explicativa.

Se estimaron los siguientes modelos:

$$PEAJEGAS_t = \alpha_0 + \alpha_1 t + \sum_{i=2}^{12} \alpha_i D_i + \beta_0 FDSLARGO_t + \varepsilon_t$$

$$PEAJEDIESEL_t = \alpha_0 + \alpha_1 t + \sum_{i=2}^{12} \alpha_i D_i + \beta_0 FDSLARGO_t + \varepsilon_t$$

Donde:

$PEAJEGAS_t$: Vehículos a Gasolina Controlados en Plazas de Peaje en el mes t

³¹ Definida en sección 3.1.1.7.

³² Definida en sección 3.1.1.7.

³³ Variables representativas observables de variables no observables.

$PEAJEDIESEL_t$: Vehículos a Diesel Controlados en Plazas de Peaje en el mes t

$FDSLARGO_t$: Fin de Semana Largo en el mes t

D_i , $i = 2, \dots, 12$: son 11 variables estacionales mensuales

$\alpha_0, \beta_0, \alpha_1, \alpha_i$, $i=2, \dots, 12$ son coeficientes estimados desde la detendencialización y desestacionalización.

ε_t : Error aleatorio o estocástico.

3.5.3 Metodología Complementaria Directa

Se ajustaron los modelos estructurales incorporando la variable $FDSLARGO$ de la siguiente forma:

Para la gasolina:

$$\log(CGAS_t) = \alpha_0 + \beta_0 \log(PGASPAIS_t) + \gamma_0 \log(IMACEC_t) + \delta_0 \log(CGAS_{t-1}) + \sum_{i=2}^{12} \omega_i D_i + \lambda_i AO_i + \theta_0 FDSLARGO_t + \varepsilon_t$$

Para el diesel:

$$\log(CDIESEL_t) = \alpha_0 + \beta_0 \log(PDIESELPAIS_t) + \gamma_0 \log(IMACEC_t) + \delta_0 \log(CDIESEL_{t-1}) + \sum_{i=2}^{12} \omega_i D_i + \lambda_i AO_i + \phi_0 FDSLARGO_t + \varepsilon_t$$

Donde:

$CGAS_t$: Consumo de gasolina automotriz en m^3 en el mes t

$CDIESEL_t$: Consumo de diesel vehicular en m^3 en el mes t

$PGASPAIS_t$: Precio de la gasolina promedio país en \$/litro en el mes t

$PDIESELPAIS_t$: Precio del diesel promedio país en \$/litro en el mes t

$FDSLARGO_t$: Fin de Semana Largo en el mes t

D_i , $i = 2, \dots, 12$: 11 variables estacionales mensuales

$\alpha_0, \beta_0, \gamma_0, \delta_0, \omega_i, \lambda_i, \theta_0, \phi_0$: Parámetros a estimar

AO_i : outliers aditivos

ε_t : Error aleatorio o estocástico.

$\log$: Operador de logaritmo natural

3.5.4 Verificación y Aplicación de Metodología Complementaria

Una vez estimados los modelos de las metodologías indirectas y directas se verificó la significancia y el signo de los parámetros asociados a la variable FDSLARGO y se compararon los resultados de ambas metodologías.

Se seleccionaron los parámetros asociados a la variable FDSLARGO de los modelos de gasolina y diesel de la metodología directa, esto es, los parámetros θ_0 y ϕ_0 para gasolina y diesel, respectivamente y se transformaron para cuantificar el porcentaje de cambio en el consumo de cada combustible ante la presencia de un fin de semana largo de la siguiente forma:

$$FDSGAS = (e^{\theta_0} - 1) * 100$$

$$FSDIESEL = (e^{\phi_0} - 1) * 100$$

Donde:

FDSGAS: es el porcentaje de cambio en el consumo de gasolina en m³ ante el cambio de FDSLARGO de 0 a 1.

FSDIESEL: es el porcentaje de cambio en el consumo de diesel en m³ ante el cambio de FDSLARGO de 0 a 1.

La anterior transformación se debe realizar puesto que el modelo estimado es un modelo logarítmico que incorpora variables dummy o dicótomas (Gujarati, 1997).

Una vez calculadas las variaciones porcentuales del consumo en ambos combustibles en forma mensual, se aplicaron estos factores a los pronósticos semanales de ambos consumos para todos los modelos estimados de estos consumos, ARIMA y estructurales de la siguiente forma:

$$CGAS_t^{(t_0)} = \begin{cases} CGAS_t * (1 + FDSGAS) & \text{para } t = t_0 \\ CGAS_t & \text{para } t \neq t_0 \end{cases}$$

Donde:

t_0 : es la semana donde se presenta un fin de semana largo³⁴.

t : semanas.

$CGAS_t$: Consumo de gasolina en m³ de la semana t .

Análogamente para el consumo de diesel se tiene:

³⁴ Las semanas comienzan el día jueves y terminan el miércoles siguiente, tal como actualmente son consideradas por la CNE para realizar sus proyecciones semanales de consumo de combustibles en sus Informes SIPCO.

$$CDIESEL_t^{(t_0)} = \begin{cases} CDIESEL_t * (1 + FDS DIESEL) & \text{para } t = t_0 \\ CDIESEL_t & \text{para } t \neq t_0 \end{cases}$$

Donde:

t_0 : es la semana donde se presenta un fin de semana largo.

t : semanas.

$CDIESEL_t$: Consumo de diesel en m³ de la semana t .

3.5.5 Empalme entre meses de pronósticos semanales

Los pronósticos semanales de consumo de los diferentes combustibles se realizaron considerando las semanas cuyo comienzo es el día jueves y terminan el miércoles siguiente, tal como actualmente son consideradas por la CNE para realizar sus proyecciones semanales de consumo de combustibles en sus Informes SIPCO.

Adicionalmente, el empalme del consumo de combustible de la última semana de cada mes con la primera semana del mes siguiente se realizó de acuerdo a la siguiente forma³⁵:

$$C_{t \text{ diario}} = C_t / lom_t$$

Donde:

$C_{t \text{ diario}}$: Consumo diario del mes t

lom_t : número de días del mes t

Finalmente se calcula el consumo semanal de la siguiente forma:

$$C_t^{(t_0)} = \begin{cases} C_{t \text{ diario}} * n_t + C_{t+1 \text{ diario}} * (7 - n_t) & \text{para } t = t_0 \\ C_{t \text{ diario}} * 7 & \text{para } t \neq t_0 \end{cases}$$

Donde:

t_0 : es la última semana del mes.

t : semanas.

C_t : Consumo de combustible de la semana t .

$C_{t \text{ diario}}$: Consumo diario del mes t

$C_{t+1 \text{ diario}}$: Consumo diario del mes $t+1$

n_t : Número de días de la última semana del mes t ³⁶.

³⁵ Forma que actualmente es utilizada por la CNE para realizar sus proyecciones semanales de consumo de combustibles en sus Informes SIPCO.

4 CAPÍTULO 3: RESULTADOS

4.1 Análisis Descriptivo de Series de Tiempo

4.1.1 Consumo Nacional de Gasolina Automotriz

Como se observa en la figura el consumo nacional de gasolina posee una marcada estacionalidad con máximos estacionales principalmente en diciembre y enero y mínimos estacionales principalmente en los meses de junio de cada año. La serie desestacionalizada por el programa X-12 ARIMA elimina dichas oscilaciones anuales. Se puede visualizar además algunos outliers o puntos atípicos en 10-2009 y 08-2012.




Figura 2. Consumo Nacional de Gasolina Automotriz.




Figura 3. Histograma de Consumo Nacional de Gasolina Automotriz.

La figura 3 muestra la distribución del consumo de gasolina automotriz para el periodo comprendido entre los meses Enero-1988 hasta Nov-2012. La distribución presenta

³⁶ Generalmente corresponde a una semana incompleta donde el número de días (n_t) es menor que 7, aunque se puede dar el caso que sea justo una semana de 7 días, en cuyo caso la segunda expresión de la ecuación se hace 0, para $t = t_0$.

una pequeña asimetría hacia la izquierda respecto de la media (Skewness=-0.47<0). Su indicador de forma (Kurtosis) muestra que esta distribución está cercana a la normal definiéndose como una distribución platycúrtica (Kurtosis<3), y el test de normalidad de Jarque-Bera indica que se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.0008<0.05$. H_0 : datos provienen de distribución normal).

4.1.2 Consumo Nacional de Diesel Vehicular

Como se observa en la figura el consumo nacional de diesel vehicular posee una marcada estacionalidad con máximos estacionales principalmente en febrero y marzo y mínimos estacionales principalmente en los meses de junio de cada año. Se puede visualizar además algunos outliers o puntos atípicos en 08-2006, 10-2009, 11-2009 y 08-2012.




Figura 4. Consumo Nacional de Diesel Vehicular.




Figura 5. Histograma de Consumo Nacional de Diesel Vehicular.

La figura 5 muestra la distribución del consumo de diesel vehicular para el periodo comprendido entre los meses Enero-1998 hasta Nov-2012. La distribución presenta una pequeña asimetría hacia la derecha respecto de la media ($\text{Skewness}=0.27>0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más achatada que normal definiéndose como una distribución platycúrtica ($\text{Kurtosis}<3$), y el test de normalidad de Jarque-Bera indica que se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.009<0.05$. H_0 : datos provienen de distribución normal).

4.1.3 Consumo Nacional de GLP Vehicular

Se puede apreciar una tendencia de crecimiento fuerte en los últimos dos años, sin embargo en los últimos meses de 2012 dicho incremento se estabiliza en torno a los 5.500 m^3 .




Figura 6. Consumo Nacional de GLP Vehicular.




Figura 7. Histograma de Consumo Nacional de GLP Vehicular.

La figura 7 muestra la distribución del consumo de GLP vehicular para el periodo comprendido entre los meses Enero-2011 hasta Nov-2012. La distribución presenta una pequeña asimetría hacia la derecha respecto de la media ($\text{Skewness}=0.24>0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más achatada que normal definiéndose como una distribución platycúrtica ($\text{Kurtosis}<3$), y el test de

normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.43>0.05$. Ho: datos provienen de distribución normal).

4.1.4 Consumo Nacional de GNC Vehicular

Es relevante destacar un posible quiebre estructural en el consumo de GNC Vehicular, ya que la demanda disminuyó desde 2726 Mm3 en mayo de 2007 a 890 Mm3 en julio de ese mismo año para luego retomar su crecimiento, tal como se visualiza en la figura 8.




Figura 8. Consumo Nacional de GNC Vehicular.




Figura 9. Histograma de Consumo Nacional de GNC Vehicular.

La figura 9 muestra la distribución del consumo de GNC vehicular para el periodo comprendido entre los meses Enero-2001 hasta Nov-2012. La distribución presenta una pequeña asimetría hacia la izquierda respecto de la media (Skewness=-0.12<0). Su indicador de forma (Kurtosis) muestra que esta distribución es más achatada que la normal definiéndose como una distribución platocúrtica (Kurtosis<3), y el test de

normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.21>0.05$. Ho: datos provienen de distribución normal).

4.1.5 Precios de Gasolina Automotriz

Es importante destacar el posible quiebre estructural en el precio de la gasolina automotriz, ya que estos disminuyeron desde 754 (\$/lt) en octubre de 2008 a 463 (\$/lt) en enero de 2009 (País), producto de la baja de los precios del petróleo debido a la crisis subprime estadounidense que desembocó en la crisis económica mundial del año 2008, tal como se visualiza en la figura 10.




Figura 10. Precios de gasolina automotriz.




Figura 11. Histogramas de precios de gasolina automotriz.

La figura 11 muestra las distribuciones de precios de gasolina automotriz para el periodo comprendido entre los meses Enero-2003 hasta Nov-2012. Las distribuciones presentan una pequeña asimetría hacia la derecha respecto de la media (Skewness>0). Su indicador de forma (Kurtosis) muestra que estas distribuciones son más achatadas que la normal definiéndose como distribuciones platocúrticas (Kurtosis<3), y el test de normalidad de Jarque-Bera indica en ambas distribuciones que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p>0.05$. Ho: datos provienen de distribución normal).

4.1.6 Precios de Diesel Vehicular

Al igual que los precios de las gasolinas cabe señalar el posible quiebre estructural en el precio del diesel, ya que estos disminuyeron desde alrededor de los 700 (\$/lt) en noviembre de 2008 a alrededor de 400 (\$/lt) en abril de 2009, por las razones antes mencionadas.




Figura 12. Precios de diesel vehicular.

La figura 13 muestra las distribuciones de precios de diesel vehicular para el periodo comprendido entre los meses Enero-2003 hasta Nov-2012. Las distribuciones presentan una pequeña asimetría hacia la derecha respecto de la media (Skewness>0). Su indicador de forma (Kurtosis) muestra que estas distribuciones son más achatadas que la normal definiéndose como distribuciones platicúrticas (Kurtosis<3), y el test de normalidad de Jarque-Bera indica en ambas distribuciones que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p > 0.05$. Ho: datos provienen de distribución normal).




Figura 13. Histograma de precios de diesel vehicular.

4.1.7 Precios de GLP Vehicular

El precio de GLP vehicular posee un comportamiento muy variable de un mes a otro, presentando mínimos en enero y marzo de 2012, con 421 y 408 (\$/lt), respectivamente. Existen muy pocas observaciones (23) para tener un conocimiento más acabado de su distribución y variabilidad.




Figura 14. Precios e histograma de GLP Vehicular.

4.1.8 Precios de GNC Vehicular




Figura 15. Precios de GNC vehicular.

Los precios de GNC vehicular RM tiene una alta variabilidad y no se reconoce ningún patrón preestablecido. Por otro lado, el precio del GNC de la XII Región presenta poca variabilidad, manteniéndose prácticamente constante durante periodos prolongados.




Figura 16. Histograma de precios de GNC vehicular.

4.1.9 Índice Mensual de Actividad Económica IMACEC

Como era de esperar el IMACEC tiene una alta componente estacional con máximos bastante marcados tanto en diciembre como en marzo de cada año y un mínimo característico en febrero de cada año.




Figura 17. Índice Mensual de Actividad Económica, IMACEC.




Figura 18. Histograma de IMACEC.

La figura 18 muestra la distribución del IMACEC para el periodo comprendido entre los meses Enero-2003 hasta Nov-2012. La distribución presenta una pequeña asimetría hacia la derecha respecto de la media ($\text{Skewness}=0.05>0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más achatada que la normal definiéndose como una distribución platicúrtica ($\text{Kurtosis}<3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.26>0.05$. H_0 : datos provienen de distribución normal).

4.2 Prueba de Raíz Unitaria de Dickey-Fuller Aumentada (ADF)³⁷

Variables	Acrónimo	N° rezagos (p)	Estadístico ADF
Consumo de gasolina automotriz	CGAS	15	-1.280
1a Diferencia Consumo de gasolina automotriz	Δ CGAS	15	-3.769(**)
Consumo de diesel vehicular	CDIESEL	13	0.822
1a Diferencia Consumo de diesel vehicular	Δ CDIESEL	13	-10.012(**)
Consumo de GLP vehicular	CGLP	4	-0.638
1a Diferencia Consumo de GLP vehicular	Δ CGLP	4	-8.451(**)
Consumo de GNC vehicular	CGNC	13	-2.157
1a Diferencia Consumo de GNC vehicular	Δ CGNC	13	-16.478(**)
Precio de Gasolina Automotriz 95 octanos RM	PGASRM	12	-2084
1a Diferencia Precio de Gasolina Automotriz 95 octanos RM	Δ PGASRM	12	-7.269(**)
Precio de Gasolina Automotriz 95 octanos PAÍS	PGASPAIS	12	-1673
1a Diferencia Precio de Gasolina Automotriz 95 octanos PAÍS	Δ PGASPAIS	12	-9.834(**)
Precio de Diesel Vehicular RM	PDIESELRM	12	-1.858
1a Diferencia Precio de Diesel Vehicular RM	Δ PDIESELRM	12	-7.001(**)
Precio de Diesel Vehicular PAÍS	PDIESELPAIS	12	-1531
1a Diferencia Precio de Diesel Vehicular PAÍS	Δ PDIESELPAIS	12	-9.900(**)
Precio de Gas Licuado de Petróleo	PGLP	4	-3.542 (*)
1a Diferencia Precio de Gas Licuado de Petróleo	Δ PGLP	-	-
Precio de Gas Natural Comprimido RM	PGNCRM	4	-2.218
1a Diferencia Precio de Gas Natural Comprimido RM	Δ PGNCRM	4	-3.489(*)
Precio de Gas Natural Comprimido XII Región	PGNCR12	10	-7.197(**)
1a Diferencia Precio de Gas Natural Comprimido XII Región	Δ PGNCR12	-	-
Índice Mensual de Actividad Económica IMACEC	IMACEC	10	0.785
1a Diferencia Índice Mensual de Actividad Económica IMACEC	Δ IMACEC	10	-5.133(**)

Tabla 13. Pruebas de Raíz Unitaria de Dickey-Fuller Aumentada (ADF).

Notas: * (**) Representa el rechazo de la hipótesis nula para una raíz unitaria con un nivel de significancia de 0.05 (0.01).

Previo a la estimación de los diferentes modelos se chequeó la presencia de raíces unitarias en las variables usando la prueba de Dickey-Fuller Aumentada. Todas las variables son integradas de orden uno, o $I(1)$, con la excepción del Precio de Gas Licuado de Petróleo (PGLP) y Precio de Gas Natural Comprimido XII Región (PGNCR12), las cuales en ambos casos se rechazó la hipótesis nula de existencia de una raíz unitaria al 5% y 1%, respectivamente, al realizar la prueba ADF en niveles³⁸.

Por lo tanto, todas las variables son no estacionarias, integradas de orden 1, excepto para PGLP y PGNCR12, en las cuales se verifica estacionariedad.

³⁷ Ver anexos 1 al 4 para pruebas ADF de consumos de combustibles.

³⁸ Variable original sin diferenciar.

4.3 Modelos ARIMA y de Series de Tiempo³⁹

4.3.1 Modelo ARIMA de consumo nacional de gasolina automotriz

4.3.1.1 Ajustes preliminares de las series

Se seleccionó la transformación logarítmica de los datos debido a que los criterios de información de dicha transformación fueron los de menor valor frente a la serie original.

```
Likelihood statistics for model fit to untransformed series.
Likelihood Statistics
-----
Number of observations (nobs)                83
Effective number of observations (nefobs)      70
Number of parameters estimated (np)           3
Log likelihood (L)                          -770.8984
AIC                                           1547.7968
AICC (F-corrected-AIC)                      1548.1605
Hannan Quinn                               1550.4762
BIC                                           1554.5423
-----

Likelihood statistics for model fit to log transformed series.
Likelihood Statistics
-----
Number of observations (nobs)                83
Effective number of observations (nefobs)      70
Number of parameters estimated (np)           3
Log likelihood                             111.2721
Transformation Adjustment                   -879.0208
Adjusted Log likelihood (L)                 -767.7487
AIC                                           1541.4973
AICC (F-corrected-AIC)                      1541.8610
Hannan Quinn                               1544.1767
BIC                                           1548.2428
-----

***** AICC (with aicdiff=-2.00) prefers log transformation *****
```

Tabla 14. Selección de transformación automática de CGAS.

Se detectaron en forma automática 2 outliers aditivos (AO), uno en octubre de 2009 y otro en agosto de 2012, tal como se aprecia en la siguiente tabla.

Variable	Parameter Estimate	Standard Error	t-value
Constant	-0.0005	0.00018	-2.65
Automatically Identified Outliers			
AO2009.Oct	0.2487	0.02495	9.97
AO2012.Aug	-0.1449	0.02674	-5.42

Tabla 15. Outliers identificados automáticamente de CGAS.

³⁹ Se privilegió la presentación de las tablas originales de resultados del software X-12 ARIMA, aunque estas presenten un formato más bien tosco, con el objetivo de que los usuarios del programa MODELOS desarrollado en Eviews puedan interpretar los resultados y no admita confusión al presentar tablas modificadas en un formato mejorado.

4.3.1.2 Estimación

En la siguiente tabla se pueden ver los cinco mejores modelos encontrados por la función AUTOMDL del software X-12 ARIMA. Estos modelos están rankeados de mayor a menor BIC, eligiendo en forma automática el modelo de menor BIC de -4.047, esto es, el modelo N° 1 ARIMA (0 1 1)(0 1 1).

```
Best Five ARIMA Models

Model # 1 : (0 1 1) (0 1 1)      (BIC = -4.047)
Model # 2 : (0 1 2) (0 1 1)      (BIC = -3.992)
Model # 3 : (1 1 1) (0 1 1)      (BIC = -3.992)
Model # 4 : (0 1 1) (0 1 2)      (BIC = -3.991)
Model # 5 : (0 1 1) (1 1 1)      (BIC = -3.991)

Automatic model choice : (0 1 1) (0 1 1)
```

Tabla 16. Cinco mejores modelos ARIMA de CGAS.

Para el consumo nacional de gasolina automotriz se obtuvo el modelo ARIMA (0 1 1)(0 1 1), tal como se aprecia en la siguiente tabla de resultados que arroja el software X12 ARIMA. El parámetro no estacional de medias móviles MA (Nonseasonal MA) corresponde a 0.9247, mientras que el parámetro estacional MA (Seasonal MA) corresponde a 0.7628. Existe una diferenciación no estacional y una estacional.

```
ARIMA Model: (0 1 1) (0 1 1)
Nonseasonal differences: 1
Seasonal differences: 1
```

Parameter	Estimate	Standard Errors

Nonseasonal MA		
Lag 1	0.9247	0.05512
Seasonal MA		
Lag 12	0.7628	0.09836
Variance	0.69434E-03	
SE of Var	0.11737E-03	

Tabla 17. Parámetros estimados del modelo ARIMA de CGAS.

En la siguiente figura se aprecia que el modelo estimado se ajusta bastante bien a la serie histórica de consumo, con residuales o errores que aproximadamente fluctúan en una banda de $\pm 10.000 \text{ m}^3$ ⁴⁰.

⁴⁰ La escala izquierda de este gráfico corresponde a los residuales o errores y la escala derecha corresponde a la serie histórica y ajuste.




Figura 19. Ajuste de modelo ARIMA Consumo de gasolina automotriz.

4.3.1.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.04	-0.03	0.17	-0.10	0.00	0.12	-0.24	0.00	0.04	-0.09	0.19	-0.01
SE	0.12	0.12	0.12	0.12	0.12	0.12	0.13	0.13	0.13	0.13	0.13	0.14
Q	0.09	0.16	2.36	3.18	3.18	4.25	9.01	9.01	9.11	9.72	12.95	12.96
DF	0	0	1	2	3	4	5	6	7	8	9	10
P	0.000	0.000	0.125	0.204	0.365	0.373	0.109	0.173	0.245	0.285	0.165	0.226

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	-0.17	0.19	0.07	-0.17	0.19	-0.05	-0.12	0.16	-0.14	-0.02	0.20	-0.11
SE	0.14	0.14	0.14	0.14	0.15	0.15	0.15	0.15	0.15	0.16	0.16	0.16
Q	15.53	18.73	19.20	21.88	25.37	25.57	26.99	29.51	31.54	31.60	35.95	37.35
DF	11	12	13	14	15	16	17	18	19	20	21	22
P	0.159	0.095	0.117	0.081	0.045	0.060	0.058	0.042	0.035	0.048	0.022	0.022

Tabla 18. Autocorrelación muestral de los residuos de modelo ARIMA CGAS.

En los rezagos (Lag) del 3 al 24 el estadístico Ljung-box (Q) es no significativo (P-values>0.05), por lo que no existe autocorrelación en los residuos del modelo⁴¹.

⁴¹ Los estadísticos Ljung Box (Q) y P-values correspondientes a los grados de libertad (DF: Degree Freedom) igual a cero se ignoran.




Figura 20. Autocorrelación muestral de los residuales de modelo ARIMA CGAS.

Se puede apreciar en la figura 19 que la Función de Autocorrelación (ACF) denotada por las “X” se encuentra dentro de los límites de línea punteada⁴², por lo que la ACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.04	-0.03	0.17	-0.10	0.00	0.09	-0.22	-0.01	-0.01	0.00	0.17	-0.03
SE	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	-0.12	0.10	0.10	-0.14	0.12	0.02	-0.08	0.05	-0.10	0.03	0.14	0.00
SE	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0.12

Tabla 19. Autocorrelación parcial muestral de los residuales de modelo ARIMA CGAS.

⁴² Corresponden a +2 errores estándar (SE).




Figura 21. Autocorrelación parcial muestral de los residuales de modelo ARIMA CGAS.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las “X” se encuentra dentro de la banda de ± 2 SE, por lo que la PACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 22. Histograma y estadísticas descriptivas de residuales modelo ARIMA CGAS⁴³.

La distribución de los residuos presenta una pequeña asimetría hacia la derecha respecto de la media (Skewness=0.3057>0). Su indicador de forma (Kurtosis) muestra

⁴³ Gráfico de Eviews con datos extraídos desde X-12 ARIMA.

que esta distribución es más achatada que la normal definiéndose como una distribución platicúrtica ($Kurtosis < 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.46 > 0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-0.049
Maximum	0.058
Median	-0.001
Robust Std Dev	0.026

Normality Statistics for regARIMA Model Residuals:

Number of residuals	:	70
Skewness coefficient	:	0.3057
Geary's a	:	0.7992
Kurtosis	:	2.6138

No indication of lack of normality.

Tabla 20. Estadísticos de normalidad de residuales de modelo ARIMA de CGAS.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA, coeficiente de sesgo (Skewness coefficient), a de Geary y Curtosis no existe indicación de falta de normalidad.

4.3.1.4 Pronósticos Mensuales Ex ante

Se puede apreciar en la siguiente figura la marcada estacionalidad que poseen los pronósticos mensuales generados por el modelo estimado, dada principalmente por el parámetro de medias móviles estacionales (Seasonal MA).




Figura 23. Pronósticos mensuales ex ante consumo de gasolina automotriz.

4.3.1.5 Pronósticos Semanales Ex ante

Se visualiza en la figura 24 que los pronósticos semanales del consumo de gasolina automotriz poseen alzas en algunas fechas, las cuales corresponden a la metodología complementaria, en la cual los fines de semana largos afectan dichos pronósticos haciéndolos aumentar en un porcentaje del consumo.




Figura 24. Pronósticos semanales modelo ARIMA consumo de gasolina automotriz.

4.3.2 Modelo ARIMA de consumo nacional de diesel vehicular

4.3.2.1 Ajustes preliminares de las series

Se seleccionó la no transformación de los datos debido a que los criterios de información fueron los de menor valor frente a la serie transformada en forma logarítmica.

```
Likelihood statistics for model fit to untransformed series.
Likelihood Statistics
-----
Number of observations (nobs)                95
Effective number of observations (nefobs)      82
Number of parameters estimated (np)           3
Log likelihood (L)                          -909.8848
AIC                                           1825.7696
AICC (F-corrected-AIC)                     1826.0773
Hannan Quinn                               1828.6684
BIC                                           1832.9898
-----

Likelihood statistics for model fit to log transformed series.
Likelihood Statistics
-----
Number of observations (nobs)                95
Effective number of observations (nefobs)      82
Number of parameters estimated (np)           3
Log likelihood                             109.1475
Transformation Adjustment                   -1025.1345
Adjusted Log likelihood (L)                 -915.9870
AIC                                           1837.9740
AICC (F-corrected-AIC)                     1838.2817
Hannan Quinn                               1840.8728
BIC                                           1845.1942
-----
***** AICC (with aicdiff=-2.00) prefers no transformation *****
```

Tabla 21. Selección de transformación automática de CDIESEL.

Se detectaron en forma automática 4 outliers aditivos (AO), en agosto de 2006, octubre y noviembre de 2009, y otro en agosto de 2012, tal como se aprecia en la siguiente tabla.

Variable	Parameter Estimate	Standard Error	t-value
Constant	10388.9627	943.83530	11.01
Automatically Identified Outliers			
AO2006.Aug	-63677.5635	6640.06291	-9.59
AO2009.Oct	51245.2475	6634.72052	7.72
AO2009.Nov	-40494.9150	6657.97809	-6.08
AO2012.Aug	-38476.5340	6642.05120	-5.79

Tabla 22. Outliers identificados automáticamente de CDIESEL.

4.3.2.2 Estimación

En la siguiente tabla se pueden ver los cinco mejores modelos encontrados por la función AUTOMDL del software X-12 ARIMA. Estos modelos están rankeados de menor a mayor BIC, eligiendo en forma automática el modelo de menor BIC de 21.569, esto es, el modelo N° 1 ARIMA (3 0 0)(0 1 1).

Best Five ARIMA Models

Model #	1	:	(3 0 0) (0 1 1)	(BIC =	21.569)
Model #	2	:	(1 0 1) (0 1 1)	(BIC =	21.574)
Model #	3	:	(3 0 1) (0 1 1)	(BIC =	21.599)
Model #	4	:	(3 0 2) (0 1 1)	(BIC =	21.604)
Model #	5	:	(1 0 3) (0 1 1)	(BIC =	21.609)

Automatic model choice : (3 0 0) (0 1 1)

Tabla 23. Cinco mejores modelos ARIMA de CDIESEL.

Para el consumo nacional de diesel vehicular se obtuvo el modelo ARIMA (3 0 0)(0 1 1), tal como se aprecia en la siguiente tabla de resultados que arroja el software X12 ARIMA. Los parámetros no estacionales autorregresivos AR (Nonseasonal AR) corresponden a -0.0805, 0.2112 y 0.5909 para AR(1), AR(2) y AR(3), respectivamente, mientras que el parámetro estacional MA (Seasonal MA) corresponde a 0.9985. Existe solo una diferenciación estacional.

ARIMA Model: (3 0 0) (0 1 1)		
Seasonal differences: 1		
Parameter	Estimate	Standard Errors

Nonseasonal AR		
Lag 1	-0.0805	0.07802
Lag 2	0.2112	0.07526
Lag 3	0.5909	0.07998
Seasonal MA		
Lag 12	0.9985	0.08893
Variance	0.52695E+08	
SE of Var	0.81799E+07	

Tabla 24. Parámetros estimados del modelo ARIMA de CDIESEL.

Se puede apreciar en la figura 25 que el modelo (ajuste) se ajusta relativamente bien a los datos históricos (serie histórica), donde los residuales varían aproximadamente en una banda de $\pm 15.000 \text{ m}^3$.




Figura 25. Ajuste de modelo ARIMA Consumo Diesel Vehicular.

4.3.2.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.03	0.00	-0.04	0.08	0.19	0.03	-0.16	0.05	0.20	-0.06	0.08	-0.12
SE	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.12	0.12	0.12	0.12	0.12
Q	0.07	0.07	0.23	0.79	4.21	4.27	6.57	6.83	10.73	11.05	11.69	13.14
DF	0	0	0	0	1	2	3	4	5	6	7	8
P	0.000	0.000	0.000	0.000	0.040	0.118	0.087	0.145	0.057	0.087	0.111	0.107

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	-0.06	0.03	0.01	-0.17	0.10	-0.09	-0.04	0.04	-0.06	-0.10	-0.04	-0.20
SE	0.12	0.12	0.12	0.12	0.13	0.13	0.13	0.13	0.13	0.13	0.13	0.13
Q	13.56	13.68	13.70	16.89	18.03	18.93	19.10	19.28	19.69	20.96	21.13	25.92
DF	9	10	11	12	13	14	15	16	17	18	19	20
P	0.139	0.188	0.250	0.154	0.156	0.168	0.209	0.254	0.290	0.281	0.330	0.168

Tabla 25. Autocorrelación muestral de los residuales de modelo ARIMA CDIESEL.

En los rezagos (Lag) del 5⁴⁴ al 24 el estadístico Ljung-box (Q) es no significativo (P-values>0.05), por lo que no existe autocorrelación en los residuos del modelo⁴⁵.

⁴⁴ Único rezago que es levemente menor a 0.05.

⁴⁵ Los estadísticos Ljung Box (Q) y P-values correspondientes a los grados de libertad (DF: Degree Freedom) igual a cero se ignoran.




Figura 26. Autocorrelación muestral de los residuales de modelo ARIMA CDIESEL.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra dentro de los límites de línea punteada⁴⁶, por lo que la ACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.03	0.00	-0.04	0.08	0.20	0.04	-0.16	0.05	0.20	-0.11	0.09	-0.04
SE	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	-0.14	-0.06	0.05	-0.17	0.10	-0.03	-0.09	0.02	0.07	-0.17	-0.05	-0.13
SE	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11

Tabla 26. Autocorrelación parcial muestral de los residuales de modelo ARIMA CDIESEL.

⁴⁶ Corresponden a +2 errores estándar (SE).




Figura 27. Autocorrelación parcial muestral de los residuos de modelo ARIMA CDIESEL.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las "X" se encuentra dentro de la banda de ± 2 SE, por lo que la PACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 28. Histograma y estadísticas descriptivas de residuos modelo ARIMA CDIESEL⁴⁷.

La distribución de los residuos presenta una pequeña asimetría hacia la izquierda respecto de la media (Skewness=-0.28<0). Su indicador de forma (Kurtosis) muestra

⁴⁷ Gráfico de Eviews con datos extraídos desde X-12 ARIMA.

que esta distribución es más achatada que la normal definiéndose como una distribución platicúrtica ($Kurtosis < 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.53 > 0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-19241.542
Maximum	12375.043
Median	475.571
Robust Std Dev	7163.204

Normality Statistics for regARIMA Model Residuals:

Number of residuals	:	83
Skewness coefficient	:	-0.2855
Geary's a	:	0.8085
Kurtosis	:	2.7962

No indication of lack of normality.

Tabla 27. Estadísticos de normalidad de residuales de modelo ARIMA de CDIESEL.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; coeficiente de sesgo (Skewness coefficient), a de Geary y Curtosis no existe indicación de falta de normalidad.

4.3.2.4 Pronósticos Mensuales Ex ante

Al igual que el consumo de gasolina, se puede apreciar en la siguiente figura, la marcada estacionalidad que poseen los pronósticos mensuales de consumo de diésel vehicular generados por el modelo estimado, dada principalmente por el parámetro de medias móviles estacionales (Seasonal MA).




Figura 29. Pronósticos mensuales ex ante consumo de diesel vehicular.

4.3.2.5 Pronósticos Semanales Ex ante

Se visualiza en la figura 30 que los pronósticos semanales poseen bajas en algunas fechas, las cuales corresponden a la metodología complementaria en la cual los fines de semana largos afectan dichos pronósticos haciéndolos descender en un porcentaje del consumo.




Figura 30. Pronósticos semanales modelo ARIMA consumo de diésel vehicular.

4.3.3 Modelo ARIMA de consumo nacional de gas natural comprimido vehicular

4.3.3.1 Ajustes preliminares de las series

Se seleccionó la transformación logarítmica de los datos debido a que los criterios de información fueron los de menor valor frente a la serie original (no transformada).

```

Likelihood statistics for model fit to untransformed series.
Likelihood Statistics
-----
Number of observations (nobs)                131
Effective number of observations (nefobs)      118
Number of parameters estimated (np)           3
Log likelihood (L)                           -821.1043
AIC                                            1648.2087
AICC (F-corrected-AIC)                      1648.4192
Hannan Quinn                                1651.5836
BIC                                           1656.5207
-----

Likelihood statistics for model fit to log transformed series.
Likelihood Statistics
-----
Number of observations (nobs)                131
Effective number of observations (nefobs)      118
Number of parameters estimated (np)           3
Log likelihood                               65.9872
Transformation Adjustment                    -877.0185
Adjusted Log likelihood (L)                  -811.0313
AIC                                           1628.0626
AICC (F-corrected-AIC)                      1628.2731
Hannan Quinn                                1631.4376
BIC                                           1636.3747
-----

***** AICC (with aicdiff=-2.00) prefers log transformation *****

```

Tabla 28. Selección de transformación automática de CGNC.

Se detectaron en forma automática 3 outliers aditivos (AO), en mayo y diciembre de 2004, y enero de 2011, y un LS en julio de 2007, tal como se aprecia en la siguiente tabla.

Variable	Parameter Estimate	Standard Error	t-value
Automatically Identified Outliers			
AO2004.May	0.3596	0.04062	8.85
AO2004.Dec	-0.3456	0.04062	-8.51
LS2007.Jul	-1.0050	0.05002	-20.09
AO2011.Jan	-0.1636	0.04162	-3.93

Tabla 29. Outliers identificados automáticamente de CGNC.

4.3.3.2 Estimación

En la siguiente tabla se pueden ver los cinco mejores modelos encontrados por la función AUTOMDL del software X-12 ARIMA. Estos modelos están rankeados de menor a mayor BIC, eligiendo en forma automática el modelo de menor BIC de -2.709, esto es, el modelo N° 1 ARIMA (1 1 0)(0 1 1).

Best Five ARIMA Models

Model #	1	:	(1 1 0) (0 1 1)	(BIC =	-2.709)
Model #	2	:	(0 1 1) (0 1 1)	(BIC =	-2.696)
Model #	3	:	(1 1 0) (1 1 1)	(BIC =	-2.696)
Model #	4	:	(0 1 0) (0 1 1)	(BIC =	-2.696)
Model #	5	:	(0 1 2) (0 1 1)	(BIC =	-2.693)

Automatic model choice : (1 1 0) (0 1 1)

Tabla 30. Cinco mejores modelos ARIMA de CGNC.

Para el consumo nacional de gas natural comprimido vehicular se obtuvo el modelo ARIMA (1 1 0)(0 1 1), tal como se aprecia en la siguiente tabla de resultados que arroja el software X12 ARIMA. El parámetro no estacional autorregresivo AR (Nonseasonal AR) corresponden a -0.2364 AR(1), mientras que el parámetro estacional MA (Seasonal MA) corresponde a 0.5963. Existe una diferenciación estacional y una no estacional.

ARIMA Model: (1 1 0) (0 1 1)		
Nonseasonal differences: 1		
Seasonal differences: 1		
Parameter	Estimate	Standard Errors

Nonseasonal AR		
Lag 1	-0.2364	0.08825
Seasonal MA		
Lag 12	0.5963	0.07546
Variance	0.33012E-02	
SE of Var	0.42977E-03	

Tabla 31. Parámetros estimados del modelo ARIMA de CGNC.

En la figura 31 se aprecia que en general el modelo se ajusta bien a la serie histórica y además se visualiza que el modelo se ajusta al cambio de nivel que se presenta en julio de 2007, mediante el outlier LS detectado en forma automática en dicha fecha⁴⁸.

⁴⁸ Ver Tabla 29.




Figura 31. Ajuste de modelo ARIMA Consumo GNC Vehicular.

4.3.3.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	0.01	0.12	0.08	0.01	-0.09	-0.07	-0.03	-0.19	0.05	0.01	-0.16	0.04
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.10	0.10	0.10	0.10	0.10	0.10
Q	0.02	1.92	2.81	2.83	3.83	4.53	4.65	9.10	9.45	9.46	12.70	12.96
DF	0	0	1	2	3	4	5	6	7	8	9	10
P	0.000	0.000	0.094	0.243	0.280	0.339	0.460	0.168	0.222	0.305	0.177	0.226

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	0.07	0.13	-0.02	0.15	0.05	-0.01	0.20	0.03	0.06	-0.06	0.02	-0.07
SE	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.11	0.11	0.11	0.11	0.11
Q	13.55	15.76	15.79	19.12	19.41	19.42	25.07	25.24	25.72	26.21	26.29	27.11
DF	11	12	13	14	15	16	17	18	19	20	21	22
P	0.259	0.203	0.261	0.160	0.196	0.248	0.093	0.118	0.138	0.159	0.195	0.207

Tabla 32. Autocorrelación muestral de los residuales de modelo ARIMA CDIESEL.

En los rezagos (Lag) del 3 al 24 el estadístico Ljung-Box (Q) es no significativo (P-values>0.05), por lo que no existe autocorrelación en los residuos del modelo⁴⁹.

⁴⁹ Los estadísticos Ljung-Box (Q) y P-values correspondientes a los grados de libertad (DF: Degree Freedom) igual a cero se ignoran.




Figura 32. Autocorrelación muestral de los residuos de modelo ARIMA CGNC.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra dentro de los límites de línea punteada⁵⁰, por lo que la ACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	0.01	0.12	0.08	0.00	-0.11	-0.08	-0.01	-0.15	0.08	0.05	-0.17	0.02
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	0.07	0.14	-0.03	0.07	0.04	-0.03	0.17	0.09	0.07	-0.09	-0.02	0.02
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09

Tabla 33. Autocorrelación parcial muestral de los residuos de modelo ARIMA CGNC.

⁵⁰ Corresponden a +2 errores estándar (SE).




Figura 33. Autocorrelación parcial muestral de los residuos de modelo ARIMA CDIESEL.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las “X” se encuentra dentro de la banda de ± 2 SE, por lo que la PACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 34. Histograma y estadísticas descriptivas de residuos modelo ARIMA CGNC⁵¹.

La distribución de los residuos presenta una pequeña asimetría hacia la derecha respecto de la media (Skewness=0.03>0). Su indicador de forma (Kurtosis) muestra

⁵¹ Gráfico de Eviews con datos extraídos desde X-12 ARIMA.

que esta distribución es más aguzada que la normal definiéndose como una distribución leptocúrtica ($Kurtosis > 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.91 > 0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-0.139
Maximum	0.143
Median	-0.002
Robust Std Dev	0.053

Normality Statistics for regARIMA Model Residuals:

Number of residuals	:	118
Skewness coefficient	:	0.0356
Geary's a	:	0.7716
Kurtosis	:	3.1774

No indication of lack of normality.

Tabla 34. Estadísticos de normalidad de residuales de modelo ARIMA de CGNC.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; coeficiente de sesgo (Skewness coefficient), a de Geary y Curtosis no existe indicación de falta de normalidad.

4.3.3.4 Pronósticos Mensuales Ex ante

Se puede apreciar en la siguiente figura, la leve estacionalidad que poseen los pronósticos mensuales generados por el modelo estimado, dada principalmente por el parámetro de medias móviles estacionales (Seasonal MA).




Figura 35. Pronósticos mensuales ex ante consumo de GNC vehicular.

Adicionalmente, se visualiza como se incrementan los límites de confianza al 95% inferior y superior a medida que el pronóstico se aleja del último dato histórico⁵².

4.3.3.5 Pronósticos Semanales Ex ante

Los pronósticos semanales ex ante de GNC vehicular muestran un sostenido crecimiento en la muestra de pronóstico, desde los 500 Mm3 en diciembre de 2012 hasta aproximadamente los 700 Mm3 en noviembre de 2014, tal como se aprecia en la Figura 36.




Figura 36. Pronósticos semanales modelo ARIMA consumo de GNC vehicular.

⁵² Esto se debe principalmente al incremento del error estándar de pronóstico, puesto que los límites de confianza están en función de este.

4.3.4 Modelo ARIMA de consumo nacional de gas licuado de petróleo vehicular⁵³

4.3.4.1 Estimación

En la siguiente tabla se puede apreciar el modelo estimado a través de Eviews. Este corresponde a un modelo autorregresivo de orden 2, AR(2).


Dependent Variable: LOG(CGLP)				
Method: Least Squares				
Date: 02/13/13 Time: 11:21				
Sample (adjusted): 2011M03 2012M11				
Included observations: 21 after adjustments				
Convergence achieved after 3 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	8.905782	0.337143	26.41546	0.0000
AR(1)	0.387708	0.155152	2.498886	0.0224
AR(2)	0.510850	0.153799	3.321540	0.0038
R-squared	0.960412	Mean dependent var	8.249218	
Adjusted R-squared	0.956013	S.D. dependent var	0.271968	
S.E. of regression	0.057040	Akaike info criterion	-2.758569	
Sum squared resid	0.058564	Schwarz criterion	-2.609352	
Log likelihood	31.96498	Hannan-Quinn criter.	-2.726185	
F-statistic	218.3408	Durbin-Watson stat	1.263879	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.93	-.55		

Tabla 35. Modelo AR(2) de CGLP.

Los parámetros no estacionales autorregresivos AR corresponden a 0.3877 y 0.5108 para AR(1) y AR(2), respectivamente, mientras que el parámetro constante (C) corresponde a 8.905. Todos los parámetros son significativos (p -value (Prob.) <0.05). El modelo es significativo en forma global (Prob(F-statistics) <0.05). La bondad de ajuste del modelo, medida a través del R cuadrado ajustado (Adjusted R-squared) es muy buena, puesto que el 95,6% de la variabilidad del consumo de GLP es explicada por el modelo.

La bondad de ajuste del modelo se puede visualizar en la Figura 37, donde los residuales fluctúan en una banda de aproximadamente $\pm 400 \text{ m}^3$.

⁵³ Modelo estimado con Eviews debido a que el número de datos era menor que 36 y por ende no se puede ejecutar X-12 ARIMA.



4.3.4.2 Tests de Especificación y Diagnóstico

A. Autocorrelación y Autocorrelación Parcial muestral de los residuos




Figura 38. Correlograma de los residuos de modelo ARIMA CGLP.

Se puede apreciar en la figura que la Función de Autocorrelación (AC) y Autocorrelación Parcial (PAC) muestrales se encuentran dentro de los límites de línea

punteada⁵⁴, por lo que la AC y PAC no son significativamente distintas de cero a (aproximadamente) un 5% de nivel de significancia. Adicionalmente, el estadístico Ljung-Box (Q) es no significativo ($P\text{-values} > 0.05$), por lo que no existe autocorrelación y autocorrelación parcial en los residuos del modelo.

B. Normalidad de los residuos




Figura 39. Histograma y estadísticas descriptivas de residuos modelo ARIMA CGLP.

La distribución de los residuos presenta una pequeña asimetría hacia la derecha respecto de la media ($\text{Skewness} = 0.32 > 0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más aguzada que la normal definiéndose como una distribución platicúrtica ($\text{Kurtosis} < 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p = 0.526 > 0.05$. H_0 : datos provienen de distribución normal).

4.3.4.3 Pronósticos Mensuales Ex ante




Figura 40. Pronósticos mensuales ex ante consumo de GLP vehicular.

⁵⁴ Corresponden a +2 errores estándar (SE).

Se puede apreciar en la figura 40 que los pronósticos mensuales de GLP se incrementan levemente y a una tasa decreciente desde los 5674 m³ en diciembre de 2012 hasta los 6961 m³ en noviembre de 2014.

4.3.4.4 Pronósticos Semanales Ex ante




Figura 41. Pronósticos semanales modelo ARIMA consumo de GLP vehicular.

4.3.5 Modelo ARIMA de Precios de Gasolina Automotriz País

4.3.5.1 Ajustes preliminares de las series

Se seleccionó la no transformación de los datos debido a que los criterios de información fueron los de menor valor frente a la serie transformada en forma logarítmica.

```

Likelihood statistics for model fit to untransformed series.
Likelihood Statistics
-----
Number of observations (nobs)                119
Effective number of observations (nefobs)      106
Number of parameters estimated (np)           3
Log likelihood (L)                          -530.4423
AIC                                           1066.8845
AICC (F-corrected-AIC)                      1067.1198
Hannan Quinn                               1070.1230
BIC                                           1074.8748
-----
Likelihood statistics for model fit to log transformed series.
Likelihood Statistics
-----
Number of observations (nobs)                119
Effective number of observations (nefobs)      106
Number of parameters estimated (np)           3
Log likelihood                              146.0007
Transformation Adjustment                   -683.2233
Adjusted Log likelihood (L)                 -537.2225
AIC                                           1080.4451
AICC (F-corrected-AIC)                      1080.6804
Hannan Quinn                               1083.6836
BIC                                           1088.4354
-----
***** AICC (with aicdiff=-2.00) prefers no transformation *****

```

Tabla 36. Selección de transformación automática de PGASPAIS.

Se detectaron en forma automática 2 outliers; 1 Level Shift (LS) en diciembre de 2008, y un outlier aditivo (AO) en la misma fecha, tal como se aprecia en la siguiente tabla.

Variable	Parameter Estimate	Standard Error	t-value
Constant	4.6511	3.44616	1.35
Automatically Identified Outliers			
AO2008.Dec	125.0681	25.78840	4.85
LS2008.Dec	-257.3847	36.53342	-7.05

Tabla 37. Outliers identificados automáticamente de PGASPAIS.

4.3.5.2 Estimación

Se encontraron los cinco mejores modelos, eligiendo en forma automática el modelo de menor BIC de 9.603, esto es, el modelo N° 1 ARIMA (0 1 0)(0 0 1).

Best Five ARIMA Models

Model #	1	:	(0 1 0) (0 0 1)	(BIC =	9.603)
Model #	2	:	(0 1 0) (1 0 0)	(BIC =	9.629)
Model #	3	:	(0 1 0) (0 0 2)	(BIC =	9.636)
Model #	4	:	(0 1 0) (1 0 1)	(BIC =	9.636)
Model #	5	:	(0 1 1) (0 0 1)	(BIC =	9.638)

Automatic model choice : (0 1 0) (0 0 1)

Tabla 38. Cinco mejores modelos ARIMA de PGASPAIS.

Respecto al modelo estimado, el único parámetro es el de medias móviles estacional (Seasonal MA) y corresponde a -0.3785. Existe sólo una diferenciación no estacional.

ARIMA Model: (0 1 0) (0 0 1)		
Nonseasonal differences: 1		
Parameter	Estimate	Standard Errors

Seasonal MA		
Lag 12	-0.3785	0.08509
Variance	0.77324E+03	
SE of Var	0.10067E+03	

Tabla 39. Parámetros estimados del modelo ARIMA de PGASPAIS.




Figura 42. Ajuste de modelo ARIMA de PGASPAIS.

4.3.5.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.09	-0.10	-0.08	-0.11	0.04	-0.01	-0.11	-0.11	0.09	0.03	0.14	-0.03
SE	0.09	0.09	0.09	0.09	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10
Q	0.92	2.22	3.01	4.63	4.86	4.88	6.41	7.83	8.86	8.97	11.68	11.76
DF	0	1	2	3	4	5	6	7	8	9	10	11
P	0.000	0.136	0.222	0.201	0.302	0.430	0.379	0.348	0.354	0.440	0.307	0.382

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	-0.14	0.08	0.11	-0.01	-0.04	-0.09	-0.05	0.15	-0.05	-0.05	-0.04	-0.08
SE	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.11	0.11	0.11	0.11
Q	14.33	15.31	17.00	17.01	17.20	18.33	18.66	21.75	22.09	22.51	22.77	23.75
DF	12	13	14	15	16	17	18	19	20	21	22	23
P	0.280	0.289	0.256	0.318	0.373	0.368	0.413	0.297	0.335	0.371	0.415	0.418

Tabla 40. Autocorrelación muestral de los residuales de modelo ARIMA PGASPAIS.

En los rezagos (Lag) del 2 al 24 el estadístico Ljung-box (Q) es no significativo (P-values>0.05), por lo que no existe autocorrelación en los residuos del modelo⁵⁵.




Figura 43. Autocorrelación muestral de los residuales de modelo ARIMA PGASPAIS.

⁵⁵ Los estadísticos Ljung Box (Q) y P-values correspondientes a los grados de libertad (DF: Degree Freedom) igual a cero se ignoran.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra dentro de los límites de línea punteada⁵⁶, por lo que la ACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.09	-0.11	-0.10	-0.15	-0.01	-0.05	-0.15	-0.17	0.02	-0.03	0.10	-0.02
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	-0.11	0.06	0.12	0.01	0.01	-0.02	-0.02	0.10	-0.05	-0.03	-0.04	-0.09
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09

Tabla 41. Autocorrelación parcial muestral de los residuales de modelo ARIMA PGASPAIS.




Figura 44. Autocorrelación parcial muestral de residuales de modelo ARIMA PGASPAIS.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las "X" se encuentra dentro de la banda de ± 2 SE, por lo que la PACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

⁵⁶ Corresponden a ± 2 errores estándar (SE).

C. Normalidad de los residuos




Figura 45. Histograma y estadísticas descriptivas residuales modelo ARIMA PGASPAIS.

La distribución de los residuos presenta una pequeña asimetría hacia la izquierda respecto de la media (Skewness=-0.03<0). Su indicador de forma (Kurtosis) muestra que esta distribución es más achatada que la normal definiéndose como una distribución platicúrtica (Kurtosis<3), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.91>0.05$. Ho: datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-60.647
Maximum	66.484
Median	-0.703
Robust Std Dev	27.368

Normality Statistics for regARIMA Model Residuals:

Number of residuals	: 118
Skewness coefficient	: -0.0285
Geary's a	: 0.8054
Kurtosis	: 2.6515

No indication of lack of normality.

Tabla 42. Estadísticos de normalidad de residuales de modelo ARIMA de PGASPAIS.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; coeficiente de sesgo (Skewness coefficient), a de Geary y Curtosis no existe indicación de falta de normalidad.

4.3.5.4 Pronósticos Mensuales Ex ante

Se puede apreciar en la siguiente figura, la leve estacionalidad que poseen los pronósticos mensuales generados por el modelo estimado, dada principalmente por el parámetro de medias móviles estacionales (Seasonal MA).




Figura 46. Pronósticos mensuales ex ante Precios Gasolina País.

4.3.6 Modelo ARIMA de Precios de Diesel Vehicular País

4.3.6.1 Ajustes preliminares de las series

Se seleccionó la no transformación de los datos debido a que los criterios de información fueron los de menor valor frente a la serie transformada en forma logarítmica.

```

Likelihood statistics for model fit to untransformed series.
Likelihood Statistics
-----
Number of observations (nobs)                119
Effective number of observations (nefobs)      106
Number of parameters estimated (np)           3
Log likelihood (L)                          -525.4802
AIC                                           1056.9603
AICC (F-corrected-AIC)                     1057.1956
Hannan Quinn                               1060.1989
BIC                                           1064.9507
-----
Likelihood statistics for model fit to log transformed series.
Likelihood Statistics
-----
Number of observations (nobs)                119
Effective number of observations (nefobs)      106
Number of parameters estimated (np)           3
Log likelihood                             128.8420
Transformation Adjustment                   -655.8161
Adjusted Log likelihood (L)                 -526.9741
AIC                                           1059.9482
AICC (F-corrected-AIC)                     1060.1835
Hannan Quinn                               1063.1867
BIC                                           1067.9385
-----
***** AICC (with aicdiff=-2.00) prefers no transformation *****

```

Tabla 43. Selección de transformación automática de PDIESELPAIS.

Se detectaron en forma automática 2 outliers; un outlier aditivo (AO) en diciembre de 2008 y 1 Level Shift (LS) en enero de 2009, tal como se aprecia en la siguiente tabla.

Variable	Parameter Estimate	Standard Error	t-value
Constant	4.8675	2.65324	1.83
Automatically Identified Outliers			
AO2008.Dec	-105.4632	25.01144	-4.22
LS2009.Jan	-265.8286	35.47964	-7.49

Tabla 44. Outliers identificados automáticamente de PDIESELPAIS.

4.3.6.2 Estimación

Se encontraron los cinco mejores modelos, eligiendo en forma automática el modelo de menor BIC de 9.223, esto es, el modelo N° 1 ARIMA (0 1 0)(0 0 1).

Best Five ARIMA Models

Model #	1	:	(0 1 0) (0 0 1)	(BIC =	9.223)
Model #	2	:	(0 1 0) (1 0 0)	(BIC =	9.227)
Model #	3	:	(0 1 0)	(BIC =	9.229)
Model #	4	:	(0 1 1) (0 0 1)	(BIC =	9.235)
Model #	5	:	(1 1 0) (0 0 1)	(BIC =	9.239)

Automatic model choice : (0 1 0) (0 0 1)

Tabla 45. Cinco mejores modelos ARIMA de PDIESELPAIS.

Respecto al modelo estimado, el único parámetro es el de medias móviles estacional (Seasonal MA) y corresponde a -0.1507. Existe sólo una diferenciación no estacional.

ARIMA Model: (0 1 0) (0 0 1)
Nonseasonal differences: 1

Parameter	Estimate	Standard Errors
Seasonal MA Lag 12	-0.1507	0.09282
Variance	0.63620E+03	
SE of Var	0.82826E+02	

Tabla 46. Parámetros estimados del modelo ARIMA de PDIESELPAIS.




Figura 47. Ajuste de modelo ARIMA de PDIESELPAIS.

4.3.6.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.10	-0.03	-0.11	-0.07	0.10	0.07	-0.11	-0.07	-0.07	0.00	0.06	-0.02
SE	0.09	0.09	0.09	0.09	0.09	0.10	0.10	0.10	0.10	0.10	0.10	0.10
Q	1.13	1.21	2.67	3.36	4.66	5.24	6.85	7.46	8.03	8.03	8.56	8.59
DF	0	1	2	3	4	5	6	7	8	9	10	11
P	0.000	0.271	0.263	0.340	0.324	0.388	0.335	0.383	0.431	0.531	0.575	0.660

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	-0.07	-0.01	0.00	-0.05	0.04	-0.06	-0.03	0.07	-0.01	0.03	0.01	-0.08
SE	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10
Q	9.31	9.34	9.34	9.65	9.85	10.30	10.40	11.03	11.04	11.17	11.17	12.08
DF	12	13	14	15	16	17	18	19	20	21	22	23
P	0.676	0.747	0.809	0.841	0.875	0.890	0.918	0.923	0.945	0.959	0.972	0.969

Tabla 47. Autocorrelación muestral de los residuos de modelo ARIMA PDIESELPAIS.

En los rezagos (Lag) del 2 al 24 el estadístico Ljung-box (Q) es no significativo (P-values>0.05), por lo que no existe autocorrelación en los residuos del modelo.

Sample Autocorrelations of the Residuals




Figura 48. Autocorrelación muestral de los residuos de modelo ARIMA PDIESELPAIS.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra dentro de los límites de línea punteada, por lo que la ACF no es

significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.10	-0.04	-0.12	-0.10	0.08	0.07	-0.12	-0.08	-0.06	-0.05	0.01	-0.02
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	-0.07	-0.02	-0.01	-0.10	-0.02	-0.05	-0.06	0.03	-0.01	0.00	0.00	-0.07
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09

Tabla 48. Autocorrelación parcial muestral de los residuales de modelo ARIMA PDIESELPAIS.

Sample Partial Autocorrelations of the Residuals




Figura 49. Autocorrelación parcial muestral de residuales de modelo ARIMA PDIESELPAIS.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las “X” se encuentra dentro de la banda de ± 2 SE, por lo que la PACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 50. Histograma y estadísticas descriptivas residuales modelo ARIMA PDIESELPAIS.

La distribución de los residuos presenta una pequeña asimetría hacia la derecha respecto de la media (Skewness=0.04<0). Su indicador de forma (Kurtosis) muestra que esta distribución es más aguzada que la normal definiéndose como una distribución leptocúrtica (Kurtosis>3), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.067>0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-71.203
Maximum	72.653
Median	0.149
Robust Std Dev	21.869

Normality Statistics for regARIMA Model Residuals:

Number of residuals	:	118
Skewness coefficient	:	0.0765
Geary's a	:	0.7625
Kurtosis	:	3.3513

No indication of lack of normality.

Tabla 49. Estadísticos de normalidad de residuos de modelo ARIMA de PDIESELPAIS.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; coeficiente de sesgo (Skewness coefficient), a de Geary y Curtosis no existe indicación de falta de normalidad.

4.3.6.4 Pronósticos Mensuales Ex ante

Se puede apreciar en la siguiente figura, la leve estacionalidad que poseen los pronósticos mensuales generados por el modelo estimado, dada principalmente por el parámetro de medias móviles estacionales (Seasonal MA).




Figura 51. Pronósticos mensuales ex ante Precios Diesel País.

4.3.7 Modelo ARIMA de Índice Mensual de Actividad Económica IMACEC

4.3.7.1 Ajustes preliminares de las series

Se seleccionó la transformación logarítmica de los datos debido a que los criterios de información fueron los de menor valor frente a la serie original.

```

Likelihood statistics for model fit to untransformed series.
Likelihood Statistics
-----
Number of observations (nobs)                119
Effective number of observations (nefobs)      106
Number of parameters estimated (np)           3
Log likelihood (L)                          -211.8233
AIC                                           429.6466
AICC (F-corrected-AIC)                      429.8819
Hannan Quinn                               432.8851
BIC                                           437.6369
-----
Likelihood statistics for model fit to log transformed series.
Likelihood Statistics
-----
Number of observations (nobs)                119
Effective number of observations (nefobs)      106
Number of parameters estimated (np)           3
Log likelihood                             278.5056
Transformation Adjustment                   -486.2804
Adjusted Log likelihood (L)                 -207.7748
AIC                                           421.5496
AICC (F-corrected-AIC)                      421.7849
Hannan Quinn                               424.7881
BIC                                           429.5399
-----
***** AICC (with aicdiff=-2.00) prefers log transformation *****

```

Tabla 50. Selección de transformación automática de IMACEC.

Se detectó en forma automática sólo un outlier aditivo (AO) en marzo de 2010.

Variable	Parameter Estimate	Standard Error	t-value
Automatically Identified Outliers			
AO2010.Mar	-0.0599	0.01065	-5.63

Tabla 51. Outliers identificados automáticamente de IMACEC.

4.3.7.2 Estimación

Se encontraron los cinco mejores modelos, eligiendo en forma automática el modelo de menor BIC de 9.223, esto es, el modelo N° 1 ARIMA (0 1 1)(0 1 1).

Best Five ARIMA Models

Model #	1	:	(0 1 1) (0 1 1)	(BIC =	-5.378)
Model #	2	:	(0 1 1) (0 1 2)	(BIC =	-5.373)
Model #	3	:	(0 1 1) (1 1 1)	(BIC =	-5.369)
Model #	4	:	(1 1 0) (0 1 2)	(BIC =	-5.368)
Model #	5	:	(2 1 0) (0 1 2)	(BIC =	-5.347)

Automatic model choice : (0 1 1) (0 1 1)

Tabla 52. Cinco mejores modelos ARIMA de IMACEC.

Respecto al modelo estimado, los únicos parámetros son de medias móviles estacional (Seasonal MA) y no estacional (Nonseasonal MA) y corresponden a 0.4161 y 0.3718, respectivamente. Existe una diferenciación estacional y no estacional.

ARIMA Model: (0 1 1) (0 1 1)		
Nonseasonal differences: 1		
Seasonal differences: 1		
Parameter	Estimate	Standard Errors

Nonseasonal MA		
Lag 1	0.3718	0.08894
Seasonal MA		
Lag 12	0.4161	0.08616
Variance	0.23156E-03	
SE of Var	0.31807E-04	

Tabla 53. Parámetros estimados del modelo ARIMA de IMACEC.




Figura 52. Ajuste de modelo ARIMA de IMACEC.

4.3.7.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.04	0.04	0.17	-0.02	0.00	-0.05	-0.22	0.10	0.04	-0.11	-0.03	0.08
SE	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.11	0.11	0.11	0.11
Q	0.21	0.35	3.44	3.49	3.49	3.78	9.14	10.30	10.51	12.05	12.18	12.90
DF	0	0	1	2	3	4	5	6	7	8	9	10
P	0.000	0.000	0.064	0.175	0.322	0.437	0.103	0.112	0.161	0.149	0.203	0.229

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	0.02	-0.04	-0.05	-0.05	0.00	0.06	-0.08	-0.08	0.12	-0.09	0.05	-0.15
SE	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11	0.11
Q	12.96	13.21	13.50	13.80	13.80	14.24	15.14	15.94	17.82	18.98	19.29	22.47
DF	11	12	13	14	15	16	17	18	19	20	21	22
P	0.296	0.354	0.410	0.464	0.541	0.581	0.585	0.597	0.534	0.523	0.566	0.432

Tabla 54. Autocorrelación muestral de los residuales de modelo ARIMA IMACEC.

En los rezagos (Lag) del 3 al 24 el estadístico Ljung-box (Q) es no significativo (P-values>0.05), por lo que no existe autocorrelación en los residuos del modelo.




Figura 53. Autocorrelación muestral de los residuales de modelo ARIMA IMACEC.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra dentro de los límites de línea punteada, por lo que la ACF no es

significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.04	0.03	0.17	-0.01	-0.01	-0.08	-0.23	0.09	0.10	-0.04	-0.09	0.05
SE	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	0.04	-0.06	-0.03	-0.06	-0.04	0.09	0.00	-0.11	0.04	-0.07	0.08	-0.18
SE	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10

Tabla 55. Autocorrelación parcial muestral de los residuales de modelo ARIMA IMACEC.




Figura 54. Autocorrelación parcial muestral de residuales de modelo ARIMA IMACEC.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las "X" se encuentra dentro de la banda de ± 2 SE, por lo que la PACF no es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 55. Histograma y estadísticas descriptivas residuales modelo ARIMA IMACEC.

La distribución de los residuos presenta una pequeña asimetría hacia la izquierda respecto de la media ($\text{Skewness} = -0.39 < 0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más aguzada que la normal definiéndose como una distribución leptocúrtica ($\text{Kurtosis} > 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p = 0.18 > 0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-0.049
Maximum	0.035
Median	0.001
Robust Std Dev	0.015

Normality Statistics for regARIMA Model Residuals:

Number of residuals	: 106
Skewness coefficient	: -0.3980
Geary's a	: 0.7920
Kurtosis	: 3.3561

No indication of lack of normality.

Tabla 56. Estadísticos de normalidad de residuales de modelo ARIMA de IMACEC.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; coeficiente de sesgo (Skewness coefficient), a de Geary y Kurtosis no existe indicación de falta de normalidad.

4.3.7.4 Pronósticos Mensuales Ex ante

Se puede apreciar en la figura 56, la marcada estacionalidad que poseen los pronósticos mensuales generados por el modelo ARIMA estimado de IMACEC, dada principalmente por el parámetro de medias móviles estacionales (Seasonal MA).




Figura 56. Pronósticos mensuales ex ante IMACEC.

4.4 Modelos Estructurales

4.4.1 Modelo Estructural de Consumo Nacional de Gasolina Automotriz

4.4.1.1 Verificación de Cointegración

Para aplicar el test de Engle-Granger de cointegración se estimó la siguiente regresión de cointegración. Todos los parámetros son significativos (Prob.<0.05) y un R cuadrado ajustado de 66,6%.

Dependent Variable: LOG(CGAS)
Method: Fully Modified Least Squares (FMOLS)
Date: 02/14/13 Time: 01:30
Sample: 2006M01 2012M11
Included observations: 83
Cointegrating equation deterministics: C
Long-run covariance estimate (Bartlett kernel, Newey-West fixed bandwidth = 4.0000)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PGASPAIS)	-0.232347	0.052917	-4.390807	0.0000
LOG(IMACEC)	0.842232	0.103055	8.172675	0.0000
LOG(CGAS(-1))	0.461188	0.068747	6.708484	0.0000
C	4.363470	0.728175	5.992338	0.0000
R-squared	0.678376	Mean dependent var	12.53239	
Adjusted R-squared	0.666163	S.D. dependent var	0.098149	
S.E. of regression	0.056709	Sum squared resid	0.254060	
Durbin-Watson stat	2.463394	Long-run variance	0.002328	

Tabla 57. Regresión de Cointegración de Consumo de Gasolina Automotriz.

El estadístico-tau de Engel-Granger (estadístico-t) y coeficiente de autocorrelación normalizada (estadístico-z), ambos rechazan la hipótesis nula de no cointegración entre las variables (raíz unitaria en los residuos) al 1% de nivel de significancia. Por lo tanto, la evidencia claramente sugiere que el consumo de gasolina, el precio y el IMACEC están cointegrados.

	Value	Prob.*
Engle-Granger tau-statistic	-10.48425	0.0000
Engle-Granger z-statistic	-94.29597	0.0000

*MacKinnon (1996) p-values.

Tabla 58. Test de Engle-Granger de cointegración⁵⁷.

⁵⁷ Test resumido, ver anexos para visualizar el test completo.

4.4.1.2 Estimación

En la siguiente tabla se puede apreciar el modelo estimado a través de Eviews del consumo de gasolina automotriz.

Dependent Variable: LOG(CGAS)
Method: Least Squares
Date: 02/14/13 Time: 01:30
Sample: 2006M01 2012M11
Included observations: 83
Convergence achieved after 13 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3.569107	0.382961	9.319774	0.0000
LOG(PGASPAIS)	-0.133386	0.031405	-4.247248	0.0001
LOG(IMACEC)	0.661179	0.072394	9.133014	0.0000
LOG(CGAS(-1))	0.541169	0.041815	12.94190	0.0000
ABR	-0.077455	0.013802	-5.611817	0.0000
JUN	-0.058804	0.013472	-4.364925	0.0000
NOV	-0.073410	0.013415	-5.472061	0.0000
DIC	0.067000	0.014079	4.758863	0.0000
D2009M10	0.213293	0.028994	7.356379	0.0000
D2012M08	-0.165810	0.030646	-5.410509	0.0000
AR(1)	-0.365547	0.112909	-3.237534	0.0018
AR(4)	-0.295227	0.109243	-2.702473	0.0086
R-squared	0.916158	Mean dependent var	12.53239	
Adjusted R-squared	0.903168	S.D. dependent var	0.098149	
S.E. of regression	0.030542	Akaike info criterion	-4.006435	
Sum squared resid	0.066230	Schwarz criterion	-3.656723	
Log likelihood	178.2671	Hannan-Quinn criter.	-3.865940	
F-statistic	70.52978	Durbin-Watson stat	1.885744	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.44-.51i	.44+.51i	-.62+.51i	-.62-.51i

Tabla 59. Estimación Modelo Estructural de Consumo de Gasolina Automotriz.

Todos los parámetros son significativos ($p\text{-value (Prob.)} < 0.05$). El modelo es significativo en forma global ($\text{Prob(F-statistics)} < 0.05$). La bondad de ajuste del modelo, medida a través del R cuadrado ajustado (Adjusted R-squared) es muy buena, puesto que el 90,3% de la variabilidad del consumo de gasolina es explicada por el modelo. Existen cuatro variables estacionales en los meses de abril, junio, noviembre y diciembre, dos variables dummy para los outliers en octubre de 2009 y agosto de 2008 y dos parámetros autorregresivos AR(1) y AR(4), los cuales eliminan la autocorrelación y mejoran el ajuste del modelo.




Figura 57. Ajuste de modelo estructural de consumo nacional de gasolina automotriz⁵⁸.

4.4.1.3 Tests de Especificación y Diagnóstico

A. Autocorrelación y Autocorrelación Parcial muestral de los residuos

Date: 02/14/13 Time: 03:32

Sample: 2006M01 2012M11

Included observations: 83

Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	0.038	0.038	0.1245
		2	0.118	0.117	1.3390
		3	0.119	0.112	2.5811
		4	-0.065	-0.087	2.9543
		5	-0.033	-0.058	3.0551
		6	-0.135	-0.133	4.7285
		7	-0.211	-0.187	8.8759
		8	-0.102	-0.067	9.8574
		9	0.077	0.163	10.419
		10	-0.118	-0.072	11.766
		11	-0.063	-0.114	12.154
		12	-0.018	-0.073	12.186
		13	0.057	0.064	12.515
		14	0.181	0.171	15.853
		15	0.161	0.177	18.549
		16	-0.016	-0.074	18.574
		17	0.250	0.144	25.261
		18	0.028	-0.060	25.349
		19	-0.030	-0.037	25.448
		20	-0.012	0.024	25.465
		21	-0.251	-0.140	32.632
		22	-0.010	0.044	32.643
		23	-0.044	0.015	32.867
		24	-0.102	-0.017	34.103

Figura 58. Correlograma de residuos de modelo estructural de CGAS.

⁵⁸ Gráfico en escala logarítmica.

Se puede apreciar en la figura que la Función de Autocorrelación (AC) y Autocorrelación Parcial (PAC) muestrales se encuentran dentro de los límites de línea punteada, por lo que la AC y PAC no son significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia. Adicionalmente, el estadístico Ljung-Box (Q) es no significativo ($P\text{-values} > 0.05$), por lo que no existe autocorrelación y autocorrelación parcial en los residuos del modelo.

B. Normalidad de los residuos




Figura 59. Histograma y estadísticas descriptivas de residuales modelo CGAS.

La distribución de los residuos presenta una pequeña asimetría hacia la izquierda respecto de la media ($\text{Skewness} = -0.21 < 0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más achatada que la normal definiéndose como una distribución platocúrtica ($\text{Kurtosis} > 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p = 0.62 > 0.05$. H_0 : datos provienen de distribución normal).

4.4.1.4 Pronósticos Mensuales Ex ante




Figura 60. Pronósticos mensuales ex ante modelo estructural de CGAS.

4.4.1.5 Pronósticos Semanales Ex ante




Figura 61. Pronósticos semanales modelo estructural de CGAS.

4.4.2 Modelo Estructural de Consumo Nacional de Diesel Vehicular

4.4.2.1 Verificación de Cointegración

Para aplicar el test de Engle-Granger de cointegración se estimó la siguiente regresión de cointegración. Todos los parámetros son significativos (Prob.<0.05) y un R cuadrado ajustado de 80,3%.

Dependent Variable: LOG(CDIESEL)
Method: Fully Modified Least Squares (FMOLS)
Date: 02/14/13 Time: 09:32
Sample (adjusted): 2003M02 2012M11
Included observations: 118 after adjustments
Cointegrating equation deterministics: C
Long-run covariance estimate (Bartlett kernel, Newey-West fixed bandwidth = 5.0000)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PDIESELPAIS)	-0.086768	0.043839	-1.979242	0.0502
LOG(IMACEC)	1.039022	0.082800	12.54864	0.0000
C	8.235086	0.201678	40.83289	0.0000
R-squared	0.806063	Mean dependent var	12.44201	
Adjusted R-squared	0.802690	S.D. dependent var	0.126509	
S.E. of regression	0.056195	Sum squared resid	0.363154	
Durbin-Watson stat	1.809255	Long-run variance	0.003623	

Tabla 60. Regresión de Cointegración de Consumo de Diesel Vehicular.

El estadístico-tau de Engel-Granger (estadístico-t) y coeficiente de autocorrelación normalizada (estadístico-z), ambos rechazan la hipótesis nula de no cointegración entre las variables (raíz unitaria en los residuos) al 1% de nivel de significancia. Por lo tanto, existe evidencia que sugiere que el consumo de diesel, el precio y el IMACEC están cointegrados.

	Value	Prob.*
Engle-Granger tau-statistic	-9.833502	0.0000
Engle-Granger z-statistic	-106.4221	0.0000

*MacKinnon (1996) p-values.

Tabla 61. Test de Engle-Granger de modelo estructural Consumo de Diesel Vehicular⁵⁹.

⁵⁹ Test resumido, ver anexos para visualizar el test completo.

4.4.2.2 Estimación

En la siguiente tabla se puede apreciar el modelo estimado a través de Eviews del consumo de diesel vehicular.

Dependent Variable: LOG(CDIESEL)
Method: Least Squares
Date: 02/14/13 Time: 09:32
Sample: 2003M01 2012M11
Included observations: 119

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7.058290	0.468281	15.07276	0.0000
LOG(PDIESELPAS)	-0.082419	0.026457	-3.115230	0.0023
LOG(IMACEC)	0.888745	0.065231	13.62460	0.0000
LOG(CDIESEL(-1))	0.147897	0.052097	2.838877	0.0054
FEB	0.042292	0.013318	3.175569	0.0019
JUN	-0.063199	0.011547	-5.473187	0.0000
D2006M08	-0.253065	0.035061	-7.217772	0.0000
D2009M10	0.180527	0.034751	5.194921	0.0000
D2009M11	-0.259855	0.036365	-7.145708	0.0000
R-squared	0.931508	Mean dependent var	12.44069	
Adjusted R-squared	0.926527	S.D. dependent var	0.126803	
S.E. of regression	0.034371	Akaike info criterion	-3.830588	
Sum squared resid	0.129950	Schwarz criterion	-3.620402	
Log likelihood	236.9200	Hannan-Quinn criter.	-3.745238	
F-statistic	187.0048	Durbin-Watson stat	2.025249	
Prob(F-statistic)	0.000000			

Tabla 62. Estimación Modelo Estructural de Consumo de Diesel Vehicular.

Todos los parámetros son significativos ($p\text{-value (Prob.)} < 0.05$). El modelo es significativo en forma global ($\text{Prob(F-statistics)} < 0.05$). La bondad de ajuste del modelo, medida a través del R cuadrado ajustado (Adjusted R-squared) es muy buena, puesto que el 92,6% de la variabilidad del consumo de diesel es explicada por el modelo. Existen dos variables estacionales en los meses de febrero y junio, y tres variables dummy para los outliers en octubre y noviembre de 2009 y agosto de 2008.




Figura 62. Ajuste de modelo estructural de consumo nacional de diesel vehicular⁶⁰.

4.4.2.3 Tests de Especificación y Diagnóstico

C. Autocorrelación y Autocorrelación Parcial muestral de los residuos

Date: 02/14/13 Time: 09:59
Sample: 2003M01 2012M11
Included observations: 119

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.019	-0.019	0.0430	0.836
		2 -0.043	-0.044	0.2745	0.872
		3 0.180	0.179	4.2983	0.231
		4 -0.155	-0.157	7.3229	0.120
		5 0.079	0.101	8.1202	0.150
		6 0.116	0.070	9.8246	0.132
		7 -0.116	-0.060	11.569	0.116
		8 0.029	-0.014	11.675	0.166
		9 0.111	0.106	13.297	0.150
		10 -0.184	-0.153	17.791	0.059
		11 0.078	0.060	18.607	0.069
		12 0.144	0.114	21.398	0.045
		13 -0.110	-0.027	23.050	0.041
		14 0.102	0.026	24.478	0.040
		15 -0.065	-0.084	25.059	0.049
		16 -0.220	-0.150	31.823	0.011
		17 0.162	0.092	35.516	0.005
		18 -0.091	-0.092	36.695	0.006
		19 -0.006	0.097	36.700	0.009
		20 0.108	-0.018	38.381	0.008
		21 -0.038	0.070	38.588	0.011
		22 -0.053	-0.066	38.999	0.014
		23 0.073	0.031	39.792	0.016
		24 0.051	0.093	40.184	0.020

Figura 63. Correlograma de residuos de modelo estructural de CDIESEL.

⁶⁰ Gráfico en escala logarítmica.

Se puede apreciar en la figura que la Función de Autocorrelación (AC) y Autocorrelación Parcial (PAC) muestrales se encuentran dentro de los límites de línea punteada, por lo que la AC y PAC no son significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia. Adicionalmente, el estadístico Ljung-Box (Q) es no significativo ($P\text{-values} > 0.05$), por lo que no existe autocorrelación y autocorrelación parcial en los residuos del modelo⁶¹.

D. Normalidad de los residuos




Figura 64. Histograma y estadísticas descriptivas de residuos modelo CDIESEL.

La distribución de los residuos presenta una pequeña asimetría hacia la izquierda respecto de la media ($\text{Skewness} = -0.078 < 0$). Su indicador de forma (Kurtosis) muestra que esta distribución es más aguzada que la normal definiéndose como una distribución leptocúrtica ($\text{Kurtosis} > 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p = 0.11 > 0.05$. H_0 : datos provienen de distribución normal).

4.4.2.4 Pronósticos Mensuales Ex ante




Figura 65. Pronósticos mensuales ex ante modelo estructural de CDIESEL.

⁶¹ Existen algunos rezagos que no cumplen esto, pero por criterio se acepta que el modelo en general no posee autocorrelación.

4.4.2.5 Pronósticos Semanales Ex ante

Se aprecia en el siguiente gráfico que los pronósticos semanales de fines de semana se ven afectados por la metodología complementaria, la cual en el caso del diésel hace disminuir el consumo en aquellas semanas.




Figura 66. Pronósticos semanales modelo estructural de CDIESEL.

4.4.3 Modelo Estructural de Consumo Nacional de GNC Vehicular

4.4.3.1 Verificación de Cointegración

Para aplicar el test de Engle-Granger de cointegración se estimó la siguiente regresión de cointegración, en la cual todos los parámetros son significativos (Prob.<0.1).

Dependent Variable: LOG(CGNC)
Method: Fully Modified Least Squares (FMOLS)
Date: 02/14/13 Time: 09:32
Sample (adjusted): 2003M02 2012M11
Included observations: 118 after adjustments
Cointegrating equation deterministics: C
Long-run covariance estimate (Bartlett kernel, Newey-West fixed bandwidth = 5.0000)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(IMACEC)	-1.041558	0.548207	-1.899937	0.0599
C	12.16896	2.502215	4.863276	0.0000
R-squared	0.074987	Mean dependent var	7.432360	
Adjusted R-squared	0.067012	S.D. dependent var	0.389947	
S.E. of regression	0.376654	Sum squared resid	16.45675	
Durbin-Watson stat	0.219030	Long-run variance	0.602619	

Tabla 63. Regresión de Cointegración de Consumo de GNC Vehicular.

El estadístico-tau de Engel-Granger (estadístico-t) y coeficiente de autocorrelación normalizada (estadístico-z), ambos no rechazan la hipótesis nula de no cointegración entre las variables (raíz unitaria en los residuos) al 5% de nivel de significancia. Por lo tanto, existe evidencia que sugiere que el consumo de GNC y el IMACEC no están cointegrados.

	Value	Prob.*
Engle-Granger tau-statistic	-1.793037	0.6347
Engle-Granger z-statistic	-6.713399	0.5853

*MacKinnon (1996) p-values.

Tabla 64. Test de Engle-Granger de modelo estructural Consumo de GNC Vehicular⁶².

⁶² Test resumido, ver anexos para visualizar el test completo.

4.4.3.2 Estimación

En la siguiente tabla se puede apreciar el modelo estimado a través de Eviews del consumo de GNC vehicular.

Dependent Variable: LOG(CGNC)
Method: Least Squares
Date: 02/14/13 Time: 10:59
Sample (adjusted): 2003M03 2012M11
Included observations: 117 after adjustments
Convergence achieved after 8 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3.226479	1.192642	2.705320	0.0079
LOG(IMACEC)	0.915037	0.243237	3.761916	0.0003
AR(1)	0.733741	0.092617	7.922304	0.0000
AR(2)	0.228995	0.092514	2.475244	0.0148
R-squared	0.887386	Mean dependent var	7.433714	
Adjusted R-squared	0.884397	S.D. dependent var	0.391345	
S.E. of regression	0.133059	Akaike info criterion	-1.162455	
Sum squared resid	2.000638	Schwarz criterion	-1.068021	
Log likelihood	72.00359	Hannan-Quinn criter.	-1.124116	
F-statistic	296.8103	Durbin-Watson stat	2.032659	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.97	-.24		

Tabla 65. Estimación Modelo Estructural de Consumo de GNC Vehicular.

Todos los parámetros son significativos ($p\text{-value (Prob.)} < 0.05$). El modelo es significativo en forma global ($\text{Prob(F-statistics)} < 0.05$). La bondad de ajuste del modelo, medida a través del R cuadrado ajustado (Adjusted R-squared) es buena, puesto que el 88,4% de la variabilidad del consumo de GNC es explicada por el modelo. Se incorporaron los parámetros autorregresivos AR(1) y AR(2) para corregir la autocorrelación de los residuos y simultáneamente mejorar el ajuste del modelo.



Figura 67. Ajuste de modelo estructural de consumo nacional de GNC vehicular⁶³.

4.4.3.3 Tests de Especificación y Diagnóstico

E. Autocorrelación y Autocorrelación Parcial muestral de los residuos

Date: 02/14/13 Time: 11:03
Sample: 2003M03 2012M11
Included observations: 117
Q-statistic probabilities adjusted for 2 ARMA term(s)

	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	-0.019	-0.019	0.0418			
2	-0.057	-0.057	0.4318			
3	0.070	0.068	1.0369	0.309		
4	-0.020	-0.021	1.0855	0.581		
5	0.037	0.045	1.2554	0.740		
6	0.068	0.062	1.8312	0.767		
7	-0.047	-0.039	2.1163	0.833		
8	-0.001	-0.000	2.1164	0.909		
9	0.147	0.136	4.8850	0.674		
10	-0.027	-0.017	4.9800	0.760		
11	0.053	0.063	5.3485	0.803		
12	0.129	0.114	7.5511	0.673		
13	-0.062	-0.042	8.0643	0.708		
14	-0.018	-0.028	8.1088	0.777		
15	-0.018	-0.052	8.1521	0.834		
16	-0.054	-0.043	8.5515	0.859		
17	0.055	0.035	8.9725	0.879		
18	-0.020	-0.048	9.0312	0.912		
19	0.031	0.065	9.1706	0.935		
20	0.025	0.003	9.2577	0.953		
21	-0.005	-0.023	9.2620	0.969		
22	-0.007	0.004	9.2684	0.980		
23	-0.014	-0.033	9.2969	0.987		
24	0.082	0.092	10.313	0.983		

Figura 68. Correlograma de residuales de modelo estructural de CGNC.

⁶³ Gráfico en escala logarítmica.

Se puede apreciar en la figura que la Función de Autocorrelación (AC) y Autocorrelación Parcial (PAC) muestral se encuentran dentro de los límites de línea punteada, por lo que la AC y PAC no son significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia. Adicionalmente, el estadístico Ljung-Box (Q) es no significativo ($P\text{-values} > 0.05$), por lo que no existe autocorrelación y autocorrelación parcial en los residuos del modelo.

F. Normalidad de los residuos




Figura 69. Histograma y estadísticas descriptivas de residuales modelo CGNC.

La distribución de los residuos presenta una gran asimetría hacia la izquierda respecto de la media ($\text{Skewness} = -3.35 < 0$). Su indicador de forma (Kurtosis) muestra que esta distribución es mucho más aguzada que la normal definiéndose como una distribución leptocúrtica ($\text{Kurtosis} \gg 3$), y el test de normalidad de Jarque-Bera indica que se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p = 0.0 < 0.05$. H_0 : datos provienen de distribución normal). Por lo tanto este modelo falla en este test de normalidad de los residuos, por lo que se viola uno de los supuestos del método de estimación OLS o MCO.

4.4.3.4 Pronósticos Mensuales Ex ante




Figura 70. Pronósticos mensuales ex ante modelo estructural de CGNC.

4.4.3.5 Pronósticos Semanales Ex ante




Figura 71. Pronósticos semanales modelo estructural de CGNC.

4.4.4 Modelo Estructural de Consumo Nacional de GLP Vehicular

4.4.4.1 Verificación de Cointegración

Para aplicar el test de Engle-Granger de cointegración se estimó la siguiente regresión de cointegración, en la cual todos los parámetros son significativos (Prob.<0.05).

Dependent Variable: LOG(CGLP)
Method: Fully Modified Least Squares (FMOLS)
Date: 02/14/13 Time: 10:59
Sample (adjusted): 2011M03 2012M11
Included observations: 21 after adjustments
Cointegrating equation deterministics: C
Long-run covariance estimate (Bartlett kernel, Newey-West fixed bandwidth = 3.0000)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(IMACEC)	1.198442	0.364767	3.285499	0.0041
LOG(CGLP(-1))	0.830654	0.051017	16.28178	0.0000
C	-4.248545	1.581823	-2.685853	0.0151
R-squared	0.942466	Mean dependent var	8.249218	
Adjusted R-squared	0.936073	S.D. dependent var	0.271968	
S.E. of regression	0.068764	Sum squared resid	0.085112	
Durbin-Watson stat	1.868396	Long-run variance	0.003650	

Tabla 66. Regresión de Cointegración de Consumo de GLP Vehicular.

El estadístico-tau de Engel-Granger (estadístico-t) y coeficiente de autocorrelación normalizada (estadístico-z), ambos rechazan la hipótesis nula de no cointegración entre las variables (raíz unitaria en los residuos) al 5% de nivel de significancia. Por lo tanto, existe evidencia que sugiere que el consumo de GLP y el IMACEC están cointegrados.

	Value	Prob.*
Engle-Granger tau-statistic	-6.028943	0.0015
Engle-Granger z-statistic	-26.82612	0.0013

*MacKinnon (1996) p-values.

Tabla 67. Test de Engle-Granger de modelo estructural Consumo de GLP Vehicular⁶⁴.

⁶⁴ Test resumido, ver anexos para visualizar el test completo.

4.4.4.2 Estimación

En la siguiente tabla se puede apreciar el modelo estimado a través de Eviews del consumo de GLP vehicular.

Dependent Variable: LOG(CGLP)
Method: Least Squares
Date: 02/14/13 Time: 10:59
Sample (adjusted): 2011M02 2012M11
Included observations: 22 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-7.051247	1.201505	-5.868681	0.0000
LOG(IMACEC)	1.896470	0.291943	6.496033	0.0000
LOG(CGLP(-1))	0.770570	0.042060	18.32055	0.0000
DIC	-0.251989	0.056300	-4.475814	0.0003
R-squared	0.979042	Mean dependent var	8.218302	
Adjusted R-squared	0.975549	S.D. dependent var	0.302442	
S.E. of regression	0.047292	Akaike info criterion	-3.101978	
Sum squared resid	0.040258	Schwarz criterion	-2.903606	
Log likelihood	38.12175	Hannan-Quinn criter.	-3.055247	
F-statistic	280.2890	Durbin-Watson stat	1.610276	
Prob(F-statistic)	0.000000			

Tabla 68. Estimación Modelo Estructural de Consumo de GLP Vehicular.

Todos los parámetros son significativos ($p\text{-value (Prob.)} < 0.05$). El modelo es significativo en forma global ($\text{Prob(F-statistics)} < 0.05$). La bondad de ajuste del modelo, medida a través del R cuadrado ajustado (Adjusted R-squared) es muy buena, puesto que el 97,5% de la variabilidad del consumo de GLP es explicada por el modelo. Se incorporó la variable dummy estacional de DIC.




Figura 72. Ajuste de modelo estructural de consumo nacional de GLP vehicular⁶⁵.

⁶⁵ Gráfico en escala logarítmica.

4.4.4.3 Tests de Especificación y Diagnóstico

A. Autocorrelación y Autocorrelación Parcial muestral de los residuos




Figura 73. Correlograma de residuales de modelo estructural de CGLP.

Se aprecia en la figura que la Función de Autocorrelación (AC) y Autocorrelación Parcial (PAC) muestral se encuentran dentro de los límites de línea punteada, por lo que la AC y PAC no son significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia. Adicionalmente, el estadístico Ljung-Box (Q) es no significativo ($P\text{-values} > 0.05$), por lo que no existe autocorrelación y autocorrelación parcial en los residuos del modelo.

B. Normalidad de los residuos




Figura 74. Histograma y estadísticas descriptivas de residuales modelo CGLP.

La distribución de los residuos presenta una leve asimetría hacia la izquierda respecto de la media ($\text{Skewness} = -0.49 < 0$). Su indicador de forma (Kurtosis) muestra que esta

distribución es más achatada que la normal definiéndose como una distribución platicúrtica ($Kurtosis < 3$), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.6 > 0.05$. H_0 : datos provienen de distribución normal).

4.4.4.4 Pronósticos Mensuales Ex ante




Figura 75. Pronósticos mensuales ex ante modelo estructural de CGLP.

4.4.4.5 Pronósticos Semanales Ex ante




Figura 76. Pronósticos semanales modelo estructural de CGLP.

4.5 Evaluación de Pronósticos Mensuales Ex Post

4.5.1 Evaluación de Pronósticos de Corto Plazo

Se evaluaron los pronósticos de corto plazo a 2 meses de los modelos ARIMA y estructurales para los diferentes consumos de combustibles. Se encontró que todos los modelos ARIMA poseen un mejor desempeño de pronóstico, excepto para el Consumo Nacional de Gas Natural Comprimido, en el que el modelo estructural posee levemente un mejor desempeño en todos los índices, excepto para el MAPE.

Modelo	RMSE	MAE	MAPE	THEIL
ARIMA Consumo Nacional de Gasolina Automotriz	5821.72	4696.80	1.64	0.0101
ARIMA Consumo Nacional de Diesel Vehicular	3567.70	2624.36	0.94	0.0064
ARIMA Consumo Nacional de Gas Natural Comprimido	63.46	51.88	3.19	0.0200
ARIMA Consumo Nacional de Gas Licuado de Petróleo	247.28	225.57	4.15	0.0220
Estructural Consumo Nacional de Gasolina Automotriz	6991.86	5467.52	1.91	0.0123
Estructural Consumo Nacional de Diesel Vehicular	7723.66	6225.96	2.25	0.0140
Estructural Consumo Nacional de Gas Natural Comprimido	57.97	51.81	3.20	0.0183
Estructural Consumo Nacional de Gas Licuado de Petróleo	586.95	460.10	8.52	0.0512

Tabla 69. Índices de evaluación de pronósticos de corto plazo de modelos⁶⁶.

4.5.2 Evaluación de Pronósticos de Largo Plazo

Se evaluaron los pronósticos de largo plazo a 18 meses de los modelos ARIMA y estructurales para los diferentes consumos de combustibles. Se encontró que los modelos estructurales de Consumo Nacional de Gasolina Automotriz y Consumo Nacional de GNC poseen un mejor desempeño de pronóstico que los modelos ARIMA, excepto para el Consumo Nacional de Diesel Vehicular, en el que el modelo ARIMA posee un mejor desempeño en todos los índices.

Modelo	RMSE	MAE	MAPE	THEIL
ARIMA Consumo Nacional de Gasolina Automotriz	15188.26	11391.13	3.89	0.0248
ARIMA Consumo Nacional de Diesel Vehicular	10248.69	8229.98	2.80	0.0172
ARIMA Consumo Nacional de Gas Natural Comprimido	388.08	314.43	15.47	0.1118
ARIMA Consumo Nacional de Gas Licuado de Petróleo (*)	-	-	-	-
Estructural Consumo Nacional de Gasolina Automotriz	15033.88	9827.37	3.39	0.0248
Estructural Consumo Nacional de Diesel Vehicular	11559.81	9476.66	3.23	0.0194
Estructural Consumo Nacional de Gas Natural Comprimido	280.34	220.49	10.79	0.0785
Estructural Consumo Nacional de Gas Licuado de Petróleo (*)	-	-	-	-

Tabla 70. Índices de evaluación de pronósticos de largo plazo de modelos.

Nota: (*) No fue posible evaluar a largo plazo (18 meses) estos modelos debido al reducido número de datos totales (23), por lo que no se podía estimar el modelo sólo con 5 datos.

⁶⁶ Todos estos índices están basados en el error de pronóstico dentro de la muestra o ex post, por lo que un menor índice involucra un mejor desempeño de pronóstico.

4.6 Metodología Complementaria

4.6.1 Metodología Complementaria Indirecta

Se estimó el siguiente modelo de PEAJEGAS, el cual elimina la tendencia a través de @trend y la estacionalidad, por medio de las variables dummy estacionales mensuales. Lo anterior se realizó para aislar el efecto real que posee la variable dummy FDSLARGO, la cual es significativa a un 5% ($\text{Prob.}=0.0239<0.05$), estimándose un coeficiente o parámetro positivo, esto es, cuando cambia la variable FDSLARGO de 0 a 1 (presencia de fin de semana largo), los peajes controlados de vehículos a gasolina aumentan, y por ende el consumo de gasolina aumentaría en forma indirecta.

Dependent Variable: LOG(PEAJEGAS)

Method: Least Squares

Date: 02/14/13 Time: 16:46

Sample: 2004M01 2012M11

Included observations: 107

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	14.49649	0.035998	402.7028	0.0000
@TREND	0.008181	0.000143	57.18116	0.0000
MAR	-0.278476	0.018590	-14.98022	0.0000
ABR	-0.333514	0.019987	-16.68686	0.0000
MAY	-0.367765	0.019987	-18.40021	0.0000
JUN	-0.436803	0.019561	-22.33036	0.0000
JUL	-0.325592	0.018725	-17.38850	0.0000
AGO	-0.380726	0.018730	-20.32690	0.0000
SEP	-0.309564	0.021046	-14.70901	0.0000
OCT	-0.315486	0.021050	-14.98730	0.0000
NOV	-0.312582	0.018954	-16.49183	0.0000
DIC	-0.175512	0.019535	-8.984580	0.0000
FDSLARGO	0.025680	0.011185	2.296029	0.0239
R-squared	0.977069	Mean dependent var	16.24347	
Adjusted R-squared	0.974141	S.D. dependent var	0.282525	
S.E. of regression	0.045432	Akaike info criterion	-3.231752	
Sum squared resid	0.194021	Schwarz criterion	-2.907016	
Log likelihood	185.8987	Hannan-Quinn criter.	-3.100108	
F-statistic	333.7678	Durbin-Watson stat	1.112163	
Prob(F-statistic)	0.000000			

Tabla 71. Modelo estimado para PEAJEGAS.

Se estimó el siguiente modelo de PEAJEDIESEL, el cual elimina la tendencia a través de @trend y la estacionalidad, por medio de las variables dummy estacionales mensuales. Lo anterior se realizó para aislar el efecto real que posee la variable dummy FDSLARGO, la cual es significativa a un 5% ($\text{Prob.}=0.0247<0.05$), estimándose un coeficiente o parámetro negativo, esto es, cuando cambia la variable FDSLARGO de 0 a 1 (presencia de fin de semana largo), los peajes controlados de vehículos a diesel disminuyen, y por ende el consumo de diesel disminuiría en forma indirecta.

Dependent Variable: LOG(PEAJEDIESEL)
Method: Least Squares
Date: 02/14/13 Time: 17:13
Sample (adjusted): 2003M02 2012M11
Included observations: 118 after adjustments
Convergence achieved after 4 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	14.22502	0.056602	251.3144	0.0000
@TREND	0.003906	0.000232	16.81056	0.0000
MAY	-0.057851	0.016044	-3.605741	0.0005
JUN	-0.139843	0.018492	-7.562216	0.0000
JUL	-0.107836	0.019219	-5.610772	0.0000
AGO	-0.102638	0.019359	-5.301791	0.0000
SEP	-0.124191	0.019789	-6.275707	0.0000
OCT	-0.048328	0.018901	-2.556938	0.0120
NOV	-0.058858	0.016265	-3.618793	0.0005
FDSLARGO	-0.019702	0.008648	-2.278374	0.0247
AR(1)	0.453166	0.086732	5.224922	0.0000
R-squared	0.912032	Mean dependent var	15.09561	
Adjusted R-squared	0.903811	S.D. dependent var	0.151192	
S.E. of regression	0.046891	Akaike info criterion	-3.193389	
Sum squared resid	0.235270	Schwarz criterion	-2.935105	
Log likelihood	199.4100	Hannan-Quinn criter.	-3.088518	
F-statistic	110.9356	Durbin-Watson stat	2.272484	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.45			

Tabla 72. Modelo estimado para PEAJEDIESEL.

Estos resultados sirven como una primera aproximación para verificar la hipótesis de que existe una relación directa entre los fines de semana largos y la variación en los consumos mensuales de gasolina y diésel por efecto de un mayor flujo de vehículos que salen de Santiago y de otras regiones con un objetivo turístico, aprovechando este feriado adicional a los fines de semana.

4.6.2 Metodología Complementaria Directa

Se cuantificó el efecto directo de los fines de semana largos en la variación del consumo de gasolina mediante el modelo de consumo estructural, incorporando la variable FDSLARGO como variable dummy explicativa, la cual es significativa a un 10% (Prob.=0.0678<0.10), estimándose un coeficiente o parámetro positivo, esto es, cuando cambia la variable FDSLARGO de 0 a 1 (presencia de fin de semana largo), el consumo de gasolina aumenta en forma directa. Este coeficiente corresponde a 0,01177.

Dependent Variable: LOG(CGAS)
Method: Least Squares
Date: 02/14/13 Time: 17:35
Sample: 2006M01 2012M11
Included observations: 83
Convergence achieved after 13 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3.476649	0.376436	9.235690	0.0000
LOG(PGASPAIS)	-0.135222	0.030472	-4.437575	0.0000
LOG(IMACEC)	0.645933	0.071993	8.972110	0.0000
LOG(CGAS(-1))	0.554675	0.041649	13.31788	0.0000
ABR	-0.081694	0.013589	-6.011611	0.0000
JUN	-0.060531	0.013458	-4.497829	0.0000
NOV	-0.072436	0.013396	-5.407222	0.0000
DIC	0.068853	0.013791	4.992679	0.0000
D2009M10	0.202825	0.028595	7.093037	0.0000
D2012M08	-0.161365	0.030077	-5.365092	0.0000
FDSLARGO	0.011777	0.006349	1.854764	0.0678
AR(1)	-0.396539	0.110670	-3.583087	0.0006
AR(4)	-0.306816	0.106557	-2.879365	0.0053
R-squared	0.920017	Mean dependent var	12.53239	
Adjusted R-squared	0.906305	S.D. dependent var	0.098149	
S.E. of regression	0.030043	Akaike info criterion	-4.029459	
Sum squared resid	0.063181	Schwarz criterion	-3.650604	
Log likelihood	180.2225	Hannan-Quinn criter.	-3.877256	
F-statistic	67.09855	Durbin-Watson stat	1.962401	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.44-.52i	.44+.52i	-.64+.51i	-.64-.51i

Tabla 73. Modelo estimado para CGAS, incluyendo FDSLARGO.

Debido a que el coeficiente de la variable FDSLARGO está relacionado con la variable CGAS en logaritmo natural (LOG) se necesita la siguiente expresión para pasar este coeficiente a porcentaje:

$$FDSGAS = (e^{0,01177} - 1) * 100 = 1,1846\%$$

Lo cual significa que cuando existe la presencia de un fin de semana largo, el consumo mensual de gasolina aumenta en 1,1846%.

Adicionalmente, se cuantificó el efecto directo de los fines de semana largos en la variación del consumo de diesel mediante el modelo de consumo estructural de diesel, incorporando la variable FDSLARGO como variable dummy explicativa, la cual es significativa a un 1% (Prob.=0.0043<0.01), estimándose un coeficiente o parámetro negativo, esto es, cuando cambia la variable FDSLARGO de 0 a 1 (presencia de fin de semana largo), el consumo de diesel disminuye en forma directa. Este coeficiente corresponde a -0,01913.

Dependent Variable: LOG(CDIESEL)
Method: Least Squares
Date: 02/14/13 Time: 17:35
Sample: 2003M01 2012M11
Included observations: 119

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7.017878	0.453286	15.48224	0.0000
LOG(PDIESELPAIS)	-0.077109	0.025662	-3.004751	0.0033
LOG(IMACEC)	0.878729	0.063206	13.90263	0.0000
LOG(CDIESEL(-1))	0.153041	0.050436	3.034361	0.0030
FEB	0.031046	0.013450	2.308250	0.0229
JUN	-0.060434	0.011212	-5.389983	0.0000
D2006M08	-0.263859	0.034124	-7.732365	0.0000
D2009M10	0.189861	0.033774	5.621486	0.0000
D2009M11	-0.270960	0.035390	-7.656483	0.0000
FDSLARGO	-0.019131	0.006559	-2.916877	0.0043
R-squared	0.936468	Mean dependent var	12.44069	
Adjusted R-squared	0.931222	S.D. dependent var	0.126803	
S.E. of regression	0.033255	Akaike info criterion	-3.888941	
Sum squared resid	0.120541	Schwarz criterion	-3.655402	
Log likelihood	241.3920	Hannan-Quinn criter.	-3.794108	
F-statistic	178.5178	Durbin-Watson stat	1.972076	
Prob(F-statistic)	0.000000			

Tabla 74. Modelo estimado para CDIESEL, incluyendo FDSLARGO.

Análogamente a la gasolina se necesita la siguiente expresión para pasar este coeficiente a porcentaje:

$$FDS DIESEL = (e^{-0,01913} - 1) * 100 = -1,8949\%$$

Lo cual significa que cuando existe la presencia de un fin de semana largo, el consumo mensual de diesel disminuye en 1,8949%.

Estas variaciones en los consumos mensuales de gasolina y diésel se traspasaron a los pronósticos semanales de los modelos ARIMA y estructurales respectivos donde existiera un fin de semana largo, de la siguiente forma:

$$CGAS_t^{(t_0)} = \begin{cases} CGAS_t * (1,011846) & \text{para } t = t_0 \\ CGAS_t & \text{para } t \neq t_0 \end{cases}$$

Donde:

t_0 : es la semana donde se presenta un fin de semana largo.

t : semanas.

$CGAS_t$: Consumo de gasolina en m³ de la semana t.

Análogamente para el consumo de diesel se tiene:

$$CDIESEL_t^{(t_0)} = \begin{cases} CDIESEL_t * (0,98105) & \text{para } t = t_0 \\ CDIESEL_t & \text{para } t \neq t_0 \end{cases}$$

Donde:

t_0 : es la semana donde se presenta un fin de semana largo.

t : semanas.

$CDIESEL_t$: Consumo de diesel en m³ de la semana t.

4.7 Análisis Comparativo de Modelos ARIMA utilizados por la CNE

4.7.1 Modelo ARIMA de Consumo Nacional de Gasolina Automotriz⁶⁷

El modelo utilizado por la CNE para el consumo de gasolina automotriz es un modelo ARIMA (2 1 1)(0 1 1), esto es, posee dos componentes autorregresivos no estacionales, AR(1) y AR(2), un componente de media móvil no estacional MA(1) y un componente de media móvil estacional (seasonal MA), además de que posee una diferenciación no estacional y una estacional.

Los datos utilizados por la CNE para estimar el modelo o muestra de estimación corresponde a la totalidad de la data disponible para el consumo de gasolina, esto es, desde enero de 1988 hasta la actualidad, la cual va siendo actualizada mes a mes en la medida que el último dato de consumo de gasolina está disponible.

Antes de estimar el modelo los datos son transformados en forma logarítmica y ajustados por el largo del mes (lom). Adicionalmente, se detectan automáticamente los outlier aditivos (AO) y de cambio de régimen o level shift (LS).

Por último, se pronostica un intervalo de 12 meses fuera de la muestra de estimación y la metodología para pasar de pronósticos mensuales a semanales es una ponderación de los pronósticos de la forma detallada en (), pero sin una metodología complementaria de ajuste de los consumos tal como se formula en el presente estudio.

4.7.1.1 Ajustes preliminares de las series

Se detectaron en forma automática 3 outliers aditivo (AO) y dos cambio de régimen (LS).

Variable	Parameter Estimate	Standard Error	t-value
Automatically Identified Outliers			
LS1990.Sep	-0.0832	0.01881	-4.43
LS1994.Jan	0.0804	0.01851	4.34
AO2004.Jan	0.1327	0.02441	5.44
AO2009.Oct	0.2498	0.02465	10.13
AO2012.Aug	-0.1666	0.02695	-6.18

Tabla 75. Outliers identificados automáticamente de modelo ARIMA CNE de CGAS.

⁶⁷ Para mayor detalle del archivo de especificación .spc X-12 ARIMA ver anexo.

4.7.1.2 Estimación

Respecto al modelo estimado, los parámetros autorregresivos no estacionales AR(1) y AR(2) (Nonseasonal AR) corresponden a -0.3418 y -0.3921, respectivamente, mientras que el parámetro de medias móviles no estacional (Nonseasonal MA) corresponde a 0.42 y de medias móviles estacional (Seasonal MA) corresponde a 0.6897. Existe desde luego una diferenciación estacional y no estacional.

ARIMA Model: (2 1 1) (0 1 1)		
Nonseasonal differences: 1		
Seasonal differences: 1		
Parameter	Estimate	Standard Errors

Nonseasonal AR		
Lag 1	-0.3418	0.08769
Lag 2	-0.3921	0.06814
Nonseasonal MA		
Lag 1	0.4230	0.09105
Seasonal MA		
Lag 12	0.6897	0.04403
Variance	0.89225E-03	
SE of Var	0.74614E-04	

Tabla 76. Parámetros estimados del modelo ARIMA CNE de CGAS.




Figura 77. Ajuste de modelo ARIMA CNE de CGAS.

4.7.1.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.01	-0.01	0.01	0.05	0.01	0.06	-0.13	0.09	0.07	-0.04	0.15	0.05
SE	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06
Q	0.01	0.06	0.07	0.76	0.77	1.75	6.70	8.89	10.20	10.74	17.62	18.39
DF	0	0	0	0	1	2	3	4	5	6	7	8
P	0.000	0.000	0.000	0.000	0.380	0.417	0.082	0.064	0.070	0.097	0.014	0.019

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	-0.05	0.08	0.07	-0.04	0.11	-0.02	-0.09	0.12	-0.02	0.05	0.04	-0.01
SE	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.07	0.07	0.07	0.07
Q	19.05	20.81	22.36	22.94	26.47	26.65	29.25	33.77	33.87	34.78	35.35	35.37
DF	9	10	11	12	13	14	15	16	17	18	19	20
P	0.025	0.022	0.022	0.028	0.015	0.021	0.015	0.006	0.009	0.010	0.013	0.018

Tabla 77. Autocorrelación muestral de los residuos de modelo ARIMA CNE de CGAS.

En los rezagos (Lag) del 11 al 24 el estadístico Ljung-box (Q) es significativo (P-values<0.05), por lo que existe autocorrelación en los residuos del modelo.




Figura 78. Autocorrelación muestral de los residuos de modelo ARIMA CNE de CGAS.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra fuera de los límites de línea punteada en el rezago 11, por lo que

la ACF es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia, por lo que se verifica autocorrelación en los residuos del modelo.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.01	-0.01	0.01	0.05	0.01	0.06	-0.13	0.09	0.06	-0.05	0.17	0.04
SE	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	-0.04	0.06	0.07	-0.04	0.08	0.01	-0.12	0.10	-0.01	0.05	0.01	0.02
SE	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06

Tabla 78. Autocorrelación parcial muestral de los residuales de modelo ARIMA CNE de CGAS.




Figura 79. Autocorrelación parcial muestral residuales de modelo ARIMA CNE de CGAS.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las "X" se encuentra fuera de la banda de ± 2 SE en el rezago 11, por lo que la PACF es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 80. Histograma y estadísticas descriptivas residuales modelo ARIMA CNE de CGAS.

La distribución de los residuos presenta una pequeña asimetría hacia la derecha respecto de la media (Skewness=0.0042>0). Su indicador de forma (Kurtosis) muestra que esta distribución es más aguzada que la normal definiéndose como una distribución leptocúrtica (Kurtosis>3), y el test de normalidad de Jarque-Bera indica que no se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p=0.45>0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-0.091
Maximum	0.091
Median	-0.001
Robust Std Dev	0.028

Normality Statistics for regARIMA Model Residuals:

Number of residuals	:	286
Skewness coefficient	:	0.0042
Geary's a	:	0.7888
Kurtosis	:	3.3645

No indication of lack of normality.

Tabla 79. Estadísticos de normalidad de residuales de modelo ARIMA CNE de CGAS.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; coeficiente de sesgo (Skewness coefficient), a de Geary y Curtosis no existe indicación de falta de normalidad.

4.7.1.4 Pronósticos Mensuales Ex ante




Figura 81. Pronósticos mensuales ex ante modelo ARIMA CNE de CGAS.

4.7.2 Modelo ARIMA de Consumo Nacional de Diesel Vehicular⁶⁸

El modelo utilizado por la CNE para el consumo de diesel vehicular es un modelo ARIMA (0 1 1)(0 1 1), esto es, posee un componente de media móvil no estacional MA(1) y un componente de media móvil estacional (seasonal MA), además presenta una diferenciación no estacional y una estacional.

Los datos utilizados por la CNE para estimar el modelo o muestra de estimación corresponde a la totalidad de la data disponible para el consumo de diesel, esto es, desde enero de 1998 hasta la actualidad, y al igual que el modelo de consumo de gasolina, la data va siendo actualizada mes a mes en la medida que el último dato de consumo de diesel está disponible.

Antes de estimar el modelo, los datos son transformados en forma logarítmica y ajustados por el largo del mes (lom). Adicionalmente, se detectan automáticamente los outlier aditivos (AO) y de cambio de régimen o level shift (LS). Por último, se pronostica un intervalo de 12 meses fuera de la muestra de estimación.

4.7.2.1 Ajustes preliminares de las series

Se detectaron en forma automática 3 outliers aditivoS (AO) en los meses de agosto de 2006, octubre y noviembre de 2009.

Variable	Parameter Estimate	Standard Error	t-value
Automatically Identified Outliers			
AO2006.Aug	-0.2696	0.03104	-8.69
AO2009.Oct	0.1692	0.03114	5.44
AO2009.Nov	-0.2117	0.03114	-6.80

Tabla 80. Outliers identificados automáticamente de modelo ARIMA CNE de CDIESEL.

4.7.2.2 Estimación

Respecto al modelo estimado, el parámetro de medias móviles no estacional (Nonseasonal MA) corresponde a 0.8395 y de medias móviles estacional (Seasonal MA) corresponde a 0.9988. Existe desde luego una diferenciación estacional y no estacional.

⁶⁸ Para mayor detalle del archivo de especificación .spc X-12 ARIMA ver anexo.

ARIMA Model: (0 1 1)(0 1 1)
Nonseasonal differences: 1
Seasonal differences: 1

Parameter	Estimate	Standard Errors
Nonseasonal MA		
Lag 1	0.8395	0.03819
Seasonal MA		
Lag 12	0.9988	0.04794
Variance	0.98046E-03	
SE of Var	0.10762E-03	

Tabla 81. Parámetros estimados del modelo ARIMA CNE de CDIESEL.




Figura 82. Ajuste de modelo ARIMA CNE de CDIESEL.

4.7.2.3 Tests de Especificación y Diagnóstico

A. Autocorrelación muestral de los residuos

Sample Autocorrelations of the Residuals with the Ljung-Box diagnostic.

Lag	1	2	3	4	5	6	7	8	9	10	11	12
ACF	-0.08	-0.05	0.18	-0.15	0.09	0.12	-0.16	0.09	0.09	-0.17	-0.02	-0.02
SE	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.09	0.09	0.09	0.09	0.09
Q	1.16	1.53	7.11	10.86	12.32	14.84	19.09	20.41	21.95	26.97	27.01	27.07
DF	0	0	1	2	3	4	5	6	7	8	9	10
P	0.000	0.000	0.008	0.004	0.006	0.005	0.002	0.002	0.003	0.001	0.001	0.003

Lag	13	14	15	16	17	18	19	20	21	22	23	24
ACF	-0.11	0.05	-0.01	-0.23	0.11	-0.04	-0.06	0.18	-0.09	-0.07	0.13	-0.21
SE	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.10	0.10	0.10	0.10
Q	29.09	29.52	29.55	39.81	41.88	42.19	42.90	48.95	50.37	51.43	54.92	63.66
DF	11	12	13	14	15	16	17	18	19	20	21	22
P	0.002	0.003	0.005	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000

Tabla 82. Autocorrelación muestral de los residuos de modelo ARIMA CNE de CDIESEL.

En los rezagos (Lag) del 3 al 24 el estadístico Ljung-box (Q) es significativo (P-values<0.05), por lo que existe una fuerte autocorrelación en los residuos del modelo.




Figura 83. Autocorrelación muestral de los residuales de modelo ARIMA CNE de CGAS.

Se puede apreciar en la figura que la Función de Autocorrelación (ACF) denotada por las "X" se encuentra fuera de los límites de línea punteada en el rezago 3 y 16, por lo que la ACF es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia, por lo que se verifica autocorrelación en los residuos del modelo.

B. Autocorrelación Parcial muestral de los residuos

Sample Partial Autocorrelations of the Residuals

Lag	1	2	3	4	5	6	7	8	9	10	11	12
PACF	-0.08	-0.05	0.17	-0.13	0.09	0.09	-0.10	0.04	0.08	-0.11	-0.10	-0.03
SE	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08

Lag	13	14	15	16	17	18	19	20	21	22	23	24
PACF	-0.05	-0.02	0.00	-0.19	0.05	-0.03	0.03	0.11	-0.01	-0.07	0.03	-0.15
SE	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08

Tabla 83. Autocorrelación parcial muestral de residuales de modelo ARIMA CNE de CDIESEL.




Figura 84. Autocorrelación parcial muestral residuales de modelo ARIMA CNE de CGAS.

Al igual que la autocorrelación, la autocorrelación parcial de los residuos denotada por las "X" se encuentra fuera de la banda de ± 2 SE en el rezago 16, por lo que la PACF es significativamente distinta de cero a (aproximadamente) un 5% de nivel de significancia.

C. Normalidad de los residuos




Figura 85. Estadísticas descriptivas residuales modelo ARIMA CNE de CDIESEL.

La distribución de los residuos presenta una fuerte asimetría hacia la izquierda respecto de la media (Skewness=-0.52<0). Su indicador de forma (Kurtosis) muestra que esta distribución es más aguzada que la normal definiéndose como una

distribución leptocúrtica ($Kurtosis > 3$), y el test de normalidad de Jarque-Bera indica que se rechaza la hipótesis nula de que estos datos provienen de una distribución normal (valor $p = 0.005 < 0.05$. H_0 : datos provienen de distribución normal).

Summary Statistics for the Unstandardized Residuals

Minimum	-0.098
Maximum	0.085
Median	0.004
Robust Std Dev	0.028

Normality Statistics for regARIMA Model Residuals:

Number of residuals	:	166	
Skewness coefficient	:	-0.5268	(significant negative skewness at one percent level)
Geary's a	:	0.7803	
Kurtosis	:	3.6353	

Significant skewness has been detected in the model residuals; this makes the Geary's a and Kurtosis statistics unreliable indicators of the normality of the residuals.

Tabla 84. Estadísticos de normalidad de residuales de modelo ARIMA CNE de CDIESEL.

De acuerdo a los estadísticos de normalidad para los residuales del modelo ARIMA; el coeficiente de sesgo (Skewness coefficient) es significativamente negativo al nivel de 1%, lo que hace que los estadísticos a de Geary y Curtosis no sean indicadores confiables de la normalidad de los residuos.

Como conclusión el modelo posee serías fallas en cuanto a la violación de los supuestos básicos como la presencia de autocorrelación en los residuos y falta de normalidad o heterocedastidad de los residuos, lo que produce parámetros estimados sesgados y no consistentes, lo que se traduce en pronósticos menos eficientes.

4.7.2.4 Pronósticos Mensuales Ex ante




Figura 86. Pronósticos mensuales ex ante modelo ARIMA CNE de CDIESEL.

4.7.3 Comparación de Desempeño de Pronósticos Ex Post entre Modelos

4.7.3.1 Pronósticos Ex Post de Corto Plazo

En cuanto al desempeño de pronósticos en el corto plazo (2 meses) para el consumo de gasolina automotriz, los modelos propuestos en el presente estudio, ARIMA y estructural son más eficientes que el modelo utilizado actualmente por la CNE de acuerdo a los cuatro índices de desempeño de pronósticos.

Respecto del consumo de diésel vehicular, sólo el modelo ARIMA propuesto en el presente estudio es más eficiente que el utilizado actualmente por la CNE, con alrededor de un 50% menos en el índice RMSE.

Modelo	RMSE	MAE	MAPE	THEIL
ARIMA Consumo Nacional de Gasolina Automotriz	5821.72	4696.80	1.64	0.0101
ARIMA CNE Consumo Nacional de Gasolina Automotriz	7903.84	6019.55	2.10	0.0139
Estructural Consumo Nacional de Gasolina Automotriz	6991.86	5467.52	1.91	0.0123
ARIMA Consumo Nacional de Diesel Vehicular	3567.70	2624.36	0.94	0.0064
ARIMA CNE Consumo Nacional de Diesel Vehicular	7240.67	7238.22	2.61	0.0130
Estructural Consumo Nacional de Diesel Vehicular	7723.66	6225.96	2.25	0.0140

Tabla 85. Comparación de Índices de evaluación de pronósticos de corto plazo de modelos.

4.7.3.2 Pronósticos Ex Post de Largo Plazo

En cuanto al desempeño de pronósticos en el largo plazo (18 meses) para el consumo de gasolina automotriz, los modelos propuestos en el presente estudio, ARIMA y estructural son menos eficientes que el modelo utilizado actualmente por la CNE de acuerdo a los cuatro índices de desempeño de pronósticos.

Respecto del consumo de diésel vehicular, sólo el modelo ARIMA propuesto en el presente estudio es más eficiente que el utilizado actualmente por la CNE.

Modelo	RMSE	MAE	MAPE	THEIL
ARIMA Consumo Nacional de Gasolina Automotriz	15188.26	11391.13	3.89	0.0248
ARIMA CNE Consumo Nacional de Gasolina Automotriz	11764.88	7824.50	2.68	0.0196
Estructural Consumo Nacional de Gasolina Automotriz	15033.88	9827.37	3.39	0.0248
ARIMA Consumo Nacional de Diesel Vehicular	10248.69	8229.98	2.80	0.0172
ARIMA CNE Consumo Nacional de Diesel Vehicular	10468.94	8421.45	2.89	0.0176
Estructural Consumo Nacional de Diesel Vehicular	11559.81	9476.66	3.23	0.0194

Tabla 86. Comparación de Índices de evaluación de pronósticos de largo plazo de modelos.

4.8 Programa MODELOS desarrollado en Eviews 7 para la CNE

Se desarrolló un programa llamado MODELOS con el objeto “program” en Eviews 7, que automatiza todos los cálculos econométricos, desde la lectura de los datos desde la base de datos Excel “BDModelos.xls”, el proceso y generación de todos los objetos en Eviews y por último la escritura de los pronósticos en dos archivos de salida en formato Excel:

- 1) Pronosticos_Mensuales_15_02_2013
- 2) Pronosticos_Semanales_15_02_2013

Con la extensión del día, mes y año en el cual se ejecuta el programa, esto es:

- 1) Pronosticos_Mensuales_DD_MM_YYYY
- 2) Pronosticos_Semanales_DD_MM_YYYY

Adicionalmente, se guarda un archivo de extensión Eviews (.wf1) con todos los cálculos realizados en esa ejecución con el siguiente nombre:

- Modelos_DD_MM_YY

	cdiesel	14-02-2013 21:15	Archivo SPC
	cgas	14-02-2013 19:49	Archivo SPC
	cgnc	12-02-2013 15:42	Archivo SPC
	evaluacion	14-02-2013 19:49	Archivo SPC
	evaluacioncgnc	12-02-2013 10:26	Archivo SPC
	imacec	12-02-2013 17:07	Archivo SPC
	pdieselpais	13-02-2013 21:10	Archivo SPC
	pdieselrm	12-02-2013 17:07	Archivo SPC
	pgaspais	13-02-2013 21:10	Archivo SPC
	pgasrm	13-02-2013 21:06	Archivo SPC
	pgncr12	12-02-2013 17:06	Archivo SPC
	modelos	15-02-2013 9:59	EViews Program
	sub_estruc_evaluacion	15-02-2013 10:02	EViews Program
	sub_grafico_ajuste	15-02-2013 10:03	EViews Program
	sub_grafico_pronosticos	15-02-2013 10:04	EViews Program
	sub_grafico_series	15-02-2013 10:04	EViews Program
	sub_grafico_series1	15-02-2013 10:05	EViews Program
	sub_muestras	15-02-2013 10:05	EViews Program
	sub_x12_estimacion_total	15-02-2013 10:05	EViews Program
	sub_x12_evaluacion	15-02-2013 10:06	EViews Program
	Modelos_15_02_2013	15-02-2013 10:08	EViews Workfile
	BDModelos	06-02-2013 17:23	Hoja de cálculo de Microsoft Excel 97-2003
	Pronosticos_Mensuales_15_02_2013	15-02-2013 10:08	Hoja de cálculo de Microsoft Excel 97-2003
	Pronosticos_Semanales_15_02_2013	15-02-2013 10:08	Hoja de cálculo de Microsoft Excel 97-2003

Figura 87. Archivos necesarios y generados por el programa MODELOS en Eviews

Los archivos con extensión .spc son los archivos necesarios para ejecutar el software X-12 ARIMA desde Eviews mediante código programado en el programa MODELOS. Se encuentran varias subrutinas con el prefijo “sub_” y la base de datos a actualizar mensualmente por la CNE para correr el programa. Estos archivos van en el CD adjunto a este informe, los cuales se tienen grabar en un directorio con a lo más 2 raíces, esto es: “C:\CNE\Modelos”, puesto que el programa Eviews tiene problemas para leer directorios con más de 3 raíces.

4.9 Propuesta de Software

Se propone utilizar el software Eviews 7.2 para actualizar los modelos econométricos y del software X-12 ARIMA, el cual viene incorporado en el primero.



Figura 88. Software Eviews 7.

4.9.1 Precios de Licencias de Eviews

EViews 7 Single-User Pricing¹

All single-user copies of EViews 7 come with complete documentation provided in PDF format on the EViews CD-ROM. Printed versions of the documentation, four volumes with over 2800 pages, are available with software purchase at a discounted price of \$100.

New purchases of EViews 7 come with a printed copy of *EViews Illustrated for Version 7* by Richard Startz (432 pages). This primer on the use of EViews is available with EViews upgrades at additional charge.

Purchase EViews 7 today and you will receive a free upgrade to EViews 8 once it is released!

Single Copy Price²

Version	Commercial	Academic
	CD only / CD & Manuals	CD only / CD & Manuals
EViews Standard Edition 7 + EViews Illustrated	\$1075 Buy online / \$1175	\$425 / \$525
EViews Enterprise Edition 7 + EViews Illustrated	\$1375 / \$1475	\$575 / \$675

Figura 89. Precios de Software Eviews 7.

5 CONCLUSIONES Y RECOMENDACIONES

En el presente estudio se proponen y aplican modelos de series de tiempo ARIMA y modelos estructurales para proyectar en el corto y largo plazo el consumo de combustibles afectos al impuesto específico de la ley N° 18.502. Además, se propone una metodología complementaria para pasar de pronósticos mensuales a semanales incorporando el efecto de los fines de semana largos en la variación semanal de los combustibles gasolina automotriz y diésel vehicular. Finalmente, se evalúan los pronósticos de los diversos modelos en el corto y largo plazo y se comparan con los actuales modelos utilizados por la CNE. A continuación se presentan las principales conclusiones y recomendaciones que se generan a partir de este estudio.

5.1 Conclusiones

Todas las series de tiempo utilizadas en los modelos ARIMA y estructurales eran originalmente no estacionarias e integradas de orden uno, fundamento precursor relevante en el tratamiento y posterior modelamiento de dichas series.

Si bien el módulo de selección automática del software X-12 ARIMA (AUTOMDL) permite seleccionar la configuración de los diversos parámetros autorregresivos, de medias móviles y diferenciación de acuerdo a criterios de información, calculados a través de la función logarítmica de máxima verosimilitud, es necesario llevar a cabo un chequeo o diagnóstico exhaustivo del cumplimiento de los supuestos básicos de la teoría econométrica de estimación, tales como la no presencia de autocorrelación en los residuos y la verificación de normalidad de estos mismos, puesto que dicho módulo falla en el cumplimiento principalmente del estadístico Q de Ljung-Box, el cual verifica autocorrelación y autocorrelación parcial muestral de los residuos, por lo que es necesaria la iteración con la muestra de estimación de las diferentes series para cumplir con los supuestos antes mencionados. De acuerdo a lo anterior, las muestras de estimación finales para los modelos ARIMA de consumo de los diversos combustibles y variables explicativas de los modelos estructurales, tales como precios e IMACEC, fueron seleccionadas bajo el criterio de cumplimiento de los supuestos anteriormente mencionados.

Debido a que los precios de los combustibles gas natural comprimido y gas licuado de petróleo no fueron significativos en la inclusión de los modelos estructurales y adicionalmente no tuvieron un comportamiento satisfactorio en la estimación y diagnóstico de modelos ARIMA no se consideraron susceptibles de modelamiento. Por otro lado, para los precios de GLP se contaba con muy poca data (23), por lo que no fue posible modelarlo mediante el software X-12 ARIMA, ya que acepta como mínimo 36 datos y respecto de los precios de GNC, estos presentaron poca variabilidad en el tiempo, tanto los precios en la Región Metropolitana como los de la XII Región, lo que no permitió una estimación y diagnóstico satisfactoria de dichos modelos.

En todos los modelos estimados no se discriminó en cuanto a corto o largo plazo, sólo se diferenció al evaluar los pronósticos en corto plazo, correspondiente al periodo de dos meses y la evaluación de largo plazo, correspondiente a un periodo de dieciocho meses.

Todos los modelos ARIMA de consumo de combustibles, precios e IMACEC estimados cumplieron con los supuestos básicos de no autocorrelación y autocorrelación parcial muestral de los residuos, además de verificar normalidad en estos mismos.

Para el consumo de gasolina automotriz se obtuvo el modelo ARIMA por defecto o “airline model”, esto es, el modelo $ARIMA(0\ 1\ 1)(0\ 1\ 1)$, lo que permite concluir que para la muestra de estimación desde enero de 2006 a noviembre de 2012 el modelo por defecto prevaleció ante el resto de combinatorias de modelos ARIMA. Adicionalmente, se obtuvo un modelo estructural para el consumo de gasolina automotriz que tuvo un mejor desempeño en el largo plazo que el modelo ARIMA, mientras que este último se desempeñó mejor en el corto plazo. No obstante lo anterior, hay que considerar que con el modelo estructural se realizan pronósticos llamados condicionales, esto es, “condicionados” a los pronósticos de las variables independientes o explicativas, en este caso, el precio de la gasolina e IMACEC, por lo que su desempeño real se tendrá que verificar a medida que se evalúen a su vez la variabilidad de los pronósticos de estas variables en su conjunto. De acuerdo a lo anterior, se puede decidir utilizar de forma dual el modelo ARIMA en los pronósticos de corto plazo y el estructural en el los de largo plazo. Adicionalmente, hay que considerar que dentro de los resultados, el modelo ARIMA actualmente utilizado por la CNE, esto es el modelo $ARIMA(2\ 1\ 1)(0\ 1\ 1)$, es competitivamente mejor en el largo plazo que los modelos ARIMA y estructural estimados en el presente estudio, aunque presente autocorrelación en sus residuos.

Para el consumo de diésel vehicular se obtuvo un modelo $ARIMA(3\ 0\ 0)(0\ 1\ 1)$ para una muestra de estimación desde enero de 2005 hasta noviembre de 2012 y un modelo estructural en función del precio del diésel e IMACEC. En ambos periodos de evaluación de pronósticos, de corto y largo plazo el primero fue superior en desempeño. Adicionalmente, también fue superior en todos los índices de desempeño al utilizado actualmente por la CNE, esto es un modelo “airline” $ARIMA(0\ 1\ 1)(0\ 1\ 1)$ que utiliza el total de la muestra para su estimación. Cabe destacar que este modelo utilizado por la CNE posee una fuerte autocorrelación en sus residuos, además de problemas de normalidad es estos mismos, traducándose en un modelo inestable y poco confiable en la generación de sus pronósticos.

Respecto del consumo de gas natural comprimido, el modelo estructural es superior en desempeño de pronósticos en el corto y largo plazo frente al modelo ARIMA estimado. No obstante lo anterior, se debe señalar que en el modelo estructural de GNC no se verifica cointegración entre el consumo de GNC e IMACEC, por lo que dichas variables en el modelo podrían tener una relación o regresión espuria, la cual se sustenta en la

forma de las tendencias de cada una de las variables, por lo que no es recomendable su utilización, puesto que los pronósticos que se hagan con este modelo estructural dependerán de una relación entre las variables que definitivamente no es de causa efecto.

Para el consumo de gas licuado de petróleo vehicular se estimó un modelo ARIMA autorregresivo de orden 2 o AR(2), el cual es muy superior en desempeño en el corto plazo que el modelo estructural estimado. Los desempeños de largo plazo de estos modelos no se llevaron a cabo debido a la restricción en el número de datos disponibles, puesto que para evaluar dichos pronósticos ex post sólo se contaba con 5 datos para la estimación.

Finalmente, se propuso y aplicó una metodología complementaria satisfactoria que cuantificó el efecto que producen los fines de semana largos en la variación de los consumos semanales respectivos de gasolina y diésel.

5.2 Recomendaciones

En general se recomienda la utilización de los modelos ARIMA estimados para los pronósticos de corto plazo, esto es, pronósticos a dos meses. Asimismo se recomienda la utilización de los modelos estructurales en los pronósticos de largo plazo en los casos en que su desempeño fue superior. No obstante lo anterior, la dinámica misma de las series de tiempo puede cambiar el desempeño de uno u otro modelo, por lo que se recomienda el monitoreo y evaluación constante, esto es, mes a mes de la estimación de cada uno de los modelos y la evaluación de sus desempeños en el corto y largo plazo, lo que se traducirá en la elaboración de una trayectoria de desempeño en el tiempo, que puede ser más beneficiosa que evaluar los modelos de forma estática en un solo instante.

Se recomienda la formulación de un mecanismo de recolección de datos de consumo semanal de los diversos combustibles con el objetivo de verificar estadísticamente que la metodología complementaria propuesta en el presente estudio sea un mecanismo plausible de corrección de la variación en el consumo por efecto de los fines de semana largos. Asimismo, es conveniente disponer de datos semanales de consumo nacional de combustibles, puesto que los mejores modelos en cuanto a pronósticos son los estimados con la misma frecuencia de tiempo.

Se recomienda la capacitación del personal de Hidrocarburos de la CNE en el manejo del software Eviews, con el objetivo de mantener y actualizar los modelos ARIMA y estructurales estimados.

6 REFERENCIAS

Araya, C., 2008. Modelos de Pronóstico de Corto Plazo para Precios del Petróleo WTI Spot, Petrotecnia, Instituto Argentino del Petróleo y Gas (IAPG).

Atkins F.J. y S.M. Tayyebi, 2004. A Literature Review of Demand Studies en World Oil Markets, Discussion Paper 2004-07, Department of Economics, University of Calgary, Calgary, Alberta, Canada.

Box, G., G. Jenkins and G. Reinsel, 2008. Time Series Analysis: Forecasting and Control (4th ed.). Ed. John Wiley & Sons, New Jersey.

Engle, R. F., and C. W. J. Granger (1987). "Co-integration and Error Correction: Representation, Estimation, and Testing," *Econometrica*, 55, 251-276.

EViews 7 User's Guide I, II, 2010. Quantitative Micro Software, LLC.

EViews 7 Command and Programming Reference, 2010. Quantitative Micro Software, LLC.

EViews 7 Object Reference, 2010. Quantitative Micro Software, LLC.

Green, W., 2008. Análisis Econométrico. Tercera Edición. Ed. Prentice Hall.

Gujarati, D.N., 2001. Econometría Básica, Ed. McGraw Hill, Tercera Edición.

Hamilton J., 1994. Time Series Analysis, 3th Ed. Prentice Hall, Princeton, New Jersey.

Ley 18.502, 1986. Establece Impuestos a Combustibles que Señala. Diario Oficial de la República de Chile.

Ley 20.493, 2011. Crea un Nuevo Sistema de Protección al Contribuyente ante las Variaciones en los Precios Internacionales de los Combustibles. Diario Oficial de la República de Chile.

Mujica, R., 1981. Análisis de la demanda y predicción del consumo de hidrocarburos en Chile : 1980-2000, Cuadernos de Economía, 58. Pontificia Universidad Católica de Chile.

Phillips, Peter C. B. and Bruce E. Hansen (1990). "Statistical Inference in Instrumental Variables Regression with I(1) Processes," *Review of Economics Studies*, 57, 99-125.

Pindyck, R., y D. Rubinfeld, 2001. Econometría: Modelos y Pronósticos, Ed. McGraw Hill, Cuarta Edición.

U.S. Census Bureau, 2011. X12 ARIMA Reference Manual.

Zeng T., and Swanson N. R., 1998. "Predictive evaluation of econometric forecasting models in commodity future markets", *Studies in Nonlinear Dynamics and Econometrics*, 2, 159-177.

7 ANEXOS

7.1 Anexo 1: Pruebas ADF consumo de gasolina automotriz

Null Hypothesis: CGAS has a unit root

Exogenous: Constant

Lag Length: 15 (Automatic - based on SIC, maxlag=15)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.280680	0.6392
Test critical values: 1% level	-3.453317	
5% level	-2.871546	
10% level	-2.572174	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(CGAS)

Method: Least Squares

Date: 02/10/13 Time: 10:43

Sample (adjusted): 1989M05 2012M11

Included observations: 283 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CGAS(-1)	-0.020140	0.015726	-1.280680	0.2014
D(CGAS(-1))	-0.752802	0.061312	-12.27827	0.0000
D(CGAS(-2))	-0.609381	0.074517	-8.177785	0.0000
D(CGAS(-3))	-0.341336	0.080149	-4.258777	0.0000
D(CGAS(-4))	-0.267859	0.076413	-3.505411	0.0005
D(CGAS(-5))	-0.145651	0.078003	-1.867258	0.0630
D(CGAS(-6))	-0.320460	0.077954	-4.110910	0.0001
D(CGAS(-7))	-0.285586	0.080065	-3.566939	0.0004
D(CGAS(-8))	-0.301957	0.080489	-3.751551	0.0002
D(CGAS(-9))	-0.149565	0.080946	-1.847714	0.0658
D(CGAS(-10))	-0.151974	0.079156	-1.919928	0.0559
D(CGAS(-11))	-0.025887	0.079202	-0.326841	0.7440
D(CGAS(-12))	0.483685	0.077744	6.221482	0.0000
D(CGAS(-13))	0.392051	0.081128	4.832509	0.0000
D(CGAS(-14))	0.340611	0.076557	4.449103	0.0000
D(CGAS(-15))	0.211608	0.063158	3.350443	0.0009
C	6503.738	3888.715	1.672465	0.0956
R-squared	0.632629	Mean dependent var	636.1714	
Adjusted R-squared	0.610531	S.D. dependent var	18015.68	
S.E. of regression	11243.12	Akaike info criterion	21.55109	
Sum squared resid	3.36E+10	Schwarz criterion	21.77008	
Log likelihood	-3032.479	Hannan-Quinn criter.	21.63890	
F-statistic	28.62898	Durbin-Watson stat	2.017789	
Prob(F-statistic)	0.000000			

Null Hypothesis: D(CGAS) has a unit root
Exogenous: Constant
Lag Length: 14 (Automatic - based on SIC, maxlag=15)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.769026	0.0036
Test critical values: 1% level	-3.453317	
5% level	-2.871546	
10% level	-2.572174	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(CGAS,2)
Method: Least Squares
Date: 02/10/13 Time: 11:07
Sample (adjusted): 1989M05 2012M11
Included observations: 283 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CGAS(-1))	-2.856466	0.757879	-3.769026	0.0002
D(CGAS(-1),2)	1.090662	0.743328	1.467269	0.1435
D(CGAS(-2),2)	0.474765	0.717264	0.661911	0.5086
D(CGAS(-3),2)	0.132355	0.679861	0.194679	0.8458
D(CGAS(-4),2)	-0.134297	0.626892	-0.214227	0.8305
D(CGAS(-5),2)	-0.276465	0.569960	-0.485060	0.6280
D(CGAS(-6),2)	-0.592036	0.511411	-1.157653	0.2480
D(CGAS(-7),2)	-0.870514	0.450553	-1.932103	0.0544
D(CGAS(-8),2)	-1.163708	0.391471	-2.972651	0.0032
D(CGAS(-9),2)	-1.302730	0.336062	-3.876459	0.0001
D(CGAS(-10),2)	-1.443341	0.285774	-5.050644	0.0000
D(CGAS(-11),2)	-1.457002	0.234900	-6.202648	0.0000
D(CGAS(-12),2)	-0.960287	0.186487	-5.149352	0.0000
D(CGAS(-13),2)	-0.559040	0.125321	-4.460862	0.0000
D(CGAS(-14),2)	-0.213189	0.063222	-3.372085	0.0009
C	1629.483	798.7961	2.039924	0.0423
R-squared	0.873527	Mean dependent var	76.52110	
Adjusted R-squared	0.866422	S.D. dependent var	30799.23	
S.E. of regression	11256.59	Akaike info criterion	21.55017	
Sum squared resid	3.38E+10	Schwarz criterion	21.75627	
Log likelihood	-3033.349	Hannan-Quinn criter.	21.63281	
F-statistic	122.9420	Durbin-Watson stat	2.019521	
Prob(F-statistic)	0.000000			

7.2 Anexo 2: Pruebas ADF consumo de diesel vehicular

Null Hypothesis: CDIESEL has a unit root

Exogenous: Constant

Lag Length: 11 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.822023	0.9942
Test critical values: 1% level	-3.469691	
5% level	-2.878723	
10% level	-2.576010	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(CDIESEL)

Method: Least Squares

Date: 02/10/13 Time: 11:11

Sample (adjusted): 1999M01 2012M11

Included observations: 167 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CDIESEL(-1)	0.022325	0.027159	0.822023	0.4123
D(CDIESEL(-1))	-0.961412	0.078559	-12.23802	0.0000
D(CDIESEL(-2))	-0.721109	0.101717	-7.089391	0.0000
D(CDIESEL(-3))	-0.542052	0.109053	-4.970537	0.0000
D(CDIESEL(-4))	-0.691811	0.108040	-6.403309	0.0000
D(CDIESEL(-5))	-0.654101	0.112212	-5.829129	0.0000
D(CDIESEL(-6))	-0.669794	0.113011	-5.926791	0.0000
D(CDIESEL(-7))	-0.624863	0.113826	-5.489625	0.0000
D(CDIESEL(-8))	-0.604114	0.110535	-5.465387	0.0000
D(CDIESEL(-9))	-0.543323	0.111194	-4.886250	0.0000
D(CDIESEL(-10))	-0.549131	0.101970	-5.385220	0.0000
D(CDIESEL(-11))	-0.429145	0.075822	-5.659880	0.0000
C	724.0437	6363.917	0.113773	0.9096
R-squared	0.593079	Mean dependent var	814.3935	
Adjusted R-squared	0.561370	S.D. dependent var	19087.32	
S.E. of regression	12641.36	Akaike info criterion	21.80198	
Sum squared resid	2.46E+10	Schwarz criterion	22.04470	
Log likelihood	-1807.466	Hannan-Quinn criter.	21.90050	
F-statistic	18.70428	Durbin-Watson stat	2.010573	
Prob(F-statistic)	0.000000			

Null Hypothesis: D(CDIESEL) has a unit root
Exogenous: Constant
Lag Length: 10 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.01208	0.0000
Test critical values: 1% level	-3.469691	
5% level	-2.878723	
10% level	-2.576010	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(CDIESEL,2)
Method: Least Squares
Date: 02/10/13 Time: 11:14
Sample (adjusted): 1999M01 2012M11
Included observations: 167 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CDIESEL(-1))	-7.806358	0.779694	-10.01208	0.0000
D(CDIESEL(-1),2)	5.867444	0.744584	7.880161	0.0000
D(CDIESEL(-2),2)	5.166871	0.687419	7.516336	0.0000
D(CDIESEL(-3),2)	4.643983	0.619498	7.496361	0.0000
D(CDIESEL(-4),2)	3.970876	0.552484	7.187313	0.0000
D(CDIESEL(-5),2)	3.335400	0.478951	6.963974	0.0000
D(CDIESEL(-6),2)	2.682949	0.402688	6.662596	0.0000
D(CDIESEL(-7),2)	2.074818	0.323601	6.411662	0.0000
D(CDIESEL(-8),2)	1.487074	0.247516	6.008001	0.0000
D(CDIESEL(-9),2)	0.959415	0.161457	5.942245	0.0000
D(CDIESEL(-10),2)	0.422418	0.075300	5.609767	0.0000
C	5871.740	1131.903	5.187496	0.0000
R-squared	0.870155	Mean dependent var	-67.50578	
Adjusted R-squared	0.860940	S.D. dependent var	33863.96	
S.E. of regression	12628.13	Akaike info criterion	21.79439	
Sum squared resid	2.47E+10	Schwarz criterion	22.01843	
Log likelihood	-1807.831	Hannan-Quinn criter.	21.88532	
F-statistic	94.42976	Durbin-Watson stat	2.002076	
Prob(F-statistic)	0.000000			

7.3 Anexo 3: Pruebas ADF Consumo de GLP Vehicular

Null Hypothesis: CGLP has a unit root
Exogenous: Constant
Lag Length: 1 (Automatic - based on SIC, maxlag=4)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.638277	0.8416
Test critical values: 1% level	-3.788030	
5% level	-3.012363	
10% level	-2.646119	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(CGLP)
Method: Least Squares
Date: 02/10/13 Time: 11:23
Sample (adjusted): 2011M03 2012M11
Included observations: 21 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CGLP(-1)	-0.029847	0.046762	-0.638277	0.5313
D(CGLP(-1))	-0.546422	0.194257	-2.812883	0.0115
C	366.2933	180.1231	2.033572	0.0570
R-squared	0.348280	Mean dependent var		163.8886
Adjusted R-squared	0.275867	S.D. dependent var		266.0811
S.E. of regression	226.4245	Akaike info criterion		13.81426
Sum squared resid	922824.8	Schwarz criterion		13.96348
Log likelihood	-142.0498	Hannan-Quinn criter.		13.84665
F-statistic	4.809612	Durbin-Watson stat		1.437069
Prob(F-statistic)	0.021210			

Null Hypothesis: D(CGLP) has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=4)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.451968	0.0000
Test critical values: 1% level	-3.788030	
5% level	-3.012363	
10% level	-2.646119	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(CGLP,2)
Method: Least Squares
Date: 02/10/13 Time: 11:26
Sample (adjusted): 2011M03 2012M11
Included observations: 21 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CGLP(-1))	-1.574392	0.186275	-8.451968	0.0000
C	257.5019	57.33102	4.491493	0.0002
R-squared	0.789906	Mean dependent var		0.910632
Adjusted R-squared	0.778849	S.D. dependent var		473.9122
S.E. of regression	222.8655	Akaike info criterion		13.74141
Sum squared resid	943711.3	Schwarz criterion		13.84088
Log likelihood	-142.2848	Hannan-Quinn criter.		13.76300
F-statistic	71.43576	Durbin-Watson stat		1.402515
Prob(F-statistic)	0.000000			

7.4 Anexo 4: Pruebas ADF Consumo de GNC Vehicular

Null Hypothesis: CGNC has a unit root
Exogenous: Constant
Lag Length: 1 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.157624	0.2229
Test critical values: 1% level	-3.477144	
5% level	-2.881978	
10% level	-2.577747	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(CGNC)
Method: Least Squares
Date: 02/10/13 Time: 11:29
Sample (adjusted): 2001M03 2012M11
Included observations: 141 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CGNC(-1)	-0.058911	0.027304	-2.157624	0.0327
D(CGNC(-1))	-0.302031	0.080092	-3.771043	0.0002
C	115.5171	48.97333	2.358775	0.0197
R-squared	0.134411	Mean dependent var	14.59130	
Adjusted R-squared	0.121867	S.D. dependent var	262.1848	
S.E. of regression	245.6902	Akaike info criterion	13.86707	
Sum squared resid	8330186.	Schwarz criterion	13.92981	
Log likelihood	-974.6282	Hannan-Quinn criter.	13.89256	
F-statistic	10.71454	Durbin-Watson stat	2.008396	
Prob(F-statistic)	0.000047			

Null Hypothesis: D(CGNC) has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-16.47858	0.0000
Test critical values: 1% level	-3.477144	
5% level	-2.881978	
10% level	-2.577747	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(CGNC,2)
Method: Least Squares
Date: 02/10/13 Time: 11:30
Sample (adjusted): 2001M03 2012M11
Included observations: 141 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CGNC(-1))	-1.325090	0.080413	-16.47858	0.0000
C	19.78395	21.00046	0.942072	0.3478
R-squared	0.661425	Mean dependent var	-1.381648	
Adjusted R-squared	0.658989	S.D. dependent var	426.2262	
S.E. of regression	248.8997	Akaike info criterion	13.88606	
Sum squared resid	8611200.	Schwarz criterion	13.92789	
Log likelihood	-976.9672	Hannan-Quinn criter.	13.90306	
F-statistic	271.5438	Durbin-Watson stat	2.014228	
Prob(F-statistic)	0.000000			

7.5 Anexo 5: Tests de Cointegración de Engle-Granger

Cointegration Test - Engle-Granger

Date: 02/24/13 Time: 16:15

Equation: EQ_CGASPAIS1

Specification: LOG(CGAS) LOG(PGASPAIS) LOG(IMACEC)
LOG(CGAS(-1)) C

Cointegrating equation deterministics: C

Null hypothesis: Series are not cointegrated

Automatic lag specification (lag=0 based on Schwarz Info Criterion,
maxlag=11)

	Value	Prob.*
Engle-Granger tau-statistic	-10.48425	0.0000
Engle-Granger z-statistic	-94.29597	0.0000

*MacKinnon (1996) p-values.

Intermediate Results:

Rho - 1	-1.149951
Rho S.E.	0.109684
Residual variance	0.002978
Long-run residual variance	0.002978
Number of lags	0
Number of observations	82
Number of stochastic trends**	4

**Number of stochastic trends in asymptotic distribution.

Engle-Granger Test Equation:

Dependent Variable: D(RESID)

Method: Least Squares

Date: 02/24/13 Time: 16:15

Sample (adjusted): 2006M02 2012M11

Included observations: 82 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID(-1)	-1.149951	0.109684	-10.48425	0.0000
R-squared	0.575732	Mean dependent var		-0.000302
Adjusted R-squared	0.575732	S.D. dependent var		0.083785
S.E. of regression	0.054574	Akaike info criterion		-2.966403
Sum squared resid	0.241243	Schwarz criterion		-2.937053
Log likelihood	122.6225	Hannan-Quinn criter.		-2.954619
Durbin-Watson stat	1.975619			

Cointegration Test - Engle-Granger

Date: 02/24/13 Time: 16:15

Equation: EQ_CDIESELPAIS1

Specification: LOG(CDIESEL) LOG(PDIESELPAIS) LOG(IMACEC) C

Cointegrating equation deterministics: C

Null hypothesis: Series are not cointegrated

Automatic lag specification (lag=0 based on Schwarz Info Criterion,
maxlag=12)

	Value	Prob.*
Engle-Granger tau-statistic	-9.833502	0.0000
Engle-Granger z-statistic	-106.4221	0.0000

*MacKinnon (1996) p-values.

Intermediate Results:

Rho - 1	-0.901882
Rho S.E.	0.091715
Residual variance	0.003026
Long-run residual variance	0.003026
Number of lags	0
Number of observations	118
Number of stochastic trends**	3

**Number of stochastic trends in asymptotic distribution.

Engle-Granger Test Equation:

Dependent Variable: D(RESID)

Method: Least Squares

Date: 02/24/13 Time: 16:15

Sample (adjusted): 2003M02 2012M11

Included observations: 118 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID(-1)	-0.901882	0.091715	-9.833502	0.0000
R-squared	0.452488	Mean dependent var		-0.000311
Adjusted R-squared	0.452488	S.D. dependent var		0.074345
S.E. of regression	0.055011	Akaike info criterion		-2.954138
Sum squared resid	0.354063	Schwarz criterion		-2.930658
Log likelihood	175.2941	Hannan-Quinn criter.		-2.944604
Durbin-Watson stat	2.009205			

Cointegration Test - Engle-Granger

Date: 02/24/13 Time: 16:15

Equation: EQ_CGLP1

Specification: LOG(CGLP) LOG(IMACEC) LOG(CGLP(-1)) C

Cointegrating equation deterministics: C

Null hypothesis: Series are not cointegrated

Automatic lag specification (lag=0 based on Schwarz Info Criterion,
maxlag=4)

	Value	Prob.*
Engle-Granger tau-statistic	-6.028943	0.0015
Engle-Granger z-statistic	-26.82612	0.0013

*MacKinnon (1996) p-values.

Intermediate Results:

Rho - 1	-1.277434
Rho S.E.	0.211884
Residual variance	0.003532
Long-run residual variance	0.003532
Number of lags	0
Number of observations	21
Number of stochastic trends**	3

**Number of stochastic trends in asymptotic distribution.

Engle-Granger Test Equation:

Dependent Variable: D(RESID)

Method: Least Squares

Date: 02/24/13 Time: 16:15

Sample (adjusted): 2011M03 2012M11

Included observations: 21 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID(-1)	-1.277434	0.211884	-6.028943	0.0000
R-squared	0.645052	Mean dependent var		0.000549
Adjusted R-squared	0.645052	S.D. dependent var		0.099754
S.E. of regression	0.059431	Akaike info criterion		-2.761560
Sum squared resid	0.070640	Schwarz criterion		-2.711820
Log likelihood	29.99637	Hannan-Quinn criter.		-2.750765
Durbin-Watson stat	1.548228			

Cointegration Test - Engle-Granger

Date: 02/24/13 Time: 16:15

Equation: EQ_CGNC1

Specification: LOG(CGNC) LOG(IMACEC) C

Cointegrating equation deterministics: C

Null hypothesis: Series are not cointegrated

Automatic lag specification (lag=1 based on Schwarz Info Criterion, maxlag=12)

	Value	Prob.*
Engle-Granger tau-statistic	-1.793037	0.6347
Engle-Granger z-statistic	-6.713399	0.5853

*MacKinnon (1996) p-values.

Intermediate Results:

Rho - 1	-0.073195
Rho S.E.	0.040822
Residual variance	0.025310
Long-run residual variance	0.015554
Number of lags	1
Number of observations	117
Number of stochastic trends**	2

**Number of stochastic trends in asymptotic distribution.

Engle-Granger Test Equation:

Dependent Variable: D(RESID)

Method: Least Squares

Date: 02/24/13 Time: 16:15

Sample (adjusted): 2003M03 2012M11

Included observations: 117 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID(-1)	-0.073195	0.040822	-1.793037	0.0756
D(RESID(-1))	-0.275637	0.089700	-3.072874	0.0026
R-squared	0.122042	Mean dependent var		0.007069
Adjusted R-squared	0.114408	S.D. dependent var		0.169057
S.E. of regression	0.159092	Akaike info criterion		-0.821720
Sum squared resid	2.910686	Schwarz criterion		-0.774503
Log likelihood	50.07063	Hannan-Quinn criter.		-0.802551
Durbin-Watson stat	1.991062			

7.6 Anexo 6: Archivo de especificación de consumo de gasolina X-12 ARIMA utilizado por la CNE⁶⁹

#gasolina automotriz consumo mensual

```
series {file="gautm1.dat"
        format="(7x,f20.0)"
        title="gasolina automotriz"
        start=1988.1
#   span=(1988.1,2000.4)
#   modelspan=(1988.1,1999.12)
        period=12
        decimals=4
}
transform {function=log
            adjust=lom
}
x11 {mode=mult
     seasonalma=msr
#   print=(none+b1+d10+d11)
}
#automdl {mode=fcst
#   file="modelo1.mdl"
#   method=best
#}
arima {model=(2 1 1)(0 1 1)
}
estimate {
}
outlier {types=(ao ls)
         print=(none+header)
}
forecast {maxlead=12
          save=(transformed)
}
```

⁶⁹ “#” corresponde a un comentario y la línea del archivo que lo posee no está incluida como especificación.

7.7 Anexo 7: Archivo de especificación de consumo de diesel X-12 ARIMA utilizado por la CNE⁷⁰

#petroleo diesel consumo vehicular mensual

```
series {file="pdm1v.dat"
        format="(7x,f20.0)"
        title="petroleo diesel"
        start=1998.1
#   span=(1988.1,2000.1)
        period=12
        decimals=4
}
transform {function=log
            adjust=lom
}
x11 {mode=mult
     seasonalma=msr
#   print=(none+b1+d10+d11)
}
#automdl {mode=fcst
#   file="modelo1.mdl"
#   method=best
#}
arima {model=(0 1 1)(0 1 1)
}
estimate {
}
outlier {types=(ao ls)
         print=(none+header)
}
forecast {maxlead=12
          save=(transformed)
}
```

⁷⁰ “#” corresponde a un comentario y la línea del archivo que lo posee no está incluida como especificación.

7.8 Anexo 8: Archivo de especificación de consumos de combustibles X-12 ARIMA utilizado en el presente estudio

```
transform {function=auto
}

outlier {types=(ao ls)
        print=(none+header)
}
automdl{maxorder= (3 2)
        maxdiff=(2 1)
        acceptdefault=no
        checkmu=yes
        ljungboxlimit=0.95
        mixed=yes
        print=(bestfivemdl autochoice autofinaltests)
        savelog = (automodel all)
}

estimate {save=(model residuals)
}

check{save=(acf)
      print=(all)
}

forecast {maxlead=24
          save=(variances transformedbcst transformed)
}
```

7.9 Anexo 9: Pronósticos mensuales de modelos ARIMA y Estructurales

Fecha	Modelos ARIMA				Modelos Estructurales			
	CGAS	CDIESEL	CGNC	CGLP	CGAS	CDIESEL	CGNC	CGLP
2012M12	346964.0	306923.0	2213.3	5674.7	367163.6	336100.3	2290.6	5171.3
2013M01	333252.7	322597.3	2100.8	5670.4	343870.6	309072.1	2065.5	5284.2
2013M02	318349.5	306977.4	1934.2	5825.8	328264.9	305079.7	1976.8	4907.6
2013M03	322877.5	323357.9	2312.6	5885.0	341939.2	329251.8	2233.6	5992.7
2013M04	305373.7	319434.8	2290.5	5990.2	322102.7	319386.7	2140.7	6418.2
2013M05	309246.3	310558.1	2426.7	6062.7	335929.1	321930.4	2165.9	6951.8
2013M06	298242.9	294498.9	2420.4	6146.5	319162.7	297079.2	2122.9	7110.8
2013M07	306518.7	308592.6	2408.9	6217.4	331396.8	311131.9	2108.3	7152.1
2013M08	307772.8	315070.3	2613.0	6289.0	336773.7	316299.7	2128.8	7348.1
2013M09	312669.8	305201.5	2455.4	6354.1	339742.4	314874.1	2114.0	7412.9
2013M10	317448.9	323987.2	2640.9	6417.0	348219.5	323706.7	2174.4	7931.0
2013M11	312621.4	317476.9	2529.2	6475.5	330815.9	328775.7	2199.0	8571.6
2013M12	353579.7	325654.8	2643.9	6531.1	390094.8	351670.0	2350.1	8136.1
2014M01	339446.5	326688.2	2515.9	6583.3	370314.5	323215.6	2131.7	8232.3
2014M02	324112.9	315171.0	2314.9	6632.5	349266.5	318971.3	2038.4	7587.8
2014M03	328567.5	337522.7	2768.2	6678.8	369706.5	343985.2	2305.0	9211.6
2014M04	310608.3	325334.6	2741.7	6722.3	341859.8	334020.1	2209.9	9821.3
2014M05	314398.7	320809.1	2904.7	6763.3	357691.6	336616.1	2236.8	10600.9
2014M06	303068.6	306181.6	2897.2	6801.8	340331.9	310470.0	2193.3	10814.5
2014M07	311331.0	316195.7	2883.4	6837.9	349847.7	324835.8	2179.1	10854.9
2014M08	312457.1	325875.5	3127.7	6871.9	357708.7	330308.9	2201.1	11134.7
2014M09	317278.6	315732.9	2939.1	6903.8	360075.5	329080.6	2186.5	11219.1
2014M10	321975.9	332806.6	3161.1	6933.7	369030.2	338219.0	2249.8	11991.9
2014M11	316929.7	328268.3	3027.4	6961.8	350248.5	343505.8	2276.1	12951.1

7.10 Anexo 10: Pronósticos Semanales de Consumo Modelos ARIMA y Estructurales

Fecha	Modelos ARIMA				Modelos Estructurales			
	CGAS	CDIESEL	CGNC	CGLP	CGAS	CDIESEL	CGNC	CGLP
12/06/2012	78346.7	69305.2	499.8	1281.4	82907.9	75893.6	517.2	1167.7
12/13/2012	78346.7	69305.2	499.8	1281.4	82907.9	75893.6	517.2	1167.7
12/20/2012	78346.7	69305.2	499.8	1281.4	82907.9	75893.6	517.2	1167.7
12/27/2012	77462.1	70316.4	492.5	1281.1	81405.1	74149.9	502.7	1175.0
1/03/2013	75250.6	72844.5	474.4	1280.4	77648.2	69790.5	466.4	1193.2
1/10/2013	75250.6	72844.5	474.4	1280.4	77648.2	69790.5	466.4	1193.2
1/17/2013	75250.6	72844.5	474.4	1280.4	77648.2	69790.5	466.4	1193.2
1/24/2013	75250.6	72844.5	474.4	1280.4	77648.2	69790.5	466.4	1193.2
1/31/2013	78967.8	76187.2	482.2	1431.3	81435.1	75344.3	490.2	1222.1
2/07/2013	79587.4	76744.4	483.5	1456.5	82066.2	76269.9	494.2	1226.9
2/14/2013	79587.4	76744.4	483.5	1456.5	82066.2	76269.9	494.2	1226.9
2/21/2013	79587.4	76744.4	483.5	1456.5	82066.2	76269.9	494.2	1226.9
2/28/2013	73862.0	73548.9	516.7	1347.1	77905.5	74621.9	502.9	1335.2
3/07/2013	72907.8	73016.3	522.2	1328.9	77212.1	74347.2	504.4	1353.2
3/14/2013	72907.8	73016.3	522.2	1328.9	77212.1	74347.2	504.4	1353.2
3/21/2013	72907.8	73016.3	522.2	1328.9	77212.1	74347.2	504.4	1353.2
3/28/2013	76023.9	67539.6	527.4	1358.4	80382.2	68183.6	502.3	1415.1
4/04/2013	71253.9	74534.8	534.5	1397.7	75157.3	74523.6	499.5	1497.6
4/11/2013	71253.9	74534.8	534.5	1397.7	75157.3	74523.6	499.5	1497.6
4/18/2013	71253.9	74534.8	534.5	1397.7	75157.3	74523.6	499.5	1497.6
4/25/2013	71050.4	73905.0	536.4	1393.6	75257.0	74262.2	498.0	1507.9
5/02/2013	69829.8	70126.0	548.0	1369.0	75855.0	72694.0	489.1	1569.8
5/09/2013	69829.8	70126.0	548.0	1369.0	75855.0	72694.0	489.1	1569.8
5/16/2013	69829.8	70126.0	548.0	1369.0	75855.0	72694.0	489.1	1569.8
5/23/2013	69829.8	70126.0	548.0	1369.0	75855.0	72694.0	489.1	1569.8
5/30/2013	69658.5	69119.2	560.0	1415.6	74866.6	70282.9	493.5	1633.6
6/06/2013	69590.0	68716.4	564.8	1434.2	74471.3	69318.5	495.3	1659.2
6/13/2013	69590.0	68716.4	564.8	1434.2	74471.3	69318.5	495.3	1659.2
6/20/2013	69590.0	68716.4	564.8	1434.2	74471.3	69318.5	495.3	1659.2
6/27/2013	69428.8	69130.3	555.8	1421.2	74625.7	69720.1	487.1	1640.2
7/04/2013	69213.9	69682.2	544.0	1403.9	74831.5	70255.6	476.1	1615.0
7/11/2013	69213.9	69682.2	544.0	1403.9	74831.5	70255.6	476.1	1615.0
7/18/2013	69213.9	69682.2	544.0	1403.9	74831.5	70255.6	476.1	1615.0
7/25/2013	69213.9	69682.2	544.0	1403.9	74831.5	70255.6	476.1	1615.0
8/01/2013	69497.1	71144.9	590.0	1420.1	76045.7	71422.5	480.7	1659.2
8/08/2013	69497.1	71144.9	590.0	1420.1	76045.7	71422.5	480.7	1659.2
8/15/2013	69497.1	71144.9	590.0	1420.1	76045.7	71422.5	480.7	1659.2
8/22/2013	69497.1	71144.9	590.0	1420.1	76045.7	71422.5	480.7	1659.2
8/29/2013	71473.8	71184.2	580.3	1455.8	77890.0	72592.9	487.9	1699.5
9/05/2013	72956.3	71213.7	572.9	1482.6	79273.2	73470.6	493.3	1729.7
9/12/2013	72956.3	71213.7	572.9	1482.6	79273.2	73470.6	493.3	1729.7
9/19/2013	76660.3	65430.3	572.9	1482.6	83298.0	67503.9	493.3	1729.7

Fecha	Modelos ARIMA				Modelos Estructurales			
	CGAS	CDIESEL	CGNC	CGLP	CGAS	CDIESEL	CGNC	CGLP
9/26/2013	72592.2	71769.3	579.6	1473.0	79089.5	73363.3	492.6	1747.2
10/03/2013	71682.0	73158.4	596.3	1449.0	78630.2	73095.1	491.0	1790.9
10/10/2013	71682.0	73158.4	596.3	1449.0	78630.2	73095.1	491.0	1790.9
10/17/2013	71682.0	73158.4	596.3	1449.0	78630.2	73095.1	491.0	1790.9
10/24/2013	71682.0	73158.4	596.3	1449.0	78630.2	73095.1	491.0	1790.9
10/31/2013	76525.2	67807.2	591.0	1502.1	81521.2	70063.2	509.9	1970.2
11/07/2013	72945.0	74077.9	590.1	1511.0	77190.4	76714.3	513.1	2000.0
11/14/2013	72945.0	74077.9	590.1	1511.0	77190.4	76714.3	513.1	2000.0
11/21/2013	72945.0	74077.9	590.1	1511.0	77190.4	76714.3	513.1	2000.0
11/28/2013	76885.3	73767.7	594.1	1490.3	83416.4	78254.3	523.1	1907.0
12/05/2013	79840.6	73534.9	597.0	1474.8	88085.9	79409.3	530.7	1837.2
12/12/2013	79840.6	73534.9	597.0	1474.8	88085.9	79409.3	530.7	1837.2
12/19/2013	79840.6	73534.9	597.0	1474.8	88085.9	79409.3	530.7	1837.2
12/26/2013	79384.7	73568.3	592.9	1476.5	87447.8	78491.5	523.6	1840.3
1/02/2014	76649.2	73768.3	568.1	1486.5	83619.4	72984.2	481.3	1858.9
1/09/2014	76649.2	73768.3	568.1	1486.5	83619.4	72984.2	481.3	1858.9
1/16/2014	76649.2	73768.3	568.1	1486.5	83619.4	72984.2	481.3	1858.9
1/23/2014	76649.2	73768.3	568.1	1486.5	83619.4	72984.2	481.3	1858.9
1/30/2014	79777.1	77357.2	575.7	1609.1	86260.3	77811.8	501.5	1886.1
2/06/2014	81028.2	78792.8	578.7	1658.1	87316.6	79742.8	509.6	1896.9
2/13/2014	81028.2	78792.8	578.7	1658.1	87316.6	79742.8	509.6	1896.9
2/20/2014	81028.2	78792.8	578.7	1658.1	87316.6	79742.8	509.6	1896.9
2/27/2014	76145.7	76951.4	611.8	1551.0	84577.7	78265.1	517.4	2027.7
3/06/2014	74192.7	76214.8	625.1	1508.1	83482.1	77674.1	520.5	2080.0
3/13/2014	74192.7	76214.8	625.1	1508.1	83482.1	77674.1	520.5	2080.0
3/20/2014	74192.7	76214.8	625.1	1508.1	83482.1	77674.1	520.5	2080.0
3/27/2014	73702.0	76128.1	629.3	1525.4	82420.7	77749.5	519.1	2140.5
4/03/2014	72475.3	75911.4	639.7	1568.5	79767.3	77938.0	515.6	2291.6
4/10/2014	72475.3	75911.4	639.7	1568.5	79767.3	77938.0	515.6	2291.6
4/17/2014	76154.9	69746.5	639.7	1568.5	83817.1	71608.5	515.6	2291.6
4/24/2014	72475.3	75911.4	639.7	1568.5	79767.3	77938.0	515.6	2291.6
5/01/2014	70993.3	72440.8	655.9	1527.2	80769.1	76010.1	505.1	2393.8
5/08/2014	70993.3	72440.8	655.9	1527.2	80769.1	76010.1	505.1	2393.8
5/15/2014	70993.3	72440.8	655.9	1527.2	80769.1	76010.1	505.1	2393.8
5/22/2014	70993.3	72440.8	655.9	1527.2	80769.1	76010.1	505.1	2393.8
5/29/2014	70834.8	71870.3	667.4	1561.4	79992.9	73971.8	508.9	2467.8
6/05/2014	70716.0	71442.4	676.0	1587.1	79410.8	72443.0	511.8	2523.4
6/12/2014	70716.0	71442.4	676.0	1587.1	79410.8	72443.0	511.8	2523.4
6/19/2014	70716.0	71442.4	676.0	1587.1	79410.8	72443.0	511.8	2523.4
6/26/2014	70597.3	71430.0	668.9	1574.8	79292.8	72702.2	506.1	2502.7
7/03/2014	70300.6	71399.0	651.1	1544.0	78997.9	73350.0	492.1	2451.1
7/10/2014	70300.6	71399.0	651.1	1544.0	78997.9	73350.0	492.1	2451.1
7/17/2014	70300.6	71399.0	651.1	1544.0	78997.9	73350.0	492.1	2451.1
7/24/2014	70300.6	71399.0	651.1	1544.0	78997.9	73350.0	492.1	2451.1
7/31/2014	70518.5	73272.5	698.4	1550.6	80519.3	74409.3	496.3	2505.3

Fecha	Modelos ARIMA				Modelos Estructurales			
	CGAS	CDIESEL	CGNC	CGLP	CGAS	CDIESEL	CGNC	CGLP
8/07/2014	70554.8	73584.8	706.3	1551.7	80772.9	74585.9	497.0	2514.3
8/14/2014	74256.3	67409.6	706.3	1551.7	85010.5	68326.7	497.0	2514.3
8/21/2014	70554.8	73584.8	706.3	1551.7	80772.9	74585.9	497.0	2514.3
8/28/2014	72044.9	73621.7	697.5	1577.1	82163.5	75528.6	502.7	2558.6
9/04/2014	74031.7	73671.0	685.8	1610.9	84017.6	76785.5	510.2	2617.8
9/11/2014	74031.7	73671.0	685.8	1610.9	84017.6	76785.5	510.2	2617.8
9/18/2014	77790.3	67688.0	685.8	1610.9	88283.2	70549.6	510.2	2617.8
9/25/2014	73842.0	73882.3	689.8	1604.4	83919.3	76726.4	509.9	2630.7
10/02/2014	72704.2	75149.9	713.8	1565.7	83329.4	76372.0	508.0	2707.9
10/09/2014	72704.2	75149.9	713.8	1565.7	83329.4	76372.0	508.0	2707.9
10/16/2014	72704.2	75149.9	713.8	1565.7	83329.4	76372.0	508.0	2707.9
10/23/2014	72704.2	75149.9	713.8	1565.7	83329.4	76372.0	508.0	2707.9
10/30/2014	77408.5	69876.3	708.5	1607.6	86554.8	72662.5	524.5	2932.2
11/06/2014	73950.3	76595.9	706.4	1624.4	81724.7	80151.3	531.1	3021.9
11/13/2014	73950.3	76595.9	706.4	1624.4	81724.7	80151.3	531.1	3021.9
11/20/2014	73950.3	76595.9	706.4	1624.4	81724.7	80151.3	531.1	3021.9