



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY



UNIVERSIDAD DE LA REPÚBLICA
Facultad de Ingeniería
Maestría en Ingeniería Matemática

**Estimación de la demanda mensual del Gas Licuado de
Petróleo para el Sector Residencial de Uruguay mediante
modelos de Vectores Autorregresivos Cointegrados.**

Ec. Nora Gesto Giannattasio

Director de Tesis: PhD. Marco Scavino
Co-Director de Tesis: Ec. Silvia Rodríguez Collazo

Diciembre 2015

Agradecimientos

Quiero agradecer a mis tutores Marco y Silvia por el apoyo constante y los valiosos aportes en la elaboración de la tesis. Marco fue además mi director académico. Su acompañamiento, dedicación y consejos a lo largo de todos estos años fueron fundamentales para que pudiera lograr este objetivo tan importante para mí.

También agradezco a mi familia y amigos que estuvieron apoyándome y motivándome todo este tiempo a seguir adelante.

Por último, el agradecimiento más importante es para Agustín y Luciana, que son la mayor motivación que tengo para seguir superándome. Me han esperado incondicionalmente y animado en los tiempos difíciles a terminar. Este logro es gracias a ellos.

Resumen

Resumen

En este trabajo se aborda el problema de la estimación de las elasticidades precio e ingresos de largo plazo para la demanda mensual de supergas y de energía eléctrica del sector residencial de Uruguay, en el período 2000 a 2012. A partir de las características de los datos disponibles, y de las de un mercado donde se espera que haya retroalimentación entre la demanda de los dos energéticos, se analiza dicho problema utilizando una flexible especificación econométrica basada en los modelos de Vectores Autorregresivos.

Se constata que es posible estimar dos relaciones de cointegración entre las variables seleccionadas, las que pueden interpretarse como ecuaciones de demanda de equilibrio del Gas Licuado de Petróleo y Energía Eléctrica. La estimación de los coeficientes de las relaciones de largo plazo β y de la velocidad de ajuste al equilibrio α son llevadas a cabo a través de restricciones de rango reducido.

Mediante el análisis realizado, se confirma que los precios de los energéticos son fuertemente exógenos respecto a la demanda de GLP. Al ser los precios establecidos por el Estado, su trayectoria no sigue una lógica de mercado, sino que en el período analizado operan como instrumento de política.

Finalmente, se presentan los resultados del análisis comparado de distintos escenarios, considerando diferentes especificaciones de la variable exógena temperatura mínima media mensual en la estación meteorológica de Carrasco, en términos de ajuste y predicción.

Palabras Clave: Vectores Autorregresivos, Cointegración, Restricciones de Rango Reducido.

Índice general

Introducción	11
1. Antecedentes	15
1.1. Antecedentes Regionales	15
1.2. Antecedentes Internacionales	17
2. Marco Teórico	19
2.1. Conceptos Económicos sobre la Demanda de un Bien	19
2.2. Análisis Multivariado	23
2.2.1. Modelos Autorregresivos de Rezagos Distribuidos	25
2.2.2. Modelos de Vectores Autorregresivos	26
2.3. Estimación del VAR	28
2.3.1. Estimación del VAR sin restricciones	30
2.3.2. Modelo VAR Cointegrado	31
2.3.3. Estimación mediante Restricciones de Rango Reducido	35
2.4. Especificación del Modelo	41
2.4.1. Componentes determinísticos en el VAR integrado I(1)	44
2.4.2. Determinación del rango de cointegración	46
2.4.3. Interpretación de $\Pi = \alpha\beta'$	48
2.4.4. Normalización	49
2.4.5. Pruebas de hipótesis sobre los coeficientes de largo plazo β	50
2.5. Exogeneidad y Causalidad	51
2.5.1. Causalidad en Sentido de Granger	51
2.5.2. Exogeneidad	54
2.5.3. Pruebas de hipótesis sobre Exogeneidad	57
2.6. Predicción	61

3. Datos a Emplear	67
3.1. Definición y descripción de las series estadísticas.	67
3.2. Caracterización del consumo del sector residencial.	70
3.3. Análisis Preliminar de las Series	73
4. Resultados	77
4.1. Pruebas de Raíz Unitaria	78
4.2. Selección de la Cantidad de Rezagos del VAR	84
4.3. Test de Johansen	88
4.4. Pruebas de hipótesis sobre la significación de los β	91
4.5. Causalidad y Exogeneidad	95
4.5.1. Prueba de Hipótesis de Causalidad de Granger	96
4.5.2. Prueba de Hipótesis de Exogeneidad Débil	97
4.5.3. Exogeneidad Fuerte	100
4.5.4. Super Exogeneidad	100
4.6. Interpretación del VECM estimado	101
4.7. Escenarios Alternativos y Pruebas en Predicción	107
5. Conclusiones	115
A. Anexo Metodológico	121
A.1. Análisis de Series de Tiempo	121
A.1.1. Modelos Univariados	122
A.1.2. Modelos Multivariados	126
A.1.3. Procesos Integrados	127
A.1.4. Regresión Espuria	128
A.1.5. Cointegración	129
A.1.6. Mecanismo de Corrección de Error	130
A.1.7. Test de Raíz Unitaria - RU	131
A.2. Selección de la Cantidad de Rezagos del VAR	137
A.3. Tests sobre los Residuos en Modelos Multiecuacionales.	138
A.3.1. Test de Normalidad de los residuos	139
A.3.2. Test de Autocorrelación de los residuos	141
A.3.3. Test de Heteroscedasticidad en los residuos	141

B. Anexo de Resultados	142
B.1. Estimaciones de la demanda de energía mediante ECM univariado.	142
B.2. Resultados en software R-project.	145
B.2.1. Pruebas de raíces unitarias para la serie del Índice de Salario Real (<i>isr</i>).	145
B.2.2. Estimación del VECM en el Escenario 1 para un modelo no restringido.	148
B.2.3. Estimación del VECM en el Escenario 1 con precios débilmente exóg.	153
B.3. Resultados en software Gretl.	159
B.3.1. Estimación del VECM en el Escenario 1 para un modelo no restringido.	159
B.3.2. Estimación del VECM en el Escenario 1 con precios débilmente exóg.	164
C. Anexo con Análisis comparado de software y programación.	169
D. Anexo con Programación en software R.	174
D.1. Programación en R	174
D.1.1. Pruebas de Raíz Unitaria	174
D.1.2. Determinación de la Cantidad de Rezagos del VAR	177
D.1.3. Definición de la matriz de datos para el Caso 2 con $p = 3$	178
D.1.4. Estimación de α y β mediante RRR sin restricciones	179
D.1.5. Estimación del Rango de Cointegración: Test de Johansen	180
D.1.6. Estimación del VECM sin restricciones	181
D.1.7. Test sobre los Residuos	182
D.1.8. Predicción e Indicadores de Errores de Predicción	183
D.1.9. Pruebas de hipótesis sobre los β	185
D.1.10. Pruebas de hipótesis sobre los α	187
D.1.11. Estimación del VECM con restricciones en los α	188
D.1.12. Test sobre Causalidad de Granger	189
D.1.13. Test de Chow	190
E. Anexo con Tablas de Valores Críticos	196
Bibliografía	197

Índice de cuadros

2.2.1. Tipologías de modelos autorregresivos de rezagos distribuidos.	25
2.4.1. Casos de Johansen sobre los componentes determinísticos.	46
3.1.1. Consumo Energético del Sector Residencial en ktep, años 2000-2012.	68
3.2.1. Principal Fuente de Energía Utilizada para Cocinar, porcentaje de hogares. . . .	71
3.2.2. Principal Fuente de Energía Utilizada para Calefaccionar, porcentaje de hogares.	71
3.2.3. Usos y Fuentes del Consumo de Energía Neta	71
3.2.4. Total de Consumo de Energía Neta por Fuentes y Usos del Sector Residencial. .	72
3.2.5. Consumo de Energía Neta del Sector Residencial en % del Total de Usos. . . .	72
3.2.6. Consumo de Energía Neta del Sector Residencial en % del Total de Fuentes. .	72
4.1.1. Resultados de la prueba de Dickey-Fuller Aumentado (ADF).	81
4.1.2. Resultados de la prueba de Zivot y Andrews (ZA).	82
4.2.1. Determinación de la cantidad de rezagos del VAR, $max.p = 4$, $T = 152$	85
4.2.2. Raíces de las estimaciones de los modelos VAR.	88
4.3.1. Test de la Traza en el Caso 2 con $p = 3$, $k = 5$	90
4.3.2. Test de la Traza en el Caso 3 con $p = 3$, $k = 5$	90
4.3.3. Test de la Traza en el Caso 4 con $p = 3$, $k = 5$	91
4.4.1. Prueba de hipótesis sobre la significación de β con $p = 3$	92
4.4.2. Pruebas multivariadas, comparación de cantidad de rezagos en Caso 2	93
4.4.3. Estimación de β y α normalizados sin restricciones, para el Caso 2 con $p = 3$. .	93
4.4.4. Estimación de β y α normalizados para el Caso 2 con $p = 3$ y $r = 2$	94
4.5.1. Prueba de Causalidad de Granger en el VAR(3).	97
4.5.2. Prueba de hipótesis sobre restricciones en los α	98
4.5.3. Estimación de β y α normalizados. Caso 2, $p = 3$ y precios débilmente exóg. . .	98
4.5.4. Estimación de β y α normalizados para el Caso 2 con $p = 3$ y $r = 2$	99

ÍNDICE DE CUADROS

4.5.5. Test de Chow	101
4.6.1. Pruebas univariadas sobre los residuos: <i>Caso 2</i> de Johansen, $p = 3, r = 2$. . .	102
4.6.2. Pruebas multivariadas sobre los residuos: <i>Caso 2</i> de Johansen, $p = 3, r = 2$. .	103
4.6.3. Relaciones de Cointegración en <i>Caso 2</i> de Johansen, $p = 3, r = 2$	103
4.7.1. Análisis comparado de los escenarios para <i>Caso 2</i> de Johansen, $p = 3, r = 2$. .	110
4.7.2. Análisis comparado de los escenarios para <i>Caso 2</i> de Johansen, $p = 3, r = 2$. .	111
4.7.3. Análisis comparado de los escenarios para <i>Caso 2</i> de Johansen, $p = 3, r = 2$. .	112
4.7.4. Predicciones para la Demanda de Supergas en 2013.	114
4.7.5. Predicciones para la Demanda de Energía Eléctrica en 2013.	114
5.0.1. Comparación de elasticidades ECM vs VECM.	117
5.0.2. Elasticidades precios e ingreso del supergas.	117
A.1.1. Algunas propiedades de los procesos estacionarios e integrados	128
A.1.2. Estadísticos para la Prueba de Hipótesis en modelos con constante y tendencia. .	132
B.1.1. Test de especificación de los ECM de <i>csg</i> y <i>cee</i>	145
E.0.1. Valores Críticos para el Test de Dickey-Fuller Aumentado (ADF).	196
E.0.2. Valores Críticos para el Test de Zivot y Andrews (ZA) [40].	196

Introducción

El objetivo de esta monografía es la estimación de la función de demanda mensual del Gas Licuado de Petróleo para el sector residencial de Uruguay en el período 2000 a 2012.

A tal efecto, se introducen técnicas econométricas que permitirán interpretar las elasticidades precio directo, precio cruzado e ingreso de dicha demanda habilitando a confirmar si la demanda mensual de dicho energético se comporta acorde a lo que plantea la teoría económica. Las capacidades predictivas de los modelos econométricos propuestos serán analizadas fuera de la muestra para el año 2013.

La estimación de la demanda del Gas Licuado de Petróleo (GLP o supergas) propone interesantes desafíos para el investigador, considerando que:

- El mercado del GLP no es un mercado en competencia perfecta.
- El período seleccionado (2000-2012) contiene una serie de shock o eventos económicos atípicos tanto nacionales (crisis económica de 2002, reinstauración de los Consejos de Salarios en 2005, crisis energética en 2006, cierre por reformas en la refinería de Ancap en 2007, fenómenos climáticos adversos en 2007), como internacionales (crisis del petróleo que generó fluctuaciones en los precios en 2007-2008).
- Las series de tiempo, tanto de precios como de cantidades y salario son no estacionarias en el período seleccionado.

Los factores recién descritos implican una dificultad adicional en la especificación y estimación de los modelos econométricos, que va más allá que la simple estimación de una ecuación de demanda de un bien.

Dentro de la variedad de energéticos que utiliza el sector residencial para los destinos principales de calefacción y cocción se destacan la energía eléctrica y el supergas. En este sentido sería de gran importancia poder obtener estimaciones de las elasticidades de la demanda de dichos energéticos, dado que comprender el funcionamiento de las condiciones del mercado de este subsector es relevante para el diseño de las políticas públicas destinadas a mejorar la eficiencia de la producción y comercialización.

Para contemplar el hecho de que la demanda del GLP se inserta en un mercado de energéticos y no depende exclusivamente de las fluctuaciones en su propio bien e ingresos de los hogares, se debe construir un modelo econométrico que incorpore a la Energía Eléctrica, asumiendo que pueda jugar un rol de energético sustituto con el GLP.

Para tal propósito, se utilizará una clase flexible de modelos econométricos, los modelos de Vectores Autorregresivos (VAR), introducidos en la literatura por Christopher Albert Sims (Premio Nobel de Economía en 2011), que habilitan a la estimación de la interrelación multivariada dinámica entre las variables con bidireccionalidad.

Dada la condición de no estacionariedad de las variables en las series observadas se procede a comprobar, mediante pruebas de hipótesis estadísticas, la existencia de cointegración entre las variables, lo cual implica su evolución conjunta a un sendero de equilibrio en el largo plazo (un método introducido por el economista británico Clive W. J. Granger, Premio Nobel de Economía en 2003).

En particular, una vez validada una especificación adecuada del VAR, expresado como modelo de vector de corrección del error (VECM), se ha determinado que hay dos relaciones de cointegración. Las cuales, a partir de las normalizaciones impuestas, permiten la interpretación de las elasticidades de la demanda del GLP en el caso de la primera relación, y la interpretación de las elasticidades de la demanda de Energía Eléctrica en el caso de la segunda relación.

Actualmente en Uruguay la producción de éstos dos energéticos es llevada a cabo por el Estado, específicamente las actividades de importación y producción de derivados del petróleo, así como también la producción de Energía Eléctrica.

No solo la producción y comercialización es altamente regulada por el Estado, sino que también lo es el tarifario de precios, siendo no solo regulado sino subsidiado en el caso específico del Gas Licuado de Petróleo. La determinación de los precios de ambos energéticos viene dada por decretos de fijación de precios que se calculan en base a las paramétricas del tarifario de cada uno. Estas regulaciones generan que no se esté en presencia de un mercado en competencia perfecta y por lo tanto, no es esperable que actúe la mecánica de ajuste de mercado.

Por tal motivo, ha sido necesario contrastar la hipótesis de que el proceso generador del dato que se propone modelizar con un VAR cointegrado dé resultados acordes a la teoría económica, implementando las pruebas estadísticas de exogeneidad y causalidad.

Otro punto a destacar es que en este trabajo de investigación se han encontrado restricciones en el software disponible al momento de realizar los cálculos necesarios para llevar a cabo las etapas de especificación de los modelos y estimación de los parámetros.

Por lo tanto, se optó por efectuar la programación ad-hoc de las técnicas propuestas, mediante el entorno de programación R, alcanzando plena transparencia en la implementación y consistencia con la teoría utilizada.

Los resultados obtenidos han sido comparados con otros software de uso común en econome-

tría. Este análisis comparado de software representa un aporte a futuros investigadores sobre la temática, en el cual se documentan determinadas debilidades en los resultados que se obtienen en cada uno, las que pueden llevar a errores de interpretación en el análisis econométrico, y se proponen las soluciones correspondientes.

La monografía consta de cinco capítulos, presentando en el primero los antecedentes regionales e internacionales sobre el tema de investigación y la metodología allí considerada, en el segundo la metodología econométrica a ser aplicada en el presente trabajo, en el tercero los datos a utilizar y el análisis descriptivo de los mismos.

En el cuarto capítulo se describen los resultados de la aplicación de las técnicas econométricas para la especificación de modelos y estimación de los parámetros al caso de estudio elegido para el sector energético de Uruguay. Se destaca la comparación entre escenarios alternativos y el ejercicio de predicción fuera de la muestra para el año 2013, junto con varias estimaciones de los errores de predicción.

El quinto capítulo está dedicado a las conclusiones, en las que se enfatiza como una especificación mediante un modelo VECM resulte adecuada para modelizar e interpretar la dinámica conjunta de los energéticos Gas Licuado de Petróleo y Energía Eléctrica.

Capítulo 1

Antecedentes

En este capítulo se presentan los principales antecedentes sobre el tema encontrados a partir de la revisión de la literatura.

Por un lado, se presentan los antecedentes Regionales, donde se mencionan las principales investigaciones encontradas sobre supergas y energéticos derivados del petróleo, que adicionalmente utilizan la metodología propuesta en este trabajo u otras similares pero con los mismos objetivos.

En el segundo apartado, se presentan los antecedentes internacionales, que están más vinculados a la utilización de la metodología propuesta y a energía eléctrica que a estimaciones de la demanda de supergas, dado que el supergas es un energético utilizado principalmente en América Latina y poco utilizado en otras partes del mundo.

1.1. Antecedentes Regionales

Amengual y Cubas (2002) [2] estiman la demanda de gasolina y gasoil para Uruguay mediante Vectores Autorregresivos (VAR) cointegrados, utilizando el método de cointegración de Máxima Verosimilitud con Información Completa de Johansen (Johansen y Juselius 1990). Las elasticidades precio encontradas para la gasolina y el gasoil son de -0,77 y -0,32 respectivamente, y las elasticidades ingreso fueron 0,6 y 1,71. En cuanto a las elasticidades cruzadas, fueron 0,34 en la demanda de gasoil y 0,24 en la de gasolina. Se concluye que el grado de sustitución entre ambos combustibles es fuerte y dio significativo. Se realizan pruebas de causalidad y exogeneidad determinando que existe causalidad en sentido de Granger desde los precios hacia las cantidades, no verificándose la causalidad en sentido contrario. En cuanto a las pruebas de exogeneidad, se da exogeneidad débil para el *PBI p/c* pero no para los precios de cada energético, las pruebas de invarianza paramétrica muestran que las elasticidades han permanecido invariantes ante cambios en el tratamiento impositivo de los combustibles.

Medinaceli (2004) [36] analiza las consecuencias redistributivas de una posible eliminación del subsidio al precio del Gas Licuado de Petróleo (GLP) en Bolivia. A través de un procedimiento

de microsimulación se estudió el cambio de comportamiento que tendrían las familias, según sea su nivel de ingreso y pobreza, ante un incremento en el precio del GLP. Para alcanzar este objetivo se tomó como base de información la encuesta de hogares realizada en Bolivia a finales del año 2000. Los resultados más importantes fueron: a) El consumo de GLP es característica de los hogares en el área urbana sean éstos pobres o no; b) el impacto redistributivo que tendría la eliminación del subsidio depende de la capacidad que tengan estas familias para sustituir este energético, por tanto, a mayor sustitución menor regresividad de la medida y; c) los energéticos que presentan una mayor probabilidad de ser sustitutos del GLP son la leña y el kerosén. Otro impacto del incremento en el precio del GLP sería la recomposición de la matriz energética, privilegiando el consumo de estos dos últimos productos.

Cordano (2005) [7] realiza estimaciones sobre la demanda de 6 combustibles en Perú (gasolinas de 84, 90 y 97 octanos, diesel 2, kerosene y gas licuado de petróleo), con el objetivo de calcular las elasticidades precio e ingreso de estos productos para luego poder realizar ejercicios de simulación sobre la sensibilidad de la demanda ante shocks en sus variables relevantes (indicador de ingreso y precios de los combustibles). Dado que las series de tiempo no son estacionarias tanto en media como en varianza, se utiliza la metodología propuesta por Pesaran, Shin y Smith (2001), la cual sugiere utilizar un esquema de Retardos Distribuidos Autorregresivos (ARDL) para evaluar las relaciones de largo plazo. Luego se procede a estimar las ecuaciones de demanda log-lineales de acuerdo a Dahl y Sterner (1991), que incluyen una estructura ARCH para modelar la varianza con el propósito de controlar la volatilidad de la serie.

Por último se estima un modelo de corrección de errores de acuerdo a los lineamientos de Pesaran et al. (2001), con el propósito de realizar un análisis de respuesta al impulso para evaluar la sensibilidad de la demanda ante cambios en los precios e ingresos. El análisis de las elasticidades precio arroja que la gasolina de mayor octanaje presenta mayor sensibilidad ante variaciones en su precio, los combustibles menos sensibles al precio son el kerosen y el GLP, hecho que se explicaría por la necesidad de su consumo para cocina y alumbrado en los hogares y la ausencia de sustitutos adecuados. En cuanto a la elasticidad ingreso, el GLP sería un bien superior en relación al kerosen, por lo que si se aumentan los impuestos al GLP el consumo de kerosen podría aumentar.

Rodríguez (2006) [42] estima las funciones de demanda agregada de los combustibles fósiles de uso común en la República Dominicana. En este sentido se estimaron funciones de demanda de gasolina (premium y regular), gasoil regular y gas licuado de petróleo (GLP), y así obtener las respectivas elasticidades precio e ingreso que permitan evaluar la sensibilidad de la demanda ante variaciones en sus determinantes. Se estudió la relación de largo plazo mediante cointegración y para explicar la dinámica de corto plazo se empleó el mecanismo de corrección de errores (ECM). La función de demanda estimada fue de tipo Cobb-Douglas con una transformación a log-lineal. El resultado evidencia que el combustible con mas sensibilidad (elástico) al precio es la gasolina regular, seguido por la gasolina premium y el GLP. El GLP fue el único combustible en el cual se encontró una elasticidad precio sustituto significativa.

Aliaga et al.(2011) [1] realizan un un análisis de las elasticidades de sustitución del sector energético boliviano tanto de corto como de largo plazo. Los energéticos que se toma en cuenta son: Electricidad, Hidrocarburos y Biomasa. Las estimaciones se realizan a partir de una función

de producción Transcendental Logarithmic. Dentro de los resultados arribados se destaca que para el modelo en bloque las combinaciones de sustitución energética en todo el espectro de la matriz energética de Bolivia presenta estadísticos muy poco significativos. En los resultados del modelo por pares todas las elasticidades cruzadas muestran imposibilidad sustitución energética. En el corto plazo sin duda es difícil encontrar sustitutos energéticos debido a los altos costos fijos iniciales que presentan algunos, así como por restricciones tecnológicas y logísticas.

1.2. Antecedentes Internacionales

Ramanathan (1999) [41] estudia la demanda de gasolina en India. En los países en desarrollo como la India, el consumo de productos derivados del petróleo repercute en su balanza de pagos, el crecimiento económico y el déficit fiscal. La gasolina es uno de los principales productos derivados del petróleo. En este trabajo se examina empíricamente la relación entre la demanda de gasolina, la renta nacional y el precio de la gasolina utilizando técnicas de cointegración y corrección de errores propuestas por Engle y Granger para analizar el comportamiento de corto y largo plazo de los consumidores, utilizando como variable de escala el PIB per cápita y sin incluir tendencia determinística.

Panagiotidis, et al.(2006) [38] estudian la relación entre los precios mayoristas del gas y el precio del petróleo Brent en Reino Unido en el período 1996-2003 con el fin de investigar si los precios del petróleo y el gas se distancian uno del otro. La hipótesis fundamental de los que apoyan la liberalización del mercado de gas natural es que bajo una completa liberalización del régimen los precios del gas y del petróleo se separan. También se presume que luego de ese distanciamiento el precio del gas cae significativamente con consecuencias positivas en el bienestar y beneficios de los consumidores.

A partir de las pruebas de raíces unitarias y cointegración se constata que existe una relación de equilibrio de largo plazo entre los precios del gas y del petróleo en Reino Unido. También se evidencia en la investigación que la relación de corto plazo es una función lineal y mediante la función de respuesta al impulso examinan el efecto que un shock en el petróleo tendría sobre el gas. Sin embargo, en los resultados no se verifica la hipótesis de que el gas y el petróleo se distancien.

Mohammadi (2009) [37] examina la relación de largo plazo y la dinámica de corto plazo entre el precio de la electricidad y el precio de tres combustibles fósiles (gas natural, petróleo y carbón) con datos anuales de U.S. de 1960 a 2007. Realiza las estimaciones mediante Vectores Autorregresivos (VAR), Modelo de Corrección de Errores (VECM), Funciones de Respuesta al Impulso. Los resultados sugieren (1) una relación estable de largo plazo entre el precio real de la electricidad y el carbón, (2) una relación de bicausalidad entre el precio del carbón y la electricidad, (3) una relación de largo plazo casi insignificante entre los precios de la electricidad y el petróleo y/o el gas natural.

Capítulo 2

Marco Teórico

Este trabajo se centra en la estimación de las elasticidades precio del Gas Licuado de Petróleo, por lo cual en éste capítulo se hará en primer instancia, un breve resumen de las nociones básicas de la determinación de dichas elasticidades en su sentido económico y su significado dentro de la curva de demanda de un bien.

En segunda instancia, se introducen las definiciones y marco econométrico mediante el cual se estimarán las elasticidades.

En el primer apartado se presentan los conceptos y teoría económica asociada a la demanda y elasticidades de un bien.

En el segundo y tercer apartado se desarrollan más profundamente los conceptos teóricos del análisis de un sistema de ecuaciones multivariado y dinámico, necesarios para la estimaciones que se proponen en este trabajo.

En el cuarto apartado se explicitan los pasos que se deben seguir al momento de la especificación del modelo a estimar y como se hacen los contrastes de pruebas de hipótesis.

Por último, en el quinto y sexto apartado se presentan los aspectos teóricos de las pruebas de causalidad, exogeneidad y predicción que se llevan a cabo en este tipo de modelos.

2.1. Conceptos Económicos sobre la Demanda de un Bien

En economía, la teoría fundamental establece que la cantidad de productos ofrecidos y demandados en competencia perfecta dependen del precio de mercado del producto.

La ley de oferta indica que hay una relación directamente proporcional al precio, o sea, cuanto más alto sea el precio del producto mayor es la oferta.

La ley de demanda establece que la relación entre el precio y la cantidad demandada es inver-

samente proporcional, por lo tanto a mayor precio se demanda menos unidades del producto.

De esta forma, el precio de equilibrio en un mercado de competencia perfecta estará determinado por el equilibrio entre la oferta (la cantidad que se está dispuesto a producir a un precio determinado) y la demanda (la cantidad que se está dispuesto a comprar a un precio determinado).

La curva de demanda representa la relación entre la cantidad de bienes que el consumidor está dispuesto a comprar en relación al precio del mismo, suponiendo que el resto de determinantes permanecen constantes (*ceteris paribus*).

Los determinantes de la demanda de un bien q_i están dados por: el precio del bien, el ingreso, las preferencias personales, el precio de los bienes sustitutos¹ y el precio de los bienes complementarios.

Un bien se considera “sustituto” cuando uno de ellos puede ser consumido en lugar del otro bien en alguno de sus posibles usos.

Un bien se considera “complementario” cuando el uso de uno de ellos implica la necesidad del uso del otro, por lo tanto sus demandas están relacionadas².

La pendiente y forma de la curva de demanda está determinada por la elasticidad precio de la demanda. En general la elasticidad precio de un bien tiene signo negativo³ que es lo que le da la pendiente negativa a la curva de demanda y por lo cual aumentos en el precio generan menor cantidad demandada.

Siendo ξ_{q_i, p_i} la elasticidad precio de la cantidad q_i respecto al precio p_i , se pueden definir los distintos tipos de demanda que puede presentar un bien:

- $\xi_{q_i, p_i} = 0$ demanda perfectamente inelástica. La curva vertical implica que variaciones en los precios no generan variaciones en la cantidad demandada.
- $-1 < \xi_{q_i, p_i} < 0$ demanda inelástica. Implica que grandes variaciones en los precios generan pequeñas variaciones en la cantidad demandada.
- $\xi_{q_i, p_i} = -1$ demanda unitaria.
- $-\infty < \xi_{q_i, p_i} < -1$ demanda elástica. Implica que pequeñas variaciones en los precios generan grandes variaciones en la cantidad demandada.
- $\xi_{q_i, p_i} = -\infty$ demanda infinitamente elástica. La curva es horizontal.

¹ Por ejemplo, el consumo de electricidad para cocinar o calefacción puede ser sustituida por consumo de GLP para los mismos propósitos.

² En el caso de dos bienes complementarios entre sí, si sube el precio del bien 1 genera variaciones no solo en la demanda del bien 1 sino también en el bien 2 que es complementario al bien 1.

³ Se pueden presentar casos excepcionales donde la curva de demanda no es decreciente, como ser el caso de demanda de bienes de lujo o bienes inferiores donde muchas veces aunque el precio sube la demanda también lo hace.

2. Marco Teórico

Por lo tanto, la elasticidad precio de la demanda es una medida que permite ver el grado de respuesta o cambio porcentual de la cantidad demandada ante cambios en el precio del propio bien considerando que el resto de los determinantes permanecen constantes.

La elasticidad precio cruzada ξ_{q_i, p_j} de la cantidad q_i respecto al precio p_j permite ver el grado de respuesta de la demanda de un bien i ante cambios en el precio de los bienes sustitutos y/o complementarios j .

- $\xi_{q_i, p_j} > 0$ Bienes sustitutos. Si aumenta el precio del bien sustituto p_j , aumenta la demanda de q_i .
- $\xi_{q_i, p_j} = 0$ Bienes independientes. Los cambios en el precio de un bien no afectan la cantidad demandada del otro bien.
- $\xi_{q_i, p_j} < 0$ Bienes complementarios. Si aumenta el precio de uno de los bienes disminuye la cantidad demandada del otro bien, dado que se consumen conjuntamente.

La elasticidad ingreso de la demanda mide el grado en que varía la cantidad demandada de un bien ante cambios en el ingreso del consumidor, se calcula como el ratio de las variaciones porcentuales como en los casos anteriores de elasticidad. Sin embargo, mientras que la elasticidad precio proporciona la pendiente de la función de demanda, la elasticidad ingreso en cambio permite caracterizar al tipo de bien.

Siendo $\xi_{q_i, y}$ la elasticidad ingreso de la cantidad q_i respecto al ingreso y , se pueden definir los distintos tipos de bienes:

- $\xi_{q_i, y} > 0$ Bienes normales. La demanda aumenta cuando aumenta el ingreso (y).
- $\xi_{q_i, y} > 1$ Bienes superiores o de lujo. La demanda de q_i crece más que proporcionalmente al aumentar y .
- $0 < \xi_{q_i, y} < 1$ Bienes necesarios. La demanda de q_i crece menos que proporcionalmente al aumentar y .
- $\xi_{q_i, y} < 0$ Bienes inferiores. Ante aumentos en el ingreso cae la cantidad demandada ⁴.
- $\xi_{q_i, y} = 0$ Bienes independientes. Cambios en el ingreso no afectan la cantidad demandada.

La forma funcional que se adoptará en este trabajo para la demanda corresponde a un modelo log-log debido a que sus coeficientes son elasticidades constantes y las pruebas Box-Cox dan

⁴Un ejemplo de bien inferior es un bien de la canasta básica de consumo que puede ser sustituido por otro que satisface la misma necesidad pero de calidad superior, como cuando al tener mejor ingreso el consumidor sustituye paleta cocida por jamón crudo

soporte estadístico a favor del empleo de dicha especificación, Dahl (1982) y se representa como:

$$\ln Q_t^i = \beta_1 \ln P_t^i + \beta_2 \ln P_t^j + \beta_3 \ln Y_t + u_t, \quad (2.1)$$

donde i representa el combustible estimado, j el combustible sustituto, Q es la cantidad demandada, P es el precio real, Y el ingreso, u es un error aleatorio y t el período de la observación.

Este modelo asume en su forma no lineal una función de demanda del tipo Cobb-Douglas:

$$Q_d^i = A P_i^{\beta_1} P_j^{\beta_2} Y^{\beta_3} e^u, \quad (2.2)$$

donde A es una constante, u es un error aleatorio y β_1 , β_2 y β_3 son las elasticidades precio propio, precio sustituto e ingreso respectivamente.

Las elasticidades precio e ingreso se definen como la variación porcentual en la demanda del bien ante cambios porcentuales del precio o ingreso [47].

Elasticidad precio propio:

$$\xi_{q_i, p_i} = \frac{\delta \ln Q_t^i}{\delta \ln P_t^i} = \frac{\frac{1}{Q_t^i} \delta Q_t^i}{\frac{1}{P_t^i} \delta P_t^i} = \frac{P_t^i}{Q_t^i} \frac{\delta Q_t^i}{\delta P_t^i}. \quad (2.3)$$

Elasticidad precio cruzada:

$$\xi_{q_i, p_j} = \frac{\delta \ln Q_t^i}{\delta \ln P_t^j} = \frac{\frac{1}{Q_t^i} \delta Q_t^i}{\frac{1}{P_t^j} \delta P_t^j} = \frac{P_t^j}{Q_t^i} \frac{\delta Q_t^i}{\delta P_t^j}. \quad (2.4)$$

Elasticidad ingreso:

$$\xi_{q_i, y} = \frac{\delta \ln Q_t^i}{\delta \ln Y_t} = \frac{\frac{1}{Q_t^i} \delta Q_t^i}{\frac{1}{Y_t} \delta Y_t} = \frac{Y_t}{Q_t^i} \frac{\delta Q_t^i}{\delta Y_t}. \quad (2.5)$$

Al emplearse una especificación log-log para la ecuación de demanda los valores de los coeficientes de la regresión β_i representan las elasticidades precio e ingreso respectivamente.

Actualmente en Uruguay la producción de parte de los energéticos es llevada a cabo por el Estado, específicamente las actividades de importación y producción de derivados del petróleo es cometido exclusivo de ANCAP (Administración Nacional de Combustibles Alcohol y Portland),

habilitando la distribución, transporte y comercialización según los reglamentos establecidos por la URSEA (Unidad Reguladora de Servicios de Energía y Agua).

No solo la producción y comercialización es altamente regulada por el Estado, sino que también lo es el tarifario de precios, siendo no solo regulado sino subsidiado en el caso específico del Gas Licuado de Petróleo (GLP o supergas).

Dentro de la variedad de energéticos que utiliza el sector residencial para los destinos principales de calefacción y cocción se destacan la energía eléctrica y el supergás. En este sentido sería de gran importancia poder obtener estimaciones de las elasticidades de la demanda de dichos energéticos, dado que comprender el funcionamiento de las condiciones del mercado de éste subsector es relevante para el diseño de las políticas públicas destinadas a mejorar la eficiencia de la producción y comercialización.

La determinación de los precios de ambos energéticos viene dada por decretos de fijación de precios que se calculan en base a las paramétricas del tarifario de cada uno. Estas regulaciones generan que no se esté en presencia de un mercado en competencia perfecta y por lo tanto, no es esperable que actúe la mecánica de ajuste de mercado donde las variaciones de precios determinan variaciones en las cantidades demandadas de los bienes y las variaciones en las cantidades demandadas determinan variaciones en los precios.

En un mercado como éste, donde el Estado es el productor y oferente de los energéticos y fija los precios de comercialización, el resultado que podría esperarse es que las cantidades demandadas sean influidas por variaciones en los precios pero no visceversa.

A partir de las estimaciones de las elasticidades y demanda de dichos energéticos se podrán realizar las pruebas de hipótesis correspondientes para comprobar si se cumplen empíricamente en éste mercado éstos supuestos dados por la teoría económica (pruebas de causalidad y exogeneidad).

2.2. Análisis Multivariado

Como establece Koopman (1951) [30] para poder hacer inferencia estadística sobre la teoría económica, debe tenerse en cuenta el proceso generador del dato que esta por detrás de las variables que se observan, a partir de las cuales se quiere hacer inferencia.

En la teoría económica, el comportamiento de los individuos, firmas, autoridades etc, se expresa a través de funciones matemáticas que resumen las relaciones entre ellos, por lo tanto es necesario ver y comprobar el rol que juega cada variable dentro de esas relaciones. Las variables pueden ser de distintos tipos:

1. Variables Endógenas o dependientes (observables), a las cuales la teoría quiere explicar. Se distancian del verdadero valor de la variable sólo en errores de observación de la

misma.

2. Variables Exógenas o independientes (observables), a las cuales la teoría toma como dadas o explicativas de las variables endógenas. Se distancian del verdadero valor de la variable sólo en errores de observación de la misma.
3. Variables no observadas o shocks, que representan el efecto agregado de variables exógenas no especificadas en la relación.
4. Variables no observadas que representan los errores de observación en las variables observadas (endógenas y exógenas).

El carácter exógeno que se le asigna a algunas variables es un supuesto que se deriva del hecho de que ese tipo de variables vienen dadas para un modelo mediante el cual se quiere representar una relación entre variables, por ejemplo describen la tecnología disponible o son instrumentos de política controlados por la autoridad económica. Sin embargo, las variables que son el objetivo de política se suponen endógenas (su valor se determina en el modelo).

En su artículo “Macroeconomics and Reality” (1980) [45] Sims sostiene que en un mundo de agentes que predicen el futuro realizando optimizaciones intertemporales, ninguna variable puede ser tratada como exógena. El carácter exógeno conferido a las variables que se utilizan como instrumentos de política, ignora la interrelación dinámica que existe entre ellas, puede inducir a cometer errores de inferencia y de interpretación en términos de relaciones causales de los instrumentos a los objetivos, expresados por las variables endógenas.

Se puede definir a y_t como un vector de k variables. En este caso las covarianzas entre las variables contienen información sobre las relaciones estáticas y dinámicas entre ellas, por lo cual es necesario estudiar adicionalmente las covarianzas entre las variables en el período t así como las covarianzas entre t y $t - h$.

Los modelos multivariados dinámicos se caracterizan por tener variables rezagadas que se relacionan a lo largo del tiempo. Por ejemplo, en el caso de la demanda de energéticos sería esperable que las cantidades demandadas tengan relación no solo con los precios corrientes, sino que también con los precios que se vienen observando en los períodos anteriores.

Dependiendo del proceso generador del dato que se este estudiando pueden darse varios casos:

- Modelos multivariados dinámicos uniecuacionales, por ejemplo los modelos autorregresivos de rezagos distribuidos.
- Modelos multivariados dinámicos multiecuacionales, por ejemplo modelos de vectores autorregresivos o modelos estructurales.

2.2.1. Modelos Autorregresivos de Rezagos Distribuidos

En Hendry (1995) [17] se define a los modelos uniecuacionales autorregresivos de rezagos distribuidos (Autorregresive Distributed Lags - ADL) $ADL(r, s, p, \dots, n)$, siendo $r, s, \dots, n$ la máxima cantidad de rezagos para las variables consideradas.

A modo de ejemplo presenta un modelo bivariado $ADL(1,1)$ y las distintas tipologías que tiene asociado dependiendo de las restricciones que se apliquen a los parámetros.

$$x_t = \beta_0 + \beta_1 z_t + \beta_2 x_{t-1} + \beta_3 z_{t-1} + \epsilon_t \text{ donde } \epsilon_t \sim IN[0, \sigma_\epsilon^2] , \quad (2.6)$$

teniendo los residuos ϵ_t con $t = 1 \dots T$ una distribución normal con media cero y varianza σ_ϵ^2 .

$$z_t = \lambda_0 + \lambda_1 z_{t-1} + v_t \text{ donde } v_t \sim IN[0, \sigma_v^2] , \quad (2.7)$$

teniendo los residuos v_t una distribución normal con media cero y varianza σ_v^2 y $E[v_t z_t] = 0 \quad \forall t, s$ siendo s la máxima cantidad de rezagos y $|\beta_2| < 1, \quad |\lambda_1| \leq 1$.

Derivado de esta especificación $ADL(1,1)$ y dependiendo de las restricciones que se impongan a los parámetros se obtienen distintos tipos de modelos presentados en el Cuadro 2.2.1 (para simplificar se asume que $\beta_0 = \lambda_0 = 0$).

Cuadro 2.2.1: Tipologías de modelos autorregresivos de rezagos distribuidos.

Tipo	Ecuación	Restricción
Autorregresivo de Rezagos Distribuidos	$x_t = \beta_1 z_t + \beta_2 x_{t-1} + \beta_3 z_{t-1} + \epsilon_t$	Ninguna
Regresión Estática	$x_t = \beta_1 z_t + u_t$	$\beta_2 = \beta_3 = 0$
Serie de Tiempo Univariada	$x_t = \beta_2 x_{t-1} + w_t$	$\beta_1 = \beta_3 = 0$
Datos en Diferencias	$\Delta x_t = \beta_1 \Delta z_t + \zeta_t$	$\beta_2 = 1, \beta_1 = -\beta_3$
Indicador Principal	$x_t = \beta_3 z_{t-1} + v_t$	$\beta_1 = \beta_2 = 0$
Ajuste Parcial	$x_t = \beta_1 z_t + \beta_2 x_{t-1} + \eta_t$	$\beta_3 = 0$
Factor Común (Error Autorregresivo)	$x_t = \beta_1 z_t + u_t \quad u_t = \beta_2 u_{t-1} + e_t$	$\beta_3 = -\beta_1 \beta_2$
Rezagos Distribuidos Finitos	$x_t = \beta_1 z_t + \beta_3 z_{t-1} + \xi_t$	$\beta_2 = 0$
Inicio Muerto (Dead Start)	$x_t = \beta_2 x_{t-1} + \beta_3 z_{t-1} + v_t$	$\beta_1 = 0$
Corrección al Equilibrio Homogéneo	$\Delta x_t = \beta_1 \Delta z_t + (\beta_2 - 1)(x - z)_{t-1} + v_t$	$\sum_{i=1}^3 \beta_i = 1$
Corrección al Equilibrio General	$\Delta x_t = \beta_1 \Delta z_t + (\beta_2 - 1)(x - k_1 z)_{t-1} + \epsilon_t$	Ninguna

Fuente: Hendry (1995) [17]

En 1980 C.A. Sims [45] introdujo los modelos multiecuacionales conocidos como Vectores Autorregresivos (VAR) planteandolos como alternativa a los tradicionales modelos macroeconómicos autorregresivos uniecuacionales.

Esta formulación no solo admite la interrelación dinámica dada por la incorporación en cada ecuación de los rezagos de las otras variables incorporadas al modelo, sino que todas las variables son consideradas simétricamente sin hacer referencia al rol dentro del modelo (exógenas o endógenas), lo cual es una diferencia sustancial respecto a otros modelos multivariados dinámicos donde se presume un determinado sentido en la causalidad o en la exogeneidad y endogeneidad de las variables.

Una de las aplicaciones de este tipo de modelos es poder constatar el tipo de relación entre determinadas variables en el marco de la teoría económica. Por ejemplo, tanto la exogeneidad de las variables, como el sentido de la causalidad de las mismas debe de contrastarse mediante pruebas de hipótesis, permitiendo así hacer una inferencia válida.

2.2.2. Modelos de Vectores Autorregresivos

Los modelos multiecuacionales se caracterizan por considerar la relación entre varias variables y su dinámica conjunta. Si no existe relación causal bidireccional (retroalimentación) entre las variables del modelo, se pueden aplicar las técnicas de análisis uniecuacional, permitiendo que los rezagos de la variable “dependiente” sean influenciados por los rezagos de una variable “exógena o independiente” Enders (2015) [10].

Sin embargo, no es frecuente que, en presencia de variables económicas que se relacionan entre sí, la relación causal sea unidireccional. En este caso, cuando existe retroalimentación entre las variables consideradas, emplear técnicas de estimación uniecuacional no es adecuado dado que no se logra reflejar en la modelización la dinámica conjunta de las variables.

El análisis mediante Vectores Autorregresivos (VAR) considera a todas las variables simétricamente, sin establecer si son dependientes o independientes. Los modelos VAR son ampliamente utilizados en análisis de series de tiempo multivariadas ya que permiten describir el comportamiento dinámico de las series económicas y financieras (permite encontrar si existen relaciones de largo y corto plazo entre las variables). Los usos principales de los modelos VAR son la predicción y el análisis estructural, Lütkepohl (2005) [35].

En Enders (2015) [p.285] [10] se presenta a modo de ejemplo, la especificación de un modelo de vectores autorregresivos de 1 rezago y 2 variables:

$$\begin{aligned} y_{1,t} &= b_{10} - b_{12}y_{2,t} + \gamma_{11}y_{1,t-1} + \gamma_{12}y_{2,t-1} + \epsilon_{y_{1,t}} \\ y_{2,t} &= b_{20} - b_{21}y_{1,t} + \gamma_{21}y_{1,t-1} + \gamma_{22}y_{2,t-1} + \epsilon_{y_{2,t}} \end{aligned} \quad (2.8)$$

donde se asume que $y_{1,t}$ y $y_{2,t}$ son series de tiempo estacionarias, $\{\epsilon_{y_{1,t}}\}$ y $\{\epsilon_{y_{2,t}}\}$ son procesos de error ruido blanco incorrelacionados, con desviación estándar σ_{y_1} y σ_{y_2} respectivamente.

Este modelo se caracteriza por contener los términos contemporáneos en cada ecuación ($y_{1,t}$ tiene un efecto contemporáneo en $y_{2,t}$ y visceversa) y se lo denomina como VAR en su *especi-*

ficación estructural.

La especificación puede simplificarse a través de una reorganizando términos. Ésto permite hacer la estimación en la forma que se presenta habitualmente en la literatura que se denomina como su *forma reducida*.

Para la reorganización de términos se parte del VAR de la ec.(2.8) y se especifica en notación vectorial:

$$\begin{bmatrix} 1 & b_{12} \\ b_{21} & 1 \end{bmatrix} \begin{bmatrix} y_{1,t} \\ y_{2,t} \end{bmatrix} = \begin{bmatrix} b_{10} \\ b_{20} \end{bmatrix} + \begin{bmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & \gamma_{22} \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \end{bmatrix} + \begin{bmatrix} \epsilon_{y_{1,t}} \\ \epsilon_{y_{2,t}} \end{bmatrix}, \quad (2.9)$$

que se puede expresar como:

$$By_t = \Gamma_0 + \Gamma_1 y_{t-1} + \epsilon_t, \quad ,$$

y a partir de la premultiplicación de B^{-1} a ambos lados de la ecuación se llega a la versión reducida del modelo VAR(1) bivariado:

$$y_t = A_0 + A_1 y_{t-1} + u_t \quad .$$

En Lütkepohl (2005) [35] se presenta una definición genérica de la versión reducida del modelo VAR(p) de vectores autorregresivos con p rezagos y k variables como:

$$y_t = v + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + u_t, \quad t = 1, \dots, T, \quad (2.10)$$

donde se considera a $y_t := (y_{1t}, \dots, y_{kt})'$ al vector que contiene las k variables observadas en cada momento t , $v := (v_1, \dots, v_k)'$ un vector de términos constantes de dimensión k que permite considerar el caso de $E(y_t) \neq 0$.

El proceso $\{u(t, k), t \in T, k \in K\}$ k -dimensional (no observable) ruido blanco $u_t := (u_{1t}, \dots, u_{kt})'$ con $t = 1, \dots, T$, en el cual $E(u_t) = 0$, $E(u_t u_t') = \Sigma_u$, y $E(u_t u_s') = 0$, si $s \neq t$.

Las matrices A_i , $i = 1, \dots, p$ son matrices fijas de coeficientes de dimensión $(k \times k)$:

$$A_i = \begin{bmatrix} \alpha_{11,i} & \cdots & \alpha_{1k,i} \\ \vdots & \ddots & \vdots \\ \alpha_{k1,i} & \cdots & \alpha_{kk,i} \end{bmatrix} \quad .$$

En un proceso k -dimensional se tendrán Tk observaciones y por lo tanto, $k + 3k + pk^2 + k(k + 1)/2$ parámetros a estimar, Johansen (1990) [25].

2.3. Estimación del VAR

La estimación de un modelo VAR puede realizarse a partir de distintos métodos de estimación. El método seleccionado depende de las características del proceso generador del dato. Particularmente, la condición de estacionariedad es determinante en la selección del método de estimación a utilizar (el concepto de estacionariedad se desarrolla en el apartado A.1.1).

Cuando las variables consideradas en el modelo son estacionarias, la estimación del VAR puede realizarse directamente a través de Mínimos Cuadrados Ordinarios (MCO) o el Método de Máxima Verosimilitud (MV), como se verá en el apartado 2.3.1.

Sin embargo, las series de tiempo económicas a menudo son procesos no estacionarios, y en este caso la estimación mediante MCO o MV debe aplicarse a las variables expresadas en primeras diferencias (no en niveles). Dichas transformaciones, que tienen el objetivo de conducirnos a variables estacionarias, implican pérdidas de información importante, Johansen (1990) [25].

Por tal motivo, cuando las series de datos provienen de procesos no estacionarios, el método de estimación más adecuado es el de Restricciones de Rango Reducido (RRR), el cual se desarrollará en el apartado 2.3.3.

Cuando todas las variables consideradas en el modelo son no estacionarias, adicionalmente pueden hacerse las pruebas sobre integración y cointegración de forma que se pueda contrastar si las variables tienen relación entre ellas, lo cual implica que su combinación lineal sea estacionaria y permite una convergencia al equilibrio en el largo plazo (los conceptos de integración y cointegración serán desarrollados en los apartados 2.3.2, A.1.3 y A.1.5).

A continuación se presenta cómo obtener un modelo VAR mediante una adecuada parametrización de un proceso condicional, a partir de la demostración desarrollada en Juselius (2006) [p.43] [29] siguiendo el enfoque de Engle-Hendry-Richard (1983) [p.115] [11].

Para una matriz de datos $Y = (y_1, y_2, y_3, \dots, y_T) \sim N_k(\mu, \Sigma)$ de $(k \times T)$ que se supone con distribución normal multivariante, se puede expresar la probabilidad conjunta $(Y|Y_0)$ dado un nivel inicial Y_0 y los parámetros θ como:

$$P(Y|Y_0; \theta) = P(y_1, y_2, \dots, y_T|Y_0; \theta) , \quad (2.11)$$

a partir de la cual, aplicando las reglas de probabilidad condicional se obtiene:

$$\begin{aligned} P(y_1, y_2, \dots, y_T|Y_0; \theta) &= P(y_T|y_{T-1}, \dots, y_1, Y_0; \theta)P(y_{T-1}, y_{T-2}, \dots, y_1|Y_0; \theta) , \\ &\vdots \\ P(y_1, y_2, \dots, y_T|Y_0; \theta) &= \prod_{t=1}^T P(y_t|Y_{t-1}^0; \theta) , \end{aligned} \quad (2.12)$$

2. Marco Teórico

donde $Y_{t-1}^0 = [y_{t-1}, y_{t-2}, \dots, y_1, Y_0]$.

A partir del desarrollo anterior, si se asume que las distribuciones condicionales tienen una distribución normal multivariada:

$$\{y_t | Y_{t-1}^0\} \sim N_k(\mu_t, \Omega) , \quad (2.13)$$

el modelo VAR de orden p se aproxima a un proceso condicional de la forma:

$$y_t = \mu_0 + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + \epsilon_t \quad i = 1, \dots, T \quad , \quad (2.14)$$

donde los residuos $\epsilon_t \sim IN_k(0, \Omega)$, $y_0, \dots, y_{-p+1}$ se asumen fijos y la matriz de covarianzas Ω es definida positiva, por lo tanto los residuos no se hallan correlacionados serialmente aunque puede darse que estén correlacionados contemporáneamente.

El supuesto de normalidad es consistente con que los agentes económicos son racionales, en el sentido de que no cometen errores sistemáticos cuando hacen sus planes para el momento t basados en la información disponible en $t - 1$, Hendry (2000-II) [19].

Por lo tanto, comprobar los supuestos del modelo y el requisito de residuos ruido blanco no sólo es crucial para hacer una correcta inferencia, sino que también para la interpretación del modelo como descripción del comportamiento de los agentes racionales.

Al analizar los residuos se puede encontrar que no estén “bien comportados” ⁵ debido a la presencia de observaciones atípicas, las cuales pueden estar originadas por intervenciones y/o políticas de gobierno.

Cuando la inspección visual indica que los datos, ya sea en niveles o en diferencias, no satisfacen el supuesto de media y varianza constante, es recomendable consultar el calendario económico para asociar tales desviaciones de los supuestos con reformas o intervenciones específicas.

El siguiente paso consiste en incluir esta información en el modelo y averiguar si la intervención o la reforma han tenido un efecto permanente o transitorio y si ha generado cambios en los parámetros del modelo. En este caso, es probable que la intervención esté definiendo un cambio de régimen que implica que el modelo deba ser re-especificado permitiendo captar el cambio en la estructura del modelo.

⁵Se denominan residuos “bien comportados” los que satisfagan las pruebas de hipótesis estadísticas de normalidad, homoscedasticidad y no correlación serial. Se puede ver la especificación completa de cada uno de las pruebas de hipótesis en el apartado A.3 del Anexo Metodológico A.

2.3.1. Estimación del VAR sin restricciones

Cuando las variables consideradas en el modelo son estacionarias la estimación del VAR puede llevarse a cabo a través del Método de Máxima Verosimilitud.

Para derivar el estimador máximo verosimil de los parámetros del modelo presentado en la ec.(2.14) se emplea la forma compacta [29]:

$$y_t = B'X_t + \epsilon_t, \quad \epsilon_t \sim IN_k(0, \Omega) \quad t = 1, \dots, T, \quad (2.15)$$

donde $B' = [\mu_0, A_1, \dots, A_p]$, $X_t' = [1, y'_{t-1}, \dots, y'_{t-p}]$ y los valores iniciales $y^0 = [y'_0, y'_{-1}, \dots, y'_{-p+1}]$ están dados.

La función de log-verosimilitud tiene la forma:

$$\ln L(B, \Omega; y) = -T \frac{k}{2} \ln(2\pi) - T \frac{1}{2} \ln |\Omega| - \frac{1}{2} \sum_{t=1}^T (y_t - B'X_t)' \Omega^{-1} (y_t - B'X_t) . \quad (2.16)$$

El estimador máximo verosimil de información completa de B es:

$$\hat{B}' = \sum_{t=1}^T (y_t X_t') \left(\sum_{t=1}^T X_t X_t' \right)^{-1} = \Sigma_{yX} \Sigma_{XX}^{-1} , \quad (2.17)$$

y el estimador máximo verosimil de Ω es:

$$\hat{\Omega} = T^{-1} \sum_{t=1}^T (y_t - \hat{B}'X_t) (y_t - \hat{B}'X_t)' = T^{-1} \sum_{t=1}^T \hat{\epsilon}_t \hat{\epsilon}_t' . \quad (2.18)$$

A partir de dichas estimaciones se determina el valor máximo de la función de log-verosimilitud como se demuestra en Juselius (2006) [p.57] [29]:

$$\ln L_{max} = -\frac{k}{2} T \ln(2\pi) - \frac{1}{2} T \ln |\hat{\Omega}| - \frac{1}{2} \sum_{t=1}^T (y_t - \hat{B}'X_t)' \hat{\Omega}^{-1} (y_t - \hat{B}'X_t) , \quad (2.19)$$

que puede reducirse a menos términos más una constante $cte = T \frac{k}{2} - T \frac{k}{2} \ln(2\pi)$:

$$\ln L_{max} = -\frac{1}{2} T \ln |\hat{\Omega}| + cte . \quad (2.20)$$

2.3.2. Modelo VAR Cointegrado

Para el análisis de las series de datos y seleccionar el método de estimación más adecuado, es importante determinar si cada una de las series con las cuales se va a trabajar es un proceso estacionario, tiene tendencia determinística, estocástica o ambas. De esta forma será posible estimar adecuadamente el comportamiento de largo plazo de las variables involucradas.

Adicionalmente, si las series son un proceso estacionario en diferencia es necesario determinar el orden de integración. En el caso de que las series fueran integradas, al ser no estacionarias, estimar un modelo multivariado ya sea uniecuacional o multiecuacional en niveles no daría estimaciones válidas e inhabilita la inferencia.

En el Anexo Metodológico se presentan las definiciones de no estacionariedad dada por tendencia estocástica o determinística [A.1.1](#), raíces unitarias [A.1.7](#), los conceptos de integración [A.1.3](#) y cointegración para el caso uniecuacional [A.1.5](#).

Al igual que en el caso uniecuacional, la presencia de raíces unitarias en el modelo VAR sin restricciones implica que hay un comportamiento estocástico no estacionario.

La cointegración depende de que las combinaciones lineales de las variables del proceso sean integradas de un orden menor, de forma que la no estacionariedad de una de las variables se corresponda con la no estacionariedad de otra de las variables llevando a que la combinación lineal entre ambas se convierta en estacionaria.

Como se define en Juselius (2006) [\[29\]](#)⁶:

- y_t es integrado de orden d si y_t tiene una representación $(1 - L)^d y_t = C(L)\epsilon_t$, donde $C(1) \neq 0$, y $\epsilon_t \sim IN(0, \Omega)$.
- El proceso $y_t \sim I(d)$ se dice que es cointegrado $CI(d, b)$ con vector de cointegración $\beta \neq 0$ si $\beta' y_t \sim I(d - b)$, $b=1, \dots, d$ y $d=1, \dots$

Cuando una o más variables tienen una tendencia conjunta (estocástica y/o determinística), van a mostrar una tendencia a moverse juntas en el largo plazo. En este sentido, la relación de cointegración $\beta' y_t$ puede interpretarse como una relación de equilibrio de largo plazo en sentido económico.

El objetivo del análisis de cointegración es identificar las combinaciones lineales que hacen estacionario al sistema de ecuaciones, dado por la especificación VAR en este caso.

Mediante la interpretación de las estimaciones de los coeficientes del sistema de ecuaciones, el objetivo es dar una interpretación y significado económico a esas combinaciones lineales a

⁶La definición de operador de rezagos y diferencias se encuentra en el Anexo Metodológico [A.1.1](#).

partir de imponer restricciones en los coeficientes a partir de una normalización ⁷ (ver desarrollo sobre normalización en el apartado 2.4.4).

Representación del VAR mediante un VECM

En los casos en que las variables están cointegradas, el Teorema de Representación de Granger (Teorema 4.2 en Johansen (1995) [p.48] [27]) establece que es posible expresar el VAR como un Vector de Corrección de Error (VECM - Vector Equilibrium Correction Model), que permite reformular el modelo VAR incluyendo además de los términos en niveles y rezagos, términos en diferencia.

Esta formulación habilita a separar la dinámica de las variables en corto plazo y en largo plazo. El VECM es la versión multiecuacional del ECM presentado en la ecuación A.16 del apartado A.1.5.

Como se plantea en Juselius (2006) [p.60] [29], esta reformulación no sólo no implica aplicar restricciones a los parámetros del modelo ni cambios en la función de verosimilitud, sino que además tiene ventajas para la interpretación:

1. El efecto de multicolinealidad que generalmente está presente en datos de series de tiempo se reduce significativamente en la formulación mediante corrección de error. Las variables en diferencias son más “ortogonales” que en niveles.
2. La información de los efectos de largo plazo queda concentrada en la matriz en niveles (Π).
3. La interpretación de los coeficientes estimados es más intuitiva, dado que dichos coeficientes han sido clasificados en efectos de corto y largo plazo.

Formulación general del VECM para un VAR(p):

$$\Delta y_t = \Gamma_1^{(m)} \Delta y_{t-1} + \Gamma_2^{(m)} \Delta y_{t-2} + \dots + \Gamma_{p-1}^{(m)} \Delta y_{t-p+1} + \Pi y_{t-m} + \Phi D_t + \epsilon_t, \quad (2.21)$$

⁷A lo largo del documento se maneja el término de restricciones con implicancias distintas dependiendo de la parte del análisis en que se encuentre. En la estimación del VAR sin restricciones, hace referencia a que la estimación de las matrices A_i no contienen restricciones dadas por la presencia de raíces unitarias. Sin embargo, cuando los datos contienen raíces unitarias las matrices A_i no pueden estimarse de forma directa, es necesario derivar las estimaciones a partir de la matriz $\Pi = \alpha\beta'$ con $1 < \text{rango}(\Pi) < k - 1$ que tiene rango reducido, y dicha estimación se hace mediante restricciones de rango reducido, siendo necesario imponer restricciones a la matriz de acuerdo a la cantidad de relaciones de cointegración que se encuentren. Cuando hay exogeneidad débil es otro caso en que se imponen otro tipo de restricciones, imponiendo el valor cero cuando es estadísticamente no significativa la estimación (en la matriz de α específicamente). En éste último caso que se menciona aquí asociado a normalización, imponer restricciones hace referencia a una re escala que se le aplica a las matrices $\alpha'\beta$ para darle interpretación en sentido económico.

donde m es un número entre 1 y p que define la posición del rezago en el término del VECM y D_t contiene la constante y/o tendencia, dummies estacionales centradas e intervenciones que vayan a incluirse en el modelo. Los cambios en el valor de m no modifican el valor de la verosimilitud ni el valor estimado de los componentes de (Π) , sino que en cambio modifican el tipo de interpretación que se puede hacer del modelo estimado en su relación de corto y largo plazo a partir de $(\Gamma_i^{(m)})$.

La forma de identificar la cantidad de combinaciones lineales o relaciones de cointegración es a través del rango de la matriz Π denominado rango de cointegración, el cual varía entre 0 y k , siendo k el número de variables endógenas del modelo.

- $rango(\Pi) = 0$, no hay ninguna relación de cointegración. Dado que las variables son no estacionarias y no están cointegradas, existen k procesos no estacionarios independientes con su propia tendencia individual, que rigen la evolución de largo plazo. En este caso las variables no tienen tendencia estocástica común que las haga mover juntas a lo largo del tiempo. El análisis de las series debe hacerse con las primeras diferencias de las variables, sin pérdidas de información de largo plazo.
- $rango(\Pi) = k$, Π es de rango completo y no singular. Implica que las variables son estacionarias $I(0)$ y existen k relaciones de cointegración. El modelo VAR debe ser especificado en los niveles de las series ya que ninguna posee raíz unitaria, y la inferencia se hace de forma convencional.
- $rango(\Pi)$ está entre 1 y $(k - 1)$, implica que puede haber hasta $(k - 1)$ relaciones de cointegración y el número de raíces unitarias y tendencias conjuntas que hay son $(k - r)$. La matriz Π se expresa como el producto de dos matrices $\Pi = \alpha\beta'$ de $(k \times r)$, ambas de rango r .

Cuando los datos contienen raíces unitarias ($1 < rango(\Pi) < k - 1$), la matriz $\Pi = \alpha\beta'$ tiene rango reducido y por lo tanto es necesario derivar las estimaciones de $\alpha\beta'$ a través de restricciones de rango reducido (RRR).

Derivación del VECM a partir de un VAR(1).

$$y_t = A_1 y_{t-1} + \Phi D_t + \epsilon_t , \quad (2.22)$$

$$y_t - y_{t-1} = A_1 y_{t-1} - y_{t-1} + \Phi D_t + \epsilon_t$$

$$\Delta y_t = (A_1 - I_k) y_{t-1} + \Phi D_t + \epsilon_t$$

$$\Delta y_t = \Pi y_{t-1} + \Phi D_t + \epsilon_t . \quad (2.23)$$

Formulación del VECM para un VAR(2) cuando $m = 1$.

$$\Delta y_t = \Gamma_1^{(1)} \Delta y_{t-1} + \Pi y_{t-1} + \Phi D_t + \epsilon_t , \quad (2.24)$$

donde $\Pi = -(I_k - A_1 - A_2)$ siendo I_k la matriz identidad de orden k , y $\Gamma_1^{(1)} = -A_2$.

Derivación del VECM a partir del VAR(2):

$$y_t = A_1 y_{t-1} + A_2 y_{t-2} + \Phi D_t + \epsilon_t , \quad (2.25)$$

$$y_t - y_{t-1} = A_1 y_{t-1} - y_{t-1} + A_2 y_{t-1} - A_2 y_{t-1} + A_2 y_{t-2} + \Phi D_t + \epsilon_t$$

$$\Delta y_t = (A_1 - I_k + A_2) y_{t-1} - A_2 (y_{t-1} - y_{t-2}) + \Phi D_t + \epsilon_t$$

$$\Delta y_t = \underbrace{-(I_k - A_1 - A_2)}_{\Pi} y_{t-1} + \underbrace{-A_2}_{\Gamma_1^{(1)}} \Delta y_{t-1} + \Phi D_t + \epsilon_t$$

$$\Delta y_t = \Gamma_1^{(1)} \Delta y_{t-1} + \Pi y_{t-1} + \Phi D_t + \epsilon_t .$$

Formulación del VECM para un VAR(2) cuando $m = 2$.

En forma análoga al caso anterior se puede derivar la formulación del VECM para el caso en que $m = 2$, resultando en:

$$\Delta y_t = \Gamma_1^{(2)} \Delta y_{t-1} + \Pi y_{t-2} + \Phi D_t + \epsilon_t , \quad (2.26)$$

donde $\Pi = -(I_k - A_1 - A_2)$ y $\Gamma_1^{(2)} = -(I_k - A_1)$.

La selección de la cantidad de rezagos p a incluir en el modelo VAR(p) se puede llevar a cabo a través de pruebas de razón de máxima verosimilitud.

Es importante que la especificación del modelo sea lo más cercana a la especificación final a adoptar porque sino los resultados de las pruebas pueden inducir a seleccionar una cantidad de rezagos que no es apropiada.

Cuando el modelo no está especificado correctamente (por ejemplo, debido a la presencia de datos atípicos y/o saltos en la media del proceso) es posible que se generen problemas de residuos autocorrelacionados, en estos casos las pruebas sobre cantidad de rezagos suelen sugerir más rezagos de los que realmente son.

Según plantea Juselius (2006) [p.72] [29] en la mayoría de los casos incluir 2 rezagos es más que suficiente para describir la estructura dinámica del proceso. También sugiere que la experiencia muestra que la autocorrelación en los residuos en un modelo VAR(2) está usualmente asociada con un problema de quiebre estructural en la especificación, más que por no captar bien la dinámica del modelo por incluir pocos rezagos. En la práctica, es rara la ocasión en que un modelo especificado correctamente necesite incluir más de 2 rezagos.

2.3.3. Estimación mediante Restricciones de Rango Reducido

La estimación de los coeficientes de la regresión lineal multivariada se puede realizar mediante varios métodos como mínimos cuadrados (LS-Least Square), mínimos cuadrados generalizados (EGLS), máxima verosimilitud (MV), mínimos cuadrados en dos etapas.

Como se expresa en Izenman (1975), cuando se asume que la matriz de coeficientes de la regresión es de rango completo se puede demostrar que la estimación por mínimos cuadrados aplicada simultáneamente a todas las ecuaciones del modelo da el mismo resultado que hacer la estimación de mínimos cuadrados ordinarios aplicada ecuación por ecuación [p.249] [23].

Asumiendo que los parámetros a estimar en el modelo VAR son no restringidos y bajo la hipótesis de normalidad de los errores, además se demuestra que el estimador por mínimos cuadrados es idéntico al estimador máximo verosímil de información completa (FIML- Full Information Maximum Likelihood) [p.241] [29].

Sin embargo, la situación es diferente cuando se admite la posibilidad de que la matriz de coeficientes de la regresión no tiene rango completo, en ese caso pueden existir restricciones lineales en los coeficientes de la regresión.

En este sentido, la regresión de rango reducido es una forma de restringir la regresión lineal multivariada asumiendo que el rango de la matriz de coeficientes sea menor a rango completo.

La técnica de regresión de rango reducido fue introducida por Anderson & Rubin (1949) [3] en relación al análisis de FIML, luego generalizada al modelo de restricciones de rango reducido por Anderson (1951) [4] y posteriormente desarrollado por Izenman (1972,1975) [22,23].

Una de las razones por las cuales la técnica multivariada de regresión de rango reducido es tan importante, es la amplitud de técnicas estadísticas clásicas que abarca, como ser el análisis de componentes principales, análisis de correlación canónica, el análisis discriminante y otros métodos lineales de análisis multivariado y de reducción de datos. Así como también se vincula en la literatura a los modelos de redes neuronales y al análisis de cointegración en econometría, Izenman (2008) ⁸.

⁸Dependiendo del tipo de técnica que se plantee aplicar varía la definición de las matrices X , Y y P . A modo de ejemplo, para el análisis de componentes principales se define $X \equiv Y$ y la matriz de pesos $P = I_s$ y para el caso de análisis de correlación canónica se define $P = \Sigma_Y^{-1}$. En Box Tiao (1977) se presenta la metodología de ajuste de procesos autorregresivos múltiples cuyas componentes, mediante una transformación canónica, son ordenadas acorde a su grado de predicibilidad.

A continuación se presenta el desarrollo de Izenman sobre el método de restricciones de rango reducido en términos generales, aplicado a 2 matrices de datos X e Y .

Posteriormente se presenta la aplicación de éste método de estimación a un modelo VAR integrado, llevada a cabo por Johansen (2004) [28], donde incorpora dentro de la ecuación a estimar una matriz adicional de datos que contiene variables exógenas y componentes determinísticos.

Por último, se presenta la estimación mediante restricciones de rango reducido desarrollado por Johansen (2004) con la notación presentada en la ec.(2.21) para un modelo VAR integrado I(1).

Desarrollo de Izenman de restricciones de rango reducido.

Siguiendo el desarrollo de Izenman (1975) [23] se considera un modelo clásico de regresión lineal multivariada con regresores aleatorios:

$$Y_{(s \times 1)} = \mu_{(s \times 1)} + \Theta_{(s \times v)} X_{(v \times 1)} + \epsilon_{(s \times 1)} , \quad (2.27)$$

donde Y depende linealmente de X , μ es un vector de medias, Θ es la matriz de coeficientes de la regresión multivariada y ϵ el término de error.

Se parte de un vector aleatorio de variables exógenas $X = (X_1, \dots, X_v)'$ con un vector de media μ_X y matriz de varianzas y covarianzas Σ_{XX} , y un vector de variables dependientes $Y = (Y_1, \dots, Y_s)'$ con media μ_Y y matriz de varianzas y covarianzas Σ_{YY} . Se supone que el vector $Z = (X', Y')'$ de dimensión $(v + s)$, tiene vector de medias y matriz de covarianzas:

$$\mu_Z = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \quad \Sigma_Z = \begin{pmatrix} \Sigma_{XX} & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_{YY} \end{pmatrix} , \quad (2.28)$$

donde se asume que Σ_{XX} y Σ_{YY} son matrices no singulares.

El estimador por mínimos cuadrados de (μ, Θ) , en el caso que Θ tiene rango completo, está dado por:

$$(\mu^*, \Theta^*) = \arg \min_{(\mu, \Theta)} E \{ (Y - \mu - \Theta X)(Y - \mu - \Theta X)' \} , \quad (2.29)$$

con $\mu^* = \mu_Y - \Theta^* \mu_X$ y $\Theta^* = \Sigma_{XY} \Sigma_{XX}^{-1}$.

El mínimo queda determinado con $(\Sigma_{YY} - \Sigma_{YX} \Sigma_{XX}^{-1} \Sigma_{XY})$, y la matriz Θ^* de $(s \times v)$ es de rango completo. Este resultado es equivalente a realizar s regresiones lineales por mínimos cuadrados ordinarios.

Sin embargo, el modelo que interesa estimar presenta restricciones de la forma:

$$Y_{(s \times 1)} = \mu_{(s \times 1)} + C_{(s \times v)} X_{(v \times 1)} + \epsilon_{(s \times 1)} \quad , \text{ con } \text{rango}(C) = r \leq \min(v, s) \quad . \quad (2.30)$$

Cuando se da esta restricción, existen dos matrices de rango completo $A_{(s \times r)}$ y $B_{(r \times v)}$ que cumplen

$$C_{(s \times v)} = A_{(s \times r)} B_{(r \times v)}, \text{ y el objetivo es estimar } (\mu, A, B).$$

Si se define una matriz de pesos P como una matriz simétrica definida positiva de $(s \times s)$, los mínimos cuadrados ponderados se estiman:

$$(\mu^*, A^*, B^*) = \arg \min_{(\mu, A, B)} E \{ (Y - \mu - ABX)' P (Y - \mu - ABX) \} \quad , \quad (2.31)$$

obteniendo:

$$\mu^* = \mu_Y - AB\mu_X \quad , \quad (2.32)$$

$$B^* = P^{-1/2} V \quad , \quad (2.33)$$

$$A^* = V' P^{1/2} \Sigma_{YX} \Sigma_{XX}^{-1} \quad , \quad (2.34)$$

donde $V = (v_1, \dots, v_r)$ es una matriz de $(s \times r)$ en que la j -ésima columna v_j corresponde al vector propio asociado al j -ésimo valor propio más grande de la matriz de $(s \times s)$:

$$P^{1/2} \Sigma_{YX} \Sigma_{XX}^{-1} \Sigma_{XY} P^{1/2} \quad . \quad (2.35)$$

Aplicación de Johansen del método de restricciones de rango reducido en un VAR integrado I(1).

En el caso particular de este trabajo de investigación, el método de regresión de rango reducido se aplica en el contexto de la estimación de un modelo cointegrado, donde a partir de la constatación de existencia de raíces unitarias en los datos, se determina que la matriz de coeficientes a estimar es de rango reducido y el método de estimación debe ser mediante RRR.

En Johansen (2004) [28] se presenta el método de estimación de RRR incluyendo un componente adicional que puede incluir tanto los valores rezagados como los componentes determinísticos del VECM.

Se considera la regresión multivariada de U_t respecto a W_t y Z_t , asumiendo que Π tiene rango reducido $\text{rango}(\Pi) = r$ con $0 < r < k$, y los errores ϵ_t tienen vector de medias cero y matriz de varianzas y covarianzas Ω :

$$U_t = \Pi W_t + \Gamma Z_t + \epsilon_t, \quad t = 1, \dots, T. \quad (2.36)$$

La dimensión de U_t es $(k \times t)$ y $\Pi = \alpha\beta'$ con dimensión de α y β igual a $(k \times r)$ con $\text{rango}(\alpha) = r$ y $\text{rango}(\beta) = r$.

La estimación del modelo $\text{RRR}(U, W|Z)$ implica estimar la regresión de U respecto a W condicionado a la información presente en Z .

Para el cálculo es necesario introducir la siguiente notación:

$$S_{uw} = T^{-1} \sum_{t=1}^T U_t W_t' , \quad (2.37)$$

y los residuos que se obtienen de regesar U_t con W_t son:

$$(U|W)_t = U_t - S_{uw} S_{ww}^{-1} W_t , \quad (2.38)$$

entonces, los productos de los momentos condicionales están dados por:

$$S_{uw.z} = S_{uw} - S_{uz} S_{zz}^{-1} S_{zw} = T^{-1} \sum_{t=1}^T (U|Z)_t (W|Z)_t' , \quad (2.39)$$

$$S_{uu.w,z} = T^{-1} \sum_{t=1}^T (U|W, Z)_t (U|W, Z)_t' = S_{uu.w} - S_{uz.w} S_{zz.w}^{-1} S_{zu.w} . \quad (2.40)$$

Las estimaciones en un modelo sin restricciones serían: $\hat{\Pi} = S_{uw.z} S_{ww.z}^{-1}$, $\hat{\Gamma} = S_{uz.w} S_{zz.w}^{-1}$ y $\hat{\Omega} = S_{uu.w,z}$.

Las estimaciones de α y β cuando se asume que $\Pi = \alpha\beta'$, α es $(k \times r)$ y β es $(k \times r)$ se hace mediante regresión de rango reducido de U_t sobre W_t corregido por Z_t .

Los pasos de la estimación son:

1. Regresar U y W por separado respecto a Z y calcular los residuos R_{0t} , R_{1t} y los productos de cada momento $S_{uw.z}$:

$$R_{0t} : (U|Z)_t = U_t - S_{uz}S_{zz}^{-1}Z_t \quad .$$

$$R_{1t} : (W|Z)_t = W_t - S_{wz}S_{zz}^{-1}Z_t \quad .$$

A partir de lo cual se puede definir el modelo que se denomina *concentrado*:

$$R_{0t} = \alpha\beta'R_{1t} + \epsilon_t \quad (2.41)$$

2. Luego obtener los valores y vectores propios mediante:

$$|\lambda S_{ww.z} - S_{wu.z}S_{uu.z}^{-1}S_{uw.z}| = 0 \quad ,$$

donde $|\cdot|$ denota al determinante.

Los valores propios ordenados son $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_k)$ y los vectores propios $V = (v_1, \dots, v_k)$. V está normalizado y como matriz de pesos se considera $P = S_{ww.z}^{-1}$.

$$S_{ww.z}V\Lambda = S_{wu.z}S_{uu.z}^{-1}S_{uw.z}V \quad , \quad (2.42)$$

$$V'S_{ww.z}V = I_k \quad ,$$

$$V'S_{uw.z}S_{ww.z}^{-1}S_{wu.z}V = \Lambda \quad .$$

Cada λ_i puede ser interpretado como la correlación canónica al cuadrado entre la combinación lineal de los niveles $\beta'_i R_{0t}$ y la combinación lineal de las diferencias R_{1t} .

Por lo tanto, la interpretación de λ_1 es la máxima correlación canónica al cuadrado entre U y W corregida por Z de forma que:

$$\lambda_1 = \max_{\xi, \eta} \frac{(\xi'S_{uw.z}\eta)^2}{\xi'S_{uu.z}\xi\eta'S_{ww.z}\eta} \quad . \quad (2.43)$$

3. Por último se definen los estimadores de rango reducido de β y α :

$$\hat{\beta} = (\hat{v}_1, \dots, \hat{v}_r)'S_{ww.z}^{-1/2} \quad . \quad (2.44)$$

A partir de $\hat{\beta}$ y el modelo concentrado se obtiene $\hat{\alpha}$:

$$\begin{aligned} R_{0t} &= \alpha\beta'R_{1t} \\ R_{0t}R'_{1t}\beta &= \alpha\beta'R_{1t}R'_{1t}\beta \\ S_{uw.z}\beta &= \alpha\beta'S_{ww.z}\beta \end{aligned}$$

$$\hat{\alpha} = S_{uw.z} \hat{\beta} (\hat{\beta}' S_{ww.z} \hat{\beta})^{-1} , \quad (2.45)$$

$$\hat{\Gamma} = S_{uz.\hat{\beta}'w} S_{zz.\hat{\beta}'w}^{-1} ,$$

$$\hat{\Omega} = S_{uu.z} - S_{uw.z} \hat{\beta} (\hat{\beta}' S_{ww.z} \hat{\beta})^{-1} \hat{\beta}' S_{wu.z} ,$$

a su vez se cumple que $|\hat{\Omega}| = |S_{uu.z}| \prod_{i=1}^r (1 - \hat{\lambda}_i)$.

Aplicación del método de restricciones de rango reducido al VAR Cointegrado.

Cuando el modelo VAR a estimar es $I(1)$ se puede reescribir el modelo como un VECM y estimar mediante regresiones de rango reducido, como se plantea en Johansen (2004).

$$\Delta y_t = \alpha \beta' y_{t-1} + \Gamma_1 \Delta y_{t-1} + \Gamma_2 \Delta y_{t-2} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + \Phi D_t + \epsilon_t , \quad (2.46)$$

donde D_t son componentes determinísticos. Para la derivación de los estimadores de máxima verosimilitud y la prueba de razón de verosimilitud se asume que $\epsilon_t \text{i.i.d} \sim N_k(0, \Omega)$.

$$RRR(\Delta y_t, y'_{t-1} | \Delta y_{t-1}, \dots, \Delta y_{t-p+1}, D_t) , \quad (2.47)$$

siguiendo los pasos de estimación previamente mencionados:

$$R_{0t} = (\Delta y_t | \Delta y_{t-1}, \dots, \Delta y_{t-p+1}, D_t) \quad (2.48)$$

$$R_{1t} = (y'_{t-1} | \Delta y_{t-1}, \dots, \Delta y_{t-p+1}, D_t) \quad (2.49)$$

$$S_{ij} = T^{-1} \sum_{i=1}^T R_{it} R'_{jt} . \quad (2.50)$$

La estimación de $\hat{\beta}$ que se obtiene de la minimización de los errores al cuadrado ponderados implica obtener los valores y vectores propios de $S_{11}^{-1/2} S_{10} S_{00}^{-1} S_{01} S_{11}^{-1/2}$ a través de:

$$|\lambda S_{11} - S_{10} S_{00}^{-1} S_{01}| = 0 . \quad (2.51)$$

Para la estimación de los errores estándar de cada componente de la matriz β se sigue a Johansen (1995), que demuestra en su Teorema 13.3 [p.183] [27], que la matriz de varianza condicional de

β tiene una distribución asintótica Gaussiana Mixta, que puede ser estimada consistentemente por:

$$T \left(I - \hat{\beta}c' \right) S_{11}^{-1} \left(I - \hat{\beta}c' \right) \otimes \left(\hat{\alpha}'\hat{\Omega}^{-1}\hat{\alpha} \right)^{-1} . \quad (2.52)$$

Siendo $c_{(k \times r)}$ la matriz de normalización que se expone más adelante en el apartado 2.4.4.

En Lütkepohl (2005) se plantea que para un modelo gaussiano la estimación del modelo mediante mínimos cuadrados (con β conocido) es equivalente a la estimación por máxima verosimilitud dado que en todas las ecuaciones aparecen los mismos regresores.

Por lo tanto, una forma de realizar la estimación del modelo de la ec.(2.21) es a través de una estimación en dos etapas, donde primero se obtiene la estimación de β mediante RRR y se utiliza esa estimación para estimar el modelo completo mediante mínimos cuadrados, Hendry (2000-II) [19].

La máxima verosimilitud, está dada por:

$$L_{max}^{-2/T} = |\hat{\Omega}| = |S_{00}| \prod_{i=1}^k (1 - \hat{\lambda}_i) . \quad (2.53)$$

A través del cálculo de la máxima verosimilitud se pueden calcular distintos estadísticos que habilitan a hacer pruebas de hipótesis, por ejemplo el cálculo de la prueba de razón de verosimilitud para determinar el rango de cointegración, como se verá en la próxima sección.

2.4. Especificación del Modelo

La especificación del VAR a estimar implica seguir una serie de pasos que se van reiterando hasta obtener una especificación que logre captar de forma adecuada la variabilidad y explicar correctamente a los datos. En la Figura 2.1 se presenta un resumen de la secuencia de pasos a seguir.

En primer instancia, es necesario identificar el modelo que quiere estimarse en base a la teoría económica y la metodología de estimación más adecuada para ese propósito. En este caso la metodología seleccionada es la de Vecores Autorregresivos, por lo tanto el siguiente paso es determinar el orden del VAR a estimar, lo cual implica determinar la cantidad de rezagos.

Para ésto se aplica una prueba de razón de verosimilitud donde se compara la estimación de máxima verosimilitud de un VAR(1) respecto a un VAR(2), luego un VAR(3) y así sucesivamente hasta determinar la cantidad de rezagos que logre captar mejor la dinámica de los datos.




Figura 2.1: Flujo con secuencia de pasos a seguir al momento de la estimación del VAR.

A su vez, se pueden usar otros indicadores complementarios para la selección de la cantidad de rezagos, como los criterios de información de AIC, SC y HQ. En el apartado A.2 del Anexo Metodológico se presenta la forma de cálculo de las pruebas de hipótesis y los resultados respectivos en el Capítulo 4.

En segunda instancia, luego de haber determinado la cantidad de rezagos del VAR, se especifica el modelo como un VECM a los efectos de realizar la estimación de parámetros. Como se mencionó en el apartado 2.3.2, al ser sólo una re-organización de los términos, no afecta el valor de la máxima verosimilitud y adicionalmente permite discernir los efectos de corto y largo plazo.

Luego de especificar el VAR como VECM se determina el rango de cointegración al mismo tiempo que se define el Caso de Johansen que mejor se adecúa a los datos, según sus componentes determinísticos dentro y fuera de la relación de cointegración. Ambos pasos son determinantes del análisis posterior.

A partir de la estimación del VECM se realizan una serie de pruebas diagnósticas para comprobar la adecuación de la especificación al proceso generador del dato y validación del modelo, lo cual implica:

- Pruebas de hipótesis sobre la significación de los coeficientes β .
- Pruebas de hipótesis sobre los residuos (normalidad, heteroscedasticidad, autocorrelación).
- Pruebas de Causalidad.
- Pruebas de Exogeneidad.
- Pruebas de hipótesis sobre la significación de los coeficientes α .

Los resultados de cada una de esas pruebas puede determinar la necesidad de reespecificar el modelo. Por ejemplo, la no normalidad puede estar dada por la presencia de shock que generan gran variabilidad en los datos, lo cual puede ser captado mediante intervenciones y corresponde incorporarlas al modelo y estimar todo nuevamente.

Si el resultado de las pruebas de hipótesis muestra que alguno de los coeficientes β son no significativos puede estar implicando que no corresponda incluirlo dentro de la relación de cointegración, pero sí sea una variable explicativa en el modelo que deba ser incluida como exógena (no restringida a la relación de cointegración).

Las pruebas de hipótesis sobre los coeficientes α permite contrastar si existe exogeneidad débil de la respectiva variable asociada (este concepto se profundizará en el apartado 2.5), lo cual puede determinar una re-especificación del VECM nuevamente.

Por lo tanto, se parte de una especificación inicial a partir de la cual se hacen las pruebas de validación y se comienza un proceso iterativo en el cual se van realizando los cambios de a

uno, porque cada cambio puede afectar mucho los valores estimados y las pruebas de hipótesis, hasta lograr una especificación que logre captar adecuadamente toda la variabilidad de los datos y con residuos que cumplen los supuestos necesarios.

Adicionalmente a estos pasos necesarios para lograr una especificación que refleje al verdadero proceso generador del dato, se realizan pruebas de hipótesis para contrastar la causalidad de las variables y poder determinar si hay relaciones bidireccionales o unidireccionales entre ellas, pruebas de hipótesis de exogeneidad e invarianza paramétrica, y por último pruebas en predicción si los resultados previos lo habilitan.

2.4.1. Componentes determinísticos en el VAR integrado I(1)

Una característica particular de la especificación mediante VECM es que se incluyen las variables tanto en niveles como en diferencias, lo cual permite analizar los efectos tanto en el largo como en el corto plazo.

Cuando las variables comparten una tendencia estocástica y/o determinística⁹ es posible encontrar una combinación lineal entre ellas que cancele esas tendencias. En ese caso forman parte de la relación de cointegración, la cual no tiene porque tener tendencia aunque las variables consideradas de forma individual sí la tengan, Hendry (2000-II) [19].

En el caso de variables económicas, frecuentemente, además de la tendencia estocástica pueden presentar tendencia determinística, por lo tanto es importante considerar el tipo de componentes determinísticos que pueden estar presentes en la especificación del modelo para poder medirlo.

Se consideran varios tipos de componentes determinísticos, como ser: constante, tendencia, variables dummy, intervenciones, variables exógenas. Primero se plantea como afecta a la estimación la inclusión de una constante y/o una tendencia y posteriormente se considera la inclusión de otras variables como las dummies estacionales¹⁰, intervenciones y exógenas.

La instancia de determinación de los componentes determinísticos es de gran importancia, dado que si los componentes determinísticos incorporados son incorrectos puede llevar a que la estimación de los parámetros del modelo sean sesgadas, principalmente porque la distribución asintótica de las pruebas de cointegración no son invariantes a ese tipo de componentes incorporados en la especificación, Hendry (2000-II) [19].

Para facilitar el análisis de las implicancias de la inclusión de una constante o una tendencia dentro y/o fuera de la relación de cointegración, se presenta el VECM derivado a partir de un VAR(1) como se presenta en Juselius (2006).

⁹La definición y ampliación sobre el tema de no estacionariedad, tendencia estocástica y determinística se encuentra en el Anexo Metodológico A.

¹⁰Las dummies estacionales se incluyen dentro de los componentes determinísticos del modelo y son incorporadas usualmente para dar cuenta de las fluctuaciones estacionales de las variables sin que afecte la distribución asintótica de las pruebas de razón de verosimilitud, Lütkepohl (2005).

$$\Delta y_t = \alpha \begin{bmatrix} \beta' & \beta_0 & \beta_1 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ 1 \\ t \end{bmatrix} + \gamma_0 + \gamma_1 t + \epsilon_t . \quad (2.54)$$

Siendo β_0 una constante y β_1 una tendencia determinística incluídas en la relación de cointegración, mientras que γ_0 y γ_1 representan a la constante y tendencia determinística consideradas fuera de la relación de cointegración.

$$\Delta y_t = \alpha \beta' y_{t-1} + \mu_0 + \mu_1 t + \epsilon_t , \quad (2.55)$$

con $\mu_0 = \alpha \beta_0 + \gamma_0$ y $\mu_1 = \alpha \beta_1 + \gamma_1$.

El tipo de especificación a modelizar va a depender de como sean los valores que toman μ_0 y μ_1 .

- Caso 1. **Sin constante (nc):** $\mu_1 = \mu_0 = 0$. Este caso corresponde al modelo sin componente determinístico en los datos. $E(\Delta y_t) = 0$ y $E(\beta' y_t) = 0$, implicando que cada constante de las relaciones de cointegración son cero.
- Caso 2. **Constante restringida (rc):** $\mu_1 = 0, \gamma_0 = 0$ pero $\beta_0 \neq 0$. El término constante está restringido a estar en la relación de cointegración. En este caso no hay tendencias lineales en los datos, siendo consistente con $E(\Delta y_t) = 0$. El único componente determinístico en el modelo es el término constante de la relación de cointegración, implicando que la media en el equilibrio es distinta de cero.
- Caso 3. **Constante no restringida (uc):** $\mu_1 = 0, (\beta_1, \gamma_1) = 0$ y el término constante μ_0 está no restringido a la relación de cointegración. En este caso no hay tendencia determinística en el espacio de cointegración, pero $E(\Delta y_t) = \gamma_0 \neq 0$ es consistente con la tendencia lineal determinística en las variables, pero como $\beta_1 = 0$, esas tendencias se cancelan en la relación de cointegración. En este sentido, $\mu_0 \neq 0$ implica ambos, tendencia lineal en los datos y una constante distinta de cero en la relación de cointegración.
- Caso 4. **Tendencia lineal restringida y constante no restringida (crt):** $\gamma_1 = 0$ pero $(\gamma_0, \beta_0, \beta_1) \neq 0$. La tendencia esta restringida a aparecer sólo en la relación de cointegración, pero la constante está no restringida en el modelo. Cuando γ_1 está restringida a cero, se permite que la tendencia sea lineal pero no cuadrática. $E(\Delta y_t) = \gamma_0 \neq 0$ implica una tendencia lineal en y_t en niveles. Si adicionalmente $\beta_1 \neq 0$ la tendencia lineal en las variables no se cancelan en la relación de cointegración. El modelo contiene relaciones “estacionarias en tendencia” que pueden describir una variable estacionaria en tendencia individual $(y_{1,t} - b_1 t) \sim I(0)$ o una relación de equilibrio $(\beta'_1 y_t - b_2 t) \sim I(0)$.
- Caso 5. **Tendencia lineal y constante no restringidas(ct):** Sin restricciones en μ_0, μ_1 . La tendencia y la constante son no restringidas en el modelo. En este caso, el modelo es consistente con tendencia lineal en las variables en diferencia Δy_t y con tendencia cuadrática en las variables en niveles y_t .

La selección de la especificación del modelo a analizar va a depender de la inspección gráfica y los contrastes de hipótesis que se hagan para determinar si los componentes determinísticos son significativos.

En el Cuadro 2.4.1 se resume los 5 casos con las restricciones en los componentes determinísticos presentados en Johansen (2004), en base a los cuales se realizan las pruebas de hipótesis para determinar la cantidad de relaciones de cointegración.

Cuadro 2.4.1: Casos de Johansen sobre los componentes determinísticos.

Caso	Término lineal	Restricción	Tendencia en y_t	$E(\Delta y_t)$	$E(\beta' y_t)$
Caso 1: nc	0	$\mu_1 = \mu_0 = 0$	cero	cero	cero
Caso 2: rc	$\alpha\beta_0$	$\mu_1 = 0, \gamma_0 = 0$	constante	cero	constante
Caso 3: uc	μ_0	$\mu_1 = 0$	lineal	constante	constante
Caso 4: crt	$\mu_0 + \alpha\beta_1 t$	$\gamma_1 = 0$	lineal	constante	lineal
Caso 5: ct	$\mu_0 + \mu_1 t$	ninguna	cuadrática	lineal	lineal

Fuente: Johansen (2004).

En general, intervenciones, shocks, reformas económicas o cambios tecnológicos pueden mostrar shocks muy grandes (no normales) en el análisis VAR, violando el supuesto de normalidad. Es importante comprender lo que origina la observación atípica (outlier) para poder determinar si debe ser intervenido en la serie de datos o no.

Como la distribución asintótica de la prueba del rango (se detalla en la siguiente sección), depende de los componentes determinísticos que se incluyen en el modelo y si están restringidos o no a la relación de cointegración, es necesario que se determine el caso de análisis de Johansen bajo el cual se va a realizar las estimaciones en forma conjunta con la determinación del rango de cointegración cuando se hacen las pruebas de especificación del modelo.

2.4.2. Determinación del rango de cointegración

El rango de cointegración se definió en el apartado 2.3.2 representando a la cantidad de posibles relaciones de cointegración que tiene el conjunto de datos a analizar. La elección del rango de cointegración determina el resto de la inferencia, por lo tanto es crucial para el análisis empírico del modelo a estimar y se lleva a cabo mediante una prueba de razón de verosimilitud (LR-Likelihood Ratio) conocido habitualmente como el test de Johansen o test de la traza.

La determinación del rango de cointegración se calcula a partir de los valores propios λ_i obtenidos de la forma que se explicitó en el apartado 2.3.3, y consiste en discriminar cuales λ_i corresponden a relaciones estacionarias $i = 1 \dots r$, de los λ_i con $i = r + 1 \dots k$ que corresponden a relaciones no estacionarias.

2. Marco Teórico

A partir de la máxima verosimilitud definida en ec.(2.53) se puede derivar la prueba de razón de máxima verosimilitud para determinar el rango de cointegración r , que implica las hipótesis:

$H_k : rango = k$; no existen raíces unitarias, y_t es estacionario.

$H_r : rango = r$; existen $k - r$ raíces unitarias que implican r relaciones de cointegración y y_t es no estacionario.

El LR test o test de la traza:

$$-2 \ln Q(H_r/H_k) = T \ln \left\{ \frac{|S_{00}|(1 - \hat{\lambda}_1)(1 - \hat{\lambda}_2) \dots (1 - \hat{\lambda}_r)}{|S_{00}|(1 - \hat{\lambda}_1)(1 - \hat{\lambda}_2) \dots (1 - \hat{\lambda}_r) \dots (1 - \hat{\lambda}_k)} \right\}, \quad (2.56)$$

$$\tau_{k-r} = -T \ln(1 - \hat{\lambda}_{r+1}) \dots (1 - \hat{\lambda}_k). \quad (2.57)$$

La hipótesis nula en esta prueba es:

$H_0 : \lambda_{r+1} = \lambda_{r+2} = \dots = \lambda_k = 0$; que corresponde a $(k - r)$ raíces unitarias.

El estadístico a calcular es:

$$\tau_{k-r} = -2 \ln Q(H_r|H_k) = -T \sum_{i=r+1}^k \ln(1 - \hat{\lambda}_i). \quad (2.58)$$

Si el valor del estadístico es grande en referencia al valor crítico calculado bajo H_0 cierta se rechaza la hipótesis nula ¹¹.

Por lo tanto, para determinar el rango es necesario hacer una secuencia de pruebas LR probando $r = 0, r = 1, \dots, r = k$.

La prueba de hipótesis está basada en una distribución asintótica no estándar que debe ser simulada para cada uno de los 5 casos de análisis, dependiendo de los componentes determinísticos incluidos en la especificación. Para las pruebas de la traza se utilizan los valores críticos presentados en Juselius (2006)[p.419].

¹¹Para la prueba de hipótesis del rango de cointegración se toman los valores críticos presentados en Juselius (2006).

2.4.3. Interpretación de $\Pi = \alpha\beta'$

En este apartado se va a desarrollar como puede interpretarse a r , $(k - r)$ y los coeficientes de α, β . Cuando las series de datos con las que se va a trabajar son procesos no estacionarios, es necesario primero realizar las pruebas de raíz unitaria a cada una de ellas para comprobarlo y luego se identifica a través del rango de la matriz Π las posibles r relaciones de cointegración que pueden existir.

En el caso en que la matriz Π tiene rango reducido (cuando $(1 < \text{rango}(\Pi) < k - 1)$ como se desarrolló en el apartado 2.3.2) puede descomponerse en dos matrices $\Pi = \alpha\beta'$ de $(k \times r)$. Siendo las columnas de β las que definen los r vectores de cointegración y las filas de α muestran cómo esas relaciones de cointegración influyen en cada ecuación.

Se puede interpretar a r (si existe cointegración) como el número de relaciones estacionarias de largo plazo, y a $(k - r)$ como el número de raíces unitarias, también interpretables como tendencias comunes.

La cointegración implica que la no estacionariedad de una variable se corresponda con la no estacionariedad de otra variable, de forma que exista una combinación lineal entre ambas que sea estacionaria.

Por lo tanto, cuando una o varias variables tienen tendencias comunes (tanto estocásticas como determinísticas) van a mostrar una tendencia a moverse juntas en el largo plazo. Esa relación de cointegración se expresa en $\beta'y_t$ que puede ser interpretado como una relación de estado estacionario de largo plazo y por lo tanto de considerable interés económico.

Así como también, es interpretado como el mecanismo de corrección de error que, ante alejamiento del sendero de equilibrio de largo plazo, corrige ese comportamiento llevando a que el proceso converja nuevamente a la senda de equilibrio.

$$\Delta y_t = \Gamma_1^{(1)} \Delta y_{t-1} + \Gamma_2^{(1)} \Delta y_{t-2} + \alpha\beta'y_{t-1} + \Phi D_t + \epsilon_t \quad (2.59)$$

La estimación de α, β debe reproducir la información estadística de la matriz Π , y a partir de la normalización tratar de describir una estructura económica interpretable y apropiada respecto a la teoría económica subyacente.

Si se asume como estado estacionario $\beta'y_t - \beta_0 = 0$, donde $\beta_0 = E(\beta'y_t)$. El modelo de corrección de error (VECM) ilustra como el proceso es conducido al estado estacionario a través de la “fuerza” α (coeficientes de ajuste) que se activa apenas el proceso se aparta del estado estacionario ($\beta'y_t - \beta_0 \neq 0$).

En este sentido, los coeficientes β caracterizan a la relación de largo plazo entre las variables en niveles.

Los coeficientes de ajuste α pueden interpretarse como la velocidad promedio del ajuste que lle-

van al mecanismo de corrección de error a la convergencia con el estado estacionario, Johansen (1990) [25].

Por lo cual, la magnitud de α_{ij} marca la velocidad del ajuste, siendo más rápido cuando es grande ¹², o lento cuando α_{ij} es pequeño. Si determinada variable no influye en el ajuste de largo plazo de la relación de cointegración $\alpha_{i,\cdot} = 0$ y se considera a la misma como débilmente exógena (este concepto se profundiza en el apartado 2.5.2).

Para una correcta interpretación de los coeficientes normalizados de la matriz α es necesario considerar el signo de α_{ij} para los α_{ij} significativos, dada su influencia en el tipo de ajuste.

Si α_{ij} tiene el signo contrario que β_{ij} ¹³ se dice que la relación de cointegración es de “corrección al equilibrio” en la ecuación Δy_t . Pero, cuando α_{ij} y β_{ij} son del mismo signo, usualmente significa que la relación de cointegración describe un comportamiento de sobreacción en la ecuación Δy_t , Juselius (2006) [p.122] [29].

Los coeficientes de Γ_i^m describen los efectos de corto plazo como resultado de los cambios recientes en el mercado, que no tienen porque tener efectos permanentes en niveles.

Los coeficientes de Φ contienen a las dummies estacionales, otras variables exógenas consideradas como la temperatura e intervenciones que describen eventos extraordinarios en el mercado.

2.4.4. Normalización

Para un número dado de r relaciones de cointegración obtenidas a partir de RRR se obtiene la estimación de $\beta' y_t$. A partir del test de Johansen se puede identificar el número de relaciones r que habilita a una interpretación en términos de relaciones de estado estacionario.

Las estimaciones de α y β sin restringir cumplen las siguientes condiciones:

- Estacionariedad, $\hat{\beta}' y_t \sim I(0)$.
- Independencia condicional de $\beta' y_t$, en el sentido que se cumple $\hat{\beta}' S_{11} \hat{\beta} = I$.
- El orden dado por la máxima condición de correlación con el proceso estacionario Δy_t .

Dado estos criterios, las relaciones de cointegración sin restringir son únicas, pero tal vez no tengan una directa interpretación económica.

Para poder interpretar las relaciones de cointegración de forma que estén asociadas a una variable económica en particular es necesario normalizar el vector de cointegración haciendo que la

¹²Se denota a la posición de las filas y columnas de la matriz α con i y j respectivamente.

¹³Se denota a la posición de las filas y columnas de la matriz β con i y j respectivamente.

variable considerada como “dependiente” sea uno y el resto esté expresado en relación a ella. La normalización seleccionada no solo debe tener sentido económico sino que también estadístico.

La normalización usualmente aplicada es la que establece $c'\beta$ no singular para una matriz de rango completo c de $(k \times r)$. Los vectores de cointegración normalizados se definen como $\tilde{\beta} = \beta (c'\beta)^{-1}$, de forma que $\tilde{\beta}$ sea único y $c'\tilde{\beta} = I_r$. La matriz c mas comunmente empleada esta dada por $c = [I_r, 0]'$, en los hechos se considera a la matriz de rango completo, Kurozumi (2007) [31].

2.4.5. Pruebas de hipótesis sobre los coeficientes de largo plazo β

Luego que fue especificado y estimado el VECM, debe de comprobarse que cada uno de los coeficientes asociados a las variables incluídas dentro de la relación de cointegración sean significativos dentro de la misma.

Ésto implica que dichas variables conforman una combinación lineal entre sí, a pesar de ser no estacionarias al ser consideradas individualmente, tienen de esta forma un sendero de ajuste común que las vuelve estacionarias en el largo plazo.

La forma de comprobar si cada una de las variables incluídas en la relación de cointegración tienen coeficientes significativos es comparar un modelo restringido, en el cual se impone la restricción de que uno de los coeficientes es cero, respecto a un modelo no restringido, en el que se consideran todos los coeficientes asociados a las variables consideradas.

Si la magnitud del estadístico es pequeña, implica que la variable puede ser omitida en la relación de largo plazo.

Para contrastar la significación de los coeficientes de largo plazo se hace una prueba de hipótesis de un modelo restringido versus uno no restringido con hipótesis nula:

$$H_0 : \beta = H\phi.$$

Bajo H_0 cierta el modelo a estimar se escribe como:

$$\Delta y_t = \alpha\phi'H'y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta y_{t-i} + \Phi D_t + \epsilon_t, \quad t = 1, \dots, T. \quad (2.60)$$

La estimación de la ecuación ec.(2.60) se resuelve mediante restricciones de rango reducido:

$$RRR(\Delta y_t, y'_{t-1} H | \Delta y_{t-1}, \dots, \Delta y_{t-p+1}, D_t) . \quad (2.61)$$

Si $\hat{\lambda}_i^*$ son los valores propios derivados bajo H_0 y $\hat{\lambda}_i$ los valores propios del modelo sin restringir, se puede calcular la prueba de razón de máxima verosimilitud con el estadístico:

$$-2 \ln LR(H_0|H_{(nr)}) = T \sum_{i=1}^r \ln \left\{ (1 - \hat{\lambda}_i^*) / (1 - \hat{\lambda}_i) \right\} , \quad (2.62)$$

el cual tiene distribución asintótica $\chi^2(v)$ con $v = rm$ grados de libertad y m el número de restricciones. Se rechaza H_0 cuando el valor del estadístico es superior al valor de tabla en la distribución χ^2 .

2.5. Exogeneidad y Causalidad

En los modelos econométricos tradicionales, los conceptos de exogeneidad y causalidad pueden confundirse y ser tratados como sinónimos o ser tomados como un supuesto que viene dado y no son sometidos a prueba. La aplicación del concepto de Causalidad en Sentido de Granger, Granger (1969) [14] genera un cambio cualitativo respecto del tratamiento del enfoque tradicional, siendo la causalidad una hipótesis relativa a la relación entre variables y diferenciándolo del concepto de exogeneidad.

Engle-Hendry-Richard (1983) [11] retoman el concepto de causalidad en el sentido de Granger para diferenciarlo del concepto de exogeneidad, el cual presenta tres grados, débil, fuerte y super exogeneidad de acuerdo con el objetivo de la inferencia¹⁴: estimación, predicción o simulación

.

2.5.1. Causalidad en Sentido de Granger

Granger (1969) [14] establece que, dada la información disponible, si al borrar la historia de un conjunto de variables (sus rezagos) no se altera la distribución conjunta del resto de las variables consideradas, entonces las variables omitidas no causan al resto de las variables consideradas.

¹⁴La **predicción** en series de tiempo implica poder realizar un pronóstico del valor futuro de una variable h períodos hacia adelante, a partir del comportamiento pasado de esa variable y de otros factores que puedan influir en la misma. La forma de tomar en cuenta ese comportamiento pasado es a través de la estimación econométrica de un modelo que represente adecuadamente a ese proceso generador del dato y calcular las predicciones de cada período en base a la esperanza de esa variable condicional a su comportamiento pasado. La **simulación** de una serie de tiempo permite, a partir de la modelización econométrica realizada en base a la serie histórica de datos, realizar un análisis de sensibilidad en la variable de interés, respecto a modificaciones de alguna de las variables exógenas determinantes en la modelización, manteniendo el resto de los parámetros estimados y los datos constantes.

En Engle-Hendry-Richard (1983) [11] se define la causalidad a partir de un vector de variables aleatorias observadas y_t generado en el momento t , a partir del cual se define a la matriz $Y_t^1 = (y_1, \dots, y_t)'$ de $(t \times k)$ y a Y_0 la matriz de condiciones iniciales, el análisis se realiza condicional en Y_0 .

El proceso que genera las T observaciones está representado por la función de densidad conjunta $P(Y_T^1|Y_0, \theta)$ donde θ es un vector de parámetros desconocidos, y la función de verosimilitud de θ dadas las condiciones iniciales Y_0 esta dada por $L^0(\theta; Y_T^1)$.

$$y_t \sim IN_k(\mu, \Sigma) . \quad (2.63)$$

El vector y_t puede particionarse en :

$$y_t = \begin{bmatrix} x_t \\ z_t \end{bmatrix}, \quad x_t \in R^{k_1}, \quad z_t \in R^{k_2}, \quad k_1 + k_2 = k . \quad (2.64)$$

Las matrices Y_0, Y_t^1, Y_t se particionan de forma análoga:

$$Y_0 = (X_0, Z_0), \quad Y_t^1 = (X_t^1, Z_t^1), \quad Y_t = (X_t, Z_t) . \quad (2.65)$$

Habitualmente el objetivo de los modelos econométricos es modelar la forma en que y_t esta generada condicionalmente en los momentos pasados, por lo cual a partir de la factorización de la funcion de densidad conjunta, hay que focalizar la atención en la función de densidad condicional $P(y_t|Y_{t-1}, \theta)$.

$$P(Y_T^1|Y_0, \theta) = \prod_{t=1}^T P(y_t|Y_{t-1}, \theta) . \quad (2.66)$$

Se puede decir que X_{t-1}^1 **no causa en sentido de Granger a** z_t **respecto a** Y_{t-1} sí y solo sí ¹⁵:

$$P(z_t|Y_{t-1}, \theta) = P(z_t|Z_{t-1}, X_0, \theta) . \quad (2.67)$$

Si la condición anterior se mantiene en el período de análisis, la omisión de la historia de un conjunto de variables X_{t-1}^1 en Y_{t-1} no modifica la distribución conjunta del resto de las variables z_t y se puede afirmar que x **no causa en sentido de granger a** z , la densidad conjunta puede factorizarse como:

¹⁵Adicionalmente debe cumplirse también que: $z_t || X_{t-1}^1 | Z_{t-1}, X_0$, donde la expresión " $x_t || y_t$ " se lee como, " x_t y y_t son independientes en probabilidad" y " $x_t || y_t | w_t$ " se lee como, " x_t y y_t son independientes en probabilidad condicional a w_t ", y está implícito que estos estados de independencia son condicionales en θ .

$$P(Y_T^1|Y_0, \theta) = \left[\prod_{t=1}^T P(x_t|z_t, Y_{t-1}, \theta) \right] \left[\prod_{t=1}^T P(z_t|Z_{t-1}, X_0, \theta) \right] . \quad (2.68)$$

Prueba de hipótesis sobre Causalidad en Sentido de Granger.

La aplicación de un modelo econométrico en la evaluación de políticas requiere que se verifique la relación de causalidad desde el instrumento hacia el objetivo de política, y la ausencia de esta relación desde el objetivo hacia el instrumento.

La realización de la prueba de causalidad implica probar que los rezagos de una variables no son significativos en la ecuación de otra variable, por lo tanto no contribuyen a mejorar la predicibilidad de la variable de interés.

Esta prueba de hipótesis puede realizarse a través de una prueba que compare un modelo restringido (r) versus un modelo no restringido (u).

La prueba de causalidad presentada en Pfaff (2008) [40] se realiza a partir de un proceso I(1) generado por un proceso VAR(p) como el de la ecuación ec.(2.14).

En la misma se plantea particionar el vector de variables endógenas y_t (k -dimensional) en un vector x_t de $(k_1 \times 1)$ y en otro z_t de $(k_2 \times 1)$ siendo $k = k_1 + k_2$ y D_t los componentes determinísticos. Se puede escribir el VAR(p) particionado:

$$\begin{bmatrix} x_t \\ z_t \end{bmatrix} = \sum_{i=1}^p \begin{bmatrix} \alpha_{11,i} & \alpha_{12,i} \\ \alpha_{21,i} & \alpha_{22,i} \end{bmatrix} \begin{bmatrix} x_{t-i} \\ z_{t-i} \end{bmatrix} + CD_t + \begin{bmatrix} u_{xt} \\ u_{zt} \end{bmatrix} , \quad (2.69)$$

donde contrastar que el sub vector x_t **no causa en sentido de Granger** a z_t se define como la prueba de hipótesis:

$$H_0 : \alpha_{21,i} = 0 \text{ para } (i = 1, 2, \dots, p) ,$$

y la hipótesis alternativa es:

$$H_a : \exists \alpha_{21,i} \neq 0 \text{ para } (i = 1, 2, \dots, p).$$

La prueba de hipótesis se realiza mediante el estadístico de Wald:

$$W = (R\alpha)' [R\Sigma_u R']^{-1} (R\alpha) \sim F(m, n - k), \quad (2.70)$$

donde R es la matriz que incluye las restricciones de la hipótesis nula. Cuando $W >$ valor crítico, se rechaza H_0 .

En el caso de causalidad no instantánea la hipótesis nula se define como:

$$H_0 : C\sigma = 0, \quad (2.71)$$

donde C es una matriz de $(N \times k(k+1)/2)$ de rango N que selecciona las covarianzas relevantes de u_{xt} con u_{zt} y $\tilde{\sigma} = \text{vech}(\tilde{\Sigma}_u)$ con $\tilde{\Sigma}_u = \frac{1}{T} \sum_{t=1}^T \hat{u}_t \hat{u}_t'$.

El estadístico de prueba de Wald para la hipótesis nula (2.71) se define como:

$$\lambda_W = T\tilde{\sigma}C' \left[2CD_k^+ (\tilde{\Sigma}_u \otimes \tilde{\Sigma}_u) D_k^{+'}C' \right]^{-1} C\tilde{\sigma}, \quad (2.72)$$

donde D_k^+ representa la pseudoinversa de Moore-Penrose de la matriz D_k .

La matriz D_k tiene dimensión $(k^2 \times \frac{1}{2}k(k+1))$ y se define de forma que, para una matriz simétrica A de $(k \times k)$, se cumple $\text{vec}(A) = D_k \text{vec}(A)$. El estadístico λ_W se distribuye asintóticamente como $\chi^2(N)$.

La distribución asintótica χ^2 puede ser una pobre aproximación asintótica en muestras pequeñas. En esos casos puede ser mejor aproximar mediante la distribución $F(pk_1k_2, kT - n^*)$ que se obtiene de dividir el estadístico χ^2 por sus grados de libertad n^* igual al número total de parámetros en el VAR(p) incluyendo a los regresores determinísticos.

2.5.2. Exogeneidad

A diferencia del concepto de causalidad, que es definido respecto a las variables, el concepto de exogeneidad se define en relación a los parámetros de interés. Los parámetros pueden ser de interés porque se desea probar determinadas relaciones entre variables económicas, o porque están relacionados con la teoría económica.

Se considera una reparametrización del modelo de la forma:

$$h : \Theta \rightarrow \Lambda; \quad \theta \rightarrow \lambda = h(\theta),$$

sea Λ_i el set de valores admisibles para λ_i , con λ particionado en (λ_1, λ_2) .

La factorización de la función de densidad conjunta en la condicional y marginal, puede realizarse si λ_1 y λ_2 están definidos para soportar la factorización: $[(x_t|z_t; \lambda_1), (z_t; \lambda_2)]$.

2. Marco Teórico

Para que la factorización constituya un corte secuencial en la distribución conjunta $P(y_t|Y_{t-1}, \lambda)$ debe cumplirse:

$$P(y_t|Y_{t-1}, \lambda) = P(x_t|z_t, Y_{t-1}, \lambda_1)P(z_t|Y_{t-1}, \lambda_2) , \quad (2.73)$$

donde λ_1 y λ_2 varían libremente $(\lambda_1, \lambda_2) \in \Lambda_1 \times \Lambda_2$

A su vez, se considera a la matriz Y_t^1 de dimensión $(t \times k)$ que representa la historia de k variables observadas hasta el momento t , particionada de la forma que se representó en la ec.(2.65), en forma condicional a sus valores pasados.

Exogeneidad Débil

Como se define en Engle-Hendry-Richard (1983) [p.278] [11], una variable z_t se define en un modelo como débilmente exógena para estimar un conjunto de parámetros λ si la inferencia sobre λ condicional a z_t no implica pérdidas de información.

Por lo tanto, z_t **es débilmente exógena para el parámetro de interés** $\psi = \phi(\lambda_1)$ en el período analizado, si y solo si, existe una reparametrización $\lambda = (\lambda_1, \lambda_2)$ que cumple:

- (i) ϕ es una función de λ_1 tal que:
 $\phi : \Lambda_1 \rightarrow \psi; \quad \lambda_1 \rightarrow \psi = \phi(\lambda_1) \quad \psi \text{ es función únicamente de } \lambda_1$
de forma que, para todo $\lambda \in \Lambda$, $\psi = f[h^{-1}(\lambda)] \equiv \phi(\lambda_1)$.
- (ii) $[(x_t|z_t; \lambda_1), (z_t; \lambda_2)]$ opera como corte secuencial en $P(y_t|Y_{t-1}, \lambda)$ que debe cumplir la condición de la ec.(2.73) y (λ_1, λ_2) varían libremente.

Exogeneidad Fuerte

Dado que los valores pasados de x_t pueden afectar el proceso que genera z_t , para que no se pierda información cuando se realizala predicción con el modelo condicional, se requiere una condición adicional a la exogeneidad débil para factorizar la densidad conjunta $P(Y_T^1|Y_0, \lambda)$. Esta condición es la no causalidad en el sentido de Granger.

Se define que z_t **es fuertemente exógena para** ψ en el período analizado, si y solo si, adicionalmente a ser débilmente exógena para ψ :

- (iii) x no causa en sentido de Granger a z

Cuando se cumple (ii) se puede factorizar a $L^0(\lambda; Y_T^1)$ de la siguiente forma:

$$L^0(\lambda; Y_T^1) = L_1^0(\lambda_1; Y_T^1) L_2^0(\lambda_2; Y_T^1) , \quad (2.74)$$

donde

$$L_1^0(\lambda_1; Y_T^1) = \prod_{t=1}^T P(x_t | z_t, Y_{t-1}, \lambda_1) , \quad (2.75)$$

$$L_2^0(\lambda_2; Y_T^1) = \prod_{t=1}^T P(z_t | Y_{t-1}, \lambda_2) . \quad (2.76)$$

Cuando se cumplen las condiciones (ii) y (iii) se puede factorizar $P(Y_T^1 | Y_0, \lambda)$ de la forma:

$$P(Y_T^1 | Y_0, \lambda) = P(X_T^1 | Z_T^1, Y_0, \lambda_1) P(Z_T^1 | Y_0, \lambda_2) , \quad (2.77)$$

$$P(X_T^1 | Z_T^1, Y_0, \lambda_1) = \prod_{t=1}^T P(x_t | z_t, Y_{t-1}, \lambda_1) , \quad (2.78)$$

$$P(Z_T^1 | Y_0, \lambda_2) = \prod_{t=1}^T P(z_t | Z_{t-1}, X_0, \lambda_2) . \quad (2.79)$$

Si se cumple esta condición es posible utilizar valores predichos de z para generar valores de x utilizando el modelo condicional sin pérdida de información. Si x tuviera una relación de causalidad en sentido de Granger con z , entonces las predicciones de x y z se tienen que realizar en forma conjunta o se perdería información importante al utilizar únicamente la distribución condicional.

Super Exogeneidad

Es posible que con el paso del tiempo algunos parámetros de la distribución conjunta puedan cambiar (por cambios en el comportamiento de los individuos, cambios en la tecnología, instituciones o cambios de política por parte del gobierno).

Sin embargo, hay parámetros que pueden permanecer constantes y que pueden ser estimados sin dificultad a pesar de la ocurrencia de “intervenciones”. En econometría esta propiedad es conocida como *invarianza paramétrica*.

Engle-Hendry-Richard (1983) definen la invarianza de la siguiente forma:

- Un parámetro es *invariante* para determinada clase de intervenciones si permanece constante bajo dichas intervenciones. Un modelo es *invariante* a las intervenciones si todos los parámetros lo son.
- Un modelo condicional es *estructuralmente invariante* si todos sus parámetros son invariantes ante cada cambio en la distribución de las variables condicionales.

$\Rightarrow z_t$ **es super exógena para** ψ si z_t es débilmente exógena para ψ y el modelo condicional $P(x_t|z_t, Y_{t-1}, \lambda_1)$ es estructuralmente invariante.

En este sentido, la super exogeneidad es una condición suficiente pero no necesaria para hacer inferencia dada la existencia de intervenciones.

Los conceptos y definiciones desarrollados por Engle-Hendry-Richard (1983) son una extensión del trabajo de Koopman (1950) sobre exogeneidad, que demuestra que en un sistema de ecuaciones simultáneas estático se tendrá una función de verosimilitud que puede factorizarse en dos componentes, uno condicional y otro marginal:

$$L^0(\lambda; Y_T^1) = L_1^0(\lambda_1; Y_T^1) L_2^0(\lambda_2; Y_T^1) . \quad (2.80)$$

En este caso las variables del segundo bloque son denominadas exógenas. Implícitamente en el análisis está contenida la noción de que los parámetros de interés están en el primer bloque de ecuaciones y que dicha parametrización opera como un corte.

A modo de resumen, Engle-Hendry-Richard (1983) define a una variable z_t como débilmente exógena para estimar a los parámetros λ si la inferencia sobre λ condicional a z_t implica que no haya pérdida de información.

Si adicionalmente a la exogeneidad débil, z_t no está causada en sentido de Granger por ninguna de las variables endógenas del sistema, entonces se define a z_t como fuertemente exógena.

Si todos los parámetros λ del modelo condicional son invariantes a los cambios en la densidad marginal de z_t , y z_t es débilmente exógena para λ , entonces se dice que z_t es super exógena.

Las pruebas de hipótesis sobre exogeneidad en el marco de los modelos VECM se desarrolla en el siguiente apartado.

2.5.3. Pruebas de hipótesis sobre Exogeneidad

Para poder utilizar los procedimientos convencionales de inferencia se requiere que el sistema sea estable, por lo tanto, la condición de estacionariedad es esencial. La presencia de raíces

unitarias es una restricción, por lo cual para no cometer errores de especificación el modelo debe expresarse como VECM.

$$\Delta y_t = \Pi y_{t-m} + \sum_{i=1}^{p-1} \Gamma_i^{(m)} \Delta y_{t-i} + \Phi D_t + \epsilon_t . \quad (2.81)$$

Una vez especificado el modelo en el espacio $I(0)$, el contraste empírico de la exogeneidad se hace a través de pruebas de hipótesis sobre la significación de los componentes de la matrices $\Pi = \alpha\beta'$ y Γ estimadas en el VECM.

Exogeneidad Débil

Para realizar la prueba de hipótesis de exogeneidad débil es necesario particionar el vector y_t de la siguiente forma:

$$\begin{aligned} \Delta x_t &= \alpha_1 \beta' y_{t-1} + \sum_{i=1}^{p-1} \Gamma_{xi} \Delta y_{t-i} + \epsilon_{xt} \\ \Delta z_t &= \alpha_2 \beta' y_{t-1} + \sum_{i=1}^{p-1} \Gamma_{zi} \Delta y_{t-i} + \epsilon_{zt} \end{aligned} \quad (2.82)$$

Los parámetros de α son interpretados habitualmente como los mecanismos de ajuste del sistema, cuando los parámetros de interés son β . La hipótesis de que una variable ha influenciado el comportamiento de largo plazo de otra variable en el sistema, pero al mismo tiempo no ha sido influenciada por el mismo, se conoce como la hipótesis de exogeneidad débil de largo plazo, Juselius (2006) [p.193] [29].

Por lo tanto, si la restricción de que la fila k de α es cero es aceptada, se puede particionar para la estimación la especificación del modelo de k ecuaciones en $(k-m)$ ecuaciones que muestran retroalimentación en niveles, y m ecuaciones que no presentan retroalimentación, siendo m la cantidad de variables débilmente exógenas.

Dado que las m variables débilmente exógenas no contienen información sobre los parámetros de largo plazo, se puede obtener estimaciones eficientes de β a partir de las $(k-m)$ ecuaciones de ajuste, condicionales a los modelos marginales de las m variables débilmente exógenas, Hendry (2000-II) [p.29] [19].

Según las definiciones previas, z_t es débilmente exógena para β , sí y solo sí $\alpha_2 = 0$. La condición $\alpha_2 = 0$ asegura que β no aparezca en la distribución marginal para z_t . Ésto implica que puede llevarse a cabo la inferencia sobre α_1 y β en el modelo condicional de forma eficiente.

Como se presenta en Johansen (2004)[p.14] [28], la estimación del modelo restringido bajo H_0 cierta implica estimar el modelo condicional para Δx_t dado Δz_t y las variables rezagadas :

$$\text{Bajo } H_0 : \quad \Delta x_t = w \Delta z_t + (\alpha_1 - w \alpha_2) \beta' y_{t-1} + \sum_{i=1}^{p-1} (\Gamma_{xi} - w \Gamma_{zi}) \Delta y_{t-i} + \epsilon_{xt} - w \epsilon_{zt} , \quad (2.83)$$

donde $w = \Omega_{12} \Omega_{22}^{-1}$ dado que $\epsilon_t \sim IN(0, \Omega)$ y $\Omega = \begin{bmatrix} \Omega_{11} & \Omega_{12} \\ \Omega_{21} & \Omega_{22} \end{bmatrix}$.

La estimación de la ecuación presentada en (2.83) se resuelve mediante:

$$RRR(\Delta x_t, y_{t-1} | \Delta z_t, \Delta y_{t-1}, \dots, \Delta y_{t-p+1}) \quad .$$

La prueba de hipótesis se hace a través de una prueba de razón de máxima verosimilitud donde se comparan los valores propios del modelo restringido H_0 respecto a uno no restringido $H_{(nr)}$ dada la cantidad r de relaciones de cointegración.

Para la hipótesis nula:

$$H_0 : \alpha_i = 0 ,$$

el estadístico de prueba utilizado es:

$$-2 \ln LR(H_0 | H_{(nr)}) = T \sum_{i=1}^r \ln \left\{ (1 - \hat{\lambda}_i^*) / (1 - \hat{\lambda}_i) \right\} , \quad (2.84)$$

el cual se distribuye asintóticamente como $\chi^2(v)$, siendo $v = rm$ y m el número de variables débilmente exógenas.

Exogeneidad Fuerte

Si el vector de interés es el vector de cointegración y se verifica que z_t es débilmente exógena y hay ausencia de causalidad desde x_t hacia el instrumento z_t , existe exogeneidad en sentido fuerte del instrumento hacia el objetivo y es posible realizar predicciones de x_t condicionado a valores predichos de z_t .

Super Exogeneidad

La hipótesis de super exogeneidad implica probar la estabilidad de β cuando se producen cambios de política que afectan la distribución de la variable utilizada como instrumento. En ese

caso puede utilizarse la distribución condicional $P(x_t|z_t, Y_{t-1}, \lambda_1)$, presentada en el apartado 2.5.2, para realizar simulaciones.

Estudios de simulación han demostrado que la inferencia estadística es más sensible ante la validez de determinados supuestos como la estabilidad de los parámetros, residuos sin correlación serial y residuos con distribución simétrica, y menos sensible a otros como exceso de curtosis (distribuciones con mucha cola) y residuos heteroscedasticos, Hendry (2000) [19].

Una forma de contrastar la estabilidad de los parámetros estimados es a través del **Test de Chow**, el cual analiza la posibilidad de presencia de un quiebre estructural a partir de la comparación de las varianzas en diferentes períodos de tiempo para decidir sobre la constancia en los parámetros.

Se reportan diferentes alternativas del mismo: i) sample-split (SS), ii) break-point (BP).

Si se asume que, puede haberse dado un quiebre estructural en el momento T_B , la prueba de hipótesis compara las estimaciones obtenidas de las observaciones previas a T_B con las obtenidas de las observaciones posteriores a T_B .

El modelo se estima para la muestra completa de observaciones T , así como para la muestra T_1 y T_2 donde $T_1 < T_B$ y $T_2 \leq T - T_B$. Se obtiene a partir de dichas estimaciones los respectivos residuos $\hat{u}_t$, $\hat{u}_t^1$ y $\hat{u}_t^2$, Lütkepohl (2004) [34].

$$\tilde{\Sigma}_u = T^{-1} \sum_{t=1}^T \hat{u}_t \hat{u}_t' , \quad (2.85)$$

$$\tilde{\Sigma}_{1,2} = (T_1 + T_2)^{-1} \left(\sum_{t=1}^{T_1} \hat{u}_t \hat{u}_t' + \sum_{t=T-T_2+1}^T \hat{u}_t \hat{u}_t' \right) , \quad (2.86)$$

$$\tilde{\Sigma}_{(1,2)} = T_1^{-1} \sum_{t=1}^{T_1} \hat{u}_t \hat{u}_t' + T_2^{-1} \sum_{t=T-T_2+1}^T \hat{u}_t \hat{u}_t' , \quad (2.87)$$

$$\tilde{\Sigma}_{(1)} = T_1^{-1} \sum_{t=1}^{T_1} \hat{u}_t^{(1)} \hat{u}_t^{(1)'} , \quad (2.88)$$

$$\tilde{\Sigma}_{(2)} = T_2^{-1} \sum_{t=T-T_2+1}^T \hat{u}_t^{(2)} \hat{u}_t^{(2)'} . \quad (2.89)$$

A partir de esta notación, el estadístico **sample-split (SS)** es:

$$\lambda_{SS} = (T_1 + T_2) \left(\ln |\tilde{\Sigma}_{(1,2)}| - \ln \left| (T_1 + T_2)^{-1} \left(T_1 \tilde{\Sigma}_{(1)} + T_2 \tilde{\Sigma}_{(2)} \right) \right| \right) , \quad (2.90)$$

y el estadístico **break-point (BP)** es:

$$\lambda_{BP} = (T_1 + T_2) \ln \left| \tilde{\Sigma}_{(1,2)} \right| - T_1 \ln \left| \tilde{\Sigma}_{(1)} \right| - T_2 \ln \left| \tilde{\Sigma}_{(2)} \right| . \quad (2.91)$$

Ambos estadísticos comparan la estimación de la varianza residual de un modelo de coeficiente constante con la estimación de la varianza residual de un modelo que permite un cambio en los parámetros. De esta manera, se comprueba si existen importantes diferencias en las estimaciones antes y después de T_B .

La prueba de hipótesis sobre SS tiene como hipótesis nula que los coeficientes autorregresivos y términos determinísticos no cambian durante el período de la muestra, mientras que BP prueba adicionalmente la constancia de la varianza ruido blanco.

Bajo la hipótesis nula de que el modelo es invariante en el tiempo en sus parámetros, ambos estadísticos tienen distribución asintótica χ^2 . La hipótesis de parámetros constantes es rechazada para valores altos de los estadísticos.

Los grados de libertad están dados por el número de restricciones impuestas al asumir un modelo de coeficientes constantes para la muestra completa.

Sin embargo, para un modelo VECM k -dimensional con r relaciones de cointegración, la determinación es un poco más complicada.

Al contar el total de parámetros en el modelo, además de los de Σ_u , se tienen $(2kr + (p-1)k^2 + k)$ parámetros. Los grados de libertad de la prueba basada en λ_{SS} son $(2kr - r^2 + (p-1)k^2 + k)$, donde r^2 se resta porque a partir de la normalización r^2 de los parámetros están fijos.

Si además la matriz de cointegración es dejada constante a lo largo del período, los grados de libertad se reducen a $(kr + (p-1)k^2 + k)$. Para λ_{BP} hay que adicionar a los grados de libertad los parámetros con covarianza ruido blanco.

2.6. Predicción

La predicción en los modelos multiecuacionales vectoriales es análoga a la predicción de procesos univariados. Si bien es posible realizar las predicciones del VECM estimado, es más conveniente realizar la predicción de y_t a partir de la especificación del VAR.

Siguiendo a Lütkepohl (2004) [34], se presenta la predicción de h -pasos hacia adelante obtenido recursivamente a partir del punto de origen en T con la esperanza condicional, a efectos de simplificar la presentación se omiten los términos determinísticos y variables exógenas.

$$y_{T+1|T} = E(y_{T+1}|y_T, y_{T-1}, \dots) = A_1 y_T + \dots + A_p y_{T+1-p} . \quad (2.92)$$

La predicción para horizontes de $h > 1$ puede obtenerse recursivamente a partir de:

$$y_{T+h|T} = A_1 y_{T+h-1|T} + \dots + A_p y_{T+h-p|T} , \quad (2.93)$$

donde $y_{T+j|T} = y_{T+j}$ para $j \leq 0$.

El correspondiente error de predicción está dado por:

$$\begin{aligned} y_{T+1} - y_{T+1|T} &= u_{T+1} , \\ y_{T+2} - y_{T+2|T} &= u_{T+2} + \phi_1 u_{T+1} , \\ \vdots \\ y_{T+h} - y_{T+h|T} &= u_{T+h} + \Phi_1 u_{T+h-1} + \dots + \Phi_{h-1} u_{T+1} , \end{aligned} \quad (2.94)$$

donde puede demostrarse a través de una sustitución sucesiva que:

$$\Phi_s = \sum_{j=1}^s \Phi_{s-j} A_j \quad s=1,2,\dots , \quad (2.95)$$

con $\Phi_0 = I_k$ y $A_j = 0$ para $j > p$.

Al igual que en el caso univariado, u_t es el error de predicción 1 paso adelante en el período $t - 1$, y la predicción es insesgada (el error de predicción tiene valor esperado 0).

La matriz con las Medias de Errores al Cuadrado (Mean Squared Error - MSE) con predicciones de h -pasos está dada por:

$$\Sigma_y(h) = E \left\{ (y_{T+h} - y_{T+h|T})(y_{T+h} - y_{T+h|T})' \right\} = \sum_{j=0}^{h-1} \Phi_j \Sigma_u \Phi_j' . \quad (2.96)$$

Si el proceso es Gaussiano, los errores de predicción también son normales $u_t \sim iidN(0, \Sigma_y(h))$ y este resultado puede ser empleado para definir intervalos de confianza para la predicción.

$$\left[y_{T+h|T} - c_{1-\gamma/2} \sigma_y(h), y_{T+h|T} + c_{1-\gamma/2} \sigma_y(h) \right] , \quad (2.97)$$

donde $c_{1-\gamma/2}$ es el $(1 - \gamma/2)100$ punto porcentual de la distribución normal estándar para un nivel de significación de γ y $\sigma_y(h)$ es la desviación estándar del error de predicción de y_t h -pasos hacia adelante.

La predicción puede utilizarse también para la comparación de modelos o distintos escenarios y a través de la comparación de los errores de predicción ver cuál modelo o especificación logra predecir mejor los datos.

Se utilizan habitualmente una serie de indicadores en base a los cuales se comparan los errores de predicción del modelo estimado.

Los indicadores pueden clasificarse según Hyndman (2006) [21] en:

- **Medidas que dependen de la escala**, son utilizadas habitualmente como medidas de precisión en la predicción que dependen de la escala en la que se presentan los datos. Son medidas que se utilizan cuando se comparan diferentes métodos o modelos aplicados a un mismo conjunto de datos, pero no deben ser utilizadas para comparar entre varios conjuntos de datos que están medidos en distintas escalas.

Las usadas más comunmente son las basadas en los errores absolutos o errores al cuadrado como: Promedio de Errores al Cuadrado (MSE-Mean Squared Error), Raíz del Promedio Errores al Cuadrado (RMSE-Root Mean Squared Error) y Promedio del Error Absoluto (MAE-Mean Absolute Error).

En general, RMSE es preferida respecto a MSE ya que está expresada en la misma escala que el conjunto de datos. Sin embargo, ambas medidas son más sensibles a la presencia de casos atípicos que MAE.

- **Medidas basadas en porcentajes**, se caracterizan por ser independientes de la escala de los datos utilizados, por lo cual son utilizadas frecuentemente para comparar la precisión en la predicción entre distintos conjuntos de datos.

Las medidas más utilizadas son: Promedio del Porcentaje de Error Absoluto (MAPE-Mean Absolute Percentage Error) y la Raíz del Promedio del Porcentaje de Error Absoluto (RMSPE-Root Mean Square Percentage Error).

Éstas medidas tienen la desventaja que dan un resultado infinito o no definido cuando la observación del momento t es cero, y tiene distribución sesgada cuando la observación es próxima a cero. También tienen la desventaja de que penalizan en mayor medida a los errores positivos que a los negativos.

Para el análisis de las predicciones puntuales en cada mes se utiliza el indicador de **Error Relativo (ER)**, que muestra en que porcentaje se distancia la predicción puntual de la demanda en determinado mes $y_{T+t|T}$, respecto al valor demandado real en ese mes y_{T+t} .

Error Relativo (ER)

$$ER = \frac{y_{T+t} - y_{T+t|T}}{y_{T+t}} . \quad (2.98)$$

Para el análisis de la predicción global del modelo seleccionado y comparación entre diversos modelos o especificaciones se utilizan los indicadores propuestos en Hyndman (2006).

Error promedio (ME-Mean Error)

$$ME = \frac{1}{h} \sum_{t=1}^h (y_{T+t} - y_{T+t|T}) . \quad (2.99)$$

Promedio de Errores al Cuadrado (MSE-Mean Squared Error)

$$MSE = \frac{1}{h} \sum_{t=1}^h (y_{T+t} - y_{T+t|T})^2 . \quad (2.100)$$

Raíz del Promedio Errores al Cuadrado (RMSE-Root Mean Squared Error)

$$RMSE = \sqrt{\frac{1}{h} \sum_{t=1}^h (y_{T+t} - y_{T+t|T})^2} . \quad (2.101)$$

Promedio del Porcentaje de Error (MPE-Mean Percentage Error)

$$MPE = \frac{1}{h} \sum_{t=1}^h \left(\frac{y_{T+t} - y_{T+t|T}}{y_{T+t}} \right) . \quad (2.102)$$

Promedio del Error Absoluto (MAE-Mean Absolute Error)

$$MAE = \frac{1}{h} \sum_{t=1}^h \left| (y_{T+t} - y_{T+t|T}) \right| . \quad (2.103)$$

Promedio del Porcentaje de Error Absoluto (MAPE-Mean Absolute Percentage Error)

$$MAPE = \frac{1}{h} \sum_{t=1}^h \left| \left(\frac{y_{T+t} - y_{T+t|T}}{y_{T+t}} \right) \right| . \quad (2.104)$$

Raíz del Promedio del Porcentaje de Error Absoluto (RMSPE-Root Mean Square Percentage Error)

$$RMSPE = \sqrt{\frac{1}{h} \sum_{t=1}^h \left| \left(\frac{y_{T+t} - y_{T+t|T}}{y_{T+t}} \right) \right|^2} . \quad (2.105)$$

Si bien la predicción se puede realizar para la estimación obtenida a partir del VECM, puede ser de interés obtener las predicciones para los valores en niveles de la variable y_t y no para las diferencias Δy_t . Dado que la especificación VECM es sólo una reorganización de términos del VAR, pueden reconstruirse las matrices A_p a partir de los coeficientes estimados del VECM.

Sin embargo, es importante tomar en cuenta que, cuando el proceso que se está estimando es integrado y hay cointegración, no se puede predecir directamente desde la estimación del VAR porque es no estacionario y no estaría tomando en cuenta la cantidad de relaciones de cointegración y las restricciones que se puedan haber impuesto (ya sea en β o en α).

Por lo tanto, debe reorganizarse los términos a partir de los coeficientes estimados del VECM para obtener las matrices $A_1, A_2, \dots, A_p$ y poder realizar la predicción.

Como se detalla en el apartado 2.3.2 en la representación del VAR mediante un VECM, se muestra como a partir de la reorganización de términos de las matrices $A_1, A_2, \dots, A_p$ se puede expresar a las matrices Π y Γ del VECM.

Por lo tanto, en este caso hay que realizar la reorganización a la inversa, partiendo de los parámetros estimados en las matrices Π y Γ del VECM, se reorganizan los términos hasta obtener los valores de las matrices $A_1, A_2, \dots, A_p$.

Para un VAR(3): $\Pi = -(I - A_1 - A_2 - A_3)$, $\Gamma_2 = -A_3$ y $\Gamma_1 = -A_2 + \Gamma_2$.

Por lo tanto,

$$A_3 = -\Gamma_2, \quad A_2 = -\Gamma_1 + \Gamma_2, \quad A_1 = \Pi + I_k + \Gamma_1 \quad .$$

Capítulo 3

Datos a Emplear

En este capítulo se describen y analizan las series de datos a utilizar. En el primer apartado se explicitan las fuentes de datos, unidades de medida y transformaciones realizadas a las series.

En el segundo apartado se hace una caracterización del consumo energético del sector residencial en función de datos auxiliares obtenidos de encuestas.

Por último se hace un breve análisis de las series de datos en función de la inspección gráfica de las mismas y la vinculación de los casos atípicos con determinados sucesos económicos a nivel nacional e internacional que se dieron en el período de estudio.

3.1. Definición y descripción de las series estadísticas.

La recopilación de información proviene de varias fuentes: Ancap, Dirección Nacional de Energía del Ministerio de Industria Energía y Minería (DNE-MIEM), Instituto Nacional de Estadística (INE), leyes y decretos con los tarifarios de los distintos energéticos y fijación de precios.

Las series estadísticas empleadas para las estimaciones tienen periodicidad mensual y abarcan desde el año 2000 a 2012. Adicionalmente se cuenta con datos para el año 2013, a partir de los cuales se van a calcular los indicadores de errores de predicción cuando se realice la predicción fuera de la muestra.

Los datos sobre las cantidades consumidas de cada energético que se utilizan en este trabajo (Cuadro 3.1.1) se obtienen de Ancap y de la Dirección Nacional de Energía-MIEM, la cual elabora y publica anualmente el Balance Energético Nacional.

La matriz energética sintetiza la información anual de oferta y demanda de energía a nivel nacional, desagregada por fuente y sector económico de consumo. En esta investigación se restringe el análisis al sector residencial.

Los valores de las diferentes fuentes de energía que componen la oferta y demanda energética,

3.1. Definición y descripción de las series estadísticas.

presentados en la matriz, poseen diferentes poderes caloríficos. Por lo tanto, para unificar la unidad de medida están expresados en ktep (miles de toneladas equivalentes de petróleo) a efectos de hacer comparables las cifras.

Una tonelada equivalente de petróleo (tep) corresponde a 10 millones de kilocalorías. La conversión de las magnitudes correspondientes de cada fuente a su expresión en ktep se realiza a través de su respectivo poder calorífico inferior (PCI) [5].

Para validar los datos de cantidades provenientes de distintas fuentes de información y en distintas unidades de medida se calcula la equivalencia a ktep mediante los PCI, se compara el agregado anual de cada energético con la información de la matriz energética y de esta forma se constata la consistencia entre las distintas fuentes de datos en una misma unidad de medida.

La cantidad de gas licuado de petróleo (GLP o supergas) se obtuvo de dos fuentes: por un lado, de la publicación que realiza DNE-MIEM de venta mensual de derivados de petróleo para el mercado interno (miles m^3), y por otro, de información de litros de supergas y otros derivados del petróleo proporcionada por Ancap a través de una solicitud específica realizada.

Para el análisis de consistencia se convirtieron los datos de las dos fuentes a ktep mediante los PCI y se compararon con el consumo final energético anual del sector residencial en ktep que también publica DNE-MIEM. A partir de la comparación se valida la información y se convierte a cantidad de supergas en kilogramos (CSGKG).

Cuadro 3.1.1: Consumo Energético del Sector Residencial en ktep, años 2000-2012.

Año	Gas Nat	Leña	Resid. Biomasa	Super gas	Gas Prop	Queros	Disel Oil	Gas Oil	Fuel Oil	Gas Manuf	Carb Veget	Elect	Total
2000	0,1	301,7	-	112,4	2,6	20,4	2,3	3,1	25,3	6,4	1,3	248,9	724,5
2001	0,5	301,7	-	105,4	3,4	15,1	2,0	1,2	26,5	5,8	1,3	248,6	711,5
2002	0,6	301,7	-	100,3	4,6	13,1	1,8	0,4	27,0	6,0	0,9	240,5	696,9
2003	5,3	301,7	-	94,4	0,9	8,5	1,1	0,1	27,4	5,7	0,8	224,4	670,3
2004	8,1	301,7	-	86,3	0,7	8,5	0,9	0,1	27,2	2,8	0,8	225,7	662,8
2005	11,8	301,7	-	88,1	0,6	7,4	0,8	0,1	24,6	0,0	0,6	231,6	667,3
2006	13,0	295,0	8,2	91,2	0,7	6,2	0,6	0,0	25,7	-	0,6	262,4	703,6
2007	16,1	295,0	8,2	100,9	0,9	7,3	0,7	0,0	29,8	-	0,1	283,9	742,9
2008	15,0	283,5	7,6	93,0	1,1	6,0	0,6	0,0	26,9	-	1,0	278,2	712,9
2009	16,4	283,5	7,6	98,7	1,5	6,1	0,6	-	26,1	-	1,3	290,0	731,8
2010	17,2	283,5	7,6	103,4	1,8	6,7	0,6	-	25,3	-	1,5	300,5	748,1
2011	20,6	283,5	7,6	103	2	7,1	0,4	-	19,7	-	1	318,2	763,1
2012	21,0	283,5	7,6	101,6	2,2	6,6	0,3	-	15,6	-	1,4	331,67	771,76

Fuente: Ministerio de Industria Energía y Minería - Dirección Nacional de Energía.

La cantidad de energía eléctrica se obtiene de la facturación de electricidad de UTE en Megawatt de DNE-MIEM para el sector residencial. Al igual que en la cantidad de supergas se hace la conversión a ktep, se calcula el agregado anual para comparar con la matriz energética y corroborar la consistencia de los datos. La unidad que se utiliza para las estimaciones es la cantidad de energía eléctrica en Kilowatt - KW (CEEKW).

Tanto el precio de los energéticos derivados del petróleo como el precio de la energía eléctrica son definidos en un mercado que no es de competencia perfecta dado que el único productor y

3. Datos a Emplear

oferente es el Estado y por lo tanto los precios están regulados. Algunos precios inclusive están subsidiados, como es el caso específico del GLP.

El precio del supergas en kg (PSGKG) con iva incluído en pesos corrientes se obtiene de la publicación de los precios medios de los derivados del petróleo con y sin impuestos de DNE-MIEM, al igual que con las series de cantidades se verifica la consistencia del dato con las publicaciones de los decretos de fijación de precios y con las series de precios promedio publicados por el INE.

El precio de la energía eléctrica (PEEKW) para el sector residencial se toma de la publicación de precio medio de la electricidad para cuentas tipo con impuestos de DNE-MIEM. Se presentan los precios en dólares corrientes por KW para 8 cuentas tipo según potencia contratada y promedio de consumo en KW/mes del sector residencial.

Para el cálculo del precio promedio se toman los tres tipos centrales de potencia contratada (2kw, 3kw, 5kw) y se calcula en pesos corrientes a partir de las cotizaciones del dólar vendedor tomado de la web del INE.

Como variable de escala se utiliza la serie del Índice de Salario Real (ISR) calculado por el INE con base en julio de 2008 y para el cálculo de los precios relativos se utiliza el Índice de Precios al Consumo (IPC) calculado por el INE con base en diciembre de 2010. Para compatibilizar los datos se realiza previamente cambio de base llevando a ambos índices a base diciembre de 2012.

Las series de promedio mensual de temperatura mínima, media y máxima se solicitaron a la Dirección de Climatología y Documentación del Instituto Uruguayo de Metereología (INUMET), los datos proporcionados son promedios mensuales de la estación Carrasco del año 1999 a 2012.

La notación que se mantendrá para el resto del documento es:

- **csg**: logaritmo de la cantidad de supergas en kilogramos, ($\log(\text{CSGKG})$).
- **PSG**: logaritmo del precio corriente del supergas en kilogramos, ($\log(\text{PSGKG})$).
- **psg**: logaritmo del precio del supergas en kg relativo al IPC con base en 2012, ($\log(\text{PSGKG})/\text{IPC}$).
- **cee**: logaritmo de la cantidad de energía eléctrica en kw, ($\log(\text{CEEKW})$).
- **PEE**: logaritmo del precio corriente de la energía eléctrica en kw, ($\log(\text{PEEKW})$).
- **pee**: logaritmo del precio de la energía eléctrica en kw relativo al IPC con base en 2012, ($\log(\text{PEEKW})/\text{IPC}$).
- **isr**: logaritmo del Índice de Salario Real con base en 2012, ($\log(\text{ISR})$).
- **tmin**: logaritmo de la temperatura mínima, ($\log(\text{TMIN})$).




Figura 3.1: Series de Supergas (panel izq.), Series de Energía Eléctrica (panel der.))

3.2. Caracterización del consumo del sector residencial.

Para la caracterización del consumo del sector residencial se emplearon:

1. Datos de la Encuesta Continua de Hogares y de la Encuesta de Gastos e Ingresos del INE.
2. Datos del Censo 2011 del INE.
3. La encuesta de consumo de energía del año 2006 donde se presentan las distintas fuentes y usos de energía y el consumo de cada fuente, expresados en tep, Landaveri (2008) [32].

Según los datos del Censo 2011 presentados en el Cuadro 3.2.1, la principal fuente de energía utilizada para cocinar es el supergas, utilizado por el 88,34 % de los hogares del Uruguay y en menor medida la electricidad 5,33 %, el gas por cañería 3,23 % y la leña 2,11 %.

Sin embargo, si se considera a la principal energía utilizada para calefaccionar (Cuadro 3.2.2) cambia la importancia relativa del supergas, pasando a ser empleado sólo en el 25,05 % de los hogares, mientras que la electricidad pasa a representar el 20,52 % y la leña el 36,97 %.

En los datos presentados en la encuesta de consumo de energía del año 2006 (Cuadro 3.2.4) se observa que las principales fuentes de energía usadas por el sector residencial son: el supergas y gas natural, la leña y la energía eléctrica. Los usos principales son para calefacción, calentamiento de agua y cocción en el caso del supergas, gas natural y leña, y para iluminación, calentamiento de agua y conservación de alimentos en la energía eléctrica.

3. Datos a Emplear

Cuadro 3.2.1: Principal Fuente de Energía Utilizada para Cocinar, porcentaje de hogares.

	Censo 2011	ECH 2010	ECHA2006	EGY 2005
Electricidad	5,33 %	5,00 %	5,82 %	6,47 %
Gas por cañería	3,23 %	2,93 %	3,86 %	3,85 %
Supergas	88,34 %	87,64 %	83,84 %	83,37 %
Queroseno	0,19 %	0,35 %	1,08 %	1,26 %
Leña o carbón	2,11 %	3,86 %	5,14 %	4,91 %
Otra	0,03 %	-	-	0,14 %
Ninguna, no cocina	0,77 %	0,21 %	0,26 %	-
Total de Hogares	1.133.256	1.179.174	1.032.867	1.048.927

Fuente: Elaboración en base a datos del Instituto Nacional de Estadística.

Cuadro 3.2.2: Principal Fuente de Energía Utilizada para Calefaccionar, porcentaje de hogares.

	Censo 2011	EGY 2005
Electricidad	20,52 %	15,65 %
Leña	36,97 %	40,86 %
Gas por cañería	1,45 %	0,81 %
Supergas	25,06 %	21,12 %
Queroseno	1,48 %	2,15 %
Gas oil-Fuel oil	0,97 %	1,67 %
Otra	0,18 %	0,26 %
Ninguna	13,36 %	17,46 %
Total de Hogares	1.133.256	1.048.927

Fuente: Elaboración en base a datos del Instituto Nacional de Estadística.

Cuadro 3.2.3: Usos y Fuentes del Consumo de Energía Neta

Fuentes	Usos
GN: Gas Natural	Iluminación
SG: Supergas	Cocción
GP: Gas Propano	Calentamiento de Agua
GO: Gas Oil	Calefacción
DO: Diesel Oil	Conservación de Alimentos
FO: Fuel Oil	Ventilación y Refrigeración de Ambientes
KE: Queroseno	Bombeo de Agua
LE: Leña	Fuerza Motriz
CV: Carbón Vegetal	Otros Artefactos
RB: Residuos de Biomasa	Otros Consumos
NF: Nafta	Consumo No Energético
SO: Energía Solar	Autoproducción de Electricidad
EO: Energía Eólica	
EE: Electricidad	

Fuente: Encuesta de Consumo de Energía año 2006. MIEM-DNETN.

3.2. Caracterización del consumo del sector residencial.

Cuadro 3.2.4: Total de Consumo de Energía Neta por Fuentes y Usos del Sector Residencial.

Usos de la energía neta	GN	SG	GP	GO	DO	FO	KE	LE	CV	NF	RB	EO	EE	Total
Iluminación	-	136	-	-	-	-	420	-	-	-	-	-	38.727	39.283
Cocción	2.744	68.196	514	-	-	-	246	108.506	513	-	3.365	-	9.674	193.758
Calentamiento de Agua	6.714	5.409	63	1.169	-	108	48	11.868	-	-	775	-	96.506	122.659
Calefacción	3.573	12.196	133	3.736	405	7.191	2.415	174.611	47	-	4.104	-	8.235	216.647
Conservación de Alim.	-	122	-	-	-	-	-	-	-	-	-	-	51.261	51.383
Ventilación y Ref Amb	-	-	-	-	-	-	-	-	-	-	-	-	6.012	6.012
Bombeo de Agua	-	-	-	-	-	-	-	-	-	-	-	177	2.423	2.600
Fuerza Motriz	-	-	-	-	-	-	-	-	-	-	-	-	1.052	1.052
Otros Artefactos	-	-	-	-	-	-	-	19	-	138	-	-	45.745	45.902
Total	13.031	86.060	710	4.905	405	7.299	3.129	295.003	560	138	8.244	177	259.634	679.295

Nota: Valores expresados en tep.

Fuente: Encuesta de Consumo de Energía año 2006.MIEM-DNETN.

Cuadro 3.2.5: Consumo de Energía Neta del Sector Residencial en % del Total de Usos.

Usos de la energía neta	GN	SG	GO	FO	KE	LE	RB	EE	Otros	Total
Iluminación	-	0,3	-	-	1,1	-	-	98,6	-	100,0
Cocción	1,4	35,2	-	-	0,1	56,0	1,7	5,0	0,5	100,0
Calentamiento de Agua	5,5	4,4	1,0	0,1	-	9,7	0,6	78,7	0,1	100,0
Calefacción	1,6	5,6	1,7	3,3	1,1	80,6	1,9	3,8	0,3	100,0
Conservación de Alim.	-	0,2	-	-	-	-	-	99,8	-	100,0
Ventilación y Ref Amb	-	-	-	-	-	-	-	100,0	-	100,0
Bombeo de Agua	-	-	-	-	-	-	-	93,2	6,8	100,0
Fuerza Motriz	-	-	-	-	-	-	-	100,0	-	100,0
Otros Artefactos	-	-	-	-	-	-	-	99,7	0,3	100,0
Total	1,9	12,7	0,7	1,1	0,5	43,4	1,2	38,2	0,3	100,0

Nota: Otros incluye GP, DO, CV, NF y EO.

Fuente: Eleboración en base a Encuesta de Consumo de Energía año 2006.MIEM-DNETN.

Cuadro 3.2.6: Consumo de Energía Neta del Sector Residencial en % del Total de Fuentes.

Usos de la energía neta	GN	SG	GO	FO	KE	LE	RB	EE	Otros	Total
Iluminación	-	0,2	-	-	13,4	-	-	14,9	-	5,8
Cocción	21,1	79,2	-	-	7,9	36,8	40,8	3,7	51,6	28,5
Calentamiento de Agua	51,5	6,3	23,8	1,5	1,5	4,0	9,4	37,2	3,2	18,1
Calefacción	27,4	14,2	76,2	98,5	77,2	59,2	49,8	3,2	29,4	31,9
Conservación de Alim.	-	0,1	-	-	-	-	-	19,7	-	7,6
Ventilación y Ref Amb	-	-	-	-	-	-	-	2,3	-	0,9
Bombeo de Agua	-	-	-	-	-	-	-	0,9	8,9	0,4
Fuerza Motriz	-	-	-	-	-	-	-	0,4	-	0,2
Otros Artefactos	-	-	-	-	-	0,0	-	17,6	6,9	6,8
Total	100,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0

Nota: Otros incluye GP, DO, CV, NF y EO.

Fuente: Eleboración en base a Encuesta de Consumo de Energía año 2006.MIEM-DNETN.

3.3. Análisis Preliminar de las Series

En el análisis de series de tiempo puede ser de interés querer desagregar e identificar los distintos componentes de la misma con su respectiva desagregación en sus componentes de tendencia, estacional y componente aleatorio.

Para estimar y predecir la dinámica de los ciclos económicos es necesario poder identificar las fluctuaciones estacionales separadamente del componente tendencia. Yule (1921) [48] reporta un trabajo de 1905 que probablemente sea el primero que plantea un método para aislar los componentes inobservables. Los componentes de la serie desagregada pueden tener una agregación aditiva $Y_t = T_t + C_t + S_t + I_t$ o multiplicativa $Y_t = T_t \times C_t \times S_t \times I_t$. Siendo I_t el componente irregular o aleatorio, S_t el componente estacional, C_t el componente ciclo y T_t el componente tendencial.

En las Figuras 3.2 y 3.3 se muestran las series de cantidades y precios respectivamente, con la descomposición tendencia, estacional y componente aleatorio ¹.




Figura 3.2: Descomposición de las series de cantidades (csg (panel izq.), cee (panel der.))

Se puede hacer una primer aproximación a los datos a analizar haciendo una inspección gráfica de las series. De esta forma se puede observar si presentan patrones comunes a lo largo del período.

Las series de cantidades de energético, tanto supergas como energía eléctrica, muestran un esperable patrón estacional dado que sus picos de consumo están vinculados a determinados

¹Para la obtención de la descomposición de las series en sus componentes de tendencia, estacional y aleatorio se utiliza la función pre-programada “*decompose*” del package “*urca*” de R-project, en este trabajo no se profundiza en el método de cálculo específico de la descomposición dado que no forma parte de los objetivos.

períodos del año (ver Figura 3.2 con la descomposición del componente estacional). En el caso del supergas, como se mostró en la caracterización de consumo del apartado anterior, se usa principalmente para cocción y calefacción. El volumen en kg utilizado en cocción se puede pensar que es relativamente estable a lo largo del año, sin embargo el volumen consumido en los meses fríos del año es notablemente superior.

En cuanto al consumo de energía eléctrica, si bien también es utilizada para cocinar y calefaccionar ambientes al igual que el supergas (por lo cual se espera que tenga un comportamiento estacional similar al del supergas) en los últimos años ha comenzado a tener mayor consumo también en los meses más calurosos dado por el incremento en el uso del aire acondicionado para refrigeración de ambientes.

Esto es observable en el componente estacional de la Figura 3.2 donde se ven unos picos pronunciados asociados a los meses fríos y otros picos intermedios vinculados a los meses de temperatura alta que lo diferencia de la serie de supergas donde se observan solo los picos pronunciados asociados a los meses fríos.

Otro aspecto destacable en el período a analizar es que se observa una caída en el consumo de ambos energéticos hasta fines del 2003 que comienza a reactivarse e incrementarse a partir del año 2004 (ver Cuadro 3.1.1 con los volúmenes consumidos en ktep año a año). Adicionalmente puede observarse a través de la inspección gráfica de las series al ver los picos estacionales mínimos en cada una de ellas Figura 3.1, o en las Figuras 3.2 observando el componente tendencial.

Cabe recordar que Uruguay atravesó una crisis económica en 2002 que fue altamente recesiva y que recién a partir de 2004 comenzó a mostrar indicios de reactivación. Este hecho afectó a la economía en general, por lo tanto no sólo se verá reflejado en las series de consumo, sino que también en las de precios y salarios.

A su vez se ve un pico marcado de consumo en las series de demanda de csg y cee en 2007 que se dio principalmente por ser un año particularmente frío (ver Figura 3.4), luego una caída en el consumo pasando nuevamente a una tendencia creciente luego de 2008. Por ese motivo se considera que la temperatura juega un rol importante en los volúmenes consumidos de ambos energéticos y es importante su consideración en la modelización a realizar.

Dada esta información, una de las hipótesis que se manejan en este trabajo es que hay un efecto sustitución entre la energía eléctrica y el supergas, que se espera poder confirmar a través de las elasticidades de precio cruzadas.

Pero además se intuye, dado por el hecho de que el uso más extendido de los aires acondicionados permiten no sólo la refrigeración sino que también la calefacción de ambientes, que en determinados tramos de ingresos se está dando un efecto sustitución de los medios para calefaccionar. En este trabajo, por el tipo de datos y metodología que se va a manejar, no se pretende confirmar esta última hipótesis. Pero sería interesante poder hacer un estudio de estas características enfocado desde los tramos de ingreso de la población y ver los efectos sustitución que pueden estar dándose a diferentes niveles socioeconómicos.

3. Datos a Emplear

Las series de precios, tanto supergas como energía eléctrica (Figura 3.3), muestran un marcado incremento y cambio de tendencia a partir del año 2002, vinculados a la crisis de ese año como se mencionó previamente.




Figura 3.3: Descomposición de las series de precios (psg (panel izq.), pee (panel der.))

Si bien ambos precios son fijados y regulados por el estado, muestran un comportamiento un poco diferente entre sí. Claramente el tarifario en base al cual se fija cada uno de esos precios no es el mismo (los componentes de costo no son iguales), además el precio del supergas es subsidiado. Si se observa a los precios en términos corrientes (PSG y PEE en la Figura 3.1), se ve el salto que pegan ambos precios en el año 2002, pero la trayectoria posterior no es similar. Esto es debido al efecto del tipo de cambio en el precio de los derivados del petróleo (importante devaluación en ese período), afectando así al precio del supergas y en menor medida al de la energía eléctrica.

En el caso del precio del supergas (PSG) tuvo un salto en la serie y luego se mantuvo en ese nivel con la presencia de varias situaciones puntuales (shocks) que lo pueden haber afectado. En el año 2007 cierra la refinería de Ancap por reformas, lo cual implicó tener que importar el GLP durante todo el período que la refinería no estaba produciendo. En 2008 se dió una crisis internacional del petróleo que comenzó con un incremento sostenido del precio del barril de petróleo en 2007, llegando a su máximo histórico de 147 usd a mediados de 2008 y luego de esa fecha de desplomó a menos de 40 usd en diciembre de 2008. Esas fluctuaciones internacionales repercutieron a nivel local y se reflejan en la serie de precios corrientes del supergas.

Sin embargo, para este trabajo se va a tomar el logaritmo del precio del supergas relativo al IPC (psg), lo que implica tomar el precio corriente y deflactarlo por el índice de precios, esta serie permite comparar la evolución del precio del producto con la evolución de los precios definidos en la canasta del IPC. Al comparar el precio en términos corrientes y constantes (luego de ser deflactado, Figura 3.1) se observa que el precio del supergas creció a una tasa muy por debajo de lo que fue el crecimiento de precios de la economía en ese período, por lo que muestra una trayectoria decreciente en términos reales a partir de 2004.

En el caso del precio de la energía eléctrica (PEE), luego del salto que pega en 2002 muestra un crecimiento a lo largo del período que acompaña al crecimiento general de precios de la economía, al ver la serie de logaritmo del precio relativo al IPC (pee) continúa con una tendencia creciente.

Adicionalmente se puede destacar un shock en la serie en el año 2006. En ese año el país atravesaba una situación de riesgo en el suministro de energía y en el marco de las medidas que se tomaron para incentivar y profundizar el ahorro energético (Decreto IE/221 del 9 de junio 2006) estuvo presente un ajuste tarifario que implicó un aumento de precios adicional y específico para el sector residencial.




Figura 3.4: Descomposición de las series de salario y temperatura (isr (panel izq.), tmin (panel der.))

En relación a la serie del Índice de Salario Real (Figura 3.4) es claramente observable el efecto de la crisis de 2002 que determinó una notable caída del salario en términos reales en ese período, y que comenzó a recuperarse junto con la reactivación global de la economía a partir del año 2004.

Otro factor que incentivó la recuperación del salario real a partir de la crisis fue la reinstauración de los Consejos de Salarios a partir del año 2005, lo cual se verá reflejado en la serie a lo largo del período a través de pequeños shocks en los momentos que los Consejos de Salarios decretan los aumentos, principalmente en los meses de enero y en menor medida a mediados de año.

Por todas las características previamente señaladas, las series de datos a analizar representan un gran desafío dada la complejidad y variedad de sucesos que afectaron a la economía en ese período. Esto determinará la necesidad de recoger el impacto de esos shocks y observaciones atípicas a través de la consideración de intervenciones y un probable cambio estructural, lo cual se analizará en el Capítulo de Resultados.

Capítulo 4

Resultados

En este capítulo se van a ir presentando los resultados de las distintas estimaciones y pruebas de hipótesis realizadas. Las mismas conducen a la especificación final del modelo econométrico mediante el cual se estima la demanda de Gas Licuado de Petróleo, permitiendo interpretar las elasticidades precio e ingreso.

Como se presentó en el apartado 2.4 llegar a esa especificación implica el pasaje por un proceso iterativo en que se van probando distintas especificaciones y sus residuos hasta llegar a una versión que represente lo más acertadamente posible el proceso generador del dato.

La hipótesis que orienta esta investigación es que las variables que componen la demanda de GLP son series no estacionarias si se consideran de forma independiente, pero que al considerarse en forma conjunta (como pasa efectivamente cuando se considera la interacción de las mismas en el mercado de un bien), tienen una convergencia estacionaria común en el largo plazo.

Asimismo, se considera que la modelización debe hacerse en el ámbito de la clase de los modelos de vectores autorregresivos (VAR), la cual permite incorporar relaciones causales bidireccionales entre las variables y relaciones de retroalimentación en la medida que todas las variables sean endógenas. La especificación VAR deberá ser analizada mediante pruebas de hipótesis cuyo objetivo es establecer el rol exógeno u endógeno ¹ de las variables involucradas en la determinación de las cantidades demandadas.

Una condición necesaria para corroborar la cointegración de estas series económicas es que sean integradas ². Por lo cual, en primera instancia se presentan las pruebas de raíz unitaria para determinar el orden de integración, para posteriormente poder comenzar a hacer las pruebas sobre la cantidad de relaciones de cointegración y la estimación del modelo.

Luego de realizar todas las validaciones y llegar a una especificación que cumple con los supuestos básicos del modelo (residuos normales, homoscedásticos y no correlacionados) se realizan

¹Los conceptos de variables endógenas y exógenas fueron manejados en el apartado 2.2 del Capítulo 2.

²Las definiciones de los conceptos de estacionariedad, integración y cointegración pueden profundizarse en el Anexo Metodológico A.

las pruebas de hipótesis sobre exogeneidad y causalidad que permitirán contrastar los datos con la teoría económica, así como completar la modelización de la dinámica de la demanda.

En este aspecto, la hipótesis de trabajo es que al ser un mercado regulado en precios por el Estado, los precios entran en la ecuación de demanda pero no determinan el ajuste al equilibrio (son débilmente exógenos).

Por último, se va a realizar un análisis comparado de distintos escenarios, propuestos a partir de la inclusión de distintas especificaciones de la variable temperatura mínima, probando como afecta a la especificación final del modelo en predicción.

4.1. Pruebas de Raíz Unitaria

Para poder estimar de forma adecuada el modelo y los comportamientos de largo y corto plazo de las series es importante identificar si el proceso generador del dato es o no estacionario.

En el caso de que las series fueran integradas, al ser no estacionarias, estimar un modelo multivariado ya sea uniecuacional o multiecuacional en niveles no daría estimaciones válidas e inhabilita la inferencia.

Por tal motivo, un primer paso en el análisis de las series, adicionalmente a la inspección gráfica de las mismas, es aplicar la prueba ADF de raíces unitarias de forma de identificar si las series son integradas de orden 1 o mayor.

Un procedimiento para determinar el orden de integración consiste en llevar a cabo la prueba con la variable en niveles. Si dicha prueba proporciona evidencia a favor de la no estacionariedad, se realiza la prueba con la variables en primeras diferencias.

Si las primeras diferencias de la serie es estacionaria implica que es $I(1)$, si la primer diferencia sigue siendo no estacionaria es posible que la serie sea $I(2)$ y debe probarse nuevamente, así sucesivamente hasta identificar el orden de integración.

A partir de la inspección gráfica de las series en niveles y en primeras diferencias (ver Figuras 4.1 a 4.3), se puede observar que las series en primeras diferencias parecen tener una media constante a lo largo del tiempo, aunque en algunos casos con una variabilidad no constante.

También se observa la presencia de observaciones atípicas (“outliers”) que pueden estar vinculados a cambios en la regulación o shocks económicos. En esos casos lo recomendable es chequear los eventos en un calendario y verificar su origen, de forma que puedan ser reflejados en la modelización a través de intervenciones. En el Capítulo 3 se analizaron los datos a emplear y se identificaron una series de sucesos en el período de análisis que pueden haber generado esas observaciones atípicas.

Incluir las intervenciones en la modelización es un paso importante del análisis dado que no hacerlo genera estimaciones sesgadas que invalidan el resto de la inferencia, Juselius (2006)[p.42]

4. Resultados

[29].




Figura 4.1: Serie de isr en niveles y en diferencias (arriba) y $\Delta tmin$ y $\Delta_{12}tmin$ (abajo).

La prueba de Dickey-Fuller Aumentado (ADF) es una prueba de hipótesis que considera como hipótesis nula a la existencia de raíz unitaria $\vartheta_i = 1$ respecto a una hipótesis alternativa de $\vartheta_i < 1$ (serie estacionaria) y luego una serie de hipótesis de significación conjunta para la constante y la tendencia dado que $\vartheta_i = 1$ (se puede ver el detalle de la prueba y las hipótesis nulas en el Cuadro A.1.2 del apartado A.1.7 del Anexo Metodológico).

En base a los resultados de la prueba ADF presentados en el Cuadro 4.1.1 se determina que todas las series son I(1) y se vuelven estacionarias al aplicarle una diferencia ³.

Primero se prueba la existencia de raíz unitaria en las series en niveles (especificación a) y si se confirma $\vartheta_i = 1$ se pasa a probar la presencia de constante y tendencia (especificaciones b o c).

En segunda instancia, se prueba la serie en primeras diferencias y se confirma que son I(1). No se rechazó la presencia de tendencia en varias de las series en niveles, lo cual no era un resultado esperado, igualmente hay que ser cauteloso en las conclusiones que se tomen a partir de la prueba ADF porque es sensible a la cantidad de rezagos incluidos y a la presencia de quiebre estructural en las series.

³Para la prueba de hipótesis se contrastan los valores del estimador con los valores críticos presentados en el Cuadro E.0.1 del Anexo E, según la especificación correspondiente de la prueba. Para determinar la cantidad de rezagos que correspondía incluir se hizo incluyendo todos los que fueran significativos en la regresión ADF y que al verificar en el correlograma de los residuos se lograra limpiar la autocorrelación de los mismos.




Figura 4.2: Series de cantidades demandadas en niveles y en primeras diferencias.




Figura 4.3: Series de precios relativos en niveles y en primeras diferencias.

4. Resultados

Cuadro 4.1.1: Resultados de la prueba de Dickey-Fuller Aumentado (ADF).

Variable	cant. rezagos	Especificación	Estadístico
log(CSGKG)	12	b	-1,69
Δ log(CSGKG)	11	a	-10,42
log(CEEKW)	24	c	-2,12
Δ log(CEEKW)	23	a	-2,12
log(ISR)	13	c	-2,60
Δ log(ISR)	12	a	-1,82
log(psgipc)	12	c	-2,00
Δ log(psgipc)	11	a	-2,58
log(peeipc)	9	c	-1,83
Δ log(peeipc)	8	a	-3,29
log(tmin)	12	a	-0,27
Δ log(tmin)	11	a	-10,10

Nota: Los valores críticos asociados a la prueba se presentan en el Cuadro E.0.1.

A partir del análisis gráfico de las series se intuye que puede llegar a haber un quiebre estructural en el período de análisis, dado por los efectos de la crisis de 2002 (donde se generan cambios en el comportamiento de las series como se analizó en el capítulo anterior).

Por este motivo, se procede a realizar adicionalmente la prueba de Zivot y Andrews que permite contrastarlo, ya que toma en cuenta la posibilidad de presencia de quiebre estructural en la especificación de la prueba de hipótesis.

La prueba de Zivot y Andrews (ZA) es una prueba de hipótesis que considera como hipótesis nula a la existencia de raíz unitaria, respecto a una hipótesis alternativa de que la serie es estacionaria en tendencia con quiebre estructural (en niveles, en tendencia o ambos) y estima el probable punto de quiebre. Se puede ver el detalle de la prueba, las hipótesis nulas y alternativas en el apartado A.1.7 del Anexo Metodológico.

En base a los resultados de la prueba de ZA presentados en el Cuadro 4.1.2 no se rechaza la hipótesis de raíz unitaria en las series de cantidades y precios, y como se ve en las Figuras 4.4 y 4.5 no habría quiebre estructural.

Al hacer la prueba a las series en primeras diferencias se rechaza la raíz unitaria ⁴.

⁴Para la prueba de hipótesis se contrastan los valores del estimador con los valores críticos presentados en el Cuadro E.0.2 del Anexo E, según la especificación correspondiente de la prueba. En el Cuadro 4.1.2 se presentan sólo los resultados para la especificación que mejor se adecuaba a los datos determinándolo de forma análoga a como se hizo en la prueba de ADF. Para la determinación de los rezagos que correspondía incluir se hizo incluyendo todos los que fueran significativos en la regresión, Zivot y Andrews (1992)[p.3] [49], y que al verificar en el correlograma de los residuos se lograra limpiar la autocorrelación de los mismos.

En el caso de la serie de Índice de Salario Real se rechaza la hipótesis nula de raíz unitaria en favor de la presencia de quiebre estructural con alta probabilidad en el año 2002 (ver Figura 4.6). La presencia de un quiebre estructural en la serie puede implicar la necesidad de inculir una intervención que capte ese cambio en el período de análisis.

Cuadro 4.1.2: Resultados de la prueba de Zivot y Andrews (ZA).

Variable	cant. rezagos	Especificación	Estadístico
log(CSGKG)	14	dt	-3,77
$\Delta \log(\text{CSGKG})$	11	du	-11,17
log(CEEKW)	24	dt	-3,83
$\Delta \log(\text{CEEKW})$	23	du	-4,61
log(ISR)	24	du y dt	-7,39
$\Delta \log(\text{ISR})$	23	dt	-4,63
log(psgipc)	12	du y dt	-4,44
$\Delta \log(\text{psgipc})$	8	du y dt	-5,83
log(peeipc)	12	dt	-3,76
$\Delta \log(\text{peeipc})$	8	du	-6,73

Nota: Los valores críticos asociados a la prueba se presentan en el Cuadro E.0.2.

Cabe resaltar que este resultado no implica que el Índice de Salario Real sea estacionario, es una serie ampliamente investigada a nivel nacional e internacional, constatándose en la mayoría de los casos su característica no estacionaria.

Dada la especificación de hipótesis nula y alternativa que tiene la prueba de ZA, es muy fuerte la evidencia que marca un quiebre estructural en la serie y por ese motivo se rechaza la hipótesis nula.

Sin embargo, al repetir la prueba para los datos posteriores al momento del quiebre no se rechaza la hipótesis de raíz unitaria en la serie (las salidas completas de las pruebas ADF y ZA para isr se presentan en el Anexo de Resultados B.2.1).

En conclusión todas las series son $I(1)$, no estacionarias con una raíz unitaria, y en el caso del isr los resultados muestran la alta probabilidad de existencia de quiebre estructural en la serie.

4. Resultados




Figura 4.4: Gráfico de potencial quiebre estructural de la prueba de Zivot y Andrews en las variables csg (panel izq.), cee (panel der.))




Figura 4.5: Gráfico de potencial quiebre estructural de la prueba de Zivot y Andrews en las variables psg (panel izq.), pee (panel der.))




Figura 4.6: Gráfico de quiebre estructural de la prueba de Zivot y Andrews en la variable de isr.

4.2. Selección de la Cantidad de Rezagos del VAR

Como se estableció en el apartado 2.4 del Capítulo 2 el primer paso para la estimación del VAR es definir la cantidad de rezagos a incluir, lo cual determina la dinámica de la serie y la influencia que tienen los valores pasados sobre cada una de las variables.

Para determinar la cantidad de rezagos a incluir se realizan una serie de pruebas de hipótesis y análisis comparados de estimar el modelo con determinada cantidad de rezagos alternativos y seleccionar el que mejor capte la dinámica del modelo. El desarrollo teórico de las pruebas utilizadas (prueba de razón de máxima verosimilitud y los criterios de información de Akaike (AIC), Schwarz (SC) y Hannan-Quinn (H-Q)) se presenta en el apartado A.2 del Anexo Metodológico.

Los indicadores AIC, SC y H-C se calculan en base al logaritmo del determinante de la matriz de varianzas y covarianzas del modelo estimado $\ln|\hat{\Omega}_p|$, más un factor de penalización relacionado a la cantidad de parámetros estimados, sin embargo la prueba de razón de máxima verosimilitud no incluye dicho factor, por lo tanto no siempre dan el mismo resultado en cuanto a la cantidad de rezagos a incluir en el modelo.

Por este motivo, se realizan varias estimaciones tanto en el VAR como en la especificación VECM y se analizan también los residuos para identificar que especificación se ajusta mejor

4. Resultados

al proceso generador del dato (dado que el cumplimiento del supuesto de normalidad de los residuos es indispensable para la inferencia en este tipo de estimaciones).

Como plantea Lütkepohl (2005) [p.134] [35] seleccionar una cantidad innecesariamente grande de rezagos reduce la precisión en la predicción, por tal motivo ésta instancia de la determinación de la cantidad de rezagos es tan importante.

Se plantea la comparación de resultados en base a un máximo de 4 rezagos y el largo de la serie es de $T = 156$ datos, dado que la comparación de los indicadores debe calcularse sobre la misma cantidad de observaciones, se calculan en base a un $T = 152$.

El modelo VAR a estimar incluye en su especificación inicial las siguientes variables:

- Logaritmo de la Cantidad de Supergas en KG (*csg*).
- Logaritmo de la Cantidad de Energía Eléctrica en KW (*cee*).
- Logaritmo del Índice de Salario Real con base en 2012 (*isr*).
- Logaritmo del Precio del supergas en kg, relativo al IPC con base en 2012 (*psg*).
- Logaritmo del Precio de la energía eléctrica en KW, relativo al IPC con base en 2012 (*pee*).
- Componentes determinísticos como: constante, tendencia, dummies estacionales centradas, y variables de intervención. Las intervenciones corresponden a determinados eventos (shocks) que se dan a lo largo del período bajo estudio y serán incluidas como variables determinísticas exógenas a la relación de cointegración.

Cuadro 4.2.1: Determinación de la cantidad de rezagos del VAR, $max.p = 4$, $T = 152$.

	$p = 1$	$p = 2$	$p = 3$	$p = 4$
MaxLogLik	2605.68	2627.74	2644.46	2664.71
AIC	-38.15	-38.11	-38.00	-37.94
SC	-37.65	-37.11	-36.51	-35.95
H-Q	-37.94	-37.70	-37.39	-37.13
LR.test	-	44.11	33.44	40.50
J.B.test	27.89	15.78	17.49	28.87
J.B.test*	129.54	84.61	69.57	69.87

Nota: Los cálculos de los criterios de información y LR test se hicieron en base a una especificación que incluye a las intervenciones dentro de los componentes determinísticos, sin embargo la prueba de Jarque-Bera (J.B.test*) se realizó en base a un modelo sin incluir las intervenciones.

Si bien los criterios de información indicarían que la cantidad de rezagos es $p = 1$, la prueba de

razón de máxima verosimilitud (LR ⁵) sostendría que la cantidad de rezagos es $p = 2$. También se presentan rezagos significativos en el VAR(3) y en el VAR(4).

Juselius (2006) [p.72] [29] argumenta que una cantidad de rezagos $p = 2$ es más que suficiente en la mayoría de los casos para describir la estructura dinámica del proceso y explica que los rezagos significativos en 4 o 5 pueden estar asociados a estacionalidad en los datos que no logró ser capturada por las dummies estacionales. Análogamente, Lütkepohl (2005) considera que incluir más rezagos de los necesarios puede ser más dañino que aceptar un poco de autocorrelación en el modelo.

La prueba de hipótesis de Jarque-Bera (J.B.test) sobre la normalidad de los residuos muestra que la especificación con $p = 1$ y $p = 4$ tiene residuos más alejados de la normalidad que en las especificaciones con $p = 2$ y $p = 3$.

Si bien la normalidad de los residuos no es una de las pruebas usuales empleadas en la selección de rezagos, aquí se consideró igualmente dado que su cumplimiento es un requisito indispensable para el resto del análisis, por lo tanto seleccionar una especificación en cantidad de rezagos que implica tener residuos no normales no sería adecuado.

Por este motivo, las estimaciones del VECM se van a hacer para un modelo VAR con $p = 2$ y $p = 3$ rezagos y seleccionar la mejor especificación luego de realizar las pruebas de hipótesis sobre la cantidad de relaciones de cointegración y pruebas de hipótesis sobre la significación de los β .

Para una especificación de VAR con 2 rezagos el modelo tiene la forma:

$$y_t = v + A_1 y_{t-1} + A_2 y_{t-2} + \Phi D_t + u_t . \quad (4.1)$$

En D_t se incluyen los componentes determinísticos.

$$\begin{bmatrix} csg_t \\ cee_t \\ isr_t \\ psq_t \\ pee_t \end{bmatrix} = v + \begin{bmatrix} a_{11,1} & \cdots & a_{15,1} \\ \vdots & \ddots & \vdots \\ a_{51,1} & \cdots & a_{55,1} \end{bmatrix} \begin{bmatrix} csg_{t-1} \\ cee_{t-1} \\ isr_{t-1} \\ psq_{t-1} \\ pee_{t-1} \end{bmatrix} + \begin{bmatrix} a_{11,2} & \cdots & a_{15,2} \\ \vdots & \ddots & \vdots \\ a_{51,2} & \cdots & a_{55,2} \end{bmatrix} \begin{bmatrix} csg_{t-2} \\ cee_{t-2} \\ isr_{t-2} \\ psq_{t-2} \\ pee_{t-2} \end{bmatrix} + \Phi D_t + \begin{bmatrix} u_{1t} \\ u_{2t} \\ u_{3t} \\ u_{4t} \\ u_{5t} \end{bmatrix} . \quad (4.2)$$

Para una especificación de VAR con 3 rezagos el modelo tiene la forma:

$$y_t = v + A_1 y_{t-1} + A_2 y_{t-2} + A_3 y_{t-3} + \Phi D_t + u_t . \quad (4.3)$$

⁵El valor crítico en la distribución $\chi^2_{(1-\alpha),(k^2)}$ para $\alpha = 0,05$ y $k^2 = 25$ es 37.5.

4. Resultados

Al estimar tanto el VAR(2) como el VAR(3) sin restricciones se encuentran 3 raíces características muy próximas al círculo unitario (Figura 4.7, Cuadro 4.2.2)⁶.

Por lo tanto, el VAR es no estacionario y tener 3 raíces características próximas al círculo unitario implicaría que puede haber hasta 2 relaciones de cointegración ($k - r = 3$)⁷.

El modelo VAR(2) especificado como VECM con $m = 1$ quedará representado como:

$$\Delta y_t = \Gamma_1^{(1)} \Delta y_{t-1} + \Pi y_{t-1} + \Phi D_t + \epsilon_t . \quad (4.4)$$

El modelo VAR(3) especificado como VECM con $m = 1$ quedará representado como:

$$\Delta y_t = \Gamma_1^{(1)} \Delta y_{t-1} + \Gamma_2^{(1)} \Delta y_{t-2} + \Pi y_{t-1} + \Phi D_t + \epsilon_t . \quad (4.5)$$




Figura 4.7: Las $pk = 10$ raíces del VAR(2)(fig. izq.), Las $pk = 15$ raíces del VAR(3)(fig. der.).

⁶Si las raíces están dentro del círculo unitario $\{y_t\}$ es estacionario, si las raíces están fuera del círculo unitario $\{y_t\}$ es explosivo, y si las raíces están sobre el círculo unitario $\{y_t\}$ es I(1).

⁷La presencia de raíces unitarias en el VAR implica que la matriz de varianzas y covarianzas ya no converge a una matriz constante en el límite, sino que a una matriz de movimientos Brownianos. En este caso los estadísticos t no se distribuyen más como t -student, sino como τ Dickey-Fuller, Juselius (2006) [p.59] [29]. Los estadísticos t se distribuyen como t -student solo si la combinación lineal $\hat{\beta}'_t y_t$ es estacionaria, Juselius (2006) [p.122].

Cuadro 4.2.2: Raíces de las estimaciones de los modelos VAR.

Raíces del VAR(2)($pk = 10$)		Raíces del VAR(3)($pk = 15$)		
0.978	0.407	0.982	0.623	0.407
0.977	0.269	0.982	0.529	0.286
0.977	0.269	0.968	0.529	0.150
0.452	0.250	0.628	0.485	0.150
0.452	0.060	0.628	0.407	0.006

4.3. Test de Johansen

Determinar la cantidad de relaciones de cointegración presentes en el modelo es un paso crucial para el análisis empírico del mismo, visto su influencia en los posteriores procedimientos inferenciales que, finalmente, conducen a utilizar el modelo con fines predictivos.

La forma de realizarlo es a través del test de la traza, también conocido como test de Johansen, donde no sólo se determina la cantidad de relaciones de cointegración sino que adicionalmente se estiman las matrices α , β y la dinámica del modelo en el corto y largo plazo.

Para realizar la estimación de los parámetros y prueba de hipótesis es necesario especificar el modelo como VECM. Si los datos en niveles muestran tendencia pero al ser considerados en primeras diferencias la tendencia es constante, la especificación mediante VECM logra captarla sin que sea necesario incluirla en la especificación.

Incluir una tendencia en el VECM implicaría la existencia de tendencia cuadrática en los datos en niveles, lo cual a partir de la inspección gráfica de las series no parece ser el caso en los datos a analizar.

Para estimar el VECM es necesario definir previamente otros componentes de la especificación además de la constante y/o tendencia no restringidas a la relación de cointegración y de las intervenciones, por ejemplo si debe incluirse constante y/o tendencia determinística restringida a la relación de cointegración.

Luego de la estimación puede comprobarse mediante pruebas de hipótesis la especificación que mejor se adecúe a los datos. Por este motivo, es importante identificar bajo que caso de análisis de los definidos por Johansen se va a trabajar (en el Capítulo 2, apartado 2.4.1 se presentan los 5 casos de análisis que plantea Johansen y en el apartado 2.4.2 el desarrollo teórico de la prueba para determinar el rango de cointegración).

Al mismo tiempo es necesario realizar las pruebas de hipótesis sobre significación de los β para confirmar si corresponde incluir las variables consideradas endógenas dentro de la relación de

4. Resultados

cointegración, o alguna resulta ser no significativa dentro de la misma.

Las variables consideradas para la estimación de los parámetros del VECM y la realización de la prueba de hipótesis sobre cantidad de relaciones de cointegración son las mismas que se consideraron para la determinación de la cantidad de rezagos: *csg*, *cee*, *isr*, *psg*, *pee*, restringidas a la relación de cointegración, y *dummies estacionales centradas e intervenciones* incluídas como variables determinísticas exógenas a la relación de cointegración. Adicionalmente se incluyen *constante y tendencia restringidas y no restringidas* a la relación de cointegración dependiendo de cada uno de los casos de análisis que corresponda.

Como se mencionó previamente, la determinación de la especificación del modelo es un proceso iterativo que implica partir de la estimación de una especificación inicial, hacer las pruebas de hipótesis correspondientes, reformularla cuando sea necesario y volver a hacer todo nuevamente hasta lograr una especificación que realmente se adecúe a los datos.

Por lo tanto, en este apartado se realizan las pruebas de hipótesis sobre la cantidad de relaciones de cointegración para los casos de análisis 2, 3 y 4, a partir de las cuales se va a determinar la especificación del VECM (según los componentes de constante y tendencia a incluir) y la cantidad de relaciones de cointegración.

La especificación mediante el *Caso 1* (asume que la serie de datos no contiene ni constante ni tendencia) o el *Caso 5* (asume que la serie tiene tendencia cuadrática) no se incorporan al análisis porque se considera que, a partir del análisis gráfico de las series, no se adecúan al proceso generador del dato.

En el siguiente apartado, se realizarán las pruebas de hipótesis sobre los coeficientes de largo plazo β , para verificar si son significativos dentro de la relación de cointegración, o corresponde realizar ajustes a la especificación.

Esta prueba de hipótesis también permite ver la significación de los componentes de constante y tendencia dentro de la relación de cointegración, y por lo tanto, permite definir el *Caso* de análisis que se va a seleccionar para continuar con los siguientes pasos de estimación del VECM.

Test de Johansen para determinar el rango de cointegración

Dado que la cantidad de rezagos del VAR quedó abierto a la posibilidad de 2 o 3 rezagos, se realizaron de forma equivalente pruebas para $p = 2$ y $p = 3$ rezagos.

En el *Caso 2* con $p = 3$ se determina que hay $r = 2$ relaciones de cointegración al 5 % de significación y no se rechaza que la constante dentro de la relación de cointegración sea significativa. En el *Caso 4* con $p = 3$ se determina $r = 2$ al 2,5 % de significación y se rechaza la presencia de una tendencia dentro de la relación de cointegración (ver los Cuadros [4.3.1](#), [4.3.2](#) y [4.3.3](#) con la determinación del rango de cointegración y el Cuadro [4.4.1](#) con los resultados de las pruebas de hipótesis sobre la significación de los β).

Dado que en el *Caso 2* no se rechaza que la constante restringida sea significativa, el *Caso 3* puede ser una posibilidad, pero al hacer la prueba de hipótesis sobre los β se rechaza que la constante restringida sea significativa.

La prueba de hipótesis para determinar el rango de cointegración determina que: si $\tau_{k-r} >$ valor crítico, se rechaza la hipótesis nula de $H_0 : k - r$ raíces unitarias.

En el Cuadro 4.3.1 se presenta el test de la traza para el *Caso 2* con $p = 3$. En este caso se rechaza $r = 0$ y $r \leq 1$, pero no se rechaza $r \leq 2$. Por lo tanto, el test de la traza concluye que hay por lo menos 2 relaciones de cointegración y por lo tanto $k - r = 3$ raíces unitarias, resultado que ya se había encontrado en el apartado 4.2 donde se identificaron 3 raíces unitarias en el VAR a partir de la cantidad de raíces sobre el círculo unidad.

Cuadro 4.3.1: Test de la Traza en el *Caso 2* con $p = 3$, $k = 5$.

τ_{k-r}		0.9	0.95	0.975	0.99
$r = 0$	165.61	72.74	76.81	80.46	84.84
$r \leq 1$	74.14	50.50	53.94	57.05	60.81
$r \leq 2$ 	26.49	32.25	35.07	37.64	40.78
$r \leq 3$	4.68	17.98	20.16	22.18	24.69
$r \leq 4$	1.21	7.60	9.14	10.63	12.53

Nota: Los valores críticos son tomados de Juselius (2006) [p.420].

En el Cuadro 4.3.2 se presenta el test de la traza para el *Caso 3* con $p = 3$, en este caso se rechaza $r = 0$ y $r \leq 1$, pero no se rechaza $r \leq 2$. Por lo tanto, el test de la traza concluye igual que en el *Caso 2*, que hay por lo menos 2 relaciones de cointegración y por lo tanto $k - r = 3$ raíces unitarias, que pueden interpretarse como 2 tendencias estocásticas comunes.

Cuadro 4.3.2: Test de la Traza en el *Caso 3* con $p = 3$, $k = 5$.

τ_{k-r}		0.9	0.95	0.975	0.99
$r = 0$	164.96	65.73	69.61	73.10	77.29
$r \leq 1$	73.50	44.45	47.71	50.66	54.23
$r \leq 2$ 	25.95	27.16	29.80	32.23	35.21
$r \leq 3$	4.14	13.42	15.41	17.28	19.62
$r \leq 4$	1.21	2.71	3.84	5.02	6.63

Nota: Los valores críticos son tomados de Juselius (2006) [p.420].

En el Cuadro 4.3.3 se presenta el test de la traza para el *Caso 4* con $p = 3$. En este caso se rechaza $r = 0$, $r \leq 1$, y se rechaza $r \leq 2$ al 5 % de significación pero no se rechaza al 2,5 %, lo cual implicaría un resultado no determinante para confirmar si hay 3 raíces unitarias

4. Resultados

o 2. Dado el resultado obtenido en el apartado 4.2 donde se determina que existen 3 raíces muy próximas al círculo unitario se hará la estimación del *Caso 4* en base a $r = 2$ para las pruebas de hipótesis sobre la significación de los componentes de β .

Cuadro 4.3.3: Test de la Traza en el *Caso 4* con $p = 3$, $k = 5$.

τ_{k-r}		0.9	0.95	0.975	0.99
$r = 0$	185.95	84.27	88.55	92.38	96.97
$r \leq 1$	94.06	60.00	63.66	66.95	70.91
$r \leq 2$	45.38	39.73	42.77	45.53	48.87
$r \leq 3$	10.23	23.32	25.73	27.95	30.67
$r \leq 4$	2.41	10.68	12.45	14.12	16.22

Nota: Los valores críticos son tomados de Juselius (2006) [p.421].

Si bien se presentan los resultados del test de la traza sólo para los casos con $p = 3$ rezagos, se realizaron las mismas instancias de análisis para $p = 2$ rezagos. Los resultados son equivalentes, dando como resultado $r = 2$ relaciones de cointegración en cada uno de los casos de análisis ⁸.

A continuación se presentan los resultados de las pruebas de hipótesis sobre significación de los componentes de β , lo cual permitirá definir que especificación se va a asumir para las estimaciones del VECM y la cantidad de rezagos a incluir en el VAR.

4.4. Pruebas de hipótesis sobre la significación de los β

La prueba de hipótesis sobre la significación de los coeficientes β se realiza para comprobar si dichos coeficientes, asociados a cada una de las variables consideradas endógenas, son significativos y por lo tanto integran a la relación de cointegración.

La prueba se lleva a cabo mediante una prueba de razón de verosimilitud (LR-test), donde se compara un modelo restringido, en el cual se impone la restricción de que uno de los coeficientes es cero, respecto a un modelo no restringido, en el que se incluyen todos los coeficientes asociados a las variables consideradas.

Si la magnitud del estadístico es pequeña, implica que la variable puede ser omitida en la relación de largo plazo. El desarrollo teórico de esta prueba de hipótesis está desarrollada en el apartado 2.4.5 del Capítulo 2.

En cualquiera de los casos analizados se rechaza que los coeficientes β sean no significativos en la relación de cointegración (Cuadro 4.4.1), por lo tanto todas las variables consideradas tienen una tendencia conjunta a la estabilidad en el largo plazo, sin embargo en la especificación del *Caso 3* la constante restringida es no significativa y en el *Caso 4* la tendencia lineal restringida es no significativa.

⁸La programación del test de la traza y los valores críticos utilizados se presentan en el apartado D.1.5.

4.4. Pruebas de hipótesis sobre la significación de los β

Este resultado permite seleccionar al *Caso 2* como la especificación que mejor se adecúa al proceso generador del dato.

Cuadro 4.4.1: Prueba de hipótesis sobre la significación de β con $p = 3$.

	Caso 2		Caso 3		Caso 4	
	<i>LR.test</i>	p-valor	<i>LR.test</i>	p-valor	<i>LR.test</i>	p-valor
H0) beta.CSG=0	61.99	0.00	61.99	0.00	49.40	0.00
H0) beta.CEE=0	30.15	0.00	30.10	0.00	20.18	0.00
H0) beta.ISR=0	22.75	0.00	22.71	0.00	19.08	0.00
H0) beta.psg=0	12.89	0.00	12.88	0.00	11.86	0.00
H0) beta.pee=0	17.06	0.00	17.03	0.00	13.97	0.00
H0) beta.cte=0	26.14	0.00	0.00	1.00	-	-
H0) beta.trend=0	-	-	-	-	1.56	0.46

Nota: El p-valor es calculado para la distribución χ_v^2 , como se establece en el apartado 2.4.5.

Se realizaron las mismas instancias de análisis para la especificación con $p = 2$ rezagos, dando resultados análogos al caso con 3 rezagos en las pruebas de hipótesis sobre los parámetros β ⁹.

Por último, luego de haber definido el caso de análisis como el *Caso 2*, es necesario definir la cantidad de rezagos a incluir en el VAR.

Para este paso, se hace un análisis comparado de los residuos de ambas opciones: *Caso 2* con $p = 2$ y *Caso 2* con $p = 3$, seleccionando la especificación que tenga residuos mejor comportados, como se presenta en el Cuadro 4.4.2¹⁰.

A partir del análisis de los residuos se observa que en el caso con 2 rezagos los residuos no son normales a un nivel de 5 % de significación, y los indicadores de criterios de información son mejores en la especificación con 3 rezagos. Por lo tanto, se va a seleccionar la especificación del *Caso 2* y $p = 3$ para continuar el análisis en las siguientes secciones.

⁹La programación de la prueba de hipótesis se presenta en el apartado D.1.9.

¹⁰Se entiende por residuos mejor comportados, a los residuos que en cuanto a las propiedades de normalidad, homoscedasticidad y no correlación serial tienen valores en sus pruebas de hipótesis más próximos al cumplimiento de dichas propiedades. Recordar que i) la hipótesis nula en la prueba de normalidad es que los residuos son normales, ii) la hipótesis nula en la prueba de correlación serial es que no existe correlación serial y iii) la hipótesis nula en la prueba de heteroscedasticidad es que los residuos son homoscedásticos. Se puede ver la especificación completa de cada una de éstas pruebas de hipótesis en el apartado A.3 del Anexo Metodológico A.

4. Resultados

Cuadro 4.4.2: Pruebas multivariadas, comparación de cantidad de rezagos en *Caso 2*

	Caso 2 con $p = 3$		Caso 2 con $p = 2$	
	Estadístico	p-valor	Estadístico	p-valor
Normalidad	18.17	0.052	22.69	0.011
Simetría	3.86	0.568	2.63	0.756
Curtosis	14.30	0.014	20.05	0.001
Corr. Serial ($h = 12$)	1.26	0.247	0.867	0.582
AIC	-37.83	-	-37.60	-
SC	-36.34	-	-36.12	-
HQ	-37.22	-	-37.00	-
Max.LogLik	2648.61	-	2.647.734	-

Nota: La especificación de cada uno de los test se presenta en el Anexo Metodológico [A.3](#).

El modelo VAR(3) especificado como VECM con $m = 1$ en la especificación del *Caso 2* de Johansen quedará representado como:

$$\begin{bmatrix} \Delta csg_t \\ \Delta cee_t \\ \Delta isr_t \\ \Delta psg_t \\ \Delta pee_t \end{bmatrix} = v + \begin{bmatrix} \gamma_{11,1} & \cdots & \gamma_{15,1} \\ \vdots & \ddots & \vdots \\ \gamma_{51,1} & \cdots & \gamma_{55,1} \end{bmatrix} \begin{bmatrix} \Delta csg_{t-1} \\ \Delta cee_{t-1} \\ \Delta isr_{t-1} \\ \Delta psg_{t-1} \\ \Delta pee_{t-1} \end{bmatrix} + \begin{bmatrix} \gamma_{11,2} & \cdots & \gamma_{15,2} \\ \vdots & \ddots & \vdots \\ \gamma_{51,2} & \cdots & \gamma_{55,2} \end{bmatrix} \begin{bmatrix} \Delta csg_{t-2} \\ \Delta cee_{t-2} \\ \Delta isr_{t-2} \\ \Delta psg_{t-2} \\ \Delta pee_{t-2} \end{bmatrix} + \\
 \begin{bmatrix} \pi_{11,1} & \cdots & \pi_{16,1} \\ \vdots & \ddots & \vdots \\ \pi_{51,1} & \cdots & \pi_{56,1} \end{bmatrix} \begin{bmatrix} csg_{t-1} \\ cee_{t-1} \\ isr_{t-1} \\ psg_{t-1} \\ pee_{t-1} \\ cte \end{bmatrix} + \Phi D_t + \begin{bmatrix} \epsilon_{1t} \\ \epsilon_{2t} \\ \epsilon_{3t} \\ \epsilon_{4t} \\ \epsilon_{5t} \end{bmatrix} \quad (4.6)$$

A partir de esta especificación se calculan las estimaciones de las matrices $\beta_{(k \times k)}$ y $\alpha_{(k \times k)}$ mediante restricciones de rango reducido, las cuales se presentan en el Cuadro [4.4.3](#) ¹¹.

Cuadro 4.4.3: Estimación de β y α normalizados sin restricciones, para el *Caso 2* con $p = 3$.

$$\hat{\beta} = \begin{bmatrix} 1,00 & 0,08 & 0,32 & -0,25 & 0,57 & -0,04 \\ -1,15 & 1,00 & -1,12 & 0,17 & 0,11 & -0,10 \\ 0,72 & -0,80 & 1,00 & 0,60 & -4,20 & 0,26 \\ 0,24 & -0,07 & 0,33 & 1,00 & -1,74 & 0,19 \\ -0,40 & 0,15 & 0,67 & -0,76 & 1,00 & -0,17 \\ 9,76 & -16,45 & 12,04 & -6,05 & 15,78 & 1,00 \end{bmatrix} \quad \hat{\alpha} = \begin{bmatrix} -1,06 & -0,96 & -0,11 & -0,03 & 0,00 & 0,00 \\ 0,06 & -0,41 & 0,17 & -0,01 & 0,00 & 0,00 \\ -0,05 & 0,06 & 0,05 & 0,00 & 0,00 & 0,00 \\ 0,07 & 0,07 & -0,02 & -0,02 & 0,00 & 0,00 \\ 0,03 & -0,11 & -0,03 & 0,01 & 0,01 & 0,00 \end{bmatrix}$$

¹¹Las salidas con los resultados completos de la estimación de β, α sin normalizar y normalizados, valores propios, errores estándar, etc, se presentan en el apartado [B.2.2](#). La programación utilizada para los cálculos de los mismos está en el apartado [D.1.4](#) y [D.1.6](#).

4.4. Pruebas de hipótesis sobre la significación de los β

El resultado de $r = 2$ relaciones de cointegración implica que para la estimación de la totalidad de los parámetros del VECM se van a restringir las matrices $\beta_{(k \times k)}$ y $\alpha_{(k \times k)}$, seleccionando las primeras r columnas de las matrices y normalizandolas de forma adecuada, según se presentó en el apartado 2.4.4, obteniéndose:

Cuadro 4.4.4: Estimación de β y α normalizados para el Caso 2 con $p = 3$ y $r = 2$.

$$\hat{\beta} = \begin{bmatrix} 1,00 & 0,00 \\ 0,00 & 1,00 \\ -0,18 & -0,78 \\ 0,15 & -0,08 \\ -0,20 & 0,17 \\ -8,37 & -15,77 \end{bmatrix} \quad \hat{\alpha} = \begin{bmatrix} -1,14 & 0,25 \\ 0,03 & -0,48 \\ -0,05 & 0,12 \\ 0,07 & -0,007 \\ 0,02 & -0,15 \end{bmatrix} .$$

Dando lugar a las elasticidades precio e ingreso de las demandas de supergás y energía eléctrica, como se presentan a continuación ¹²:

$$csg_t = 8,37 + 0,18isr_t - 0,15psg_t + 0,20pee_t . \quad (4.7)$$

En la demanda de supergás, las elasticidades precio e ingreso tiene signos acordes a lo esperado según la teoría económica. La elasticidad ingreso al estar entre 0 y 1, y con su signo positivo muestra que el supergás es un bien normal con magnitud $\beta_{1,3} = 0,18$. La elasticidad precio del supergás tiene signo negativo $\beta_{1,4} = -0,15$ que es acorde a la teoría, y la elasticidad precio cruzada $\beta_{1,5} = 0,20$ con su signo positivo muestra que la energía eléctrica es un bien sustituto al supergás con una elasticidad mayor a la del precio propio.

$$cee_t = 15,77 + 0,78isr_t + 0,08psg_t - 0,17pee_t . \quad (4.8)$$

En el caso de la demanda de energía eléctrica, las elasticidades también tienen signos acordes a lo esperado según la teoría económica. La elasticidad ingreso al igual que en el caso del supergás muestra que es un bien normal pero con una influencia en la demanda de energía eléctrica mayor que la que tiene en la demanda de supergás $\beta_{2,3} = 0,78$. La elasticidad precio de la energía eléctrica $\beta_{2,5} = -0,17$ con signo negativo también dió acorde a la teoría, y la elasticidad precio cruzada $\beta_{2,4} = 0,08$ con su signo positivo muestra que el supergás es un bien sustituto a la energía eléctrica pero al ser de magnitud tan pequeña es poco influyente.

En el apartado 4.6 se amplía la interpretación de los coeficientes y la estimación del VECM, luego de realizadas las pruebas de causalidad y exogeneidad.

¹²La interpretación de las elasticidades se realiza con el signo contrario al que se presenta en la representación vectorial.

4.5. Causalidad y Exogeneidad

A partir de la estimación del rango de cointegración y posterior estimación del VECM se llegó a una especificación que presenta 2 relaciones de cointegración, una para la demanda de Gas Licuado de Petróleo (*csg*) y otra para la demanda de Energía Eléctrica (*cee*) (los resultados completos de las estimaciones se presentan en el apartado 4.6).

En la especificación de la ecuación de demanda que se maneja en este documento pueden identificarse las elasticidades de precios e ingresos, cuya magnitud y signo tienen implicancias ya definidas previamente en el Capítulo 2.

En Uruguay los precios de los energéticos (supergas y energía eléctrica) son regulados por el Estado, por lo tanto la determinación de los mismos viene dada por decretos de fijación de precios que se calculan en base a las paramétricas del tarifario de cada uno.

En este sentido, no es esperable que actúe la mecánica de ajuste bidireccional de un mercado en competencia perfecta, donde las variaciones de precios determinan variaciones en las cantidades demandadas de los bienes y las variaciones en las cantidades demandadas determinan variaciones en los precios.

En el mercado de Uruguay el Estado es el productor y oferente de los energéticos y fija los precios de comercialización. En un mercado monopolístico (un único oferente), en general el monopolista fija los precios de forma que logra maximizar sus beneficios. En este caso, si bien el Estado es el único oferente no fija los precios de forma de maximizar sus beneficios con una función objetivo de maximizar su recaudación. Al ser bienes necesarios de consumo e inclusive en el caso del supergas su precio es subsidiado, son otros los criterios de fijación de precios.

Por lo tanto, el resultado que podría esperarse de la prueba de causalidad sería que confirme que las cantidades de los energéticos son causadas por los precios, pero no viceversa. En el mismo sentido, sería esperable que los precios fueran débilmente exógenos en la relación de cointegración.

En cuanto al *isr*, es una variable que se utiliza para aproximar al ingreso y cuyo coeficiente en la ecuación de demanda muestra la elasticidad ingreso. Sería esperable, desde el punto de vista de la teoría económica que las cantidades demandadas de cada uno de los energéticos esten causadas en sentido de Granger por el *isr* (implicando que las variaciones en el salario determine variaciones en el consumo), pero que no se dé la relación inversa (que las variaciones en el consumo generen variaciones en los salarios).

El conjunto de pruebas de causalidad y exogeneidad va a determinar el tipo de conclusiones que pueden extraerse de las estimaciones. La exogeneidad fuerte es una propiedad que si está presente habilita a realizar predicción, y para realizar simulaciones es necesario que se constate la super exogeneidad. Por lo tanto, es un requisito para poder predecir y/o simular datos poder verificar el cumplimiento de estas dos propiedades.

4.5.1. Prueba de Hipótesis de Causalidad de Granger

Como se planteó en el apartado 2.5.1, la aplicación de un modelo econométrico en la evaluación de políticas requiere que se verifique la relación de causalidad desde el instrumento hacia el objetivo de política, y la ausencia de esta relación desde el objetivo hacia el instrumento. En este sentido se quiere comprobar mediante la prueba de hipótesis explicitada en ese mismo apartado, como se dan las relaciones de causalidad bivariada entre las variables consideradas en este trabajo de investigación.

La prueba de causalidad bivariada implica probar que los rezagos de una variables no son significativos en la ecuación de otra de las variables del modelo. Por lo tanto, la prueba realiza un contraste para verificar si los rezagos de las variables x_t logran contribuir a mejorar la predicibilidad de la variable z_t , permitiendo analizar no solo la causalidad sino que también la dirección de la misma.

La prueba se realiza a partir de la especificación del VAR(3) de las secciones anteriores.

La hipótesis nula está definida como: x_t **no causa en sentido de Granger** a z_t cuando los coeficientes asociados a los rezagos de x_t no son significativos en la ecuación de z_t . Los resultados de las pruebas para cada una de las ecuaciones se presentan en el Cuadro 4.5.1 presentándose en cada fila la ecuación “ z_t ” y en las columnas las variables “ x_t ”.

Mediante estas pruebas de hipótesis se pretende confirmar determinadas relaciones de causalidad que sería lógico que se dieran desde el punto de vista de la teoría económica, sin embargo no necesariamente pueden dar los resultados esperados dado que se está trabajando con series para un determinado período de tiempo acotado que contiene varios eventos atípicos y los resultados podrían cambiar usando otro período.

A partir de los resultados de las pruebas presentadas en el Cuadro 4.5.1 se puede concluir para cada una de las ecuaciones que:

1. En la ecuación de **csg** los resultados de la prueba muestran que se rechaza H_0 para las variables de *isr* y *psg*, lo cual estaría confirmando lo esperado, que tanto *isr* como *psg* causan al consumo de supergas. Sin embargo no se rechaza H_0 para *pee*, implicando que no causa en sentido de Granger a *csg* y por lo tanto los valores pasados del precio de la energía eléctrica no contribuyen a predecir la cantidad demandada de supergas.
2. En la ecuación de **cee** los resultados de la prueba muestran que se rechaza H_0 para la variable *isr*, interpretándose de forma análoga a la ecuación anterior (*isr* causa en sentido de Granger al consumo de energía eléctrica). No se rechaza H_0 para las variables *psg* y *pee*, determinando que la cantidad de energía eléctrica no está causada por los precios. Si bien, no es el resultado esperable puede tener una justificación desde el punto de vista que, el supergás sería un bien sustituto débil de la energía eléctrica y por lo tanto el precio del mismo en los períodos anteriores (corto plazo) no necesariamente tienen que afectar a las cantidades consumidas de energía eléctrica (EE), y por otro lado al ser la EE un bien

4. Resultados

tan necesario los niveles de su propio precio en los períodos anteriores (corto plazo) no determinan la demanda de cee.

3. En la ecuación de **isr** los resultados de la prueba muestran que no se rechaza H_0 para las variables de cantidades de energéticos (las cantidades consumidas no causan en sentido de Granger al salario). Se rechaza H_0 para las variables de precios, implicando que los precios causan al *isr*, relación que puede venir dada por la vinculación que tiene el salario real con el índice de precios, del cual los precios de los energéticos también forman parte.
4. En la ecuación de **psg** los resultados de la prueba muestran que no se rechaza H_0 para ninguna de las variables, por lo tanto ninguna de las variables causan en sentido de Granger al *psg*.
5. En la ecuación de **pee** los resultados de la prueba muestran que no se rechaza H_0 para ninguna de las variables, por lo tanto ninguna de las variables causan en sentido de Granger al *pee*.

El resultado que se ha obtenido en las ecuaciones de precios, según el cual ninguna variable rezagada contribuiría en mejorar la predicibilidad de los precios, es consistente con la forma de fijación de precios que tienen los mismos en Uruguay. Visto la actividad de regulación del Estado, el precio no es determinado por los valores pasados de otras variables, sino por los criterios del Estado.

Cuadro 4.5.1: Prueba de Causalidad de Granger en el VAR(3).

Ecuación	csg	cee	isr	psg	pee
Ec: csg	-	-	8.37	10.48	1.08
	-	-	(0.00)	(0.00)	(0.31)
Ec: cee	-	-	11.87	1.69	1.55
	-	-	(0.00)	(0.19)	(0.20)
Ec: isr	1.35	0.94	-	2.10	6.74
	(0.16)	(0.35)	-	(0.03)	(0.004)
Ec: psg	1.76	0.53	0.85	-	0.64
	(0.19)	(0.56)	(0.43)	-	(0.51)
Ec: pee	0.52	0.42	2.13	0.56	-
	(0.56)	(0.65)	(0.16)	(0.52)	-

Nota: En cada fila se presenta el valor del estadístico de Wald de la prueba de Causalidad de Granger y debajo entre paréntesis el respectivo p-valor asociado.

4.5.2. Prueba de Hipótesis de Exogeneidad Débil

Como se expuso previamente en el apartado 2.4.3, los coeficientes de ajuste α representan la velocidad de ajuste respecto al desvío del largo plazo. Permiten analizar si la dinámica de las series de datos está influenciada por los desequilibrios de largo plazo.

La hipótesis de que una variable ha influenciado el comportamiento de largo plazo de otra variable en el sistema, pero al mismo tiempo no ha sido influenciada por el mismo, es conocido como la hipótesis de exogeneidad débil de largo plazo o que no hay efectos de retroalimentación en niveles, Juselius (2006) [p.193] [29].

La prueba de exogeneidad débil respecto a las elasticidades de las funciones de demanda es equivalente a probar que los coeficientes de ajuste son $\alpha_i = 0$ (este concepto está desarrollado en el apartado 2.5.2).

Cuadro 4.5.2: Prueba de hipótesis sobre restricciones en los α .

	<i>LR.test</i>	p-valor
H0) $\alpha_{CSG}=0$	53.83	0.00
H0) $\alpha_{CEE}=0$	12.68	0.00
H0) $\alpha_{ISR}=0$	15.77	0.00
H0) $\alpha_{psg}=0$	4.06	0.13
H0) $\alpha_{pee}=0$	4.34	0.11

Nota: El p-valor es calculado para la distribución χ^2_v , como se establece en el apartado 2.5.3.

Para el caso de los precios, los resultados de las pruebas de hipótesis muestran que no se rechaza la hipótesis nula de que el coeficiente α de los precios es igual a cero, por lo tanto son débilmente exógenos.

Este resultado es acorde a la hipótesis inicial de este trabajo en que las variaciones de precios no determinan el ajuste al equilibrio. En un mercado regulado como éste donde los precios son fijados por el Estado, sería esperable que variaciones de precios influyan en la cantidad demandada pero no visceversa, por lo tanto que no determinen la velocidad del ajuste al largo plazo.

A partir de la especificación en el Caso 2 con $p = 3$ y precios débilmente exógenos se reestima el modelo obteniendo nuevas estimaciones de las matrices $\beta_{(k \times k)}$ y $\alpha_{(k \times k)}$ mediante restricciones de rango reducido, las cuales se presentan en el Cuadro 4.5.3 ¹³.

Cuadro 4.5.3: Estimación de β y α normalizados. Caso 2, $p = 3$ y precios débilmente exóg.

$$\hat{\beta} = \begin{bmatrix} 1,00 & 0,07 & 0,37 & -0,79 & 0,48 & -0,00 \\ -1,17 & 1,00 & -1,15 & -2,40 & 0,31 & -0,08 \\ 0,76 & -0,81 & 1,00 & -8,41 & -1,33 & 0,11 \\ 0,26 & -0,07 & 0,35 & 1,00 & -1,26 & 0,07 \\ -0,39 & 0,12 & 0,83 & -3,56 & 1,00 & -0,08 \\ 9,98 & -16,25 & 11,95 & 93,38 & -1,71 & 1,00 \end{bmatrix} \quad \hat{\alpha} = \begin{bmatrix} -1,08 & -1,06 & -0,11 & 0,00 & 0,00 & 0,00 \\ 0,06 & -0,47 & 0,13 & 0,00 & 0,00 & 0,00 \\ -0,04 & 0,06 & 0,04 & 0,00 & 0,00 & 0,00 \\ 0,00 & 0,00 & 0,00 & 0,00 & 0,00 & 0,00 \\ 0,00 & 0,00 & 0,00 & 0,00 & 0,00 & 0,00 \end{bmatrix}$$

Dado que hay $r = 2$ relaciones de cointegración, para la estimación del resto de los parámetros del VECM se van a restringir las matrices $\beta_{(k \times k)}$ y $\alpha_{(k \times k)}$, seleccionando las primeras r co-

¹³Las salidas con los resultados completos de la estimación de β, α sin normalizar y normalizados, valores propios, errores estándar, etc, para el modelo con restricciones se presentan en el apartado B.2.3. La programación utilizada para los cálculos de los mismos está en el apartado D.1.11.

4. Resultados

lumnas de las matrices y normalizandolas de forma adecuada, según se presentó en el apartado 2.4.4, obteniéndose:

Cuadro 4.5.4: Estimación de β y α normalizados para el Caso 2 con $p = 3$ y $r = 2$.

$$\hat{\beta} = \begin{bmatrix} 1,00 & 0,00 \\ 0,00 & 1,00 \\ -0,17 & -0,80 \\ 0,16 & -0,08 \\ -0,23 & 0,14 \\ -8,40 & -15,66 \end{bmatrix} \quad \hat{\alpha} = \begin{bmatrix} -1,16 & 0,21 \\ 0,03 & -0,54 \\ -0,04 & 0,12 \\ 0,00 & 0,00 \\ 0,00 & 0,00 \end{bmatrix} .$$

Dando lugar a las elasticidades precio e ingreso de las demandas de supergás y energía eléctrica, como se presentan a continuación ¹⁴:

$$csg_t = 8,4 + 0,17isr_t - 0,16psg_t + 0,23pee_t . \quad (4.9)$$

Imponer las restricciones en α para reflejar que los precios son débilmente exógenos no modifica sustancialmente los coeficientes estimados de las elasticidades respecto al modelo sin restricciones en los precios, por lo tanto, la interpretación es análoga.

En la demanda de supergas, la elasticidad ingreso muestra que el supergas es un bien normal con magnitud $\beta_{1,3} = 0,17$. La elasticidad precio del supergas tiene signo negativo $\beta_{1,4} = -0,16$ que es acorde a la teoría, y la elasticidad precio cruzada $\beta_{1,5} = 0,23$ con su signo positivo muestra que la energía eléctrica es un bien sustituto al supergas con una elasticidad mayor a la del precio propio.

$$cee_t = 15,66 + 0,80isr_t + 0,08psg_t - 0,14pee_t . \quad (4.10)$$

En el caso de la demanda de energía eléctrica, la elasticidad ingreso al igual que en el caso del supergas muestra que es un bien normal pero con una influencia en la demanda de energía eléctrica mayor que la que tiene en la demanda de supergas $\beta_{2,3} = 0,80$. La elasticidad precio de la energía eléctrica $\beta_{2,5} = -0,14$ con signo negativo también dió acorde a la teoría, y la elasticidad precio cruzada $\beta_{2,4} = 0,08$ muestra que el supergas es un bien sustituto a la energía eléctrica pero poco influyente en la demanda.

En el apartado 4.6 se presentan los resultados completos de la estimación del VECM para la ecuación de supergas y se amplía la interpretación de los coeficientes.

¹⁴La interpretación de las elasticidades se realiza con el signo contrario al que se presenta en la representación vectorial.

4.5.3. Exogeneidad Fuerte

A partir de las pruebas realizadas de causalidad en sentido de Granger y exogeneidad débil se puede concluir si existe o no exogeneidad fuerte, dado que abarca ambos conceptos.

Como se presentó en el apartado 2.5.2 si el vector de interés es el vector de cointegración y se verifica que z_t (el instrumento de política) es débilmente exógeno y hay ausencia de causalidad desde x_t hacia el instrumento z_t , existe exogeneidad en sentido fuerte del instrumento hacia el objetivo y es posible realizar predicciones de x_t condicionado a valores predichos de z_t .

En este contexto, si se interpreta a los precios como instrumentos de política y a las cantidades como el objetivo, se comprobó en los apartados anteriores que los precios son débilmente exógenos y que ambos precios no están causados en sentido de Granger por las cantidades, por lo tanto se puede concluir que existe exogeneidad fuerte de los precios hacia las cantidades lo cual implica que se puede realizar predicción de las cantidades de energéticos condicionado a los valores de los precios.

4.5.4. Super Exogeneidad

La hipótesis de super exogeneidad implica probar la estabilidad de los parámetros β en el período de análisis cuando se producen cambios de política que afectan la distribución de la variable utilizada como instrumento. En el caso que se pruebe la estabilidad de los parámetros puede utilizarse la distribución condicional $P(x_t|z_t, Y_{t-1}, \lambda_1)$, presentada en el apartado 2.5.2, para realizar simulaciones.

Para el análisis de la estabilidad de los parámetros se aplica el Test de Chow como se planteó en el apartado 2.5.3. Para la prueba se analizan 2 estadísticos, *Sample-Split (SS)* y *Break-Point (BP)*, ambos comparan la estimación de la varianza residual de un modelo de coeficiente constante con la estimación de la varianza residual de un modelo que permite un cambio en los parámetros. De esta manera, se comprueba si existen importantes diferencias en las estimaciones antes y después de un punto T_B seleccionado que particiona la muestra.

La prueba de hipótesis que utiliza el estadístico *SS* tiene como hipótesis nula que los coeficientes autorregresivos y términos determinísticos no cambian durante el período de la muestra, mientras que la prueba que utiliza el estadístico *BP* prueba adicionalmente la constancia de la varianza ruido blanco (los detalles de cada una de estas pruebas están planteados en el apartado 2.5.3 del Capítulo 2).

Bajo la hipótesis nula de que los parámetros estimados del modelo son invariantes en el tiempo, ambos estadísticos tienen distribución χ^2 y la hipótesis de parámetros constantes es rechazada para valores altos de los estadísticos.

En el Cuadro 4.5.5 se presentan los resultados de ambos estadísticos para cuatro alternativas de puntos de corte T_B de la muestra a partir de enero de 2004, junto con los respectivos tamaños que tiene cada parte de la muestra luego de la partición. Se seleccionaron dichos años dado que

4. Resultados

tomar como partición años anteriores o posteriores a los seleccionados representaría tamaños de muestra muy pequeños, perdiéndose robustez en las estimaciones.

A partir de los resultados del Test de Chow presentados en el Cuadro 4.5.5, se rechaza H_0 en cada una de las particiones seleccionadas y se comprueba que no hay estabilidad en los parámetros durante el período de análisis. Este es un resultado esperado, dado por la cantidad de eventos atípicos presentes en el período de análisis, destacándose la crisis de 2002.

Por lo tanto, al no haber invarianza paramétrica no se verifica la propiedad de Super Exogeneidad y en consecuencia el modelo no es adecuado para hacer simulación.

Cuadro 4.5.5: Test de Chow

	T_B 01/2004	T_B 01/2005	T_B 01/2006	T_B 01/2007
<i>Sample-Split (SS)</i>	878.93 (0.00)	849.83 (0.00)	886.56 (0.00)	845.00 (0.00)
<i>Break-Point (BP)</i>	955.77 (0.00)	893.55 (0.00)	915.39 (0.00)	878.44 (0.00)
N_1	48	60	72	84
N_2	108	96	84	72

Nota: En cada una de las pruebas se presenta el valor del estadístico y debajo entre paréntesis el respectivo p-valor asociado.

4.6. Interpretación del VECM estimado

A partir de los resultados de las pruebas de hipótesis realizadas en los apartados anteriores se llega a una especificación del VECM para el Caso 2 de Johansen con $p = 3$ rezagos, $r = 2$ relaciones de cointegración y precios débilmente exógenos.

El análisis de cointegración está diseñado para encontrar combinaciones lineales de variables que, consideradas individualmente son no estacionarias, pero cuando existe dicha combinación lineal, el vector de cointegración determina relaciones $I(0)$. Estas relaciones son llamadas “equilibrios de largo plazo”, ya que funcionan como “atractores” hacia las que se produce la convergencia cada vez hay salidas del mismo, Hendry (2000-II) [19]. Los atractores están dados por $\beta'y_t$ y la velocidad a la que converge al equilibrio nuevamente está dada por α .

El modelo estimado tiene la forma:

$$\Delta y_t = \Gamma_1 \Delta y_{t-1} + \Gamma_2 \Delta y_{t-2} + \alpha \beta' y_{t-1} + \Phi I_t + \Psi S_t + \epsilon_t \quad (4.11)$$

donde β son los coeficientes que caracterizan la relación de largo plazo entre las variables en

niveles; α son los coeficientes que describen los cambios que ayudan a restablecer al mercado al equilibrio; los $\gamma_{.,1}$ y $\gamma_{.,2}$ son los coeficientes que describen los cambios de corto plazo como resultado de los cambios en momentos previos en el mercado, no necesariamente tienen efectos permanentes en niveles; ϕ son los coeficiente asociados a las intervenciones incorporadas al modelo para lograr captar los eventos extraordinarios que afectaron al mercado y las variables exógenas; ψ son los coeficientes asociados a las dummies estacionales centradas.

A continuación se presentan los resultados de las pruebas diagnósticas sobre los residuos de las estimaciones realizadas para dos modelos. El *Modelo 1* es la especificación del VECM sin restricciones en los precios como se presentó en el Cuadro 4.4.4, y el *Modelo 2* es la especificación del VECM que incorpora en la estimación la restricción dada por los precios débilmente exógenos como se presentó en el Cuadro 4.5.4.

En el Cuadro 4.6.1 se presentan las pruebas univariadas para cada ecuación y en el Cuadro 4.6.2 las pruebas multivariadas.

Se observa que en la especificación con restricciones en los precios mejora la bondad de ajuste en algunas de las ecuaciones, y los residuos tanto a nivel multivariado como univariado son mejor comportados, no se rechaza la normalidad, homoscedasticidad y ausencia de correlación serial.

En el Cuadro 4.6.3 se presentan las relaciones de largo plazo (β_1, β_2) y los coeficientes de velocidad de ajuste (α_1, α_2) para el *Modelo 1*: sin restricciones en α , y para el *Modelo 2*: con restricciones en α .

Cuadro 4.6.1: Pruebas univariadas sobre los residuos: *Caso 2* de Johansen, $p = 3, r = 2$.

	Modelo 1 Sin restricciones en α					Modelo 2 Con restricciones en α				
	Δcsg	Δcee	Δisr	Δpsg	Δpee	Δcsg	Δcee	Δisr	Δpsg	Δpee
ARCH ($h = 12$)	11.74 (0.46)	10.31 (0.58)	10.69 (0.55)	5.62 (0.93)	11.31 (0.50)	10.85 (0.54)	14.20 (0.28)	8.51 (0.74)	5.61 (0.93)	8.88 (0.71)
Normalidad	4.11 (0.12)	0.71 (0.70)	6.22 (0.045)	2.90 (0.23)	6.32 (0.04)	2.72 (0.25)	0.60 (0.73)	4.80 (0.09)	4.21 (0.12)	6.22 (0.04)
Corr. Serial ($h = 12$)	1.27 (0.24)	2.43 (0.008)	1.43 (0.15)	1.54 (0.11)	0.95 (0.49)	1.60 (0.10)	2.57 (0.005)	1.46 (0.14)	1.59 (0.10)	0.90 (0.54)
Error Estándar	0.080	0.029	0.008	0.023	0.019	0.080	0.029	0.007	0.023	0.019
Adj. R^2	0.84	0.85	0.62	0.44	0.19	0.84	0.86	0.65	0.44	0.19
Valores propios	0.45	0.267	0.132	0.022	0.007	0.436	0.244	0.127	0.00	0.00

Nota: En las pruebas sobre los residuos se presenta el valor del estadístico y debajo entre paréntesis el respectivo p-valor asociado. La especificación de cada uno de los test se presenta en el Anexo Metodológico A.3. En “valores propios” se presentan los 5 mayores valores propios.

4. Resultados

Cuadro 4.6.2: Pruebas multivariadas sobre los residuos: *Caso 2* de Johansen, $p = 3$, $r = 2$.

	Modelo 1 Sin restricciones en α		Modelo 2 Con restricciones en α	
	Pruebas Multivariados de Especificación			
	Estadístico	p-valor	Estadístico	p-valor
Normalidad	18.17	0.05	12.05	0.28
Simetría	3.86	0.56	3.16	0.67
Curtosis	14.30	0.014	8.88	0.11
Corr. Serial ($h = 12$)	1.26	0.24	1.26	0.24
AIC	-37.83	-	-37.77	-
SC	-36.34	-	-36.29	-
H-Q	-37.22	-	-37.17	-
Max.LogLik	2648.61	-	2644.36	-

Nota: La especificación de cada uno de los test se presenta en el Anexo Metodológico [A.3](#).

Cuadro 4.6.3: Relaciones de Cointegración en *Caso 2* de Johansen, $p = 3$, $r = 2$.

	Modelo 1 Sin restricciones en α		Modelo 2 Con restricciones en α		Modelo 1 Sin restricciones en α		Modelo 2 Con restricciones en α	
	Relaciones de Cointegración (β)				Coeficientes de ajuste (α)			
	β_1	β_2	β_1	β_2	α_1	α_2	α_1	α_2
<i>csg</i>	1.00	0.00	1.00	0.00	-1.14	0.25	-1.16	0.21
<i>cee</i>	0.00	1.00	0.00	1.00	0.03	-0.48	0.03	-0.54
<i>isr</i>	-0.18	-0.78	-0.17	-0.80	-0.05	0.12	-0.04	0.12
<i>psg</i>	0.15	-0.08	0.16	-0.08	0.07	-0.007	0.00	0.00
<i>pee</i>	-0.20	0.17	-0.23	0.14	0.02	-0.15	0.00	0.00
<i>cte</i>	-8.37	-15.77	-8.40	-15.66	-	-	-	-

A continuación se presentan los resultados de la ecuación correspondiente al Consumo de Supergas con restricciones en α , interpretándose a las relaciones de largo plazo dentro la misma como la ecuación que representa a la demanda de supergas.

Las salidas completas con los resultados correspondientes a las cinco ecuaciones se presentan en el Anexo de Resultados [B.2.3](#).

Debajo de cada estimación se presenta el error estándar entre paréntesis.

$$\begin{aligned} \Delta csg_t = & \begin{bmatrix} 0,1518 & -0,3360 & -0,5195 & -0,0115 & -0,1315 \\ (0,1260) & (0,3063) & (0,8218) & (0,2962) & (0,3587) \end{bmatrix} \begin{bmatrix} \Delta csg_{t-1} \\ \Delta cee_{t-1} \\ \Delta isr_{t-1} \\ \Delta psg_{t-1} \\ \Delta pee_{t-1} \end{bmatrix} + \\ & \begin{bmatrix} 0,0864 & 0,0979 & -0,1848 & 0,6125 & -0,5896 \\ (0,0905) & (0,2100) & (0,7932) & (0,2785) & (0,3607) \end{bmatrix} \begin{bmatrix} \Delta csg_{t-2} \\ \Delta cee_{t-2} \\ \Delta isr_{t-2} \\ \Delta psg_{t-2} \\ \Delta pee_{t-2} \end{bmatrix} + \\ & \begin{bmatrix} -1,16 & 0,21 \\ (0,146) & (0,339) \end{bmatrix} \begin{bmatrix} 1,00 & 0,00 & -0,17 & 0,16 & -0,23 & -8,40 \\ (0,000) & (0,000) & (0,121) & (0,071) & (0,124) & (0,765) \\ 0,00 & 1,00 & -0,80 & -0,08 & 0,14 & -15,66 \\ (0,000) & (0,000) & (0,069) & (0,041) & (0,071) & (0,436) \end{bmatrix} \begin{bmatrix} csg_{t-1} \\ cee_{t-1} \\ isr_{t-1} \\ psg_{t-1} \\ pee_{t-1} \\ cte \end{bmatrix} + \\ \Phi I_t + \Psi S_t + & \begin{bmatrix} 0,4564 & -0,2665 \\ (0,3201) & (0,3874) \end{bmatrix} \begin{bmatrix} \Delta psg_t \\ \Delta pee_t \end{bmatrix} + \epsilon_{1t} \quad (4.12) \end{aligned}$$

A partir de la estimación de las relaciones de cointegración se obtienen las elasticidades precio e ingreso asociados a la demanda de supergas y la demanda de energía eléctrica ¹⁵.

$$csg_t = 8,4 + 0,17isr_t - 0,16psg_t + 0,23pee_t \quad (4.13)$$

La ecuación 4.13 representa a la demanda de supergas, la elasticidad precio respecto al propio precio del supergas es $\beta_{1,4} = -0,16$ la cual es significativa a más del 5 % ¹⁶ y tiene signo acorde a la teoría económica, determinando que incrementos en el precio del supergas conllevan disminuciones en la cantidad demandada.

La elasticidad precio cruzada es $\beta_{1,5} = 0,23$ significativa casi al 5 % y su signo positivo implica que la energía eléctrica es un bien sustituto al supergas. Por lo tanto, aumentos en el precio de la energía eléctrica determinan mayor consumo de supergas. En magnitud es levemente superior a la elasticidad precio directa del supergas, por lo tanto la demanda de supergas es más elástica respecto a pee que a psg , lo cual evidencia una fuerte sustitución entre energía eléctrica y el supergas.

La elasticidad ingreso es $\beta_{1,3} = 0,17$ significativa apenas al 10 %, el signo positivo y de magnitud entre 0 y 1 implica que el supergas es un bien normal - necesario, por lo tanto la demanda de

¹⁵La interpretación de las elasticidades se realiza con el signo contrario al que se presenta en la ecuación Δcsg_t .

¹⁶Los niveles de significación se calculan en base al estadístico t y se comparan con los valores críticos de la tabla de distribución t -student con $(n - 2)$ grados de libertad.

4. Resultados

supergas crece cuando aumentan los ingresos pero menos que proporcionalmente. En magnitud está más cercano a cero que a uno mostrando la baja elasticidad e implicando que está más próximo a ser un bien independiente (los cambios en el ingreso no afectan el consumo del bien) que un bien superior.

Este resultado es acorde a una de las hipótesis manejadas, que interpreta que tener mayores niveles de ingreso no determinan que se incremente notablemente el consumo en supergas, por ser un bien necesario para el consumo habitual tanto en cocción como en calefacción, principalmente en los hogares de ingresos medios y bajos. En todo caso, en los niveles medio - alto de ingreso podrían llevar a sustituir supergas por energía eléctrica para calefacción.

$$cee_t = 15,66 + 0,80isr_t + 0,08psg_t - 0,14pee_t \quad (4.14)$$

La ecuación 4.14 representa a la demanda de energía eléctrica, la elasticidad precio directa es $\beta_{2,5} = -0,14$ significativa al 5 % con signo negativo acorde a la teoría económica determinando que incrementos en el precio de la energía eléctrica conllevan disminuciones en la cantidad demandada. En magnitud no es grande, lo cual muestra baja elasticidad implicando que la demanda de energía eléctrica varía poco a partir de variaciones de su propio precio.

La elasticidad precio cruzada es $\beta_{2,4} = 0,08$ significativa al 5 % y su signo positivo implica que el supergas es un bien sustituto a la energía eléctrica. Sin embargo, en magnitud es pequeña determinando la muy baja elasticidad y que por lo tanto, aumentos en el precio del supergas apenas tengan influencia en la demanda de energía eléctrica con un grado muy bajo de sustitución.

La elasticidad ingreso es $\beta_{2,3} = 0,80$ significativa al 1 %, el signo positivo y la magnitud entre 0 y 1 implica que el supergas es un bien normal - necesario. En magnitud está mas cercano a uno que a cero lo cual se considera como alta elasticidad, por lo tanto está próximo a ser un bien superior (al aumentar los ingresos genera aumento en la demanda de consumo de energía eléctrica).

Mediante los parámetros β se interpretó como se realizan los ajustes al equilibrio de largo plazo cuando hay apartamientos del mismo, a través de la interpretación de las elasticidades que muestran como reaccionan los consumidores ante los precios e ingresos.

En las Figuras 4.8 y 4.9 se presentan los atractores también conocidos como términos de corrección de error (ect - error correction term) $\beta'y_t$.

En cuanto a la velocidad de ajuste a la senda de equilibrio, se interpreta a través de la magnitud de los parámetros α . La velocidad de ajuste ante apartamientos del equilibrio en la demanda de supergas está dada por el parámetro $\alpha_{1,1} = -1,16$ que es significativo al 5 %, y además muestra el sentido de la corrección de la demanda de supergas respecto a sus propios desequilibrios. Su magnitud al ser mayor a la unidad sugiere que es rápido.

Sin embargo, en el caso del parámetro de ajuste en Δcsg_t respecto a desequilibrios en la demanda de energía eléctrica $\alpha_{2,1} = 0,21$ es no significativo.




Figura 4.8: Término de corrección de error $\beta_1 y_{t-1}$.




Figura 4.9: Término de corrección de error $\beta_2 y_{t-1}$.

El detalle de los coeficientes estimados de las matrices Φ y Ψ pueden verse en el apartado [B.2.3](#) del Anexo de Resultados.

Sin embargo se puede comentar brevemente que las intervenciones con coeficientes ϕ significativas en la ecuación de demanda del supergas son: $dls0102$ (cuyo coeficiente tiene signo negativo y muestra un escalón en la serie marcando el cambio dado a partir de la crisis de 2002), $dao0311$ (coeficiente con signo negativo en la fecha en que se da la menor cantidad de supergas consumido en la serie), $dao0607$ (coeficiente con signo negativo, en 2007 se dieron temperaturas extremadamente bajas con consumo atípico no tan alto en junio y el consumo más

elevado de toda la serie en julio de ese año), dao0706 (consumo que baja en julio frente a valores muy superiores en junio y agosto), y dao0708 con signo negativo¹⁷.

En cuanto a las dummies estacionales, tienen coeficientes ψ significativos y con signo positivo los meses de más bajas temperaturas en el año - de mayo a setiembre - y enero con signo negativo. Esto es acorde con que a menores temperaturas la demanda es más grande y a mayores temperaturas (como en enero) la demanda se reduce.

De esta forma se ve reflejado en las dummies estacionales la importancia que la época del año tiene en la demanda de dicho energético, por lo cual se analizará en la siguiente sección las implicancias de considerar a la variable temperatura en el modelo.

4.7. Escenarios Alternativos y Pruebas en Predicción

A partir de la selección de cantidad de rezagos del VAR y del rango de cointegración en el *Modelo 1* especificado en el apartado anterior, se va a realizar un análisis de sensibilidad del modelo ante variantes en la inclusión de la variable de temperatura mínima.

Se parte de la hipótesis de que el consumo de supergas en los meses fríos del año está determinado principalmente por la temperatura y en menor medida por el precio en sí mismo. Dado que los principales usos del supergas son la cocción y la calefacción, y que el mayor volumen de consumo se da en los meses de invierno al usarse para calefaccionar, se quiere investigar si incluir la variable temperatura mínima puede mejorar el ajuste del modelo.

Para este objetivo se va a hacer la búsqueda del umbral de temperatura para el cual se identifique que el modelo cambia sustancialmente en cuanto a la bondad de ajuste global del modelo y se compara en predicción en un horizonte de 12 meses con el resto de escenarios alternativos.

La búsqueda del umbral se realiza a partir de la especificación del VECM del *Modelo 1* y la variable temperatura que adopta una especificación no lineal alternativa en cada prueba realizada, la misma entra en la especificación como variable exógena a la relación de cointegración.

Los escenarios estimados en función de la especificación de temperatura mínima incorporada son los siguientes ¹⁸:

1. Escenario 1 - sin variable de temperatura.

¹⁷ **dls0102**: variable *level-shift* con valor cero antes de enero de 2002 y 1 en el resto. **dao0311**: variable *additive outlier* con valor 1 en marzo de 2011 y cero en el resto. **dao0607**: variable *additive outlier* con valor 1 en junio de 2007 y cero en el resto. **dao0706**: variable *additive outlier* con valor 1 en julio de 2006 y cero en el resto. **dao0708**: variable *additive outlier* con valor 1 en julio de 2008 y cero en el resto.

¹⁸ Se realizaron las pruebas para los umbrales desde 6 grados a 15 y luego con la diferencia de la temperatura respecto al umbral (20 estimaciones en total), pero se presentan los resultados y conclusiones sólo respecto a los que tienen resultados más interesantes para el análisis y coeficientes estimados significativos en la variable temperatura.

2. Escenario 2 - Logaritmo de la temperatura mínima tomada en diferencias.
3. Escenario 3 - Logaritmo de la temperatura mínima tomada en diferencias estacionales.
4. Escenario 4 - Umbral en 6 grados: variable que tiene el dato de la temperatura mínima sólo cuando la temperatura es ≤ 6 grados o cero en otro caso.
5. Escenario 5 - Umbral en 7 grados: variable que tiene el dato de la temperatura mínima sólo cuando la temperatura es ≤ 7 grados o cero en otro caso.
6. Escenario 6 - Umbral en 8 grados: variable que tiene el dato de la temperatura mínima sólo cuando la temperatura es ≤ 8 grados o cero en otro caso.
7. Escenario 7 - Umbral en 9 grados: variable que tiene el dato de la temperatura mínima sólo cuando la temperatura es ≤ 9 grados o cero en otro caso.
8. Escenario 8 - Diferencia con el Umbral en 6 grados: cantidad de grados que la temperatura mínima esta por debajo de 6 grados o cero en otro caso.
9. Escenario 9 - Diferencia con el Umbral en 7 grados: cantidad de grados que la temperatura mínima esta por debajo de 7 grados o cero en otro caso.
10. Escenario 10 - Diferencia con el Umbral en 8 grados: cantidad de grados que la temperatura mínima esta por debajo de 8 grados o cero en otro caso.
11. Escenario 11 - Diferencia con el Umbral en 9 grados: cantidad de grados que la temperatura mínima esta por debajo de 9 grados o cero en otro caso.

Los cálculos de diferencias al umbral se realizaron con: (temperatura del umbral - temperatura mínima) y cero en otro caso. Por lo tanto, para los meses que la temperatura esta por debajo del umbral me muestra la cantidad de grados que la temperatura mínima esta por debajo del umbral analizado o cero en otro caso.

Se realizaron las estimaciones completas para los umbrales adicionales de 10 - 11 - 12 - 13 - 14 - 15 grados, para los cuales la temperatura mínima resultó ser no significativa en ninguna de las 5 ecuaciones, al igual que se dió en el umbral 9.

Como las variables de consumo tienen cierta estacionalidad dada por la época del año, se incluyeron variables dummies estacionales centradas. Se presume que la inclusión de estas dummies estacionales puedan estar recogiendo el efecto de la temperatura y por lo tanto no resulte significativa en determinadas especificaciones. Se realizaron todas las instancias de análisis para especificaciones que consideraran los umbrales de temperatura sin incluir a las dummies estacionales, teniendo como resultado modelos con menor ajuste y con residuos no normales, por lo tanto no válidos para continuar el análisis y la inferencia y esos resultados no se presentan en la comparación de escenarios.

La comparación de los distintos escenarios se hace por un lado, a través de la comparación de los indicadores de criterios de información (AIC, SC, H-Q) recordando que la mejor especificación es la que tiene menor valor en los mismos y mayor valor de máxima verosimilitud. Y, por otro

4. Resultados

lado, mediante la comparación de los resultados de las pruebas de normalidad, correlación serial y homoscedasticidad, seleccionando la especificación que tenga residuos mejor comportados.

Por último, se comparan los indicadores de errores de predicción calculados para cada una de las especificaciones. La descripción detallada de los cálculos de predicción y los respectivos indicadores sobre los errores de predicción se encuentra en el apartado 2.6 del Capítulo 2.

En los Cuadros 4.7.1 a 4.7.3 se presentan los resultados de cada uno de los escenarios planteados para la comparación, mostrando los valores de las relaciones de cointegración adicionalmente a los 3 aspectos previamente mencionados (pruebas diagnósticas de los residuos, criterios de información, indicadores de errores de predicción).

En el Cuadro 4.7.1 se presentan los escenarios 1 a 4. Al observar los resultados de las pruebas multivariadas se concluye que en los escenarios 1 y 2 no se rechaza la normalidad de los residuos al 5 % de significación y no se rechaza que no existe correlación serial, sin embargo en los escenarios 3 y 4 se rechaza la normalidad al 5 %.

En cuanto a la comparación de los indicadores de errores de predicción, el mejor escenario de los 4 sería el que incorpora a la variable de temperatura mínima en primeras diferencias basandose en el RMSE, o el escenario sin temperatura si se toma en cuenta el MAPE. Los valores de las relaciones de cointegración no cambian sustancialmente de un escenario al otro.

Al observar los resultados de las pruebas multivariadas del Cuadro 4.7.2, donde se presentan los escenarios 5 a 8, se concluye que sólo en el escenario 7 no se rechaza la normalidad de los residuos al 5 % de significación. Sin embargo en ese escenario la variable de umbral de temperatura en 9 grados resultó ser no significativa en todas las ecuaciones. Los valores de las relaciones de cointegración de los escenarios 5 y 8 se distancian un poco más de las estimaciones del escenario de referencia (sin temperatura).

Por último, en el Cuadro 4.7.3 se presentan los escenarios 9 a 11. Sólo en el escenario 11 no se rechaza la normalidad de los residuos al 5 % de significación y en todos los escenarios se cumple el supuesto de que no hay correlación serial en los residuos. Sin embargo, respecto a los indicadores sobre la precisión de la predicción no muestran mejoras sustanciales respecto a los escenarios anteriores.

En función del análisis realizado, los indicadores muestran que no hay mejoras sustanciales por la incorporación de la variable temperatura mínima en ninguna de las opciones manejadas en los escenarios seleccionados.

4.7. Escenarios Alternativos y Pruebas en Predicción

Cuadro 4.7.1: Análisis comparado de los escenarios para Caso 2 de Johansen, $p = 3, r = 2$.

	Escenario 1 Sin tmin		Escenario 2 $\Delta tmin$		Escenario 3 $\Delta_{12}tmin$		Escenario 4 Ut06	
	Relaciones de Cointegración							
	β_1	β_2	β_1	β_2	β_1	β_2	β_1	β_2
<i>csg</i>	1.00	0.00	1.00	0.00	1.00	0.00	1.00	0.00
<i>cee</i>	0.00	1.00	0.00	1.00	0.00	1.00	0.00	1.00
<i>isr</i>	-0.18	-0.78	-0.18	-0.79	-0.14	-0.78	-0.18	-0.78
<i>psg</i>	0.15	-0.08	0.14	-0.08	0.17	-0.08	0.15	-0.08
<i>pee</i>	-0.20	0.17	-0.24	0.15	-0.21	0.17	-0.19	0.17
<i>cte</i>	-8.37	-15.77	-8.29	-15.72	-8.65	-15.80	-8.34	-15.76
	Pruebas Multivariadas de Especificación							
	Est.	p-valor	Est.	p-valor	Est.	p-valor	Est.	p-valor
Normalidad	18.17	0.052	18.00	0.055	19.57	0.033	19.99	0.029
Simetría	3.86	0.568	4.03	0.544	4.50	0.479	3.66	0.598
Curtosis	14.30	0.014	13.96	0.016	15.06	0.010	16.33	0.006
Corr.Serial (<i>h</i> = 12)	1.26	0.247	0.95	0.498	1.08	0.382	1.12	0.345
AIC	-37.83	-	-37.98	-	-38.01	-	-37.99	-
SC	-36.34	-	-36.49	-	-36.53	-	-36.50	-
H-Q	-37.22	-	-37.37	-	-37.41	-	-37.38	-
MaxLogLik	2648.61	-	2660.20	-	2663.01	-	2660.93	-
	Indicadores de Errores de Predicción para las ecuaciones de <i>csg</i> y <i>cee</i>							
	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>
ME	-0.022	-0.001	-0.019	-0.0009	-0.034	-0.001	-0.039	-0.012
MSE	0.006	0.001	0.005	0.001	0.007	0.002	0.006	0.001
RMSE	0.078	0.036	0.073	0.037	0.082	0.038	0.076	0.038
MAE	0.056	0.029	0.060	0.030	0.063	0.029	0.058	0.029
MPE	-0.260	-0.007	-0.229	-0.003	-0.409	-0.006	-0.452	-0.065
MAPE	0.634	0.147	0.678	0.155	0.710	0.151	0.655	0.149

4. Resultados

Cuadro 4.7.2: Análisis comparado de los escenarios para Caso 2 de Johansen, $p = 3, r = 2$.

	Escenario 5 Ut07		Escenario 6 Ut08		Escenario 7 Ut09		Escenario 8 dif-Ut06	
	Relaciones de Cointegración							
	β_1	β_2	β_1	β_2	β_1	β_2	β_1	β_2
<i>csg</i>	1.00	0.00	1.00	0.00	1.00	0.00	1.00	0.00
<i>cee</i>	0.00	1.00	0.00	1.00	0.00	1.00	0.00	1.00
<i>isr</i>	-0.14	-0.77	-0.18	-0.78	-0.19	-0.78	-0.12	-0.78
<i>psg</i>	0.15	-0.08	0.15	-0.08	0.14	-0.08	0.18	-0.08
<i>pee</i>	-0.15	0.19	-0.18	0.18	-0.20	0.17	-0.20	0.16
<i>cte</i>	-8.59	-15.84	-8.38	-15.78	-8.29	-15.76	-8.73	-15.76
	Pruebas Multivariadas de Especificación							
	Est.	p-valor	Est.	p-valor	Est.	p-valor	Est.	p-valor
Normalidad	26.21	0.003	22.94	0.01	16.12	0.09	25.09	0.005
Simetría	5.74	0.33	5.41	0.36	3.17	0.67	4.18	0.52
Curtosis	20.47	0.001	17.52	0.003	12.94	0.02	20.90	0.00
Corr.Serial (<i>h</i> = 12)	1.08	0.37	1.51	0.12	1.42	0.16	1.06	0.39
AIC	-38.02	-	-37.98	-	-37.88	-	-37.97	-
SC	-36.54	-	-36.50	-	-36.39	-	-36.48	-
H-Q	-37.42	-	-37.38	-	-37.27	-	-37.36	-
MaxLogLik	2663.49	-	2660.40	-	2652.34	-	2659.33	-
	Indicadores de Errores de Predicción para las ecuaciones de <i>csg</i> y <i>cee</i>							
	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>
ME	-0.026	-0.002	-0.022	-0.002	-0.025	0.0002	-0.025	-0.006
MSE	0.005	0.001	0.006	0.001	0.006	0.0014	0.005	0.001
RMSE	0.072	0.035	0.076	0.036	0.077	0.037	0.072	0.035
MAE	0.055	0.029	0.056	0.028	0.056	0.030	0.055	0.027
MPE	-0.305	-0.009	-0.266	-0.011	-0.304	0.0005	-0.290	-0.034
MAPE	0.623	0.150	0.634	0.146	0.628	0.155	0.616	0.138

4.7. Escenarios Alternativos y Pruebas en Predicción

Cuadro 4.7.3: Análisis comparado de los escenarios para Caso 2 de Johansen, $p = 3$, $r = 2$.

	Escenario 9 dif-Ut07		Escenario 10 dif-Ut08		Escenario 11 dif-Ut09	
	Relaciones de Cointegración					
	β_1	β_2	β_1	β_2	β_1	β_2
<i>csg</i>	1.00	0.00	1.00	0.00	1.00	0.00
<i>cee</i>	0.00	1.00	0.00	1.00	0.00	1.00
<i>isr</i>	-0.10	-0.77	-0.08	-0.76	-0.07	-0.76
<i>psg</i>	0.18	-0.07	0.18	-0.07	0.19	-0.07
<i>pee</i>	-0.19	0.17	-0.16	0.18	-0.11	0.20
<i>cte</i>	-8.84	-15.84	-8.97	-15.90	-9.16	-15.96
	Pruebas Multivariadas de Especificación					
	Est.	p-valor	Est.	p-valor	Est.	p-valor
Normalidad	24.32	0.006	20.65	0.02	16.98	0.07
Simetría	4.15	0.53	4.49	0.48	4.94	0.42
Curtosis	20.17	0.001	16.16	0.006	12.04	0.03
Corr.Serial (<i>h</i> = 12)	1.09	0.36	1.14	0.33	0.92	0.53
AIC	-38.04	-	-38.09	-	-38.15	-
SC	-36.55	-	-36.61	-	-36.67	-
H-Q	-37.43	-	-37.49	-	-37.55	-
MaxLogLik	2664.43	-	2669.11	-	2673.57	-
	Indicadores de Errores de Predicción para las ecuaciones de <i>csg</i> y <i>cee</i>					
	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>	<i>csg</i>	<i>cee</i>
ME	-0.032	-0.009	-0.033	-0.007	-0.037	-0.004
MSE	0.005	0.001	0.006	0.001	0.006	0.001
RMSE	0.075	0.035	0.078	0.035	0.079	0.035
MAE	0.052	0.026	0.055	0.027	0.057	0.027
MPE	-0.361	-0.046	-0.377	-0.036	-0.415	-0.022
MAPE	0.585	0.137	0.613	0.140	0.647	0.140

En las Figuras 4.10 y 4.11 se presentan las predicciones de *csg* y *cee* en los escenarios 1 y 2 con sus respectivos intervalos de confianza en un horizonte de predicción de 12 meses.

Si bien en la inspección gráfica de las predicciones, los intervalos de confianza parecen ser relativamente acotados, para tener indicadores más exactos de la capacidad predictiva de los modelos se calculan las predicciones puntuales y errores relativos en cada mes para el año 2013 en su escala de datos original: miles de kg de supergas y en millones de MW para la energía

4. Resultados

eléctrica.




Figura 4.10: Predicciones en Escenario 1. log(CSG) (fig. izq.), log(CEE)(fig. der.).




Figura 4.11: Predicciones en Escenario 2. log(CSG) (fig. izq.), log(CEE)(fig. der.).

Las predicciones puntuales para los Escenarios 1 y 2 se presentan en el Cuadro 4.7.4 para el caso de la demanda de supergas y en el Cuadro 4.7.5 para la demanda de energía eléctrica.

En base a las predicciones puntuales se concluye que los modelos de ambos escenarios tienen un error de predicción menor al 1 % si se considera a los datos en su acumulación anual, pero al observar las predicciones puntuales mes a mes los modelos no logran predecir con precisión la demanda de ninguno de los dos energéticos.

Cabe resaltar que los meses con mayores errores relativos en la predicción son los meses del año donde se dan grandes saltos en el consumo (ya sea a la baja o al alza), lo cual claramente está vinculado a factores asociados con los consumos estacionales. Sin embargo, la variable temperatura en la variedad de formas en que fue incorporada al análisis, no logra captar esta particularidad de las series para obtener mejores predicciones en esos meses del año.

4.7. Escenarios Alternativos y Pruebas en Predicción

Cuadro 4.7.4: Predicciones para la Demanda de Supergas en 2013.

	csg 2013	Predicción en Escenario 1			Predicción en Escenario 2		
$t + h$	csg_{2013}	csg_{t+h}	Err.Rel.	int.conf.95 %	csg_{t+h}	Err.Rel.	int.conf.95 %
Enero	5581,89	5749,56	-3,00 %	5004,84 - 6605,09	5811,77	-4,12 %	5091,65 - 6633,75
Febrero	5211,31	6116,83	-17,38 %	5321,96 - 7030,42	6057,66	-16,24 %	5297,35 - 6927,10
Marzo	6540,20	6617,94	-1,19 %	5741,85 - 7627,70	6887,24	-5,31 %	6009,46 - 7893,22
Abril	7161,97	7152,77	0,13 %	6203,89 - 8246,80	7025,01	1,91 %	6127,82 - 8053,57
Mayo	9550,73	9166,66	4,02 %	7945,03 - 10576,11	9232,17	3,34 %	8049,10 - 10589,13
Junio	10939,59	11444,85	-4,62 %	9915,48 - 13210,10	11957,42	-9,30 %	10420,15 - 13721,46
Julio	13731,34	13587,91	1,04 %	11766,51 - 15691,24	12856,80	6,37 %	11198,12 - 14761,18
Agosto	11955,17	10541,50	11,82 %	9123,45 - 12179,97	11210,59	6,23 %	9758,68 - 12878,52
Setiembre	8260,20	8465,87	-2,49 %	7323,06 - 9787,03	8002,75	3,12 %	6962,12 - 9198,92
Octubre	7019,90	6814,97	2,92 %	5891,79 - 7882,80	6789,96	3,28 %	5903,41 - 7809,64
Noviembre	6058,88	6348,15	-4,77 %	5485,05 - 7347,06	6156,69	-1,61 %	5349,41 - 7085,78
Diciembre	5807,15	6741,35	-16,09 %	5821,48 - 7806,56	6610,51	-13,83 %	5740,07 - 7612,93
Acum.Anual	97818,33	98748,35	-0,95 %	85544,37 - 113990,89	98598,56	-0,80 %	85907,33 - 113165,20

Nota: Valores expresados en miles de kg.

Cuadro 4.7.5: Predicciones para la Demanda de Energía Eléctrica en 2013.

	cee 2013	Predicción en Escenario 1			Predicción en Escenario 2		
$t + h$	cee_{2013}	cee_{t+h}	Err.Rel.	int.conf.95 %	cee_{t+h}	Err.Rel.	int.conf.95 %
Enero	290,73	287,54	1,09 %	273,42 - 302,40	287,54	1,10 %	273,45 - 302,35
Febrero	287,37	287,54	-0,06 %	273,42 - 302,40	287,54	-0,06 %	273,45 - 302,35
Marzo	253,20	269,43	-6,41 %	254,25 - 285,51	269,63	-6,49 %	254,53 - 285,63
Abril	251,43	270,28	-7,50 %	254,57 - 286,96	269,82	-7,32 %	254,24 - 286,36
Mayo	272,55	264,83	2,83 %	248,17 - 282,61	265,75	2,50 %	249,23 - 283,37
Junio	282,70	272,03	3,77 %	254,23 - 291,08	270,81	4,21 %	253,31 - 289,52
Julio	318,01	291,44	8,36 %	271,86 - 312,43	291,01	8,49 %	271,70 - 311,68
Agosto	339,57	320,95	5,49 %	298,67 - 344,89	322,03	5,17 %	300,02 - 345,66
Setiembre	314,40	325,65	-3,58 %	302,38 - 350,71	322,20	-2,48 %	299,58 - 346,54
Octubre	282,04	304,83	-8,08 %	282,52 - 328,90	305,96	-8,48 %	283,97 - 329,65
Noviembre	264,54	279,94	-5,82 %	258,95 - 302,63	277,39	-4,86 %	256,99 - 299,40
Diciembre	260,12	270,30	-3,92 %	249,57 - 292,76	268,88	-3,37 %	248,69 - 290,71
Acum.Anual	3416,66	3444,77	-0,82 %	3222,01 - 3683,28	3438,57	-0,64 %	3219,17 - 3673,23

Nota: Valores expresados en millones de MWH.

Capítulo 5

Conclusiones

A lo largo de este trabajo de investigación se fueron planteando una serie de hipótesis sobre el proceso generador del dato y cómo debería verse reflejado en su asociación con la teoría económica, las cuales se fueron confirmando mayoritariamente a través de las pruebas de hipótesis realizadas.

Adicionalmente a la contrastación de las hipótesis de trabajo y lograr una especificación que logre reflejar adecuadamente al proceso generador del dato, estaban presentes los objetivos de predicción de la cantidad de demanda de supergas y la simulación de la misma ante variaciones en los precios.

Las hipótesis principales manejadas en este trabajo de investigación fueron:

1. La demanda de supergas, al formar parte de un mercado de diversos energéticos que se utilizan para fines comunes (cocción y calefacción), no puede estimarse de forma aislada sin considerar su interacción con por lo menos, el energético que más influencia tiene en el mercado (Energía Eléctrica). A su vez, el mercado de estos dos energéticos forma parte de un mercado que no funciona en competencia perfecta, dado que los precios y la producción de los mismos está regulada por el Estado.
2. El comportamiento de largo y corto plazo de las series de cantidades, precios y salario consideradas en el modelo no deben considerarse como variables exógenas. La hipótesis fue que las series de datos consideradas, al formar parte de un mercado tienen un comportamiento asociado entre ellas que las lleva a una senda de equilibrio en el largo plazo, por lo tanto es necesario contemplar los efectos de retroalimentación entre ellas.
3. Influencia de la temperatura en la demanda de supergas. Dado que el consumo de supergas se incrementa notablemente en los meses de invierno, asociado al mayor consumo para calefaccionar, se quiere comprobar si la consideración de esta variable logra mejorar sustancialmente el ajuste del modelo y la predicción del mismo.

Para poder comprobar estas hipótesis se partió de un modelo multivariado dinámico multiecuacional a partir de Vectores Autorregresivos, que no solo considera a todas las variables incluidas

simétricamente, sino que también la dinámica conjunta de las demandas de ambos energéticos, y la posible retroalimentación que se pueda dar a partir de las variaciones en cada uno de ellos. Éstos modelos econométricos propuestos, gracias a su flexibilidad (bidireccionalidad y retroalimentación) permitieron analizar y contrastar las hipótesis planteadas.

A partir de los análisis y contrastes de hipótesis realizados con los datos se pueden extraer una serie de conclusiones principales.

1. La especificación mediante modelos multivariados dinámicos multiecuacionales es adecuada para representar al proceso generador del dato analizado.

Habitualmente en la estimación de ecuaciones de demanda se utilizan modelos multivariados dinámicos uniecuacionales, que son más sencillos de aplicar pero tienen restricciones, dado que no contemplan adecuadamente la retroalimentación que puede haber entre las variables e imponen el sentido de la causalidad (asignando apriori cuales son endógenas y exógenas dentro del modelo).

En el apartado 4.6 del Capítulo de Resultados se presentó el modelo a partir de una especificación multiecuacional y en el apartado B.1 del Anexo de Resultados se realizaron los cálculos para una especificación uniecuacional para poder comparar y ver las diferencias en estimación entre ambos.

A grandes razgos, la diferencia principal está dada en que la especificación uniecuacional, al no admitir la bidireccionalidad entre variables pierde parte de la capacidad de análisis en un mercado de demanda donde interaccionan fuerzas de oferta y demanda.

A su vez, determinadas variables pueden presentar correlación con los rezagos de las otras variables contenidas en la demanda y por lo tanto no pueden ser incorporadas al modelo, perdiendo la capacidad de interpretación de esos coeficientes. Sin embargo, esta dificultad y ese tipo de interpretación sí se puede hacer a partir de la especificación multiecuacional.

Como se observa en el Cuadro 5.0.1 de comparación de elasticidades estimadas con cada una de las especificaciones, las elasticidades cambian al usar una u otra, siendo más rico el análisis que se desprende del modelo multiecuacional (ver interpretaciones de las estimaciones realizadas y de las elasticidades en los apartados correspondientes, VECM en 4.6 y ECM en B.1).

Por lo tanto, se comprueba que la modelización que mejor se adecúa al proceso generador del dato es la seleccionada, dado que permite considerar la retroalimentación y bidireccionalidad entre las variables incorporadas al modelo.

Cuadro 5.0.1: Comparación de elasticidades ECM vs VECM.

Especificación Uniecuacional: ECM					
	isr_t	psg_t	pee_t	cte	α
csg_t	-	-0.29	-0.17	10.69	-0.96
cee_t	0.53	0.05	-0.17	14.16	-0.84

Especificación Multiecuacional: VECM					
	isr_t	psg_t	pee_t	cte	α
csg_t	0.17	-0.16	0.23	8.4	-1.16
cee_t	0.80	0.08	-0.14	15.66	-0.54

Adicionalmente, se confirma mediante la comparación con las elasticidades estimadas por Cordano (2005) [7] y Rodríguez (2006) [42] (ver Cuadro 5.0.2) que la elasticidad precio e ingreso tienen magnitudes similares a las que obtuvieron en sus estimaciones (las estimaciones llevadas a cabo por ambos es a través de modelos multivariados dinámicos uniecuacionales).

Cuadro 5.0.2: Elasticidades precios e ingreso del supergas.

País		$\epsilon_{qsg,psg}$	$\epsilon_{qsg,y}$
Cordano (2005)	Perú	-0.247	0.498
Rodríguez (2006)	Rep. Dominicana	-0.29	0.42

Fuente: Cordano (2005) y Rodríguez (2006).

2. Se confirma el comportamiento asociado de las variables consideradas, encontrándose 2 relaciones de cointegración, y se confirma la presencia de condiciones acordes a un mercado no en competencia perfecta, dado por la regulación del Estado.

Adicionalmente, se confirma la exogeneidad fuerte, habilitando a la predicción de las cantidades demandadas, pero al constatar que no hay invarianza paramétrica no se puede realizar simulaciones.

Las pruebas de hipótesis de raíz unitaria dieron de resultado que las variables consideradas individualmente son no estacionarias, y a partir de las pruebas de cointegración se confirmó que al ser consideradas en forma conjunta muestran una interacción entre ellas que determina que en el largo plazo tengan una convergencia conjunta a una senda de equilibrio.

Las pruebas de cointegración se realizaron mediante el Test de Johansen donde se determinó que existen dos relaciones de cointegración. Dichas relaciones de cointegración pueden asociarse a las ecuaciones de demanda, la primera a la demanda de supergas, y la segunda a la demanda de energía eléctrica. A partir de las cuales se habilita a la interpretación en sentido económico de las elasticidades precio e ingreso.

A su vez, a través de las pruebas de exogeneidad y causalidad se constató que el proceso generador del dato se comporta como establece la teoría económica, dando como resultado que los

precios son débilmente exógenos y no hay Causalidad en Sentido de Granger desde las cantidades hacia los precios. Por lo cual, se confirmó la hipótesis de que el mercado se comporta como un mercado de no competencia perfecta por tener precios regulados.

Este resultado es fundamental, dado que a su vez confirma que existe exogeneidad fuerte de los precios hacia las cantidades lo cual implica que se puede hacer predicción de las cantidades de energéticos condicionando a los valores de los precios.

Este resultado habilita a cumplir con uno de los objetivos de este trabajo que es realizar predicciones de la demanda de supergas, y adicionalmente al haber estimado también la demanda de energía eléctrica y cumplirse la exogeneidad fuerte, también habilita a la predicción de la demanda de este energético.

Para cumplir con el objetivo de simulación de las cantidades demandadas, a partir de variaciones en los precios de ambos energéticos, es necesario que se cumpla la condición de super exogeneidad.

Dado que se manejaba la posibilidad de que no se diera estabilidad en los parámetros estimados en el período de análisis, por la presencia de los efectos asociados a la crisis económica que se dió en el año 2002, así como otros factores y shocks económicos durante el período, se realizaron las pruebas de hipótesis de invarianza paramétrica.

Las pruebas confirmaron que no hay estabilidad en los parámetros estimados para el período considerado y por lo tanto no se habilita a hacer pruebas de simulación con los datos.

3. La incorporación al modelo de la variable temperatura mínima media mensual de la estación Carrasco como variable exógena no aporta mejoras sustanciales al ajuste del modelo. Estudios adicionales deben realizarse para especificar de manera alternativa la variable climática en presencia/ausencia de las variables ficticias estacionales.

Se ha analizado de manera pormenorizada la hipótesis de que la variable climatológica temperatura mínima mensual pudiera ser incorporada en la especificación del modelo predictivo.

En base a los estudios realizados, considerando 10 escenarios estimados que difieren por la manera de incorporar a la variable temperatura mínima como variable exógena a la relación de cointegración, se ha constatado que dicha variable, en presencia de las variables ficticias estacionales, no resulta ser sustancial para mejorar el ajuste del modelo y su capacidad predictiva.

Por otra parte, las variables ficticias estacionales logran captar adecuadamente la variabilidad climática, en el sentido de que un modelo que incorpora a la variable temperatura mínima, en ausencia de las ficticias, da resultados de una calidad de ajuste inferior e intervalos de predicción mucho más amplios.

A partir de las predicciones mensuales realizadas se detecta que, el modelo es bueno para predecir las cantidades demandas de supergas y energía eléctrica anual con menos de 1 % de error relativo. Sin embargo, al observar las predicciones mensuales hay determinados meses del año

5. Conclusiones

(donde se dan las variaciones más fuertes en el consumo tanto al alza como a la baja) que son predichos con errores relativos superiores al 10 %.

Se interpreta, a partir de los resultados de las predicciones mensuales, que la consideración de la variable temperatura en la variedad de alternativas que se hizo no logra captar las variaciones generadas en la demanda por los factores estacionales.

Las estimaciones y pruebas en predicción se realizaron para los escenarios seleccionados en base a la temperatura mínima mensual, sin embargo no se realizaron las estimaciones equivalentes para las alternativas de temperatura media y/o máxima mensual.

Es un desafío pendiente considerar estas alternativas adicionales de la inclusión de la variable temperatura, las cuales tal vez permitan lograr mejores predicciones de las cantidades demandadas.

4. *Análisis comparado de software.*

Si bien el análisis comparado de software y la programación no estaba dentro de los objetivos iniciales de este trabajo de investigación, fue una instancia relevante del proceso a la cual se llegó a partir de las dificultades que se fueron presentando al momento de realizar los cálculos.

Las diferencias en los resultados presentados en los distintos software utilizados hicieron necesario realizar la programación específica para este trabajo, de esta forma contribuyeron a una mejor comprensión del método de estimación y encontrar soluciones a las debilidades detectadas en los software manejados.

Apéndice A

Anexo Metodológico

En el primer apartado se desarrollaran conceptos y definiciones sobre series de tiempo en términos generales, marcando la diferencia entre el análisis que se da a las series univariadas versus el análisis multivariado y el análisis dinámico versus el estático.

En los siguientes apartados se irán explicitando los distintos test estadísticos que se aplicaran en el análisis de las series.

A.1. Análisis de Series de Tiempo

El análisis de una variable puede hacerse desde un punto de vista estático (corte transversal), cuando se estudia una situación en un momento dado del tiempo, por ejemplo la relación entre dos variables en el momento t específicamente.

Cuando la acumulación de datos sobre una variable lo permite, el análisis puede hacerse desde un punto de vista dinámico (cuando se estudia la trayectoria de la/las variables a través del tiempo) lo cual puede hacerse a través del análisis de series de tiempo.

Se entiende habitualmente por *serie de tiempo* a la observación de una única variable $x_{s,t}$ a través del tiempo con $s = 1, \dots, S$ y $t = 1, \dots, T$, siendo S las realizaciones de la variable x a través de los T períodos de tiempo. Cuando $S > 1$ puede ser el caso en que los datos observados de la variable $x_{s,t}$ constituyen un panel que estudia el proceso x_t en el tiempo para un número S de replicaciones en cada t .

En el presente trabajo se va analizar el caso $S = 1$, debido a que sólo hay una realización del proceso en cada período t , no hay suficiente información para hacer inferencia estadística acerca de la forma funcional subyacente de la distribución de cada x_t , $t \in T$.¹

Un supuesto típico en los modelos de series de tiempo es que cada x_t tiene la misma distribución

¹Un desarrollo más profundo de estos conceptos pueden verse en el Capítulo 3 de Juselius (2006).

y que la forma funcional es aproximadamente normal.

A.1.1. Modelos Univariados

El análisis puede darse desde un punto de vista *univariado* cuando se mira la evolución de una única variable en el tiempo, o *multivariado* cuando se analiza además la interacción de varias variables a lo largo del tiempo).

Dentro de los procesos univariados dinámicos se puede destacar a los procesos autorregresivos y a los de medias móviles.

Procesos Autorregresivos y de Medias Móviles

En un proceso autorregresivo de orden p $AR(p)$ la variable a explicar depende de las realizaciones pasadas de sí misma, se puede expresar como:

$$x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \epsilon_t \quad (\text{A.1})$$

siendo ϵ_t un proceso ruido blanco.

Si el componente del residuo no es ruido blanco, sino que también tiene componentes autorregresivos, se define como un proceso de medias móviles con q rezagos $MA(q)$, siendo en este caso que la variable a explicar depende no sólo de un shock contemporáneo sino que también de shocks en períodos anteriores, de forma que:

$$x_t = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (\text{A.2})$$

Un proceso que contiene no sólo el componente autorregresivo en la variable, sino que también en el residuo es un proceso $ARMA(p, q)$:

$$x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (\text{A.3})$$

Procesos Estacionarios en Diferencia vs Estacionarios en Tendencia

Como se define en Banerjee et al. (1993) [6], un proceso estocástico es una secuencia ordenada de variables aleatorias $\{x(s, t), s \in S, t \in T\}$, de forma que para cada $t \in T$, $x(., t)$ es una variable aleatoria en el espacio muestral S y para cada $s \in S$, $x(s, .)$ es una realización del proceso estocástico en el índice del conjunto T .

Una realización puntual del proceso puede ser representada como $\{x(t), t \in T\}$, en lo sucesivo se utilizará la notación x_t para un valor dado en el momento t y se restringirá el análisis a procesos estocásticos discretos.

Si $\{x(t), t \in T\}$ es un proceso estocástico de forma que $E(|x(t)|) < \infty$ para todo $t \in T$, y $E(x(t)|\zeta_{t-1}) = x(t-1)$ para todo $t \in T$ donde $E(\cdot)$ es el operador esperanza y ζ_{t-1} representa un set particular de información de datos realizados en $t-1$, un proceso estocástico en diferencia puede definirse como $\{z(t) = x(t) - x(t-1), t \in T\}$, de forma que $E(|x(t)|) < \infty \quad \forall t \in T$ y $E(z(t)|\zeta_{t-1}) = 0 \quad \forall t \in T$.

Se puede definir de esta forma a un proceso estocástico como **estacionario estricto** sí, para cada subconjunto $(t_1, t_2, \dots, t_n)$ de T y cada número real h tal que $t_i + h \in T, i = 1, 2, \dots, n$ se tiene:

$$F(x(t_1), x(t_2), \dots, x(t_n)) = F(x(t_1 + h), x(t_2 + h), \dots, x(t_n + h))$$

donde $F(\cdot)$ es una función de distribución conjunta de los n valores. En este sentido, estacionario estricto implica que todos los momentos existentes del proceso son constantes respecto al tiempo.

Por otro lado, un proceso se puede considerar **estacionario en sentido débil**² si tiene momentos de primer y segundo orden finitos y que no varían en función del tiempo.

Se puede expresar formalmente que un proceso estocástico es estacionario en covarianza sí:

$$\begin{aligned} E[x(t_i)] &= E[x(t_i + h)] = \mu < \infty, \\ E[(x(t_i))^2] &= E[(x(t_i + h))^2] = \mu_2 < \infty, \\ E[x(t_i)x(t_j)] &= E[x(t_i + h)x(t_j + h)] = \mu_{ij} < \infty, \end{aligned}$$

donde μ, μ_2, μ_{ij} son constantes para todo $t \in T$ y h de forma que $t_r + h \in T (r = i, j)$.

Ésto implica que los momentos de primer y segundo orden sean constantes dado que no dependen del tiempo, por lo tanto, también lo sea la varianza del proceso y que la covarianza dependa sólo de la ventana de rezagos.

Como se expresa en Suriñach et al. (1995) [46], si un proceso estocástico presenta un momento de primer orden que depende del tiempo es no estacionario en media y se lo denomina como un *proceso con tendencia determinística*. Sí en cambio, se observa la presencia de tendencia en la varianza, el proceso también es no estacionario y se lo denomina como un *proceso con tendencia estocástica*.

Se pueden distinguir 4 ejemplos de procesos generadores de datos que ilustran las posibles

²También se lo puede encontrar definido en la literatura sobre el tema como estacionario de segundo orden o estacionario en covarianza.

combinaciones:

- **Ausencia de tendencias.** Sí x_t está generado por un proceso autorregresivo estacionario con $\epsilon_t \sim \text{i.i.d}(0, \sigma_\epsilon^2)$ ruido blanco y $|\phi| < 1$

$$x_t = \mu + \phi x_{t-1} + \epsilon_t \quad (\text{A.4})$$

$$E(x) = \frac{\mu}{1 - \phi} \quad \text{VAR}(x) = \frac{\sigma_\epsilon^2}{1 - \phi^2} \quad (\text{A.5})$$

se observa que ambas son independientes del tiempo (estacionariedad en media y en varianza).

En este caso, la estimación por mínimos cuadrados ordinarios (MCO) del parámetro ϕ será consistente, aunque sea sesgada (por la presencia de la variable endógena retardada como regresor), siendo su distribución asintótica normal.

- **Tendencia determinística.** Sí x_t viene determinada por un proceso autorregresivo estacionario sobre una tendencia determinística, con $\epsilon_t \sim \text{i.i.d}(0, \sigma_\epsilon^2)$ ruido blanco y $|\phi| < 1$.

$$x_t = \mu + \beta t + \phi x_{t-1} + \epsilon_t \quad (\text{A.6})$$

$$E(x) = \frac{\mu}{1 - \phi} + \frac{\beta}{1 - \phi} t \quad V(x) = \frac{\sigma_\epsilon^2}{1 - \phi^2} \quad (\text{A.7})$$

Se comprueba que la media es función del tiempo, pero la varianza sigue siendo independiente del tiempo. En este caso, la especificación de la tendencia determinística en la estimación del modelo elimina el problema de la no estacionariedad en media.

A estos procesos no estacionarios que tienen tendencia en la media (tendencia determinística) se les denomina *Procesos Estacionarios en Tendencia* (TS, *Trend Stationary*), los cuales pueden ser transformados en estacionarios al remover la tendencia determinística.

- **Tendencia estocástica.** Sí el proceso generador del dato está dado por un paseo aleatorio sin deriva con $\phi = 1$ suponiendo $x_0 = 0$,

$$x_t = \phi x_{t-1} + \epsilon_t \quad (\text{A.8})$$

$$E(x) = 0 \quad V(x) = t\sigma^2 \quad (\text{A.9})$$

donde la media de la serie es constante, pero la varianza es función del tiempo. La estimación MCO de ϕ sigue siendo consistente pero es sesgada, tendiendo a subestimar el valor poblacional del parámetro ($\phi = 1$).³ En éste tipo de procesos un shock externo tiene un efecto permanente sobre la serie. Que la varianza sea función del tiempo puede estar provocado por la presencia de raíces en el polinomio autorregresivo dentro del círculo unidad, o por la existencia de raíces unitarias.

El ejemplo más simple de no estacionariedad en varianza causada por una raíz unitaria en el polinomio autorregresivo es el paseo aleatorio o random walk⁴ (Suriñach, et al. 1995):

$$x_t - \phi x_{t-1} = (1 - \phi L)x_t = \epsilon_t \quad \text{con} \quad \phi = 1 \quad (\text{A.10})$$

donde ϵ_t es un ruido blanco y L es el operador de rezagos, de forma que $L \cdot x_t = x_{t-1}$.

Se define el operador de rezagos como: $L^n x_t = x_{t-n}$. A partir del operador de rezagos se define el operador de diferencias como: $\Delta^d = (1 - L)^d$ ⁵.

La no estacionariedad en varianza del paseo aleatorio se comprueba al sustituir recursivamente en $x_t = \phi x_{t-1} + \epsilon_t$, llegando a:

$$x_t = \phi^t x_0 + \sum_{i=0}^{t-1} \phi^i \epsilon_{t-i} \quad (\text{A.11})$$

sí $\phi = 1$, σ^2 es la varianza de ϵ_t y la $V(x_0) = 0$, la varianza de x_t será $t\sigma^2$. De ésta forma se observa que el proceso generado por un paseo aleatorio tiene una tendencia en la varianza y que ésta viene causada por la raíz unitaria en el polinomio autorregresivo.

- **Tendencia determinística junto con estocástica.** Sí el proceso generador del dato es

$$x_t = \mu + \phi x_{t-1} + \epsilon_t \quad (\text{A.12})$$

³En este caso el estimador no se distribuye asintóticamente como una normal, sino que su distribución es función de procesos de Wiener. Por lo tanto, hay una discontinuidad en la distribución asintótica del estimador MCO cuando éste vale 1, esto impide que se aplique la inferencia estándar sobre el parámetro, Suriñach et al. (1995) [46].

⁴Además de las raíces unitarias dadas por un random walk, también son raíces unitarias las raíces complejas de módulo unidad y la raíz asociada al factor $(1+L)$, este tipo de raíz genera integrabilidad de tipo estacional.

⁵La primera diferencia de x_t se puede expresar como $\Delta x_t = (1 - L)x_t = x_t - x_{t-1}$ y la segunda diferencia $\Delta^2 x_t = \Delta x_t - \Delta x_{t-1} = (1 - L)^2 x_t = x_t - 2x_{t-1} + x_{t-2}$.

con ϵ_t ruido blanco y $\phi = 1$. Suponiendo $x_0 = 0$ y sustituyendo recursivamente en x_t obtengo

$$x_t = \mu t + \sum_{i=0}^{t-1} \epsilon_{t-i} \quad (\text{A.13})$$

$$E(x) = t\mu \quad V(x) = t\sigma^2 \quad (\text{A.14})$$

tanto la media como la varianza son funciones del tiempo.

A éste tipo de procesos se les denomina *Procesos Estacionarios en Diferencia* (DS, *Difference Stationary*) ya que pueden ser transformados en estacionarios aplicando diferencias a la serie ⁶.

Es importante identificar el tipo de proceso generador del dato para poder aplicar la transformación adecuada para hacer la serie estacionaria. Por ejemplo, cuando el proceso tiene tendencia determinística, diferenciar la serie con la intención de volverla estacionaria no sólo no lograría transformar el proceso en estacionario, sino que además generaría un proceso con media móvil no invertible. Los parámetros estimados por MCO seguirán siendo consistentes aunque no eficientes.

Por este motivo, es importante realizar pruebas estadísticas que permitan confirmar si la serie es estacionaria o tiene tendencia determinística, estocástica o ambas para poder aplicar las técnicas correctas de análisis en cada caso. En primer instancia la inspección de las series se hace gráficamente (mediante la descomposición de la serie y los correlogramas ACF y PACF), luego se pueden hacer pruebas de hipótesis de raíz unitaria para determinar el orden de integración, ver sección A.1.3.

A.1.2. Modelos Multivariados

Cuando se está analizando un conjunto de variables se puede definir a y_t como un vector de k variables. En este caso las covarianzas entre las variables contienen información sobre las relaciones estáticas y dinámicas entre ellas, por lo cual es necesario estudiar adicionalmente las covarianzas entre las variables en el período t así como las covarianzas entre t y $t - h$.

Los modelos multivariados dinámicos se caracterizan por tener variables rezagadas que se relacionan a lo largo del tiempo. Dependiendo del proceso generador del dato que se este estudiando pueden darse varios casos:

⁶La no estacionariedad en varianza generada por la presencia de raíces en el polinomio autorregresivo dentro del círculo unidad, a diferencia de las raíces unitarias, no desaparece al aplicar el operador diferencia (1-L).

- Modelos multivariados dinámicos uniecuacionales, por ejemplo los modelos autorregresivos de rezagos distribuidos.
- Modelos multivariados dinámicos multiecuacionales, por ejemplo modelos de vectores autorregresivos o modelos estructurales.

Estos modelos se desarrollan en el apartado 2.2 del Capítulo 2.

A.1.3. Procesos Integrados

Como se desarrolló en la sección A.1.1 es importante para el análisis determinar si la serie con la cual se va a trabajar es un proceso estacionario, tiene tendencia determinística, estocástica o ambas. Si la serie es un proceso estacionario en diferencia es necesario determinar el orden de integración.

Se define en Banerjee et al. (1993) [6] a una serie integrada de orden d como: “una serie sin componente determinístico, que tiene una representación autorregresiva de media móvil (AR-MA) estacionaria e invertible luego de ser diferenciado d veces, pero que no es estacionaria si es diferenciada sólo $d - 1$ veces, la cual se denota $x_t \sim I(d)$ ”.

Según Engle y Granger (1987) [12], un proceso $I(0)$ estacionario se caracteriza por tener:

- una media constante y una tendencia de la serie a volver a esa media cuando se ha desviado de ella. Por lo tanto, tiende a fluctuar en torno a la media.
- una función de autocorrelación simple que decrece rápidamente cuando aumentan los retardos.
- varianza finita e independiente del tiempo.
- “memoria limitada” de su comportamiento pasado. Por lo tanto, los efectos de un shock aleatorio son sólo transitorios y van decreciendo en el tiempo.

En cambio, las características de un proceso $I(1)$ no estacionario son:

- no se mantiene un valor medio a lo largo de su historia.
- las autocorrelaciones tienden a 1 para cualquier retardo.
- la varianza depende del tiempo y tiende a infinito cuando éste tiende a infinito.
- el proceso tiene “memoria ilimitada” y por lo tanto, un shock aleatorio tendrá efectos permanentes en el proceso.

Cuadro A.1.1: Algunas propiedades de los procesos estacionarios e integrados

	I(0) PGD ec.A.4	I(1) PGD ec.A.8
Varianza	Finita, $(\sigma^2(1 - \rho^2)^{-1})$	Sin límites, crece con $t\sigma^2$
Varianza Condicional	σ^2	σ^2
Autocorrelación en función del rezago i	$\rho_i = \rho^i$	$\rho_i = \sqrt{1 - (i/t)} \rightarrow 1 \forall i$ cuando $t \rightarrow \infty$
Tiempo esperado al cruce de $y = 0$	Finito	Infinito
Memoria ^a	Temporal	Permanente ^b

Fuente: Banerjee et al. (1993)

a: Se puede decir que una serie tiene memoria permanente si el efecto de un shock no desaparece cuando $t \rightarrow \infty$.

b: En un contexto multivariado, el proceso integrado puede tener componentes que no se mantienen indefinidamente en el tiempo. Por ejemplo, en un random walk con drift es un proceso integrado pero la memoria es permanente sólo para el componente del random walk.

A.1.4. Regresión Espuria

El problema fue abordado de manera profunda por Granger y Newbold (1974) [15], que denominaron “regresiones espurias” a las regresiones econométricas que involucran variables no estacionarias (integradas de orden igual o mayor a 1) que están correlacionadas y tienen una relación estadísticamente significativa, pero que en los hechos son relaciones sin sentido ni relación causal, las cuales se caracterizan por [6]:

- El estadístico de bondad de ajuste del modelo (R^2) da elevado, y su distribución converge a una variable estocástica en lugar de hacerlo a su valor poblacional (que sería cero).
- Las distribuciones de los estadísticos t-student (usualmente empleados para poner a prueba la significación individual de los coeficientes de regresión) no convergen, por lo tanto, no son utilizables las tablas de valores críticos estándar.
- El valor del estadístico Durbin-Watson (DW) tiende a cero (es menor al valor 2, que corresponde a la ausencia de autocorrelación). Granger y Newbold (1974) sugieren que cualquier regresión en que $R^2 > DW$ sea analizada como una posible regresión espuria [6].

Las principales consecuencias de la presencia de autocorrelación de los errores en una regresión son:

- Los coeficientes estimados por la regresión son sesgados e ineficientes.
- Las proyecciones basadas en las ecuaciones son suboptimales.
- Las pruebas de significación sobre los coeficientes no son válidas.

Por lo tanto, cuando se presume que dos o más variables pueden estar relacionadas se analiza la correlación y significación de esa relación. Cuando las series son no estacionarias los test de significación habituales están sesgados tendiendo a rechazar la hipótesis nula cuando es verdadera, y pueden dar altos niveles de bondad de ajuste del modelo cuando en realidad no existe relación entre las variables en los hechos, implicando que la relación sea espuria.

Sin embargo, también se puede dar el caso en que las variables son no estacionarias pero que una combinación de ellas sí lo es, por lo tanto, implica que las variaciones y tendencias a lo largo del tiempo se compensan mostrando una evolución conjunta, éste es el caso de variables cointegradas.

A.1.5. Cointegración

Como se define en Banerjee et al. (1993) [6], el concepto de equilibrio desde un punto de vista estadístico se centra en procesos estacionarios. En este sentido, se puede definir que una relación de equilibrio $f(x_1, x_2) = 0$ se da entre dos variables x_1 y x_2 si la magnitud en la cual las observaciones se desvían del equilibrio $\epsilon_t \equiv f(x_1, x_2)$ es un proceso estacionario en media. Esto implica que, el error o discrepancia entre el producto y el equilibrio tenga una distribución fija y centrada en cero. El error ϵ_t en una relación de equilibrio de corto plazo no debe tener tendencia que crezca sistemáticamente a lo largo del tiempo.

El concepto de cointegración describe la existencia de una relación de equilibrio o estacionaria entre dos o más variables, que si son consideradas individualmente, son no estacionarias. Si se consideran dos procesos integrados $\{x_{1t}\}$ y $\{x_{2t}\}$, que no están vinculados a ninguna media fija, y una combinación lineal de esas variables genera una serie que es un proceso estacionario, en este caso se dice que las variables x_1 y x_2 están asociadas entre sí a través de una relación de equilibrio. Cuando se considera el caso bivariado, éste tipo de relación es única (sí existe), sin embargo al considerar el caso multivariado pueden darse múltiples relaciones de cointegración.

Una propiedad importante que caracteriza a las variables que están cointegradas, es que pueden ser representadas a través de un modelo de corrección de error (ECM - Error Correction Mechanism), en el cual el término que representa el valor observado de desviación del equilibrio de largo plazo es considerado dentro del modelo. En este sentido, el ECM permite captar la dinámica de ajuste de los procesos, tanto en el corto plazo como en el largo plazo, simultáneamente. Estos conceptos relacionados a la incorporación de la dinámica de ajuste al estado estacionario a través de los modelos de corrección de error fue sugerido por Sargan (1964) [44] y desarrollados posteriormente por Hendry y Anderson (1977) [16] y Davidson et al. (1978) [8] entre otros.

El concepto de cointegración fue introducido por Engle y Granger (1987) [12] y establece que un conjunto de series no estacionarias están cointegradas cuando la combinación lineal de las mismas es estacionaria.

Los componentes de un vector $y_t = (x_{1t}, x_{2t}, \dots, x_{kt})'$ se dice que están cointegrados, con orden

d, b [10]

$$y_t \approx CI(d, b) \text{ sí}$$

1. Todos los componentes de y_t son integrados de orden d .
2. Existe un vector $\beta = (\beta_1, \beta_2, \dots, \beta_k) \neq 0$ de forma que la combinación lineal $\beta' y_t = (\beta_1 x_{1t} + \beta_2 x_{2t} + \dots + \beta_k x_{kt})$ es integrada de orden $(d - b)$, $\beta' y_t \sim I(d - b)$ con $d \geq b > 0$.

siendo el vector β , el vector de cointegración.

Sí y_t tiene $k > 2$ componentes, puede llegar a haber más de un vector de cointegración. Si existen exactamente r vectores de cointegración linealmente independientes, con $r \leq k - 1$, entonces β puede definirse como una matriz de $k \times r$. En este caso, el rango de β será r y se denomina *rango de cointegración*.

A.1.6. Mecanismo de Corrección de Error

En el Capítulo 2 apartado 2.2 se desarrolló el modelo multivariado dinámico uniecuacional “Modelo Autorregresivo de Rezagos Distribuidos”, que se caracteriza por incluir no solo los valores corrientes de las variables explicativas, sino también sus valores rezagados. En el mismo, cuando se da que cada una de las variables son $I(1)$ de forma individual, pero que la combinación lineal de las mismas es estacionaria (están cointegradas) puede interpretarse su convergencia conjunta a una relación estable en el largo plazo.

A partir de la especificación del ADL, mediante una simple reorganización de términos puede reespecificarse como un ECM que permite desagregar el efecto de largo y corto plazo, de forma de poder analizar la magnitud del atractor común que lleva a la combinación lineal de las series no estacionarias a converger a una trayectoria estacionaria en el largo plazo.

Un vector de series de tiempo y_t tiene una representación como modelo de corrección de error si puede ser expresado como [6]:

$$A(L)(1 - L)y_t = -\gamma z_{t-1} + \varpi_t,$$

donde ϖ_t es una distorsión estacionaria multivariada, $z_t = \alpha' y_t$ y γ un vector distinto de cero, y $A(L)$ una matriz polinómica cuyos elementos $\{a_{ij}(L)\}$ son polinomios escalares en el argumento de L ($a_{ij}(L) = \sum_{r=0}^{k_{ij}} a_{ij,r} L^r$) con $A(0) = I_n$, $A(1)$ que contiene sólo elementos finitos. $A(L)$ puede ser expresado como $A(L) = A_0 + A_1 L + A_2 L^2 + \dots + A_k L^k = \sum_{r=0}^k A_r L^r$.

A modo de ejemplo se puede derivar de un proceso ADL(1,1) el ECM como se plantea en Hendry (1995) [17], recordar la especificación del cuadro 2.2.1:

$$x_t = \beta_0 + \beta_1 z_t + \beta_2 x_{t-1} + \beta_3 z_{t-1} + \epsilon_t \text{ donde } \epsilon_t \sim IN[0, \sigma_\epsilon^2] \quad (\text{A.15})$$

$$x_t - x_{t-1} = \beta_0 + \beta_1 z_t - \beta_1 z_{t-1} + \beta_2 x_{t-1} - x_{t-1} + \beta_3 z_{t-1} + \epsilon_t$$

$$\Delta x_t = \beta_0 + \beta_1 \Delta z_t - (1 - \beta_2)x_{t-1} + (\beta_1 + \beta_3)z_{t-1} + \epsilon_t$$

$$\Delta x_t = \beta_0 + \beta_1 \Delta z_t + (\beta_2 - 1) [x_{t-1} + k z_{t-1}] + \epsilon_t \quad (\text{A.16})$$

donde las expectativas de largo plazo están dadas por:

$$E[x_t - k z_t] = 0 \text{ cuando } k = \frac{(\beta_1 + \beta_3)}{(1 - \beta_2)}$$

En el modelo de corrección del equilibrio general recién planteado está contenido el mecanismo de corrección de error $(x + k z)_{t-1}$, que captura los distanciamientos del equilibrio de largo plazo, mientras $(\beta_2 - 1) > 0$ representa la proporción del desequilibrio entre x_{t-1} y z_{t-1} que se refleja en Δx_t .

A.1.7. Test de Raíz Unitaria - RU

Como se mencionó en la sección A.1.1 es importante identificar si el proceso generador del dato es o no estacionario para poder estimar de forma adecuada el comportamiento de largo plazo de la serie. En el caso de que la serie fuera integrada, al ser no estacionaria, estimar un modelo multivariado ya sea uniecuacional o multiecuacional en niveles no daría estimaciones válidas e inhabilita la inferencia. Por tal motivo, un primer paso en el análisis de las series, adicionalmente a la inspección gráfica de las mismas, es hacerle tests de raíces unitarias que permitan identificar si las series son integradas de orden 1 o mayor.

Muchas series económicas pueden contener una raíz unitaria exacta si se consideró la transformación en logaritmos de la serie. Sin embargo, si la raíz es cercana pero menor a la unidad la serie es casi integrada, estos casos dificultan la distinción entre series de RU y las casi integradas en muestras de tamaño moderado [6].

Se observa que las distribuciones de los estadísticos de prueba dependen no solo del proceso generador del dato, sino también del modelo que se investiga.

Test de Dickey-Fuller (DF)

Dickey & Fuller (1979) [9] han obtenido, mediante simulaciones Monte Carlo, tablas de valores críticos para el estadístico t en base a la especificación de tres modelos.

Las tres especificaciones auxiliares planteadas son [6][p.100]:

$$x_t = \vartheta_a x_{t-1} + u_t , \quad (\text{A.17})$$

$$x_t = \mu_b + \vartheta_b x_{t-1} + u_t , \quad (\text{A.18})$$

$$x_t = \mu_c + \gamma_c t + \vartheta_c x_{t-1} + u_t . \quad (\text{A.19})$$

La hipótesis nula es $H_0 : \vartheta_i = 1$ y la alternativa $H_1 : \vartheta_i < 1$ para $i = a, b, c$. La aplicabilidad de cada modelo depende de lo que se sabe del proceso generador del dato. Si el modelo que se quiere estimar no es apropiado a la especificación del test, las conclusiones tomadas a partir de los valores críticos del estadístico de prueba de Dickey-Fuller pueden invalidar la inferencia.

Cuadro A.1.2: Estadísticos para la Prueba de Hipótesis en modelos con constante y tendencia.

Hipótesis Nula	Estadístico dado $\vartheta_a = 1$
Hipótesis simples	
$\mu_b = 0$	$\tau_1 = \hat{\mu}_b / SE(\hat{\mu}_b)$
$\mu_c = 0$	$\tau_2 = \hat{\mu}_c / SE(\hat{\mu}_c)$
$\gamma_c = 0$	$\tau_3 = \hat{\gamma}_c / SE(\hat{\gamma}_c)$
Hipótesis conjuntas	
$\mu_b = 0$ y $\vartheta_b = 1$	$\phi_1 = (2S_u^2)^{-1} \left[(T-1)S_0^2 - (T-3)S_u^2 \right]$
$\mu_c = 0, \gamma_c = 0, \vartheta_c = 1$	$\phi_2 = (3S_u^2)^{-1} \left[(T-1)S_0^2 - (T-4)S_u^2 \right]$
$\gamma_c = 0, \vartheta_c = 1$	$\phi_3 = (2S_u^2)^{-1} \left\{ (T-1) \left[S_0^2 - (\bar{x}_0 - \bar{x}_1)^2 \right] - (T-4)S_u^2 \right\}$

Fuente: Banerjee et al. (1993).

Test de Dickey-Fuller Aumentado (ADF)

La prueba de Dickey-Fuller Aumentado es un método más general que permite incluir los cambios rezagados en la variable dependiente para poder capturar las variables omitidas autocorrelacionadas, que de otra forma aparecerían en el término de error (autocorrelacionado). Al incluir los términos rezagados adicionales, el modelo a estimar tendrá términos de error que son asintóticamente ruido blanco, Banerjee et al. (1993) [6].

Los tres modelos planteados son:

$$\Delta x_t = \rho_a x_{t-1} + \sum_{j=1}^p \gamma_j \Delta x_{t-j} + u_{at} \quad (\text{A.20})$$

$$\Delta x_t = \mu_b + \rho_b x_{t-1} + \sum_{j=1}^p \gamma_j \Delta x_{t-j} + u_{bt} \quad (\text{A.21})$$

$$\Delta x_t = \mu_c + \delta t + \rho_c x_{t-1} + \sum_{j=1}^p \gamma_j \Delta x_{t-j} + u_{ct} \quad (\text{A.22})$$

En este caso el test a una cola tiene como hipótesis nula $H_0 : \rho_i = \vartheta_i - 1 = 0$ versus la alternativa $H_1 : \rho_i = \vartheta_i - 1 < 0$ para $i = a, b, c$. Por lo tanto, un alto valor negativo del estadístico conduce a rechazar la hipótesis nula.

Un aspecto particular de este test es que su distribución límite no es estandar bajo la hipótesis nula, cambia la forma de la distribución y por lo tanto también cambian los valores críticos para hacer las pruebas de hipótesis, los cuales van a depender de la forma del término μ_t .

Por este motivo, Dickey & Fuller (1979) proponen tablas de valores críticos simulados para cada uno de los test propuestos, que pueden usarse cuando los errores son ruido blanco ⁷.

Test de Zivot y Andrews (ZA)

Un aspecto importante a considerar en el análisis de raíces unitarias es la existencia de quiebres estructurales. En los test de ADF se analiza la no estacionariedad ante la presencia de una raíz unitaria en la serie, pero ese tipo de tests pueden dar resultados incorrectos si la serie tiene quiebre estructural.

Un cambio estructural puede ocurrir, por ejemplo, como consecuencia de la introducción de una nueva normativa en materia de economía, y la serie verse afectada de dos maneras distintas. El cambio ocasionado podría tener un carácter transitorio, o bien permanecer a lo largo del restante período de observación de la serie.

En la práctica, estos cambios estructurales son modelados a través de la introducción de variables ficticias. En el primer caso, se modela con una variable que toma el valor 1 en el momento de corte y toma el valor 0 en el resto, en el segundo caso se modela con una dummy que es 0 antes de la fecha de corte y 1 después, de esta forma el cambio estructural tendrá un efecto duradero en la serie.

$$x_t = \mu + \delta D_t + x_{t-1} + \epsilon_t ,$$

⁷Véase la tabla de valores críticos del test en el Anexo D.

donde D_t es una variable dummy de impulso:

$$D_t = \begin{cases} 1 & \text{si } t = \tau \\ 0 & \text{de otra forma} \end{cases}$$

donde τ es el día del cambio.

Aunque el cambio ocurra sólo en 1 período, tendrá un efecto duradero en la serie.

$$x_t = \mu + \delta S_t + x_0 + \sum_{i=1}^t \epsilon_t$$

$$S_t = \begin{cases} 1 & \text{si } t > \tau \\ 0 & \text{de otra forma} \end{cases}$$

Perron (1989) [39] demuestra que la inferencia que se puede haber hecho a partir de los test de RU del estilo de Dickey-Fuller no es confiable en casos de cambio estructural. Propone un test donde la hipótesis nula es que la serie tiene una raíz unitaria con la posibilidad de constante distinta de cero contra una hipótesis alternativa de que el proceso es “Trend-Stationary”, adicionalmente permiten la presencia de una variable ficticia (ya sea un salto o un escalón). Esta intervención es determinada y fijada por el analista subjetivamente.

Se plantea la estimación de tres modelos para tres casos de quiebre estructural.

Las hipótesis nulas de las tres opciones de modelos son:

A. $x_t = \mu + x_{t-1} + dD(T_\tau)_t + \epsilon_t$

B. $x_t = \mu_1 + x_{t-1} + (\mu_2 - \mu_1)DU_t + \epsilon_t$

C. $x_t = \mu_1 + x_{t-1} + dD(T_\tau)_t + (\mu_2 - \mu_1)DU_t + \epsilon_t$

donde:

a) $1 < T_\tau < T$ asigna el punto de quiebre principal,

b)

$$D(T_\tau) = \begin{cases} 1 & \text{si } t = T_\tau + 1 \\ 0 & \text{de otra forma} \end{cases}$$

c)

$$DU_t = \begin{cases} 1 & \text{si } t > T_\tau \\ 0 & \text{de otra forma} \end{cases}$$

El error se representa como $\phi(L)\epsilon_t = \theta(L)\xi_t$ con ξ i.i.d, donde $\phi(L)$ y $\theta(L)$ son polinomios de rezagos.

Las cuales implican:

- Modelo A. Quiebre en niveles, se toma en cuenta sólo un salto en niveles de la serie.
- Modelo B. Quiebre en tendencia, se permite un cambio en la tasa de crecimiento de la serie.
- Modelo C. Quiebre en tendencia y niveles, es una combinación de los 2 modelos anteriores.

Las hipótesis alternativas de cada uno de los modelos cuando la especificación del proceso es de tendencia estacionaria son:

A. $x_t = \mu_1 + \beta t + (\mu_2 - \mu_1)DU_t + \epsilon_t$

B. $x_t = \mu + \beta_1 t + (\beta_2 - \beta_1)DT_t^* + \epsilon_t$

C. $x_t = \mu + \beta_1 t + (\mu_2 - \mu_1)DU_t + (\beta_2 - \beta_1)DT_t^* + \epsilon_t$,

donde:

$$DT_t^* = \begin{cases} t - T_\tau & \text{si } t > T_\tau \\ 0 & \text{de otra forma} \end{cases}$$

Las cuales implican [49]:

- Modelo A. Quiebre en niveles “*crash model*”, se toma en cuenta sólo un salto en niveles de la serie. La diferencia $(\mu_2 - \mu_1)$ representa la magnitud del cambio en el intercepto de la función con tendencia que ocurre en el momento T_τ .
- Modelo B. Quiebre en tendencia “*changing growth*”, se permite un cambio en la tasa de crecimiento de la serie. La diferencia $(\beta_2 - \beta_1)$ representa la magnitud del cambio en la pendiente de la función con tendencia que ocurre en el momento T_τ .

- Modelo C. Quiebre en tendencia y niveles, es una combinación de los 2 modelos anteriores.

Perron (1989) aplicó un test de raíz unitaria del tipo ADF que implica incluir rezagos en las regresiones de cada uno de los modelos.

$$A. x_t = \mu + \theta DU_t + \beta t + dD(T_\tau)_t + \alpha x_{t-1} + \sum_{j=1}^k c_j \Delta x_{t-j} + \epsilon_t$$

$$B. x_t = \mu + \beta t + \gamma DT_t^* + \alpha x_{t-1} + \sum_{j=1}^k c_j \Delta x_{t-j} + \epsilon_t$$

$$C. x_t = \mu + \theta DU_t + \beta t + \gamma DT_t^* + dD(T_\tau)_t + \alpha x_{t-1} + \sum_{j=1}^k c_j \Delta x_{t-j} + \epsilon_t$$

Los k regresores extra se agregan para eliminar las posibles dependencias con otros parámetros en la distribución límite del estadístico del test, causada por la dependencia temporal en las desviaciones. El número de los k regresores extra está determinada por un test de significación de los coeficientes estimados de c_j^i para $i = A, B, C$.

Para ver el nivel de significación de los parámetros y testear formalmente la presencia de raíz unitaria, el estadístico empleado por Perron es el *Student t-ratio* $t_{\hat{\alpha}^i}(\lambda)$ para $i=A,B,C$. Este estadístico es dependiente de la fracción de puntos con quiebre estructural respecto al total de la muestra, p.e. $\lambda = \frac{T_\tau}{T}$.

Para rechazar la hipótesis nula de $I(1)$ debe darse que $t_{\hat{\alpha}^i}(\lambda) < k_\alpha(\lambda)$, donde $k_\alpha(\lambda)$ denota al valor crítico de $t_{\hat{\alpha}^i}(\lambda)$ para un valor fijo de λ (el estadístico debe ser alto y negativo).⁸

Zivot y Andrews (1992) [49] profundizan en el análisis de Perron y plantean un test que trata de verificar la hipótesis nula de presencia de raíz unitaria de forma similar a la planteada por Perron, con la variante de que el momento de cambio estructural en vez de ser determinado a priori por el analista, es estimado.

Señalaron que existe el riesgo de no especificar bien el modelo y no tener una correcta inferencia, si el punto de quiebre se establece exógenamente por el investigador. Proponen una prueba que elude esta posibilidad mediante la determinación endógena de la mayor probabilidad de ocurrencia del cambio estructural. Por lo tanto, proponen un test de ADF ajustado para cada uno de los modelos.

El proceso de estimación que proponen es definir la fecha del cambio estructural en el punto del tiempo que resulta menos favorable a que se de la hipótesis nula de un random walk con drift sin cambio estructural.

$$H_0 : x_t = \mu + x_{t-1} + \epsilon_t \tag{A.23}$$

⁸Los valores críticos de este estadístico están en Perron(1989) y/o Perron(1993).

Se asume como hipótesis alternativas que x_t puede ser representado como un proceso estacionario en tendencia con un cambio en la tendencia que ocurre en un punto del tiempo desconocido “breakpoint”.

El objetivo es estimar ese punto del tiempo que proporciona el resultado menos probable de que se cumpla la hipótesis nula, de esta forma λ es seleccionada para que minimice el estadístico t a una cola, para testear $H_0 : \alpha^i = 1$ para $i=A,B,C$. El rechazo de la hipótesis nula se da para valores bajos del estadístico.

El estadístico es:

$$t_{\hat{\alpha}^i}[\hat{\lambda}_{inf}^i] = \underbrace{\inf_{\lambda \in \Delta} t_{\hat{\alpha}^i}(\lambda)}_{\lambda \in \Delta} \quad \text{para } i = A, B, C \quad (\text{A.24})$$

donde Δ es cercano al intervalo $(0, 1)$. Dependiendo el modelo seleccionado, el estadístico ⁹ se deriva de los modelos de regresión:

$$A. \quad x_t = \hat{\mu} + \hat{\theta}DU_t(\hat{\lambda}) + \hat{\beta}t + \hat{\alpha}x_{t-1} + \sum_{i=1}^k \hat{c}_i \Delta x_{t-i} + \hat{\epsilon}_t \quad (\text{A.25})$$

$$B. \quad x_t = \hat{\mu} + \hat{\beta}t + \hat{\gamma}DT_t^*(\hat{\lambda}) + \hat{\alpha}x_{t-1} + \sum_{i=1}^k \hat{c}_i \Delta x_{t-i} + \hat{\epsilon}_t \quad (\text{A.26})$$

$$C. \quad x_t = \hat{\mu} + \hat{\theta}DU_t(\hat{\lambda}) + \hat{\beta}t + \hat{\gamma}DT_t^*(\hat{\lambda}) + \hat{\alpha}x_{t-1} + \sum_{i=1}^k \hat{c}_i \Delta x_{t-i} + \hat{\epsilon}_t \quad (\text{A.27})$$

$$DU_t(\lambda) = \begin{cases} 1 & \text{si } t > T\lambda \\ 0 & \text{de otra forma} \end{cases}$$

$$DT_t^* = \begin{cases} t - T\lambda & \text{si } t > T\lambda \\ 0 & \text{de otra forma} \end{cases}$$

A.2. Selección de la Cantidad de Rezagos del VAR

Para determinar la cantidad de rezagos del VAR se utiliza un test de razón de verosimilitud donde la hipótesis nula es H_p : cantidad de rezagos = p, y la alternativa H_{p+1} : cantidad de rezagos = p+1.

⁹Al estimarse el valor de λ los valores críticos de Perron ya no son válidos y deben usarse los valores críticos publicados en Zivot y Andrews (1992).

$$-2 \ln Q (H_p/H_{p+1}) = T \left(\ln |\hat{\Omega}_p| - \ln |\hat{\Omega}_{p+1}| \right) \quad (\text{A.28})$$

El estadístico $(-2 \ln Q)$ se distribuyen asintóticamente como $\chi^2_{(1-\alpha), (k^2)}$ con k^2 grados de libertad y un nivel de significación de α ¹⁰. La hipótesis nula se rechazará cuando el valor del estadístico sea mayor al valor $\chi^2_{(1-\alpha), (k^2)}$.

Complementariamente al test LR se pueden calcular otros indicadores, como los criterios de información de Akaike (AIC), Schwarz (SC) y Hannan-Quinn (H-Q).

$$AIC = \ln |\hat{\Omega}_p| + (k^2 p) \frac{2}{T} \quad (\text{A.29})$$

$$SC = \ln |\hat{\Omega}_p| + (k^2 p) \frac{\ln T}{T} \quad (\text{A.30})$$

$$H - Q = \ln |\hat{\Omega}_p| + (k^2 p) \frac{2 \ln \ln T}{T} \quad (\text{A.31})$$

Todos ellos se calculan en base al logaritmo del determinante de la matriz de varianzas y covarianzas del modelo estimado $\ln |\hat{\Omega}_p|$, más un factor de penalización relacionado a la cantidad de parámetros estimados.

Luego de calcular el VAR para distintos valores de rezagos, se selecciona el que tenga menor valor de los indicadores AIC, SC, H-Q.

Este tipo de indicadores sirven para comparar la bondad de ajuste del modelo no solo en el caso específico del VAR, sino que son utilizados para seleccionar modelos de regresión en general, por lo tanto son indicadores que también se podran utilizar en la búsqueda de la mejor especificación del VECM.

Otro indicador importante a analizar que apoya la selección de la especificación que mejor se adecúe al proceso generador del dato es que los residuos cumplan con los supuestos del modelo (normalidad, homoscedasticidad y no autocorrelacionados), a veces los problemas de autocorrelación pueden estar en la falta de incorporación de rezagos.

A.3. Tests sobre los Residuos en Modelos Multiecuacionales.

Como se planteo en el apartado 2.2.2 el supuesto de que los residuos sean ruido blanco es importante para la inferencia. Sin embargo, si el objetivo es la predicción, el supuesto de que

¹⁰La cantidad efectiva de observaciones T tomadas en cuenta en el contraste de H_p vs H_{p+1} debe ser igual, tanto en el test de razón de verosimilitud como en los criterios de información AIC, BIC, etc.

los residuos sean ruido blanco no es imprescindible siempre y cuando el modelo prediga bien, Lütkepohl (2005) [35].

A.3.1. Test de Normalidad de los residuos

El test de normalidad está basado en los momentos de tercer y cuarto orden (simetría y curtosis). Si se considera una variable aleatoria x con distribución estándar $x \sim N(0, 1)$, los momentos de tercer y cuarto orden son: $E(x^3) = 0$ y $E(x^4) = 3$.

Si se considera u_t un proceso Gaussiano K -dimensional con $u_t \sim N(\mu_u, \Sigma_u)$ y una matriz P que satisfaga $PP' = \Sigma_u$ ¹¹

$$w_t = (w_{1t}, \dots, w_{Kt})' := P^{-1}(u_t - \mu_u) \sim N(0, I_K)$$

$$E \begin{bmatrix} w_{1t}^3 \\ \vdots \\ w_{Kt}^3 \end{bmatrix} = 0 \quad \text{y} \quad E \begin{bmatrix} w_{1t}^4 \\ \vdots \\ w_{Kt}^4 \end{bmatrix} = \begin{bmatrix} 3 \\ \vdots \\ 3 \end{bmatrix} =: \mathbf{3}_K \quad (\text{A.32})$$

La idea del test es comparar los momentos de tercer y cuarto orden del proceso transformado, con los valores teóricos de ec.A.32 que se obtienen de un proceso Gaussiano. Este test es conocido como Jarque-Bera en el caso univariado.

Para el caso multivariado, se define a partir de las estimaciones de $\hat{u}_1, \dots, \hat{u}_T$:

$$\bar{u} := \frac{1}{T} \sum_{t=1}^T \hat{u}_t, \quad S_u := \frac{1}{T-1} \sum_t (\hat{u}_t - \bar{u})(\hat{u}_t - \bar{u}) \quad (\text{A.33})$$

con una matriz P_s tal que, $P_s P_s' = S_u$.

$$v_t := (v_{1t}, \dots, v_{Kt})' = P_s^{-1}(\hat{u}_t - \bar{u}), \quad t = 1, \dots, T. \quad (\text{A.34})$$

$$\hat{b}_1 := (\hat{b}_{11}, \dots, \hat{b}_{K1})' \quad \text{con} \quad \hat{b}_{K1} = \frac{1}{T} \sum_t v_{kt}^3 \quad k = 1, \dots, K \quad (\text{A.35})$$

$$\hat{b}_2 := (\hat{b}_{12}, \dots, \hat{b}_{K2})' \quad \text{con} \quad \hat{b}_{K2} = \frac{1}{T} \sum_t v_{kt}^4 \quad k = 1, \dots, K \quad (\text{A.36})$$

¹¹La matriz P puede obtenerse a partir de una descomposición de Choleski de la matriz Σ_u .

$$\sqrt{T} \begin{bmatrix} \hat{b}_1 \\ \hat{b}_2 - \mathbf{3}K \end{bmatrix} \xrightarrow{d} N \left(0, \begin{bmatrix} 6I_K & 0 \\ 0 & 24I_K \end{bmatrix} \right), \quad (\text{A.37})$$

siendo $\hat{b}_1$ y $\hat{b}_2$ los estimadores para los vectores de ec.A.32, a partir de los cuales se pueden definir los estadísticos $\hat{\lambda}_s$ y $\hat{\lambda}_k$.

Para testear las hipótesis:

$$H_0 : E \begin{bmatrix} w_{1t}^3 \\ \vdots \\ w_{Kt}^3 \end{bmatrix} = 0 \quad \text{contra} \quad H_1 : E \begin{bmatrix} w_{1t}^3 \\ \vdots \\ w_{Kt}^3 \end{bmatrix} \neq 0 \quad (\text{A.38})$$

Se utiliza el estadístico:

$$\hat{\lambda}_s := T(\hat{b}_1' \hat{b}_1)/6 \xrightarrow{d} \chi^2(K) \quad (\text{A.39})$$

Para testear las hipótesis:

$$H_0 : E \begin{bmatrix} w_{1t}^4 \\ \vdots \\ w_{Kt}^4 \end{bmatrix} = \mathbf{3}_k \quad \text{contra} \quad H_1 : E \begin{bmatrix} w_{1t}^4 \\ \vdots \\ w_{Kt}^4 \end{bmatrix} \neq \mathbf{3}_k \quad (\text{A.40})$$

Se utiliza el estadístico:

$$\hat{\lambda}_k := T(\hat{b}_2 - \mathbf{3}_k)'(\hat{b}_2 - \mathbf{3}_k)/24 \xrightarrow{d} \chi^2(K) \quad (\text{A.41})$$

Para hacer un test conjunto de ambas hipótesis nulas se puede usar el estadístico:

$$\hat{\lambda}_{sk} = \hat{\lambda}_s + \hat{\lambda}_k \xrightarrow{d} \chi^2(2K) \quad (\text{A.42})$$

En el caso univariado el test de normalidad también se hace mediante el cálculo de la simetría y curtosis, los estadísticos cambian respecto al caso multivariado.

$$\begin{aligned} \hat{b}_1 &= \left(\frac{\sum_{t=1}^T (\hat{u}_t - \bar{u})^3 / T}{\sigma_u^3} \right)^2 \\ \hat{b}_2 &= \frac{\sum_{t=1}^T (\hat{u}_t - \bar{u})^4 / T}{\sigma_u^4} - 3 \end{aligned} \quad (\text{A.43})$$

$$\hat{\lambda}_{sk} = T(\hat{b}_1/6) + T(\hat{b}_2^2/24) \xrightarrow{d} \chi^2(2) \quad (\text{A.44})$$

A.3.2. Test de Autocorrelación de los residuos

Una forma de testear la autocorrelación de los residuos del VAR: $Y = BZ + U$, es asumir que el vector de residuos U se comporta como un VAR de la forma $u_t = D_1 u_{t-1} + \dots + D_h u_{t-h} + v_t$ con v_t ruido blanco, con matriz de covarianzas Σ_u . Cuando no hay autocorrelación en los residuos u_t y v_t serían iguales.

$$\begin{aligned} H_0 : D_1 = \dots = D_h = 0 \\ H_1 : D_j \neq 0 \text{ para al menos un } j \in \{1, \dots, h\} \end{aligned}$$

Para la prueba de hipótesis se define la regresión auxiliar:

$$\hat{u}_t = w + A_1 y_{t-1} + \dots + A_p y_{t-p} + D_1 \hat{u}_{t-1} + \dots + D_h \hat{u}_{t-h} + \epsilon_t \quad (\text{A.45})$$

en notación matricial $\hat{U} = BZ + D\hat{U}_- + E$. A partir de los dos modelos se aplica un test de multiplicadores de lagrange.

$$\lambda_{LM}(h) = T\hat{c}_h' \hat{\Sigma}_c(h)^{-1} \hat{c}_h \sim \chi^2(hK^2) \quad (\text{A.46})$$

$$\text{con } \hat{\Sigma}_c(h) = \frac{1}{T} [\hat{U}_- \hat{U}_- - \hat{U}_- Z' (ZZ')^{-1} Z \hat{U}_-'] \otimes \hat{\Sigma}_u, \quad \hat{\Sigma}_u = \frac{1}{T-Kp-1} \sum_{t=1}^T \hat{u}_t \hat{u}_t' \text{ y } \hat{c}_h = T^{-1} \text{vec}(\hat{U} \hat{U}_-')$$

En caso de no tener gran cantidad de datos, el test LM (Lagrange Multiplier, también conocido como Breusch-Godfrey) es el más adecuado [35].

A.3.3. Test de Heteroscedasticidad en los residuos

El test ARCH de orden m plantea como hipótesis nula que los residuos son homoscedasticos y se calcula como $(T + p - m) \times R^2$, donde T es el tamaño total de la muestra, p es la cantidad de rezagos del VAR, y R^2 es el derivado a partir de la regresión auxiliar:

$$\hat{\epsilon}_{i,t}^2 = \gamma_0 + \sum_{j=1}^m \gamma_j \hat{\epsilon}_{i,t-j}^2 + \text{error} \quad (\text{A.47})$$

El test se distribuye aproximadamente como χ^2 con m grados de libertad.

Apéndice B

Anexo de Resultados

En el primer apartado de este anexo se presentan los resultados de las estimaciones de las demandas de supergas y energía eléctrica en una especificación uniecuacional, de forma de poder comparar la diferencias en los parámetros estimados a partir de dicha especificación respecto a la especificación multiecuacional presentada en el Capítulo de Resultados.

En el segundo apartado se presentan los resultados completos de la especificación sin la variable temperatura (Escenario 1) estimados a partir de la programación ad-hoc y posteriormente los resultados de las estimaciones en el software Gretl para poder comparar las similitudes y diferencias en la presentación de resultados previamente comentadas en el Anexo C sobre Comparación de Softwares.

No se presentaran los resultados de todos los escenarios estimados en este trabajo dado que sería demasiado extenso.

B.1. Estimaciones de la demanda de energía mediante ECM univariado.

La estimación de la demanda de energéticos puede hacerse de forma univariada o multivariada. Existe amplia bibliografía donde realizan las estimaciones de forma univariada, imponiendo a priori el rol que las variables juegan en los modelos (si exógenas o endógenas) y el tipo de relación de causalidad.

Por lo tanto, como se expuso previamente en el Capítulo 2 lo adecuado es partir de una especificación donde todas las variables se tomen como simétricas y determinar, mediante pruebas de hipótesis, la existencia de retroalimentación, la forma y dirección de la misma, y si es adecuado adoptar un modelo uniecuacional. El sentido sería por lo tanto, pasar de una especificación multiecuacional a una uniecuacional cuando los datos lo comprueban y no viceversa.

En esta sección se presentan los resultados que refiere a la estimación de un modelo ECM

uniecual, a efectos de su comparación con el modelos VECM (ver el apartado con los resultados de las estimaciones multiecuacionales en 4.6), que exhibe mejoras significativas en cuanto a las estimaciones obtenidas en la especificación ECM uniecual.

Todas las variables que se incluyen en el análisis son no estacionarias I(1) en niveles, pero estacionarias I(0) en primeras diferencias.

Una vez determinada la existencia de la relación de cointegración según la metodología planteada por Engle y Granger ¹, la ecuación de demanda de supergas se puede especificar como ECM.

Se incluyen los precios, variables estacionales ficticias (dummies), la temperatura mínima, una constante y dos intervenciones de impulso (en junio 2007 y en marzo 2011), pero no se incluye al índice de salario real por resultar no significativo y presentar colinealidad con el precio del supergas, por lo tanto no se podrá interpretar la elasticidad ingreso en esta ecuación.

$$\Delta csg_t = 10,69 + \begin{bmatrix} -0,0027 & -0,69 \end{bmatrix} \begin{bmatrix} \Delta psg_t \\ \Delta pee_t \end{bmatrix} - 0,96 \begin{bmatrix} 1 & 0,29 & 0,17 \end{bmatrix} \begin{bmatrix} csg_{t-1} \\ psg_{t-1} \\ pee_{t-1} \end{bmatrix} - 0,37 tmin_t + \phi D_t + \epsilon_t \quad (B.1)$$

A partir de la estimación de la relación de cointegración se obtienen las elasticidades precio asociadas a la demanda de supergas.

$$csg_t = -0,29psg_t - 0,17pee_t \quad (B.2)$$

La relación de largo plazo de la cantidad de supergas respecto a los precios muestra que la elasticidad precio propia (respecto al precio del supergas) es de - 0.29 teniendo signo negativo (acorde a la teoría económica) y significativo a menos del 1 %. En el caso del precio de la energía eléctrica al tener signo negativo implica que es un bien complementario con una elasticidad de -0.17 significativo al 5 %.

El atractor común de magnitud -0.96 lleva a la combinación lineal de las series no estacionarias, si son consideradas individualmente, a converger a una trayectoria estacionaria en el largo plazo, y su magnitud implica que el ajuste se da de forma rápida.

En cuanto al corto plazo, la elasticidad de corto plazo de psg es -0.0027 y no significativa, implicando que las variaciones de precios del supergas en el corto plazo no afectan a la cantidad demandada, pero en el caso del pee la elasticidad es -0.69 significativa al 5 %.

¹La metodología planteada por Engle y Granger para la estimación del ECM uniecual determina que en primer instancia se realice la estimación MCO de la ecuación especificada en niveles $csg_t = c + \beta_1 psg_t + \beta_2 pee_t + \beta_3 isr_t + \epsilon_t$ y testear que los residuos sean I(0). En ese caso las variables se encuentran cointegradas y puede pasarse a estimar la especificación ECM.

La temperatura mínima también tiene signo negativo -0.37 lo cual es acorde a que aumentos en la temperatura determinen menor demanda de supergas, también significativo a menos del 1 %. Las dummy estacionales tienen signos acorde a lo esperado, negativos en los meses de calor y positivos y muy significativos en los meses de frío.

La ecuación de demanda de energía eléctrica especificada como ECM incluye los precios, el salario real, dummies estacionales, constante y tendencia, no incluye a la temperatura mínima por resultar no significativa.

$$\Delta cee_t = 14,16 + 0,00068t + \begin{bmatrix} 0,379 & -0,389 & 0,29 \end{bmatrix} \begin{bmatrix} \Delta psg_t \\ \Delta pee_t \\ \Delta isr_t \end{bmatrix}$$
$$-0.838 \begin{bmatrix} 1 & -0,049 & 0,175 & -0,533 \end{bmatrix} \begin{bmatrix} cee_{t-1} \\ psg_{t-1} \\ pee_{t-1} \\ isr_{t-1} \end{bmatrix} + \phi D_t + \epsilon_t \quad (B.3)$$

A partir de la estimación de la relación de cointegración se obtienen las elasticidades precio e ingreso asociadas a la demanda de energía eléctrica.

$$cee_t = 0,049psg_t - 0,175pee_t + 0,533isr_t \quad (B.4)$$

La relación de largo plazo de la cantidad de energía eléctrica respecto a los precios y el salario real muestra que el supergas sería bien sustituto a la energía eléctrica dado que tiene una elasticidad positiva 0.049, sin embargo es no significativa. La elasticidad precio propia, respecto al precio de la energía eléctrica es -0.175 (acorde a la teoría económica) significativa al 5 % y la elasticidad ingreso 0.533 muestra que es un bien necesario, dado que la demanda de energía eléctrica aumenta al aumentar los ingresos pero lo hace de forma menos que proporcional.

El atractor común de magnitud -0.838 lleva a la combinación lineal de las series no estacionarias a converger a una trayectoria estacionaria en el largo plazo en forma rápida pero menor al caso de la demanda del supergas.

En cuanto al corto plazo, la elasticidad de corto plazo de psg es 0.379 significativa a menos del 1 %, en el caso del pee es -0.389 significativa al 1 % y en el caso de la elasticidad ingreso de corto plazo es 0.29 pero no significativa.

Cuadro B.1.1: Test de especificación de los ECM de *csg* y *cee*.

	Δcsg_t	Δcee_t
Adj. R^2	0.889	0.835
Error estándar res.	0.067	0.031
Jarque-Bera	0.246 (0.88)	0.804 (0.66)
Durbin-Watson	1.913 (0.25)	1.976 (0.32)
Breusch-Pagan	25.56 (0.14)	20.56 (0.36)
ADF	-5.78	-3.75

Nota: Entre paréntesis se presenta el p-valor asociado a cada test. El test Jarque-Bera tiene como H_0) la normalidad de los residuos, el test Durbin-Watson tiene como H_0) cero autocorrelación en los residuos y el test Breuch-Pagan H_0) residuos homoscedásticos.

El ECM tiene un buen ajuste en ambas ecuaciones y los residuos son normales, no correlacionados y homoscedásticos ya que no se rechaza la hipótesis nula en ninguno de ellos, el test ADF también muestra residuos estacionarios.

B.2. Resultados en software R-project.

Según una convención consensuada en la literatura, los niveles de significación que presenta el software en los resultados, están identificados con asteriscos.

- '***' corresponde a un p-valor “muy altamente significativo”.
- '**' “altamente significativo”.
- '*' “significativo”.
- '.' “no hay suficiente evidencia de significación”.
- ' ' “no significativo”.

B.2.1. Pruebas de raíces unitarias para la serie del Índice de Salario Real (*isr*).

```
> adf_isr=ur.df(isr, lags=13, type='trend');summary(adf_isr)
```

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####
```

```
Test regression trend
```

```
Call:
```

```
lm(formula = z.diff ~ z.lag.1 + 1 + tt + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.032702 -0.005113 -0.000251  0.004475  0.027074

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.031e-01  4.111e-02   2.508 0.013425 *
z.lag.1      -2.497e-02  9.621e-03  -2.595 0.010579 *
tt           8.797e-05  2.940e-05   2.992 0.003334 **
z.diff.lag1  3.272e-01  8.433e-02   3.880 0.000167 ***
z.diff.lag2  7.416e-02  6.959e-02   1.066 0.288603
z.diff.lag3  4.366e-02  6.962e-02   0.627 0.531742
z.diff.lag4  4.782e-03  6.988e-02   0.068 0.945554
z.diff.lag5 -3.501e-02  6.966e-02  -0.503 0.616169
z.diff.lag6  1.163e-01  6.971e-02   1.668 0.097873 .
z.diff.lag7 -4.350e-02  7.027e-02  -0.619 0.537050
z.diff.lag8 -7.370e-02  6.999e-02  -1.053 0.294374
z.diff.lag9 -6.402e-02  7.035e-02  -0.910 0.364534
z.diff.lag10 -6.923e-02  7.067e-02  -0.980 0.329122
z.diff.lag11 -3.788e-02  7.089e-02  -0.534 0.594078
z.diff.lag12  6.744e-01  7.559e-02   8.922 4.52e-15 ***
z.diff.lag13 -3.209e-01  9.156e-02  -3.505 0.000633 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.009793 on 126 degrees of freedom
Multiple R-squared:  0.538,    Adjusted R-squared:  0.483
F-statistic: 9.783 on 15 and 126 DF,  p-value: 5.571e-15
```

Value of test-statistic is: -2.5951 3.5076 5.1553

```
Critical values for test statistics:
      1pct  5pct 10pct
tau3  -3.99 -3.43 -3.13
phi2   6.22  4.75  4.07
phi3   8.43  6.49  5.47
```

```
> za_isr=ur.za(isr, model='both', lag=24);summary(za_isr)
```

```
#####
# Zivot-Andrews Unit Root Test #
#####
```

```
Call:
lm(formula = testmat)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-0.0216547 -0.0043551 -0.0005922  0.0044360  0.0182677
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.165419   0.155522   7.494 2.51e-11 ***
y.l1          0.786393   0.027245  28.864 < 2e-16 ***
trend        -0.008142   0.002676  -3.042 0.00299 **
y.dl1         0.083207   0.081230   1.024 0.30810
y.dl2         0.004094   0.081348   0.050 0.95996
y.dl3        -0.046894   0.080809  -0.580 0.56299
y.dl4        -0.123847   0.080804  -1.533 0.12845
y.dl5        -0.047934   0.080927  -0.592 0.55495
y.dl6         0.069196   0.081076   0.853 0.39540
y.dl7        -0.010748   0.080527  -0.133 0.89409
y.dl8        -0.142895   0.079399  -1.800 0.07486 .
y.dl9        -0.121916   0.080214  -1.520 0.13163
y.dl10       -0.080102   0.081150  -0.987 0.32594
```

B. Anexo de Resultados

```
y.dl11      -0.140119   0.080677  -1.737   0.08545 .
y.dl12       0.402502   0.084886   4.742  6.90e-06 ***
y.dl13      -0.105949   0.087834  -1.206   0.23052
y.dl14      -0.033449   0.087671  -0.382   0.70360
y.dl15       0.045418   0.087723   0.518   0.60576
y.dl16       0.113914   0.087339   1.304   0.19507
y.dl17      -0.054847   0.087435  -0.627   0.53187
y.dl18      -0.026538   0.087695  -0.303   0.76280
y.dl19      -0.060336   0.086998  -0.694   0.48955
y.dl20       0.059689   0.086879   0.687   0.49362
y.dl21      -0.028651   0.086903  -0.330   0.74231
y.dl22      -0.119856   0.087365  -1.372   0.17311
y.dl23       0.028425   0.086967   0.327   0.74445
y.dl24       0.256940   0.082762   3.105   0.00247 **
du          -0.028918   0.008921  -3.242   0.00161 **
dt           0.008917   0.002700   3.303   0.00132 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.00811 on 102 degrees of freedom
(25 observations deleted due to missingness)
Multiple R-squared:  0.9964,    Adjusted R-squared:  0.9955
F-statistic: 1019 on 28 and 102 DF,  p-value: < 2.2e-16

Teststatistic: -7.8403
Critical values: 0.01= -5.57 0.05= -5.08 0.1= -4.82

Potential break point at position: 30

# miro despues del quiebre
> za_isr=ur.za(isr[31:156], model='intercept', lag=24);summary(za_isr)

#####
# Zivot-Andrews Unit Root Test #
#####

Call:
lm(formula = testmat)

Residuals:
    Min       1Q   Median       3Q      Max
-0.0187284 -0.0039420 -0.0005308  0.0037267  0.0183484

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  3.6598508  0.8448612   4.332 4.64e-05 ***
y.l1         0.1195586  0.2040830   0.586 0.559794
trend        0.0029823  0.0007115   4.191 7.68e-05 ***
y.dl1        0.4892785  0.1829900   2.674 0.009248 **
y.dl2        0.3932387  0.1682991   2.337 0.022210 *
y.dl3        0.3865745  0.1602094   2.413 0.018336 *
y.dl4        0.1724888  0.1474582   1.170 0.245908
y.dl5        0.2517104  0.1355335   1.857 0.067319 .
y.dl6        0.3400849  0.1364006   2.493 0.014924 *
y.dl7        0.2611893  0.1349961   1.935 0.056891 .
y.dl8        0.0688154  0.1323957   0.520 0.604796
y.dl9        0.0546818  0.1213034   0.451 0.653480
y.dl10       0.0205912  0.1193128   0.173 0.863458
y.dl11       0.0013640  0.1143158   0.012 0.990513
y.dl12       0.4537948  0.1150458   3.944 0.000182 ***
y.dl13       0.0669369  0.1081269   0.619 0.537805
y.dl14       0.1086534  0.1086460   1.000 0.320581
y.dl15       0.1037349  0.1075380   0.965 0.337913
y.dl16       0.2337279  0.1093363   2.138 0.035890 *
y.dl17       0.0238746  0.1127298   0.212 0.832864
y.dl18      -0.0152953  0.1057445  -0.145 0.885391
y.dl19      -0.0878950  0.1027801  -0.855 0.395252
```

```

y.dl20      0.0189967  0.1014730  0.187 0.852016
y.dl21     -0.0852598  0.1023591 -0.833 0.407591
y.dl22     -0.1019148  0.1024438 -0.995 0.323102
y.dl23     -0.0521315  0.1004013 -0.519 0.605170
y.dl24      0.2270861  0.0946984  2.398 0.019043 *
du          0.0175665  0.0045451  3.865 0.000239 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.007396 on 73 degrees of freedom
(25 observations deleted due to missingness)
Multiple R-squared:  0.9966,    Adjusted R-squared:  0.9954
F-statistic: 803.7 on 27 and 73 DF,  p-value: < 2.2e-16

Teststatistic: -4.3141
Critical values: 0.01= -5.34 0.05= -4.8 0.1= -4.58

Potential break point at position: 78

```

B.2.2. Estimación del VECM en el Escenario 1 para un modelo no restringido.

```

> round(V,6) # beta no normalizado
      csg.l1      cee.l1      isr.l1      psg.l1      pee.l1      cte
csg.l1 -22.071378   3.492177  -8.009414  -1.719912   3.219091   0.834566
cee.l1  25.372597  43.379206  27.681752   1.182641   0.626274   2.003527
isr.l1 -15.931340 -34.607855 -24.768685   4.136851 -23.631253  -4.983052
psg.l1  -5.357253  -2.956640  -8.110778   6.875467  -9.783000  -3.663023
pee.l1   8.742679   6.672414 -16.707753  -5.191103   5.624762   3.205558
cte    -215.378979 -713.408532 -298.222840 -41.596533  88.751446 -19.201446
> round(W,6) # alpha no normalizado
      csg.l1      cee.l1      isr.l1      psg.l1      pee.l1      cte
csg.l1  0.047911 -0.022203  0.004604 -0.003924 -0.000288   0
cee.l1 -0.002807 -0.009358 -0.006731 -0.001221 -0.000173   0
isr.l1  0.002327  0.001298 -0.002022  0.000362  0.000134   0
psg.l1 -0.003000  0.001577  0.000611 -0.002653  0.000783   0
pee.l1 -0.001262 -0.002629  0.001181  0.000809  0.001319   0
> round(Vn,6) # beta normalizado
      csg.l1      cee.l1      isr.l1      psg.l1      pee.l1      cte
csg.l1  1.000000  0.080503  0.323369 -0.250152  0.572307 -0.043464
cee.l1 -1.149570  1.000000 -1.117611  0.172009  0.111342 -0.104343
isr.l1  0.721810 -0.797798  1.000000  0.601683 -4.201290  0.259514
psg.l1  0.242724 -0.068158  0.327461  1.000000 -1.739274  0.190768
pee.l1 -0.396109  0.153816  0.674551 -0.755018  1.000000 -0.166944
cte     9.758293 -16.445864 12.040318 -6.049994 15.778704  1.000000
> round(Wn,6) # alpha normalizado
      csg.l1      cee.l1      isr.l1      psg.l1      pee.l1      cte
csg.l1 -1.057465 -0.963166 -0.114027 -0.026977 -0.001618   0
cee.l1  0.061946 -0.405945  0.166718 -0.008397 -0.000970   0
isr.l1 -0.051370  0.056297  0.050070  0.002490  0.000753   0
psg.l1  0.066206  0.068405 -0.015144 -0.018239  0.004402   0
pee.l1  0.027849 -0.114034 -0.029240  0.005561  0.007419   0

> round(lambda,6) # valores propios
[1] 0.450015 0.267601 0.132847 0.022415 0.007887 0.000000

> round(betanorm,6) # beta normalizado para r relaciones de cointegracion
      ect1      ect2
csg.l1  1.000000  0.000000
cee.l1  0.000000  1.000000
isr.l1 -0.178771 -0.783407
psg.l1  0.150448 -0.080270

```

B. Anexo de Resultados

```
pee.l1 -0.200712 0.169974
cte -8.372549 -15.771845
> round(alphanorm,6) # alpha normalizado para r relaciones de cointegracion
      ect1      ect2
csg.d -1.135003 0.252464
cee.d 0.029266 -0.477156
isr.d -0.046838 0.115350
psg.d 0.071713 -0.007704
pee.d 0.018669 -0.146048

> round(OMEGA,8) # Matriz de varianzas y covarianzas a partir de la normalización
      csg.d      cee.d      isr.d      psg.d      pee.d
csg.d 0.00501151 0.00039116 -8.092e-05 0.00018551 -0.00006291
cee.d 0.00039116 0.00066067 3.854e-05 0.00006635 -0.00006108
isr.d -0.00008092 0.00003854 5.012e-05 -0.00004182 0.00000456
psg.d 0.00018551 0.00006635 -4.182e-05 0.00041221 0.00003388
pee.d -0.00006291 -0.00006108 4.560e-06 0.00003388 0.00028111

> sd.error # Errores estándar de los beta normalizados
      ect1      ect2
csg.l1 0.000000 0.000000
cee.l1 0.000000 0.000000
isr.l1 0.116856 0.067324
psg.l1 0.068206 0.039295
pee.l1 0.121659 0.070091
cte 0.740907 0.426857

> summary(rlm)
Response csg.d :

Call:
lm(formula = csg.d ~ csg.d.l1 + cee.d.l1 + isr.d.l1 + psg.d.l1 +
  pee.d.l1 + csg.d.l2 + cee.d.l2 + isr.d.l2 + psg.d.l2 + pee.d.l2 +
  dls0102 + dao0311 + dao0607 + dao0706 + dls0103 + dao0903 +
  dls0110 + dls0702 + dao0112 + dao0108 + dao0708 + sd1 + sd2 +
  sd3 + sd4 + sd5 + sd6 + sd7 + sd8 + sd9 + sd10 + sd11 + ect1 +
  ect2 - 1, data = data.mat)

Residuals:
      Min       1Q   Median       3Q      Max
-0.234311 -0.034525  0.000265  0.040354  0.188361

Coefficients:
      Estimate Std. Error t value Pr(>|t|)
csg.d.l1  0.156365   0.125922   1.242 0.216767
cee.d.l1 -0.354433   0.300943  -1.178 0.241250
isr.d.l1 -0.532256   0.810710  -0.657 0.512751
psg.d.l1  0.064639   0.291767   0.222 0.825049
pee.d.l1 -0.127601   0.358868  -0.356 0.722796
csg.d.l2  0.080780   0.090486   0.893 0.373800
cee.d.l2  0.085751   0.209391   0.410 0.682889
isr.d.l2 -0.328367   0.786635  -0.417 0.677115
psg.d.l2  0.601724   0.278757   2.159 0.032890 *
pee.d.l2 -0.523641   0.358826  -1.459 0.147113
dls0102 -0.095141   0.032453  -2.932 0.004044 **
dao0311 -0.419279   0.087897  -4.770 5.27e-06 ***
dao0607 -0.221408   0.088223  -2.510 0.013429 *
dao0706 -0.370853   0.087021  -4.262 4.08e-05 ***
dls0103  0.050183   0.054074   0.928 0.355256
dao0903  0.023127   0.085495   0.271 0.787243
dls0110 -0.075993   0.060994  -1.246 0.215248
dls0702 -0.068069   0.068307  -0.997 0.321019
dao0112 -0.001979   0.086473  -0.023 0.981780
dao0108  0.022378   0.085336   0.262 0.793596
dao0708 -0.342205   0.087225  -3.923 0.000147 ***
sd1      -0.159383   0.045201  -3.526 0.000600 ***
sd2      -0.084719   0.055570  -1.525 0.130029
sd3      -0.072572   0.063507  -1.143 0.255442
sd4       0.045149   0.049088   0.920 0.359563
sd5       0.267329   0.052954   5.048 1.62e-06 ***
```

```

sd6      0.511851    0.055481    9.226 1.28e-15 ***
sd7      0.689192    0.070041    9.840 < 2e-16 ***
sd8      0.466654    0.083523    5.587 1.49e-07 ***
sd9      0.246833    0.077977    3.165 0.001967 **
sd10     0.014947    0.061498    0.243 0.808384
sd11     -0.058890    0.040920   -1.439 0.152729
ect1     -1.135003    0.145014   -7.827 2.29e-12 ***
ect2      0.252464    0.326127    0.774 0.440390
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.08027 on 119 degrees of freedom
Multiple R-squared:  0.8762,    Adjusted R-squared:  0.8409
F-statistic: 24.78 on 34 and 119 DF,  p-value: < 2.2e-16

Response cee.d :

Call:
lm(formula = cee.d ~ csg.d.l1 + cee.d.l1 + isr.d.l1 + psg.d.l1 +
  pee.d.l1 + csg.d.l2 + cee.d.l2 + isr.d.l2 + psg.d.l2 + pee.d.l2 +
  dls0102 + dao0311 + dao0607 + dao0706 + dls0103 + dao0903 +
  dls0110 + dls0702 + dao0112 + dao0108 + dao0708 + sd1 + sd2 +
  sd3 + sd4 + sd5 + sd6 + sd7 + sd8 + sd9 + sd10 + sd11 + ect1 +
  ect2 - 1, data = data.mat)

Residuals:
    Min       1Q   Median       3Q      Max
-0.07959 -0.01586  0.00000  0.01928  0.06392

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
csg.d.l1    0.1069163   0.0457204   2.338 0.021031 *
cee.d.l1   -0.2963026   0.1092676  -2.712 0.007685 **
isr.d.l1    0.7421412   0.2943564   2.521 0.013017 *
psg.d.l1    0.0646075   0.1059361    0.610 0.543109
pee.d.l1   -0.0038948   0.1302995  -0.030 0.976204
csg.d.l2    0.0490466   0.0328539    1.493 0.138118
cee.d.l2   -0.2249539   0.0760265  -2.959 0.003726 **
isr.d.l2    0.1675552   0.2856151    0.587 0.558552
psg.d.l2    0.0420150   0.1012125    0.415 0.678804
pee.d.l2   -0.0543685   0.1302842  -0.417 0.677206
dls0102     0.0426199   0.0117831    3.617 0.000438 ***
dao0311     0.0157016   0.0319140    0.492 0.623628
dao0607     0.0733294   0.0320323    2.289 0.023829 *
dao0706    -0.1091806   0.0315959  -3.456 0.000762 ***
dls0103     0.0080918   0.0196333    0.412 0.680974
dao0903    -0.0067147   0.0310420   -0.216 0.829117
dls0110     0.0164877   0.0221461    0.744 0.458044
dls0702    -0.0002557   0.0248012   -0.010 0.991792
dao0112     0.0091372   0.0313969    0.291 0.771540
dao0108     0.0301971   0.0309840    0.975 0.331735
dao0708    -0.0402869   0.0316702   -1.272 0.205826
sd1         0.1447877   0.0164117   8.822 1.14e-14 ***
sd2         0.0385520   0.0201767    1.911 0.058446 .
sd3         0.0549371   0.0230583    2.383 0.018778 *
sd4         0.0134747   0.0178233    0.756 0.451134
sd5         0.0597151   0.0192268    3.106 0.002372 **
sd6         0.0965298   0.0201442    4.792 4.81e-06 ***
sd7         0.1703244   0.0254307    6.698 7.41e-10 ***
sd8         0.1459131   0.0303259    4.812 4.44e-06 ***
sd9         0.1137281   0.0283123    4.017 0.000104 ***
sd10        0.0455016   0.0223290    2.038 0.043789 *
sd11        0.0322567   0.0148574    2.171 0.031909 *
ect1        0.0292662   0.0526523    0.556 0.579365
ect2       -0.4771560   0.1184116  -4.030 9.89e-05 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.02915 on 119 degrees of freedom

```


B. Anexo de Resultados

Multiple R-squared: 0.889, Adjusted R-squared: 0.8572
F-statistic: 28.02 on 34 and 119 DF, p-value: < 2.2e-16

Response isr.d :

Call:

```
lm(formula = isr.d ~ csg.d.l1 + cee.d.l1 + isr.d.l1 + psg.d.l1 +  
    pee.d.l1 + csg.d.l2 + cee.d.l2 + isr.d.l2 + psg.d.l2 + pee.d.l2 +  
    dls0102 + dao0311 + dao0607 + dao0706 + dls0103 + dao0903 +  
    dls0110 + dls0702 + dao0112 + dao0108 + dao0708 + sd1 + sd2 +  
    sd3 + sd4 + sd5 + sd6 + sd7 + sd8 + sd9 + sd10 + sd11 + ect1 +  
    ect2 - 1, data = data.mat)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.017791	-0.003877	0.000000	0.003705	0.021309

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
csg.d.l1	0.0316253	0.0125923	2.511	0.013363 *
cee.d.l1	-0.0560216	0.0300944	-1.862	0.065137 .
isr.d.l1	0.0004999	0.0810715	0.006	0.995091
psg.d.l1	-0.0512533	0.0291769	-1.757	0.081551 .
pee.d.l1	-0.0144015	0.0358870	-0.401	0.688919
csg.d.l2	0.0141676	0.0090486	1.566	0.120070
cee.d.l2	-0.0435354	0.0209392	-2.079	0.039753 *
isr.d.l2	0.0874332	0.0786640	1.111	0.268604
psg.d.l2	0.0157625	0.0278759	0.565	0.572832
pee.d.l2	-0.0158217	0.0358828	-0.441	0.660067
dls0102	-0.0115220	0.0032453	-3.550	0.000552 ***
dao0311	-0.0131776	0.0087897	-1.499	0.136470
dao0607	0.0006007	0.0088223	0.068	0.945831
dao0706	-0.0080398	0.0087021	-0.924	0.357415
dls0103	-0.0090229	0.0054074	-1.669	0.097820 .
dao0903	0.0013044	0.0085496	0.153	0.878993
dls0110	0.0075800	0.0060995	1.243	0.216407
dls0702	-0.0484233	0.0068307	-7.089	1.04e-10 ***
dao0112	0.0329642	0.0086473	3.812	0.000220 ***
dao0108	0.0262852	0.0085336	3.080	0.002570 **
dao0708	-0.0005609	0.0087226	-0.064	0.948837
sd1	0.0269162	0.0045201	5.955	2.70e-08 ***
sd2	-0.0005669	0.0055571	-0.102	0.918922
sd3	-0.0027534	0.0063507	-0.434	0.665393
sd4	-0.0061459	0.0049089	-1.252	0.213024
sd5	0.0026344	0.0052955	0.497	0.619769
sd6	0.0078833	0.0055481	1.421	0.157960
sd7	0.0216851	0.0070041	3.096	0.002446 **
sd8	0.0136210	0.0083523	1.631	0.105576
sd9	0.0126422	0.0077978	1.621	0.107610
sd10	0.0105403	0.0061498	1.714	0.089147 .
sd11	0.0066106	0.0040920	1.615	0.108854
ect1	-0.0468378	0.0145015	-3.230	0.001601 **
ect2	0.1153504	0.0326129	3.537	0.000578 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.008027 on 119 degrees of freedom
Multiple R-squared: 0.7094, Adjusted R-squared: 0.6264
F-statistic: 8.546 on 34 and 119 DF, p-value: < 2.2e-16

Response psg.d :

Call:

```
lm(formula = psg.d ~ csg.d.l1 + cee.d.l1 + isr.d.l1 + psg.d.l1 +  
    pee.d.l1 + csg.d.l2 + cee.d.l2 + isr.d.l2 + psg.d.l2 + pee.d.l2 +  
    dls0102 + dao0311 + dao0607 + dao0706 + dls0103 + dao0903 +  
    dls0110 + dls0702 + dao0112 + dao0108 + dao0708 + sd1 + sd2 +  
    sd3 + sd4 + sd5 + sd6 + sd7 + sd8 + sd9 + sd10 + sd11 + ect1 +
```

```

ect2 - 1, data = data.mat)

Residuals:
    Min       1Q   Median       3Q      Max
-0.066152 -0.010614  0.001618  0.009623  0.051690

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
csg.d.l1 -0.0163928   0.0361143  -0.454  0.650717
cee.d.l1  0.0109458   0.0863098   0.127  0.899297
isr.d.l1 -0.2415972   0.2325103  -1.039  0.300873
psg.d.l1  0.1711045   0.0836783   2.045  0.043081 *
pee.d.l1 -0.0311071   0.1029227  -0.302  0.762999
csg.d.l2 -0.0204439   0.0259511  -0.788  0.432388
cee.d.l2 -0.0216629   0.0600529  -0.361  0.718941
isr.d.l2 -0.2058788   0.2256056  -0.913  0.363319
psg.d.l2 -0.0261421   0.0799471  -0.327  0.744248
pee.d.l2  0.0940268   0.1029107   0.914  0.362736
dls0102  0.0043147   0.0093074   0.464  0.643796
dao0311  0.0778095   0.0252086   3.087  0.002519 **
dao0607 -0.0159538   0.0253022  -0.631  0.529556
dao0706 -0.0909817   0.0249574  -3.645  0.000397 ***
dls0103  0.0650313   0.0155082   4.193  5.32e-05 ***
dao0903  0.0857780   0.0245199   3.498  0.000659 ***
dls0110 -0.0053119   0.0174930  -0.304  0.761920
dls0702  0.0345529   0.0195903   1.764  0.080336 .
dao0112  0.0077687   0.0248002   0.313  0.754638
dao0108 -0.0001748   0.0244741  -0.007  0.994315
dao0708  0.0218748   0.0250161   0.874  0.383646
sd1      0.0031336   0.0129635   0.242  0.809412
sd2      0.0094962   0.0159374   0.596  0.552411
sd3      0.0294503   0.0182136   1.617  0.108539
sd4      0.0095620   0.0140785   0.679  0.498335
sd5      0.0206306   0.0151872   1.358  0.176899
sd6     -0.0080201   0.0159118  -0.504  0.615168
sd7     -0.0392418   0.0200875  -1.954  0.053103 .
sd8     -0.0254404   0.0239542  -1.062  0.290367
sd9     -0.0267066   0.0223637  -1.194  0.234778
sd10    -0.0291103   0.0176375  -1.650  0.101484
sd11    -0.0121926   0.0117357  -1.039  0.300943
ect1     0.0717133   0.0415897   1.724  0.087250 .
ect2    -0.0077043   0.0935326  -0.082  0.934491
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.02302 on 119 degrees of freedom
Multiple R-squared:  0.5663,    Adjusted R-squared:  0.4423
F-statistic: 4.569 on 34 and 119 DF,  p-value: 3.495e-10

```

Response pee.d :

```

Call:
lm(formula = pee.d ~ csg.d.l1 + cee.d.l1 + isr.d.l1 + psg.d.l1 +
  pee.d.l1 + csg.d.l2 + cee.d.l2 + isr.d.l2 + psg.d.l2 + pee.d.l2 +
  dls0102 + dao0311 + dao0607 + dao0706 + dls0103 + dao0903 +
  dls0110 + dls0702 + dao0112 + dao0108 + dao0708 + sd1 + sd2 +
  sd3 + sd4 + sd5 + sd6 + sd7 + sd8 + sd9 + sd10 + sd11 + ect1 +
  ect2 - 1, data = data.mat)

```

```

Residuals:
    Min       1Q   Median       3Q      Max
-0.040344 -0.007602 -0.000211  0.006106  0.046222

```

```

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
csg.d.l1 -2.024e-02   2.982e-02  -0.679  0.49876
cee.d.l1  8.707e-02   7.128e-02   1.222  0.22426
isr.d.l1 -3.254e-01   1.920e-01  -1.695  0.09270 .
psg.d.l1  3.072e-03   6.910e-02   0.044  0.96462

```

B. Anexo de Resultados

```
pee.d.l1 -3.571e-02 8.499e-02 -0.420 0.67511
csg.d.l2 2.533e-05 2.143e-02 0.001 0.99906
cee.d.l2 2.789e-02 4.959e-02 0.562 0.57490
isr.d.l2 2.817e-01 1.863e-01 1.512 0.13318
psg.d.l2 -2.074e-02 6.602e-02 -0.314 0.75395
pee.d.l2 -5.962e-02 8.498e-02 -0.702 0.48434
dls0102 1.493e-02 7.686e-03 1.943 0.05440 .
dao0311 2.688e-02 2.082e-02 1.291 0.19909
dao0607 -2.941e-02 2.089e-02 -1.408 0.16185
dao0706 2.222e-02 2.061e-02 1.078 0.28319
dls0103 1.435e-02 1.281e-02 1.120 0.26485
dao0903 -1.224e-02 2.025e-02 -0.604 0.54681
dls0110 -5.073e-02 1.445e-02 -3.512 0.00063 ***
dls0702 2.045e-02 1.618e-02 1.264 0.20862
dao0112 4.035e-02 2.048e-02 1.970 0.05114 .
dao0108 -1.845e-02 2.021e-02 -0.913 0.36313
dao0708 9.793e-03 2.066e-02 0.474 0.63633
sd1 5.726e-03 1.071e-02 0.535 0.59374
sd2 2.496e-02 1.316e-02 1.896 0.06033 .
sd3 -4.744e-03 1.504e-02 -0.315 0.75303
sd4 -4.166e-05 1.163e-02 -0.004 0.99715
sd5 -3.861e-03 1.254e-02 -0.308 0.75871
sd6 1.137e-02 1.314e-02 0.865 0.38853
sd7 -1.597e-02 1.659e-02 -0.963 0.33755
sd8 3.537e-03 1.978e-02 0.179 0.85839
sd9 -1.778e-03 1.847e-02 -0.096 0.92346
sd10 2.200e-03 1.457e-02 0.151 0.88022
sd11 8.861e-03 9.692e-03 0.914 0.36238
ect1 1.867e-02 3.435e-02 0.544 0.58776
ect2 -1.460e-01 7.724e-02 -1.891 0.06108 .
---
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.01901 on 119 degrees of freedom
Multiple R-squared: 0.3758, Adjusted R-squared: 0.1975
F-statistic: 2.108 on 34 and 119 DF, p-value: 0.001729

```
> # Matriz de varianzas y covarianzas, determinante y loglik
> omega=crossprod(residuals(rlm))/N; round(omega,8)
      csg.d      cee.d      isr.d      psg.d      pee.d
csg.d 0.00501151 0.00039116 -8.092e-05 0.00018551 -0.00006291
cee.d 0.00039116 0.00066067 3.854e-05 0.00006635 -0.00006108
isr.d -0.00008092 0.00003854 5.012e-05 -0.00004182 0.00000456
psg.d 0.00018551 0.00006635 -4.182e-05 0.00041221 0.00003388
pee.d -0.00006291 -0.00006108 4.560e-06 0.00003388 0.00028111
> detcov=det(omega);detcov
[1] 1.394036e-17
> K
[1] 5
> c=N*(K/2)-(N*(K/2)*log(2*pi))
> logLmax=-(0.5*N)*log(detcov)+c;logLmax
[1] 2648.61
>
> aic=log(detcov)+(K^2*p)*(2/N);aic
[1] -37.83135
> sc=log(detcov)+(K^2*p)*(log(N)/N);sc
[1] -36.34584
> HQ=log(detcov)+(K^2*p)*(2*log(log(N))/N);HQ
[1] -37.22791
```

B.2.3. Estimación del VECM en el Escenario 1 con precios débilmente exóg.

```
> round(V,6) # beta no normalizado
```

```

      csg.l1    cee.l1    isr.l1    psg.l1    pee.l1    cte
csg.l1 -22.363567 -3.168694 -7.857681 -0.623600  3.100373 -0.019874
cee.l1  26.239987 -45.341051  24.352590 -1.901297  2.036060 -1.636994
isr.l1 -17.021114  36.660687 -21.146796 -6.673585 -8.689967  2.386901
psg.l1 -5.823714  3.246522 -7.387903  0.793394 -8.196866  1.547206
pee.l1  8.789029 -5.608939 -17.548657 -2.821876  6.510943 -1.664141
cte    -223.103718 736.591386 -252.706104 74.085026 -11.114321 21.227613
> round(W,6) # alpha no normalizado
      csg.l1    cee.l1    isr.l1    psg.l1    pee.l1    cte
csg.l1  0.048348  0.023281  0.005205      0      0      0
cee.l1 -0.002672  0.010453 -0.005979      0      0      0
isr.l1  0.002003 -0.001398 -0.002111      0      0      0

> round(as.numeric(lambda),6) # valores propios
[1] 0.436301 0.244682 0.127802 0.000000 0.000000 0.000000

> round(betanorm,6) # beta normalizado para r relaciones de cointegracion
      ect1    ect2
csg.l1  1.000000  0.000000
cee.l1  0.000000  1.000000
isr.l1 -0.173380 -0.796437
psg.l1  0.163029 -0.082996
pee.l1 -0.229074  0.139715
cte    -8.396778 -15.658759
> round(alphanorm,6) # alpha normalizado para r relaciones de cointegracion
      ect1    ect2
csg.d -1.155014  0.213060
cee.d  0.026642 -0.544064
isr.d -0.040368  0.115972

> round(OMEGA,8) # Matriz de varianzas y covarianzas a partir de normalizacion
      csg.d    cee.d    isr.d
csg.d  0.00490532 0.00034075 -6.133e-05
cee.d  0.00034075 0.00062627  4.671e-05
isr.d -0.00006133 0.00004671  4.608e-05

> sd.error # Errores estándar de los beta normalizados
      ect1    ect2
csg.l1 0.000000 0.000000
cee.l1 0.000000 0.000000
isr.l1 0.121265 0.069195
psg.l1 0.071017 0.040523
pee.l1 0.123692 0.070580
cte    0.764542 0.436253

> summary(rlm.1.2.3)
Response csg.d :

Call:
lm(formula = csg.d ~ -1 + ECT + Z1 + Z0[, c(4, 5)])

Residuals:
    Min       1Q   Median       3Q      Max
-0.23066 -0.03301  0.00000  0.03914  0.19245

Coefficients:
      Estimate Std. Error t value Pr(>|t|)
ECTect1      -1.15501    0.14625  -7.897 1.71e-12 ***
ECTect2       0.21306    0.33920   0.628 0.531151
Z1csg.d.l1     0.15189    0.12603   1.205 0.230575
Z1cee.d.l1    -0.33608    0.30630  -1.097 0.274797
Z1isr.d.l1    -0.51955    0.82188  -0.632 0.528526
Z1psg.d.l1    -0.01159    0.29623  -0.039 0.968843
Z1pee.d.l1    -0.13152    0.35879  -0.367 0.714600
Z1csg.d.l2     0.08648    0.09054   0.955 0.341448
Z1cee.d.l2     0.09798    0.21007   0.466 0.641797
Z1isr.d.l2    -0.18486    0.79320  -0.233 0.816128
Z1psg.d.l2     0.61252    0.27851   2.199 0.029824 *
Z1pee.d.l2    -0.58962    0.36073  -1.635 0.104837
Z1dls0102     -0.09632    0.03230  -2.982 0.003481 **

```

B. Anexo de Resultados

```

Z1dao0311      -0.44970      0.09154    -4.912  2.95e-06 ***
Z1dao0607      -0.22373      0.08878    -2.520  0.013078 *
Z1dao0706      -0.32138      0.09224    -3.484  0.000696 ***
Z1dls0103       0.02368      0.05805     0.408  0.684152
Z1dao0903      -0.01670      0.08983    -0.186  0.852856
Z1dls0110      -0.09354      0.06400    -1.462  0.146543
Z1dls0702      -0.07797      0.06948    -1.122  0.264073
Z1dao0112       0.00297      0.08764     0.034  0.973025
Z1dao0108       0.01827      0.08544     0.214  0.831070
Z1dao0708      -0.34944      0.08737    -4.000  0.000112 ***
Z1sd1          -0.15727      0.04509    -3.488  0.000687 ***
Z1sd2          -0.07959      0.05617    -1.417  0.159154
Z1sd3          -0.08390      0.06384    -1.314  0.191347
Z1sd4           0.04217      0.04898     0.861  0.390945
Z1sd5           0.25791      0.05331     4.838  4.04e-06 ***
Z1sd6           0.51918      0.05577     9.309  9.26e-16 ***
Z1sd7           0.70215      0.07120     9.861  < 2e-16 ***
Z1sd8           0.47761      0.08357     5.715  8.50e-08 ***
Z1sd9           0.25613      0.07795     3.286  0.001342 **
Z1sd10          0.02641      0.06177     0.428  0.669732
Z1sd11         -0.05224      0.04109    -1.271  0.206138
Z0[, c(4, 5)]psg.d 0.45649      0.32016     1.426  0.156579
Z0[, c(4, 5)]pee.d -0.26656      0.38747    -0.688  0.492841
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Residual standard error: 0.08009 on 117 degrees of freedom
Multiple R-squared: 0.8789, Adjusted R-squared: 0.8416
F-statistic: 23.58 on 36 and 117 DF, p-value: < 2.2e-16

Response cee.d :

Call:
lm(formula = cee.d ~ -1 + ECT + Z1 + Z0[, c(4, 5)])

Residuals:

Min	1Q	Median	3Q	Max
-0.07663	-0.01516	0.00000	0.01933	0.06531

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
ECTect1	0.0266420	0.0522571	0.510	0.611135
ECTect2	-0.5440643	0.1212013	-4.489	1.69e-05 ***
Z1csg.d.l1	0.0996793	0.0450335	2.213	0.028806 *
Z1cee.d.l1	-0.2558785	0.1094460	-2.338	0.021089 *
Z1isr.d.l1	0.6743818	0.2936687	2.296	0.023432 *
Z1psg.d.l1	0.0349117	0.1058449	0.330	0.742112
Z1pee.d.l1	-0.0151555	0.1281986	-0.118	0.906097
Z1csg.d.l2	0.0498205	0.0323509	1.540	0.126260
Z1cee.d.l2	-0.2064618	0.0750590	-2.751	0.006894 **
Z1isr.d.l2	0.2428555	0.2834196	0.857	0.393265
Z1psg.d.l2	0.0441929	0.0995143	0.444	0.657801
Z1pee.d.l2	-0.0950488	0.1288929	-0.737	0.462341
Z1dls0102	0.0455141	0.0115399	3.944	0.000137 ***
Z1dao0311	0.0089628	0.0327098	0.274	0.784562
Z1dao0607	0.0691384	0.0317210	2.180	0.031292 *
Z1dao0706	-0.0879357	0.0329601	-2.668	0.008714 **
Z1dls0103	0.0017089	0.0207432	0.082	0.934483
Z1dao0903	-0.0236802	0.0320978	-0.738	0.462143
Z1dls0110	0.0030172	0.0228671	0.132	0.895254
Z1dls0702	0.0002751	0.0248268	0.011	0.991179
Z1dao0112	0.0157639	0.0313131	0.503	0.615609
Z1dao0108	0.0256935	0.0305272	0.842	0.401696
Z1dao0708	-0.0429397	0.0312180	-1.375	0.171611
Z1sd1	0.1449578	0.0161122	8.997	4.98e-15 ***
Z1sd2	0.0427230	0.0200692	2.129	0.035369 *
Z1sd3	0.0490389	0.0228116	2.150	0.033635 *
Z1sd4	0.0117874	0.0174997	0.674	0.501908
Z1sd5	0.0537284	0.0190496	2.820	0.005635 **

B.2. Resultados en software R-project.

```
Z1sd6      0.0988914  0.0199287  4.962 2.39e-06 ***
Z1sd7      0.1720164  0.0254417  6.761 5.68e-10 ***
Z1sd8      0.1508471  0.0298590  5.052 1.63e-06 ***
Z1sd9      0.1186124  0.0278514  4.259 4.17e-05 ***
Z1sd10     0.0521517  0.0220703  2.363 0.019778 *
Z1sd11     0.0372107  0.0146817  2.534 0.012582 *
Z0[, c(4, 5)]psg.d 0.1785510  0.1143959  1.561 0.121268 .
Z0[, c(4, 5)]pee.d -0.2362309  0.1384456 -1.706 0.090604 .
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.02862 on 117 degrees of freedom
Multiple R-squared: 0.8947, Adjusted R-squared: 0.8623
F-statistic: 27.62 on 36 and 117 DF, p-value: < 2.2e-16

Response isr.d :

Call:
lm(formula = isr.d ~ -1 + ECT + Z1 + Z0[, c(4, 5)])

Residuals:

Min	1Q	Median	3Q	Max
-0.0174140	-0.0033674	-0.0003043	0.0032859	0.0208635

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
ECTect1	-4.037e-02	1.417e-02	-2.848	0.005199 **
ECTect2	1.160e-01	3.288e-02	3.528	0.000600 ***
Z1csg.d.l1	3.061e-02	1.222e-02	2.506	0.013583 *
Z1cee.d.l1	-5.563e-02	2.969e-02	-1.874	0.063443 .
Z1isr.d.l1	-9.730e-03	7.966e-02	-0.122	0.902992
Z1psg.d.l1	-3.259e-02	2.871e-02	-1.135	0.258597
Z1pee.d.l1	-1.593e-02	3.477e-02	-0.458	0.647720
Z1csg.d.l2	1.216e-02	8.775e-03	1.386	0.168527
Z1cee.d.l2	-4.564e-02	2.036e-02	-2.242	0.026862 *
Z1isr.d.l2	6.632e-02	7.688e-02	0.863	0.390103
Z1psg.d.l2	1.430e-02	2.699e-02	0.530	0.597211
Z1pee.d.l2	-3.824e-03	3.496e-02	-0.109	0.913079
Z1dls0102	-1.083e-02	3.130e-03	-3.460	0.000754 ***
Z1dao0311	-5.836e-03	8.872e-03	-0.658	0.511976
Z1dao0607	1.436e-04	8.604e-03	0.017	0.986709
Z1dao0706	-1.788e-02	8.940e-03	-1.999	0.047873 *
Z1dls0103	-2.766e-03	5.626e-03	-0.492	0.623914
Z1dao0903	1.029e-02	8.706e-03	1.182	0.239751
Z1dls0110	8.753e-03	6.203e-03	1.411	0.160831
Z1dls0702	-4.555e-02	6.734e-03	-6.764	5.61e-10 ***
Z1dao0112	3.298e-02	8.493e-03	3.883	0.000171 ***
Z1dao0108	2.671e-02	8.280e-03	3.226	0.001628 **
Z1dao0708	1.606e-02	8.468e-03	0.190	0.849924
Z1sd1	2.682e-02	4.370e-03	6.137	1.18e-08 ***
Z1sd2	-6.119e-04	5.444e-03	-0.112	0.910686
Z1sd3	5.869e-05	6.188e-03	0.009	0.992448
Z1sd4	-5.216e-03	4.747e-03	-1.099	0.274097
Z1sd5	4.809e-03	5.167e-03	0.931	0.353929
Z1sd6	6.756e-03	5.406e-03	1.250	0.213838
Z1sd7	1.826e-02	6.901e-03	2.646	0.009264 **
Z1sd8	1.132e-02	8.099e-03	1.398	0.164788
Z1sd9	1.046e-02	7.554e-03	1.385	0.168698
Z1sd10	7.956e-03	5.986e-03	1.329	0.186413
Z1sd11	5.337e-03	3.982e-03	1.340	0.182811
Z0[, c(4, 5)]psg.d	-1.034e-01	3.103e-02	-3.333	0.001152 **
Z0[, c(4, 5)]pee.d	2.663e-02	3.755e-02	0.709	0.479620

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.007762 on 117 degrees of freedom
Multiple R-squared: 0.7329, Adjusted R-squared: 0.6507
F-statistic: 8.916 on 36 and 117 DF, p-value: < 2.2e-16

B. Anexo de Resultados

```
>
> rlm.4.5 <- lm(Z0[,c(4,5)]~ -1 + Z1)
> summary(rlm.4.5)
Response psg.d :

Call:
lm(formula = psg.d ~ -1 + Z1)

Residuals:
    Min       1Q   Median       3Q      Max
-0.067202 -0.010085  0.000272  0.010629  0.052130

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
Z1csg.d.l1  0.032969    0.019865   1.660 0.099573 .
Z1cee.d.l1  0.006781    0.061530   0.110 0.912423
Z1isr.d.l1 -0.304071    0.231191  -1.315 0.190917
Z1psg.d.l1  0.201914    0.082103   2.459 0.015336 *
Z1pee.d.l1 -0.052968    0.102681  -0.516 0.606902
Z1csg.d.l2  0.002724    0.021798   0.125 0.900764
Z1cee.d.l2 -0.010704    0.054333  -0.197 0.844147
Z1isr.d.l2 -0.218164    0.224725  -0.971 0.333584
Z1psg.d.l2  0.010092    0.077598   0.130 0.896736
Z1pee.d.l2  0.059787    0.101499   0.589 0.556934
Z1dls0102 -0.001547    0.002217  -0.698 0.486517
Z1dao0311  0.070871    0.024846   2.852 0.005104 **
Z1dao0607 -0.016442    0.025023  -0.657 0.512365
Z1dao0706 -0.093697    0.025033  -3.743 0.000280 ***
Z1dls0103  0.068751    0.015229   4.514 1.48e-05 ***
Z1dao0903  0.083612    0.024623   3.396 0.000927 ***
Z1dls0110 -0.007581    0.017512  -0.433 0.665864
Z1dls0702  0.034808    0.019583   1.777 0.077999 .
Z1dao0112  0.006930    0.024922   0.278 0.781430
Z1dao0108 -0.002917    0.024549  -0.119 0.905619
Z1dao0708  0.019891    0.025126   0.792 0.430106
Z1sd1      -0.001825    0.012093  -0.151 0.880298
Z1sd2       0.001564    0.014972   0.104 0.916964
Z1sd3       0.016303    0.016675   0.978 0.330186
Z1sd4      -0.003713    0.012094  -0.307 0.759337
Z1sd5       0.011304    0.014124   0.800 0.425082
Z1sd6      -0.006521    0.015489  -0.421 0.674494
Z1sd7      -0.024742    0.018364  -1.347 0.180388
Z1sd8       0.002791    0.018351   0.152 0.879373
Z1sd9       0.004040    0.014295   0.283 0.777945
Z1sd10     -0.005020    0.010744  -0.467 0.641171
Z1sd11     -0.001428    0.009809  -0.146 0.884525
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.02315 on 121 degrees of freedom
Multiple R-squared:  0.5542,    Adjusted R-squared:  0.4363
F-statistic:  4.7 on 32 and 121 DF,  p-value: 2.68e-10
```

Response pee.d :

```
Call:
lm(formula = pee.d ~ -1 + Z1)

Residuals:
    Min       1Q   Median       3Q      Max
-0.046153 -0.008089 -0.000663  0.006806  0.045388

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
Z1csg.d.l1 -0.0008415    0.0164238  -0.051 0.959220
Z1cee.d.l1 -0.0080186    0.0508710  -0.158 0.875014
Z1isr.d.l1 -0.3282905    0.1911413  -1.718 0.088441 .
Z1psg.d.l1 -0.0086591    0.0678805  -0.128 0.898706
```

```

Z1pee.d.l1 -0.0281984 0.0848931 -0.332 0.740340
Z1csg.d.l2 0.0093888 0.0180216 0.521 0.603336
Z1cee.d.l2 -0.0123615 0.0449212 -0.275 0.783647
Z1isr.d.l2 0.2352731 0.1857957 1.266 0.207838
Z1psg.d.l2 -0.0316395 0.0641554 -0.493 0.622786
Z1pee.d.l2 -0.0479647 0.0839165 -0.572 0.568669
Z1dls0102 0.0018873 0.0018328 1.030 0.305191
Z1dao0311 0.0220811 0.0205418 1.075 0.284542
Z1dao0607 -0.0365256 0.0206878 -1.766 0.079992 .
Z1dao0706 0.0209550 0.0206964 1.012 0.313321
Z1dls0103 0.0101151 0.0125907 0.803 0.423330
Z1dao0903 -0.0119045 0.0203577 -0.585 0.559793
Z1dls0110 -0.0522939 0.0144781 -3.612 0.000444 ***
Z1dls0702 0.0171606 0.0161904 1.060 0.291289
Z1dao0112 0.0393711 0.0206047 1.911 0.058399 .
Z1dao0108 -0.0172372 0.0202967 -0.849 0.397413
Z1dao0708 0.0103173 0.0207735 0.497 0.620333
Z1sd1 0.0121376 0.0099982 1.214 0.227121
Z1sd2 0.0309118 0.0123784 2.497 0.013861 *
Z1sd3 -0.0009964 0.0137862 -0.072 0.942501
Z1sd4 -0.0005746 0.0099985 -0.057 0.954266
Z1sd5 0.0005964 0.0116771 0.051 0.959352
Z1sd6 0.0174277 0.0128054 1.361 0.176055
Z1sd7 -0.0124380 0.0151826 -0.819 0.414269
Z1sd8 0.0018157 0.0151718 0.120 0.904939
Z1sd9 -0.0083525 0.0118189 -0.707 0.481105
Z1sd10 -0.0058750 0.0088827 -0.661 0.509613
Z1sd11 0.0042092 0.0081097 0.519 0.604684
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Residual standard error: 0.01914 on 121 degrees of freedom
Multiple R-squared: 0.357, Adjusted R-squared: 0.1869
F-statistic: 2.099 on 32 and 121 DF, p-value: 0.002124

```

>
> residuos=data.frame(cbind(residuals(rlm.1.2.3),residuals(rlm.4.5)))
>
> # Matriz de varianzas y covarianzas, determinante y loglik
> omega=crossprod(as.matrix(residuos))/N; round(omega,8)
      csg.d    cee.d    isr.d    psg.d    pee.d
csg.d 0.00490532 0.00034075 -6.133e-05 0.000e+00 0.00000000
cee.d 0.00034075 0.00062627 4.671e-05 0.000e+00 0.00000000
isr.d -0.00006133 0.00004671 4.608e-05 0.000e+00 0.00000000
psg.d 0.00000000 0.00000000 0.000e+00 4.237e-04 0.00003352
pee.d 0.00000000 0.00000000 0.000e+00 3.352e-05 0.00028962
> detcov=det(omega);detcov
[1] 1.473509e-17
> K=k-1
> c=N*(K/2)- (N*(K/2)*log(2*pi))
> logLmax=-(0.5*N)*log(detcov)+c;logLmax
[1] 2644.369
>
> aic=log(detcov)+(K^2*p)*(2/N);aic
[1] -37.77591
> sc=log(detcov)+(K^2*p)*(log(N)/N);sc
[1] -36.2904
> HQ=log(detcov)+(K^2*p)*(2*log(log(N))/N);HQ
[1] -37.17247

```


B.3. Resultados en software Gretl.

B.3.1. Estimación del VECM en el Escenario 1 para un modelo no restringido.

```
# Determinación del rango de cointegración
coint2 3 l_CSGKG l_CEEKWH l_ISR12 l_psgipc l_peekpc ; \
dls0102 dao0311 dao0607 dao0708 dls0702 dao0112 dao0108 dao0706 dls0103 dao0903 dls0110 \
--seasonals --rc

? coint2 3 l_CSGKG l_CEEKWH l_ISR12 l_psgipc l_peekpc ; dls0102 dao0311 \
dao0607 dao0708 dls0702 dao0112 dao0108 dao0706 dls0103 dao0903 dls0110 \
--seasonals --rc
```

```
Johansen test:
Number of equations = 5
Lag order = 3
Estimation period: 2000:04 - 2012:12 (T = 153)
Case 2: Restricted constant
Exogenous regressor(s): dls0102 dao0311 dao0607 dao0708 dls0702 dao0112
dao0108 dao0706 dls0103 dao0903 dls0110
```

Log-likelihood = 2331.05 (including constant term: 1896.85)

Cointegration tests, ignoring exogenous variables

Rank	Eigenvalue	Trace test	p-value	Lmax test	p-value
0	0.45001	165.61	[0.0000]	91.473	[0.0000]
1	0.26760	74.137	[0.0002]	47.649	[0.0000]
2	0.13285	26.489	[0.3196]	21.809	[0.0567]
3	0.022415	4.6800	[0.9821]	3.4685	[0.9692]
4	0.0078867	1.2114	[0.9075]	1.2114	[0.9067]

Corrected for sample size (df = 115)

Rank	Trace test	p-value
0	165.61	[0.0000]
1	74.137	[0.0003]
2	26.489	[0.3378]
3	4.6800	[0.9827]
4	1.2114	[0.9067]

Note: in general, the test statistics above are valid only in the absence of additional regressors.

eigenvalue	0.45001	0.26760	0.13285	0.022415	0.0078867
------------	---------	---------	---------	----------	-----------

beta (cointegrating vectors)

	l_CSGKG	l_CEEKWH	l_ISR12	l_psgipc	l_peekpc	const
l_CSGKG	-22.071	-3.4922	8.0094	1.7199	-3.2191	
l_CEEKWH	25.373	-43.379	-27.682	-1.1826	-0.62627	
l_ISR12	-15.931	34.608	24.769	-4.1368	23.631	
l_psgipc	-5.3573	2.9566	8.1108	-6.8755	9.7830	
l_peekpc	8.7427	-6.6724	16.708	5.1911	-5.6248	
const	-215.38	713.41	298.22	41.597	-88.752	

alpha (adjustment vectors)

	l_CSGKG	l_CEEKWH	l_ISR12	l_psgipc	l_peekpc
l_CSGKG	0.047911	0.022203	-0.0046037	0.0039236	0.00028763
l_CEEKWH	-0.0028066	0.0093580	0.0067310	0.0012214	0.00017250
l_ISR12	0.0023274	-0.0012978	0.0020215	-0.00036221	-0.00013385
l_psgipc	-0.0029996	-0.0015769	-0.00061140	0.0026527	-0.00078264
l_peekpc	-0.0012618	0.0026288	-0.0011805	-0.00080880	-0.0013190

renormalized beta

	l_CSGKG	l_CEEKWH	l_ISR12	l_psgipc
l_CSGKG	1.0000	0.080504	0.32337	-0.25015
l_CEEKWH	-1.1496	1.0000	-1.1176	0.17201
l_ISR12	0.72181	-0.79780	1.0000	0.60168
l_psgipc	0.24272	-0.068158	0.32746	1.0000

```

l_peekpc      -0.39611      0.15382      0.67455      -0.75502      1.0000
const         9.7583       -16.446      12.040       -6.0500      15.779

renormalized alpha
l_CSGKG       -1.0575       -0.96317     -0.11403     -0.026977    -0.0016179
l_CEEKWH      0.061946     -0.40594      0.16672     -0.0083974   -0.00097028
l_ISR12       -0.051370     0.056297     0.050070     0.0024904    0.00075285
l_psgipc      0.066206     0.068405     -0.015144    -0.018238     0.0044021
l_peekpc      0.027849     -0.11403     -0.029240     0.0055609    0.0074188

long-run matrix (alpha * beta')
      l_CSGKG      l_CEEKWH      l_ISR12      l_psgipc      l_peekpc      const
l_CSGKG      -1.1661      0.37508     -0.11834     -0.25253      0.21255      4.2858
l_CEEKWH      0.084723     -0.66503     0.53432     0.090588      0.030852      9.3234
l_ISR12      -0.030839     0.059903     -0.033587     0.0012712     0.061655     -0.82746
l_psgipc      0.073898     0.0065734    -0.051397     -0.019446     -0.0077459    -0.48144
l_peekpc      0.012068     -0.11159     0.054015     -0.0023856     -0.045075

# Estimación del VECM
c2p3r2 <- vecm 3 2 l_CSGKG l_CEEKWH l_ISR12 l_psgipc l_peekpc ; \
  dls0102 dao0311 dao0607 dao0708 dls0702 dao0112 dao0108 dao0706 dls0103 dao0903 dls0110 \
  --seasonals --rc

? c2p3r2 <- vecm 3 2 l_CSGKG l_CEEKWH l_ISR12 l_psgipc l_peekpc ; dls0102 \
  dao0311 dao0607 dao0708 dls0702 dao0112 dao0108 dao0706 dls0103 dao0903 \
  dls0110 --seasonals --rc

VECM system, lag order 3
Maximum likelihood estimates, observations 2000:04-2012:12 (T = 153)
Cointegration rank = 2
Case 2: Restricted constant

beta (cointegrating vectors, standard errors in parentheses)

l_CSGKG      1.0000      0.00000
(0.00000)    (0.00000)
l_CEEKWH      0.00000      1.0000
(0.00000)    (0.00000)
l_ISR12      -0.17877     -0.78341
(0.13093)    (0.075430)
l_psgipc      0.15045     -0.080270
(0.075940)    (0.043751)
l_peekpc     -0.20071      0.16997
(0.12135)    (0.069911)
const        -8.3725     -15.772
(0.81574)    (0.46997)

alpha (adjustment vectors)

l_CSGKG      -1.1350      0.25246
l_CEEKWH      0.029266     -0.47716
l_ISR12      -0.046838      0.11535
l_psgipc      0.071713     -0.0077043
l_peekpc      0.018669     -0.14605

Log-likelihood = 1883.6103
Determinant of covariance matrix = 1.3940374e-017
AIC = -22.2041
BIC = -18.5398
HQC = -20.7156

Equation 1: d_l_CSGKG

      coefficient      std. error      t-ratio      p-value
-----
d_l_CSGKG_1      0.156365      0.126455      1.237      0.2187
d_l_CSGKG_2      0.0807798      0.0908682      0.8890      0.3758
d_l_CEEKWH_1     -0.354433      0.302215     -1.173      0.2432
d_l_CEEKWH_2      0.0857510      0.210276      0.4078      0.6842

```

B. Anexo de Resultados

d_l_ISR12_1	-0.532256	0.814138	-0.6538	0.5145	
d_l_ISR12_2	-0.328367	0.789961	-0.4157	0.6784	
d_l_psgipc_1	0.0646390	0.293001	0.2206	0.8258	
d_l_psgipc_2	0.601724	0.279936	2.150	0.0336	**
d_l_peekpc_1	-0.127602	0.360386	-0.3541	0.7239	
d_l_peekpc_2	-0.523639	0.360343	-1.453	0.1488	
dls0102	-0.0951412	0.0325900	-2.919	0.0042	***
dao0311	-0.419279	0.0882685	-4.750	5.78e-06	***
dao0607	-0.221408	0.0885959	-2.499	0.0138	**
dao0708	-0.342205	0.0875943	-3.907	0.0002	***
dls0702	-0.0680692	0.0685957	-0.9923	0.3231	
dao0112	-0.00197890	0.0868384	-0.02279	0.9819	
dao0108	0.0223778	0.0856964	0.2611	0.7944	
dao0706	-0.370853	0.0873888	-4.244	4.40e-05	***
dls0103	0.0501834	0.0543023	0.9241	0.3573	
dao0903	0.0231265	0.0858568	0.2694	0.7881	
dls0110	-0.0759927	0.0612521	-1.241	0.2172	
S1	-0.159383	0.0453920	-3.511	0.0006	***
S2	-0.0847185	0.0558052	-1.518	0.1317	
S3	-0.0725715	0.0637753	-1.138	0.2575	
S4	0.0451492	0.0492961	0.9159	0.3616	
S5	0.267329	0.0531781	5.027	1.79e-06	***
S6	0.511851	0.0557154	9.187	1.68e-015	***
S7	0.689192	0.0703369	9.798	6.03e-017	***
S8	0.466654	0.0838761	5.564	1.68e-07	***
S9	0.246833	0.0783070	3.152	0.0021	***
S10	0.0149471	0.0617582	0.2420	0.8092	
S11	-0.0588905	0.0410929	-1.433	0.1545	
EC1	-1.13500	0.145627	-7.794	2.83e-012	***
EC2	0.252465	0.327506	0.7709	0.4423	
Mean dependent var	-0.000880	S.D. dependent var	0.201891		
Sum squared resid	0.766762	S.E. of regression	0.080610		
R-squared	0.876242	Adjusted R-squared	0.840583		
rho	0.045338	Durbin-Watson	1.864856		

Equation 2: d_l_CEEKWH

	coefficient	std. error	t-ratio	p-value	
d_l_CSGKG_1	0.106916	0.0459138	2.329	0.0216	**
d_l_CSGKG_2	0.0490466	0.0329928	1.487	0.1398	
d_l_CEEKWH_1	-0.296302	0.109730	-2.700	0.0079	***
d_l_CEEKWH_2	-0.224954	0.0763480	-2.946	0.0039	***
d_l_ISR12_1	0.742141	0.295601	2.511	0.0134	**
d_l_ISR12_2	0.167555	0.286823	0.5842	0.5602	
d_l_psgipc_1	0.0646076	0.106384	0.6073	0.5448	
d_l_psgipc_2	0.0420151	0.101640	0.4134	0.6801	
d_l_peekpc_1	-0.00389535	0.130850	-0.02977	0.9763	
d_l_peekpc_2	-0.0543692	0.130835	-0.4156	0.6785	
dls0102	0.0426199	0.0118329	3.602	0.0005	***
dao0311	0.0157016	0.0320489	0.4899	0.6251	
dao0607	0.0733295	0.0321678	2.280	0.0244	**
dao0708	-0.0402869	0.0318041	-1.267	0.2077	
dls0702	-0.000255648	0.0249060	-0.01026	0.9918	
dao0112	0.00913723	0.0315297	0.2898	0.7725	
dao0108	0.0301971	0.0311150	0.9705	0.3338	
dao0706	-0.109181	0.0317295	-3.441	0.0008	***
dls0103	0.00809183	0.0197163	0.4104	0.6822	
dao0903	-0.00671465	0.0311733	-0.2154	0.8298	
dls0110	0.0164877	0.0222397	0.7414	0.4599	
S1	0.144788	0.0164811	8.785	1.47e-014	***
S2	0.0385520	0.0202620	1.903	0.0595	*
S3	0.0549371	0.0231558	2.372	0.0193	**
S4	0.0134747	0.0178986	0.7528	0.4530	
S5	0.0597150	0.0193081	3.093	0.0025	***
S6	0.0965298	0.0202294	4.772	5.28e-06	***
S7	0.170324	0.0255382	6.669	8.73e-010	***
S8	0.145913	0.0304541	4.791	4.87e-06	***
S9	0.113728	0.0284320	4.000	0.0001	***

B.3. Resultados en software Gretl.

S10	0.0455016	0.0224234	2.029	0.0447	**
S11	0.0322568	0.0149202	2.162	0.0326	**
EC1	0.0292661	0.0528749	0.5535	0.5810	
EC2	-0.477156	0.118912	-4.013	0.0001	***
Mean dependent var	0.000673	S.D. dependent var	0.077382		
Sum squared resid	0.101082	S.E. of regression	0.029268		
R-squared	0.888950	Adjusted R-squared	0.856953		
rho	-0.004897	Durbin-Watson	1.928111		

Equation 3: d_l_ISR12

	coefficient	std. error	t-ratio	p-value	

d_l_CSGKG_1	0.0316253	0.0126456	2.501	0.0138	**
d_l_CSGKG_2	0.0141676	0.00908688	1.559	0.1216	
d_l_CEEKWH_1	-0.0560215	0.0302217	-1.854	0.0663	*
d_l_CEEKWH_2	-0.0435354	0.0210277	-2.070	0.0406	**
d_l_ISR12_1	0.000499893	0.0814143	0.006140	0.9951	
d_l_ISR12_2	0.0874332	0.0789966	1.107	0.2706	
d_l_psgipc_1	-0.0512533	0.0293003	-1.749	0.0828	*
d_l_psgipc_2	0.0157625	0.0279938	0.5631	0.5745	
d_l_peeipc_1	-0.0144015	0.0360388	-0.3996	0.6902	
d_l_peeipc_2	-0.0158216	0.0360346	-0.4391	0.6614	
dls0102	-0.0115220	0.00325901	-3.535	0.0006	***
dao0311	-0.0131776	0.00882690	-1.493	0.1381	
dao0607	0.000600678	0.00885964	0.06780	0.9461	
dao0708	-0.000560881	0.00875948	-0.06403	0.9491	
dls0702	-0.0484233	0.00685961	-7.059	1.24e-010	***
dao0112	0.0329642	0.00868389	3.796	0.0002	***
dao0108	0.0262852	0.00856969	3.067	0.0027	***
dao0706	-0.00803978	0.00873893	-0.9200	0.3595	
dls0103	-0.00902294	0.00543026	-1.662	0.0992	*
dao0903	0.00130444	0.00858573	0.1519	0.8795	
dls0110	0.00758003	0.00612525	1.238	0.2184	
S1	0.0269162	0.00453923	5.930	3.09e-08	***
S2	-0.000566868	0.00558055	-0.1016	0.9193	
S3	-0.00275341	0.00637757	-0.4317	0.6667	
S4	-0.00614592	0.00492963	-1.247	0.2150	
S5	0.00263438	0.00531784	0.4954	0.6212	
S6	0.00788333	0.00557157	1.415	0.1597	
S7	0.0216851	0.00703373	3.083	0.0026	***
S8	0.0136210	0.00838766	1.624	0.1071	
S9	0.0126422	0.00783074	1.614	0.1091	
S10	0.0105403	0.00617585	1.707	0.0905	*
S11	0.00661059	0.00410931	1.609	0.1104	
EC1	-0.0468378	0.0145628	-3.216	0.0017	***
EC2	0.115350	0.0327508	3.522	0.0006	***
Mean dependent var	0.000677	S.D. dependent var	0.013159		
Sum squared resid	0.007668	S.E. of regression	0.008061		
R-squared	0.709437	Adjusted R-squared	0.625715		
rho	-0.069100	Durbin-Watson	2.097751		

Equation 4: d_l_psgipc

	coefficient	std. error	t-ratio	p-value	

d_l_CSGKG_1	-0.0163928	0.0362670	-0.4520	0.6521	
d_l_CSGKG_2	-0.0204439	0.0260608	-0.7845	0.4343	
d_l_CEEKWH_1	0.0109458	0.0866747	0.1263	0.8997	
d_l_CEEKWH_2	-0.0216628	0.0603068	-0.3592	0.7201	
d_l_ISR12_1	-0.241597	0.233493	-1.035	0.3029	
d_l_ISR12_2	-0.205879	0.226560	-0.9087	0.3654	
d_l_psgipc_1	0.171105	0.0840321	2.036	0.0440	**
d_l_psgipc_2	-0.0261420	0.0802851	-0.3256	0.7453	
d_l_peeipc_1	-0.0311073	0.103358	-0.3010	0.7640	
d_l_peeipc_2	0.0940271	0.103346	0.9098	0.3648	
dls0102	0.00431471	0.00934674	0.4616	0.6452	
dao0311	0.0778095	0.0253152	3.074	0.0026	***

B. Anexo de Resultados

dao0607	-0.0159538	0.0254091	-0.6279	0.5313	
dao0708	0.0218748	0.0251219	0.8707	0.3857	
dls0702	0.0345529	0.0196731	1.756	0.0816	*
dao0112	0.00776869	0.0249051	0.3119	0.7556	
dao0108	-0.000174763	0.0245776	-0.007111	0.9943	
dao0706	-0.0909816	0.0250629	-3.630	0.0004	***
dls0103	0.0650313	0.0155738	4.176	5.72e-05	***
dao0903	0.0857779	0.0246236	3.484	0.0007	***
dls0110	-0.00531187	0.0175670	-0.3024	0.7629	
S1	0.00313355	0.0130183	0.2407	0.8102	
S2	0.00949622	0.0160048	0.5933	0.5541	
S3	0.0294503	0.0182906	1.610	0.1100	
S4	0.00956198	0.0141380	0.6763	0.5002	
S5	0.0206306	0.0152514	1.353	0.1787	
S6	-0.00802014	0.0159791	-0.5019	0.6167	
S7	-0.0392418	0.0201725	-1.945	0.0541	*
S8	-0.0254404	0.0240555	-1.058	0.2924	
S9	-0.0267066	0.0224583	-1.189	0.2368	
S10	-0.0291103	0.0177121	-1.644	0.1029	
S11	-0.0121927	0.0117854	-1.035	0.3030	
EC1	0.0717132	0.0417656	1.717	0.0886	*
EC2	-0.00770426	0.0939281	-0.08202	0.9348	
Mean dependent var	0.001116	S.D. dependent var	0.030909		
Sum squared resid	0.063069	S.E. of regression	0.023119		
R-squared	0.566254	Adjusted R-squared	0.441277		
rho	0.062988	Durbin-Watson	1.870190		
Equation 5: d_l_peekpc					
	coefficient	std. error	t-ratio	p-value	
d_l_CSGKG_1	-0.0202358	0.0299497	-0.6757	0.5006	
d_l_CSGKG_2	2.52899e-05	0.0215213	0.001175	0.9991	
d_l_CEEKWH_1	0.0870722	0.0715770	1.216	0.2262	
d_l_CEEKWH_2	0.0278913	0.0498020	0.5600	0.5765	
d_l_ISR12_1	-0.325444	0.192821	-1.688	0.0941	*
d_l_ISR12_2	0.281700	0.187095	1.506	0.1348	
d_l_psgipc_1	0.00307162	0.0693947	0.04426	0.9648	
d_l_psgipc_2	-0.0207414	0.0663004	-0.3128	0.7550	
d_l_peekpc_1	-0.0357133	0.0853541	-0.4184	0.6764	
d_l_peekpc_2	-0.0596185	0.0853441	-0.6986	0.4862	
dls0102	0.0149330	0.00771864	1.935	0.0554	*
dao0311	0.0268825	0.0209056	1.286	0.2010	
dao0607	-0.0294119	0.0209832	-1.402	0.1636	
dao0708	0.00979331	0.0207459	0.4721	0.6378	
dls0702	0.0204526	0.0162463	1.259	0.2105	
dao0112	0.0403505	0.0205669	1.962	0.0521	*
dao0108	-0.0184509	0.0202964	-0.9091	0.3652	
dao0706	0.0222188	0.0206973	1.074	0.2852	
dls0103	0.0143472	0.0128610	1.116	0.2669	
dao0903	-0.0122360	0.0203344	-0.6017	0.5485	
dls0110	-0.0507287	0.0145070	-3.497	0.0007	***
S1	0.00572590	0.0107507	0.5326	0.5953	
S2	0.0249589	0.0132170	1.888	0.0614	*
S3	-0.00474367	0.0151046	-0.3141	0.7540	
S4	-4.17146e-05	0.0116753	-0.003573	0.9972	
S5	-0.00386141	0.0125948	-0.3066	0.7597	
S6	0.0113721	0.0131957	0.8618	0.3905	
S7	-0.0159733	0.0166587	-0.9589	0.3396	
S8	0.00353705	0.0198653	0.1781	0.8590	
S9	-0.00177812	0.0185463	-0.09587	0.9238	
S10	0.00219950	0.0146269	0.1504	0.8807	
S11	0.00886137	0.00973249	0.9105	0.3644	
EC1	0.0186690	0.0344905	0.5413	0.5893	
EC2	-0.146048	0.0775669	-1.883	0.0622	*
Mean dependent var	0.000985	S.D. dependent var	0.021269		
Sum squared resid	0.043011	S.E. of regression	0.019092		
R-squared	0.375843	Adjusted R-squared	0.196001		

rho 0.005001 Durbin-Watson 1.986403

Cross-equation covariance matrix:

	l_CSGKG	l_CEEKWH	l_ISR12	l_psgipc	l_peeipc
l_CSGKG	0.0050115	0.00039116	-8.0920e-005	0.00018551	-6.2905e-005
l_CEEKWH	0.00039116	0.00066067	3.8539e-005	6.6345e-005	-6.1077e-005
l_ISR12	-8.0920e-005	3.8539e-005	5.0116e-005	-4.1818e-005	4.5636e-006
l_psgipc	0.00018551	6.6345e-005	-4.1818e-005	0.00041221	3.3884e-005
l_peeipc	-6.2905e-005	-6.1077e-005	4.5636e-006	3.3884e-005	0.00028111

determinant = 1.39404e-017

B.3.2. Estimación del VECM en el Escenario 1 con precios débilmente exóg.

RESULTADOS DE LA ESTIMACION DEL VECM CON PRECIOS DEBILMENTE EXOGENOS

Restriction set

1: a[4] = 0
2: a[5] = 0

VECM system, lag order 3

Maximum likelihood estimates, observations 2000:04-2012:12 (T = 153)

Cointegration rank = 2

Case 2: Restricted constant

Restrictions on alpha:

a4 = 0
a5 = 0

Unrestricted loglikelihood (lu) = 1883.6103

Restricted loglikelihood (lr) = 1879.3689

2 * (lu - lr) = 8.48279

P(Chi-square(4) > 8.48279) = 0.0754106

beta (cointegrating vectors)

	22.364	-3.1687
l_CSGKG	22.364	-3.1687
l_CEEKWH	-26.240	-45.341
l_ISR12	17.021	36.661
l_psgipc	5.8237	3.2465
l_peeipc	-8.7890	-5.6089
const	223.10	736.59

alpha (adjustment vectors)

	-0.048348	0.023281
l_CSGKG	-0.048348	0.023281
l_CEEKWH	0.0026724	0.010453
l_ISR12	-0.0020032	-0.0013985
l_psgipc	0.00000	0.00000
l_peeipc	0.00000	0.00000

Determinant of covariance matrix = 1.4735099e-017

AIC = -22.1486

BIC = -18.4844

HQC = -20.6601

Equation 1: d_l_CSGKG

	coefficient	std. error	t-ratio	p-value	
d_l_CSGKG_1	0.167166	0.0688536	2.428	0.0167	**
d_l_CSGKG_2	0.0852241	0.0755525	1.128	0.2616	

B. Anexo de Resultados

d_l_CEEKWH_1	-0.330851	0.213267	-1.551	0.1235	
d_l_CEEKWH_2	0.0963830	0.188324	0.5118	0.6097	
d_l_ISR12_1	-0.570847	0.801325	-0.7124	0.4776	
d_l_ISR12_2	-0.347162	0.778915	-0.4457	0.6566	
d_l_psgipc_1	0.0828847	0.284577	0.2913	0.7714	
d_l_psgipc_2	0.625561	0.268960	2.326	0.0217	**
d_l_peeipc_1	-0.148185	0.355899	-0.4164	0.6779	
d_l_peeipc_2	-0.549541	0.351805	-1.562	0.1209	
dls0102	-0.0975309	0.00768378	-12.69	7.23e-024	***
dao0311	-0.423232	0.0861177	-4.915	2.87e-06	***
dao0607	-0.221500	0.0867300	-2.554	0.0119	**
dao0708	-0.343106	0.0870890	-3.940	0.0001	***
dls0702	-0.0666581	0.0678753	-0.9821	0.3281	
dao0112	-0.00436141	0.0863816	-0.05049	0.9598	
dao0108	0.0215300	0.0850903	0.2530	0.8007	
dao0706	-0.369743	0.0867659	-4.261	4.09e-05	***
dls0103	0.0523630	0.0527843	0.9920	0.3232	
dao0903	0.0246431	0.0853459	0.2887	0.7733	
dls0110	-0.0830572	0.0606968	-1.368	0.1738	
S1	-0.161335	0.0419157	-3.849	0.0002	***
S2	-0.0871120	0.0518944	-1.679	0.0958	*
S3	-0.0761947	0.0577963	-1.318	0.1899	
S4	0.0406313	0.0419171	0.9693	0.3343	
S5	0.262911	0.0489540	5.371	3.95e-07	***
S6	0.511560	0.0536844	9.529	2.44e-016	***
S7	0.694173	0.0636504	10.91	1.27e-019	***
S8	0.478395	0.0636050	7.521	1.13e-011	***
S9	0.260202	0.0495485	5.251	6.69e-07	***
S10	0.0256859	0.0372389	0.6898	0.4917	
S11	-0.0540113	0.0339985	-1.589	0.1148	
EC1	-0.0483484	NA	NA	NA	
EC2	0.0232814	NA	NA	NA	
Mean dependent var	-0.000880	S.D. dependent var	0.201891		
Sum squared resid	0.765923	S.E. of regression	0.080227		
R-squared	0.876377	Adjusted R-squared	0.842095		
rho	0.049510	Durbin-Watson	1.854217		

Equation 2: d_l_CEEKWH

	coefficient	std. error	t-ratio	p-value	

d_l_CSGKG_1	0.105765	0.0248699	4.253	4.23e-05	***
d_l_CSGKG_2	0.0480889	0.0272895	1.762	0.0806	*
d_l_CEEKWH_1	-0.252773	0.0770320	-3.281	0.0014	***
d_l_CEEKWH_2	-0.205453	0.0680225	-3.020	0.0031	***
d_l_ISR12_1	0.697642	0.289438	2.410	0.0175	**
d_l_ISR12_2	0.148323	0.281343	0.5272	0.5990	
d_l_psgipc_1	0.0730092	0.102789	0.7103	0.4789	
d_l_psgipc_2	0.0534692	0.0971481	0.5504	0.5831	
d_l_peeipc_1	-0.0179521	0.128550	-0.1397	0.8892	
d_l_peeipc_2	-0.0730437	0.127072	-0.5748	0.5665	
dls0102	0.0447920	0.00277537	16.14	9.49e-032	***
dao0311	0.0164006	0.0311056	0.5273	0.5990	
dao0607	0.0748311	0.0313268	2.389	0.0185	**
dao0708	-0.0418254	0.0314565	-1.330	0.1862	
dls0702	0.00243627	0.0245165	0.09937	0.9210	
dao0112	0.00770065	0.0312010	0.2468	0.8055	
dao0108	0.0292447	0.0307345	0.9515	0.3433	
dao0706	-0.109616	0.0313398	-3.498	0.0007	***
dls0103	0.0115949	0.0190656	0.6082	0.5442	
dao0903	-0.00593890	0.0308269	-0.1927	0.8476	
dls0110	0.0140171	0.0219236	0.6394	0.5238	
S1	0.141765	0.0151399	9.364	6.02e-016	***
S2	0.0357000	0.0187442	1.905	0.0592	*
S3	0.0521851	0.0208760	2.500	0.0138	**
S4	0.0112602	0.0151404	0.7437	0.4585	
S5	0.0556058	0.0176821	3.145	0.0021	***
S6	0.0936101	0.0193908	4.828	4.15e-06	***
S7	0.170537	0.0229905	7.418	1.93e-011	***

B.3. Resultados en software Gretl.

S8	0.150917	0.0229741	6.569	1.40e-09	***
S9	0.121307	0.0178969	6.778	4.96e-010	***
S10	0.0526433	0.0134507	3.914	0.0002	***
S11	0.0359615	0.0122802	2.928	0.0041	***
EC1	0.00267237	NA	NA	NA	
EC2	0.0104528	NA	NA	NA	
Mean dependent var	0.000673	S.D. dependent var	0.077382		
Sum squared resid	0.099926	S.E. of regression	0.028978		
R-squared	0.890221	Adjusted R-squared	0.859778		
rho	0.004694	Durbin-Watson	1.907647		

Equation 3: d_l_ISR12

	coefficient	std. error	t-ratio	p-value	
d_l_CSGKG_1	0.0271798	0.00692432	3.925	0.0001	***
d_l_CSGKG_2	0.0121263	0.00759799	1.596	0.1131	
d_l_CEEKWH_1	-0.0565434	0.0214474	-2.636	0.0095	***
d_l_CEEKWH_2	-0.0448628	0.0189390	-2.369	0.0195	**
d_l_ISR12_1	0.0129721	0.0805859	0.1610	0.8724	
d_l_ISR12_2	0.0951422	0.0783322	1.215	0.2269	
d_l_psgipc_1	-0.0537034	0.0286187	-1.877	0.0630	*
d_l_psgipc_2	0.0124161	0.0270482	0.4590	0.6470	
d_l_peekipc_1	-0.0112035	0.0357912	-0.3130	0.7548	
d_l_peekipc_2	-0.0112846	0.0353795	-0.3190	0.7503	
dls0102	-0.0106208	0.000772725	-13.74	2.51e-026	***
dao0311	-0.0125769	0.00866049	-1.452	0.1491	
dao0607	0.000871248	0.00872207	0.09989	0.9206	
dao0708	-0.000176492	0.00875817	-0.02015	0.9840	
dls0702	-0.0486904	0.00682593	-7.133	8.29e-011	***
dao0112	0.0333156	0.00868703	3.835	0.0002	***
dao0108	0.0265551	0.00855717	3.103	0.0024	***
dao0706	-0.00762832	0.00872568	-0.8742	0.3837	
dls0103	-0.00960634	0.00530829	-1.810	0.0729	*
dao0903	0.00132397	0.00858288	0.1543	0.8777	
dls0110	0.00814447	0.00610402	1.334	0.1847	
S1	0.0273329	0.00421528	6.484	2.12e-09	***
S2	4.95154e-05	0.00521880	0.009488	0.9924	
S3	-0.00165374	0.00581233	-0.2845	0.7765	
S4	-0.00484712	0.00421543	-1.150	0.2525	
S5	0.00365588	0.00492310	0.7426	0.4592	
S6	0.00789473	0.00539881	1.462	0.1463	
S7	0.0204875	0.00640105	3.201	0.0018	***
S8	0.0110814	0.00639648	1.732	0.0858	*
S9	0.00982246	0.00498288	1.971	0.0510	*
S10	0.00831900	0.00374496	2.221	0.0282	**
S11	0.00559641	0.00341909	1.637	0.1043	
EC1	-0.00200323	NA	NA	NA	
EC2	-0.00139846	NA	NA	NA	
Mean dependent var	0.000677	S.D. dependent var	0.013159		
Sum squared resid	0.007746	S.E. of regression	0.008068		
R-squared	0.706465	Adjusted R-squared	0.625064		
rho	-0.067776	Durbin-Watson	2.093629		

Equation 4: d_l_psgipc

	coefficient	std. error	t-ratio	p-value	
d_l_CSGKG_1	0.0329691	0.0200312	1.646	0.1024	
d_l_CSGKG_2	0.00272382	0.0219801	0.1239	0.9016	
d_l_CEEKWH_1	0.00678135	0.0620448	0.1093	0.9132	
d_l_CEEKWH_2	-0.0107044	0.0547882	-0.1954	0.8454	
d_l_ISR12_1	-0.304071	0.233126	-1.304	0.1946	
d_l_ISR12_2	-0.218164	0.226606	-0.9627	0.3376	
d_l_psgipc_1	0.201914	0.0827905	2.439	0.0162	**
d_l_psgipc_2	0.0100923	0.0782472	0.1290	0.8976	
d_l_peekipc_1	-0.0529678	0.103540	-0.5116	0.6099	
d_l_peekipc_2	0.0597873	0.102349	0.5842	0.5602	

B. Anexo de Resultados

dls0102	-0.00154736	0.00223540	-0.6922	0.4902	
dao0311	0.0708710	0.0250538	2.829	0.0055	***
dao0607	-0.0164423	0.0252319	-0.6516	0.5159	
dao0708	0.0198914	0.0253364	0.7851	0.4340	
dls0702	0.0348083	0.0197466	1.763	0.0805	*
dao0112	0.00693015	0.0251306	0.2758	0.7832	
dao0108	-0.00291684	0.0247549	-0.1178	0.9064	
dao0706	-0.0936969	0.0252424	-3.712	0.0003	***
dls0103	0.0687505	0.0153563	4.477	1.75e-05	***
dao0903	0.0836122	0.0248293	3.367	0.0010	***
dls0110	-0.00758067	0.0176582	-0.4293	0.6685	
S1	-0.00182498	0.0121943	-0.1497	0.8813	
S2	0.00156423	0.0150974	0.1036	0.9177	
S3	0.0163026	0.0168144	0.9696	0.3342	
S4	-0.00371326	0.0121947	-0.3045	0.7613	
S5	0.0113038	0.0142419	0.7937	0.4290	
S6	-0.00652086	0.0156181	-0.4175	0.6771	
S7	-0.0247423	0.0185175	-1.336	0.1840	
S8	0.00279084	0.0185043	0.1508	0.8804	
S9	0.00404025	0.0144149	0.2803	0.7797	
S10	-0.00501993	0.0108337	-0.4634	0.6440	
S11	-0.00142763	0.00989102	-0.1443	0.8855	
EC1	0.000000	NA	NA	NA	
EC2	0.000000	NA	NA	NA	
Mean dependent var 0.001116 S.D. dependent var 0.030909					
Sum squared resid 0.064826 S.E. of regression 0.023340					
R-squared 0.554170 Adjusted R-squared 0.430536					
rho 0.077634 Durbin-Watson 1.839375					

Equation 5: d_l_peekpc

	coefficient	std. error	t-ratio	p-value	
d_l_CSGKG_1	-0.000841534	0.0165612	-0.05081	0.9596	
d_l_CSGKG_2	0.00938881	0.0181725	0.5167	0.6064	
d_l_CEEKWH_1	-0.00801823	0.0512967	-0.1563	0.8761	
d_l_CEEKWH_2	-0.0123613	0.0452971	-0.2729	0.7854	
d_l_ISR12_1	-0.328290	0.192741	-1.703	0.0911	*
d_l_ISR12_2	0.235272	0.187351	1.256	0.2117	
d_l_psgipc_1	-0.00865910	0.0684486	-0.1265	0.8995	
d_l_psgipc_2	-0.0316397	0.0646923	-0.4891	0.6257	
d_l_peekpc_1	-0.0281987	0.0856035	-0.3294	0.7424	
d_l_peekpc_2	-0.0479641	0.0846188	-0.5668	0.5719	
dls0102	0.00188731	0.00184816	1.021	0.3092	
dao0311	0.0220812	0.0207137	1.066	0.2886	
dao0607	-0.0365257	0.0208610	-1.751	0.0825	*
dao0708	0.0103174	0.0209473	0.4925	0.6232	
dls0702	0.0171606	0.0163259	1.051	0.2953	
dao0112	0.0393711	0.0207772	1.895	0.0605	*
dao0108	-0.0172372	0.0204666	-0.8422	0.4014	
dao0706	0.0209550	0.0208696	1.004	0.3174	
dls0103	0.0101151	0.0126961	0.7967	0.4272	
dao0903	-0.0119047	0.0205281	-0.5799	0.5631	
dls0110	-0.0522939	0.0145993	-3.582	0.0005	***
S1	0.0121375	0.0100819	1.204	0.2310	
S2	0.0309118	0.0124820	2.477	0.0147	**
S3	-0.000996487	0.0139016	-0.07168	0.9430	
S4	-0.000574670	0.0100822	-0.05700	0.9546	
S5	0.000596329	0.0117748	0.05064	0.9597	
S6	0.0174277	0.0129126	1.350	0.1797	
S7	-0.0124381	0.0153097	-0.8124	0.4182	
S8	0.00181559	0.0152988	0.1187	0.9057	
S9	-0.00835259	0.0119178	-0.7009	0.4848	
S10	-0.00587503	0.00895699	-0.6559	0.5131	
S11	0.00420918	0.00817759	0.5147	0.6077	
EC1	0.000000	NA	NA	NA	
EC2	0.000000	NA	NA	NA	
Mean dependent var 0.000985 S.D. dependent var 0.021269					

Sum squared resid	0.044311	S.E. of regression	0.019297
R-squared	0.356965	Adjusted R-squared	0.178644
rho	0.004677	Durbin-Watson	1.987837

Cross-equation covariance matrix:

	l_CSGKG	l_CEEKWH	l_ISR12	l_psgipc	l_peeipc
l_CSGKG	0.0050060	0.00038831	-8.2059e-005	0.00018448	-6.1897e-005
l_CEEKWH	0.00038831	0.00065311	3.8039e-005	6.7732e-005	-6.2431e-005
l_ISR12	-8.2059e-005	3.8039e-005	5.0628e-005	-4.2923e-005	4.2462e-006
l_psgipc	0.00018448	6.7732e-005	-4.2923e-005	0.00042370	3.3524e-005
l_peeipc	-6.1897e-005	-6.2431e-005	4.2462e-006	3.3524e-005	0.00028962

determinant = 1.47351e-017

Apéndice C

Anexo con Análisis comparado de software y programación.

Un aspecto muy importante en toda investigación es la forma en que se realizan los cálculos de las estimaciones. Si bien todo investigador conoce y analiza los aspectos metodológicos de cómo se realizan las estimaciones dependiendo de la técnica econométrica a utilizar, en general se utiliza para realizar dichas estimaciones software que ya tiene muchas de las funciones necesarias pre programadas. Ésto tiene puntos positivos y otros no tanto; en algunos aspectos facilita el trabajo del investigador al momento de obtener los resultados, pero en algunas ocasiones (cuando el cálculo que se desea hacer no esta pre programado en el software) genera una limitación importante que no siempre es fácil de solucionar.

En otras ocasiones la facilidad de cálculo que ofrece este tipo de software determina que el investigador no se interiorice lo suficiente de los aspectos teóricos del cálculo de las estimaciones y pueda cometer errores involuntarios de interpretación.

A lo largo de este trabajo de investigación se fueron realizando los cálculos en diferentes software de forma de tener una mejor comprensión del tipo de cálculo que hace cada uno y las diferencias en análisis y conclusiones que puede representar para un investigador el tipo de software que decide utilizar.

En este sentido, se considera un gran aporte de éste trabajo de investigación poder hacer éste análisis comparado de forma que valide los cálculos de cada uno respecto a las definiciones teóricas de las estimaciones.

La comparación se hizo entre:

1. **R-project** (<https://www.r-project.org/>) , es un software libre muy conocido para procesamiento estadísticos en general, con mucha versatilidad dado que no solo es un software libre, sino que es de código abierto por lo tanto, se puede acceder a la programación de cada función pre programada en cada uno de los paquetes del mismo, y modificarlo en función de las necesidades de cada investigador.

-
2. **Gretl** (Gnu Regression, Econometrics and Time-series Library, <http://gretl.sourceforge.net/es.html>) es un paquete de software, libre y de código abierto, para el análisis econométrico escrito en el lenguaje de programación C.
 3. **Eviews** (<http://www.eviews.com/home.html>) es un software comercial, actualmente desarrollado por IHS Global Inc., específico para el análisis econométrico, distribuido bajo diferentes tipos de licencias. Visto sus características, y no siendo de código abierto, el investigador queda más limitado a la interpretación que puede hacer a partir de los resultados obtenidos, sin mucho margen de modificar los cálculos cuando se considere que no son los adecuados para la interpretación.

En todos ellos existen actualmente funciones pre programadas para realizar el tipo de estimaciones necesarias en este trabajo, estimación de los modelos VAR, VECM, test de causalidad, invarianza paramétrica, pruebas de hipótesis, normalidad, homoscedasticidad, autocorrelación, etc.

El software R-project tiene el package “vars” específico para estimación de modelos VAR y VECM a partir del cual se va a realizar el análisis comparado.

En primer instancia, se programó a partir del package “vars” de R-project, y luego fueron contrastándose los resultados con hacer el mismo tipo de cálculos en Gretl y Eviews, a modo de corroborar la consistencia de la programación en R. En el proceso se detectaron algunas diferencias entre los software y algunos problemas o errores que hicieron necesario realizar una programación ad-hoc.

En segunda instancia se realiza un contraste entre los resultados obtenidos de los software Eviews y Gretl con la programación ad-hoc basada en las definiciones teóricas contenidas en el texto de este documento (que se fundamentan en los textos de Juselius (2006, 2000-I, 2000-II) [18, 19, 29], Lütkepohl (2004, 2005) [34, 35], Johansen (1995, 2004) [27, 28] y Izenman (1972, 1975, 2008) [22–24] principalmente), a partir de la cual se concluye que los resultados obtenidos a partir de cada software y la programación ad-hoc son consistentes entre sí en las estimaciones del VAR y VECM sin restricciones.

En este sentido, hacer la programación ad-hoc para los cálculos no sólo representa una valiosa instancia de aprendizaje y profunda comprensión del método de estimación planteado en este trabajo, sino que también representa una contribución a futuros investigadores en esta temática que puedan hacer uso de esta alternativa de programación realizada.

En el contraste entre los resultados obtenidos del **software Gretl** y la programación ad-hoc, si bien se encuentran diferencias que no afectan los resultados globales (diferentes estadísticos utilizados en algunas pruebas de hipótesis), la diferencia principal detectada está en la presentación de resultados dependiendo del caso de análisis que utiliza para los cálculos del VECM.

En el apartado 2.4.1 del Capítulo 2, se enumeran los casos de análisis de acuerdo a los componentes determinísticos a incluir en la especificación de la estimación del VECM según definió Johansen, los cuales determinan los cálculos subsiguiente a realizar y los resultados. Si bien a

partir de la comparación de las estimaciones en cada uno de los casos de análisis no se detectan diferencias, en la especificación a partir del *Caso 3* de Johansen ¹ se detecta una pequeña diferencia entre la presentación de los resultados del vector de cointegración calculado con Gretl y lo calculado con Eviews y R. La diferencia no está en el resultado del vector de cointegración, sino en la presentación del resultado.

Si bien la estimación del *Caso 3* en Gretl incluye la constante restringida al vector de cointegración y la constante no restringida, al presentar los resultados el vector de cointegración no presentan el valor de la constante restringida, dando lugar a confusión interpretando que la relación de cointegración no contiene una constante restringida, e inhabilitando la interpretación de ese coeficiente.

En Eviews el vector de cointegración tiene los mismos valores que en Gretl y R pero se diferencia en el valor de las constantes estimadas. La constante restringida presenta un valor menor a lo estimado en R, y las constantes no restringidas de cada ecuación presentan un valor considerablemente mayor a las presentadas en Eviews, siendo el resto de los coeficientes estimados en cada ecuación iguales en las estimaciones de los 3 software.

Como se mencionó previamente, al realizar un contraste entre los resultados obtenidos a través de las funciones disponibles en el **package “vars” de R-project** y la programación ad-hoc se detectaron diferencias y problemas en la aplicación de las mismas para el análisis específico de los datos de esta investigación, de las cuales se resumen los principales hallazgos:

1. La función “ca.jo” que calcula las estimaciones de α y β y el test de Johansen, no admite una especificación de VECM de un VAR(1), sólo admite cantidad de rezagos $p \geq 2$, por lo tanto en el momento de hacer la selección de la mejor especificación y comparar los resultados de un VECM a partir de un VAR(1) respecto a los de mayor orden hubo que programarlo ad-hoc, así como también para comparar con las salidas de los software alternativos.
2. La función “ca.jo” es muy sensible al tipo de variables exógenas que se incorporen al modelo y a la posición en que se incorporan dentro de la matriz de datos, resultando que en gran cantidad de intentos de estimación da error y no se puede proseguir con los cálculos y estimaciones. Ésta fue la principal razón que determinó realizar la programación ad-hoc porque la función no permitió realizar los cálculos necesarios para esta investigación.
3. Si bien permite realizar las pruebas de hipótesis sobre la significación de los α y β no tiene una función que permita realizar las estimaciones completas a partir de un modelo con restricciones en los α . Por lo tanto, fue una necesidad realizar la programación a partir de ese punto de análisis.
4. No calcula los desvíos estándar ni de β ni de α .

¹El *Caso 3* de Johansen asume una especificación para el VECM que implica tener una constante restringida a la relación de cointegración y una constante no restringida (especificación que también esta reflejada de esa forma en Eviews). Esta especificación es consistente con la existencia de tendencia lineal en los datos y que las mismas se cancelen dentro de la relación de cointegración, y una constante distinta de cero en la relación de cointegración.

Profundizando en el segundo punto recién mencionado, se comprueba a partir de varias pruebas realizadas que la función “ca.jo” da error y no realiza el cálculo cuando se considera como variable exógena exclusivamente a una constante no restringida, y en algunas ocasiones también sucede cuando se considera dentro de las exógenas una constante y otras variables, dependiendo de la posición en la que se ubique la constante.

El error se presenta al momento de calcular la descomposición de Cholesky (paso necesario para poder calcular $S_{11}^{-1/2}$), en la cual da como resultado una matriz indefinida inhabilitando continuar con la estimación de α y β y por lo tanto el vector de cointegración y el resto de estimaciones que dependen del mismo.

Ésto se corroboró a partir de la comparación de los resultados con la función “ca.jo” y la programación ad-hoc, dado que “ca.jo” daba error se procedió a realizar las estimaciones en la programación ad-hoc cambiando la posición de la constante dentro de la matriz de datos, logrando de esta forma poder realizar la estimación, contrastandola con los resultados de Eviews y Gretl y constatar que dan iguales.

Por último, se da una diferencia sustancial entre los resultados de los software al realizar las estimaciones de los modelos restringidos.

Tanto en **Gretl** como **Eviews** cuando se realizan las estimaciones restringiendo alguno de los parámetros (por ejemplo, los α cuando se constata la exogeneidad débil de alguna de las variables) presentan los resultados de la relación de cointegración sin normalizar, lo cual dificulta la interpretación y no es equivalente la interpretación de los datos a partir de un modelo normalizado de uno sin la normalización.

Por otro lado, hay diferencias entre los resultados obtenidos entre Gretl y Eviews, a partir de los cuales se obtenían resultados idénticos en la estimación sin restricciones, pero que al imponer las restricciones en los α no presentan los mismos valores en la relación de cointegración ni en el resto de los coeficientes estimados.

Las principales diferencias en la estimación de los modelos con restricciones en α en Gretl y Eviews están dadas por:

1. La relación de cointegración β y los atractores α se presenta sin la normalización, lo cual inhabilita la interpretación en el sentido habitual de esos coeficientes, y pierde el sentido económico que habitualmente se le da.
2. Los coeficientes estimados de la relación de cointegración sin normalización no presentan los desvíos estándar correspondientes (siendo que en las estimaciones sin restricciones sí los presentaban).
3. El resto de coeficientes estimados en cada una de las ecuaciones (Γ_i , Φ y Ψ), al haber sido estimados a partir de α y β no normalizados, no tienen los mismos valores y por lo tanto modifica la interpretación de los mismos.

Dado que en la programación ad-hoc se puede realizar la normalización de la relación de cointegración calculada a partir de un modelo con restricciones, de forma equivalente a como se realizaba en las estimaciones sin restricciones, se puede solucionar parte de estas diferencias para lograr interpretar de forma adecuada las relaciones de cointegración obtenidas a partir de Ewiews o Gretl aplicando la normalización y cálculos como se presentan a continuación.

Para los cálculos es necesario tomar las relaciones de cointegración que presenta Ewiews o Gretl sin normalizar y la matriz de varianzas y covarianzas Ω y aplicar la normalización que se propone en este documento, de esta forma se habilita a continuar con la interpretación de forma más intuitiva.

El $\hat{\beta}$ normalizado se obtiene con la ecuación previamente presentada en el apartado 2.4.4 del Capítulo 2 $\tilde{\beta} = \hat{\beta} (c' \hat{\beta})^{-1}$, de forma que $\tilde{\beta}$ sea único y $c' \tilde{\beta} = I_r$, siendo $c = [I_r, 0]'$ la matriz más utilizada.

La matriz $\hat{\alpha}$ normalizada se calcula a partir de la formula de cálculo de $\tilde{\alpha} = S_{uw.z} \tilde{\beta} (\tilde{\beta}' S_{uw.z} \tilde{\beta})^{-1}$ y los errores estándar a partir de $T (I - \tilde{\beta} c') S_{uw.z}^{-1} (I - \tilde{\beta} c') \otimes (\tilde{\alpha}' \tilde{\Omega}^{-1} \tilde{\alpha})^{-1}$.

Si bien el cálculo de los errores estándar no da exactamente igual a los que ofrece Gretl (como podrá compararse en las salidas presentadas en los Anexos B.2.2 vs B.3.1), se realiza a partir de lo propuesto por Johansen (1995) en su Teorema 13.3 [p.183] [27] y se considera suficientemente justificado y validado para incorporar al análisis.

En conclusión, se realiza el contraste de los resultados de estos dos software con la programación ad-hoc, dando como resultado que las salidas obtenidas en Gretl coinciden con la programación ad-hoc y son consistentes con las definiciones teóricas aplicadas hasta el momento, y los resultados no normalizados pueden corregirse con las formulas aquí presentadas.

En cuanto al package “vars”, no logra realizar la totalidad de cálculos necesarios para este trabajo de investigación, lo cual hizo necesario realizar la programación ad-hoc que queda disponible en el Anexo D del presente documento para consultar.

No se puede ser concluyente en cuanto a la estimación que ofrece Ewiews dado que no se conoce en profundidad los mecanismos de cálculo que está aplicando (al no conocer la programación específica) pero se recomienda realizar la interpretación con cautela en estos casos y profundizar el análisis en este software para no realizar interpretaciones erróneas de las estimaciones.

En el Anexo de Programación D se presenta los códigos con la programación ad-hoc realizada y en el Anexo de Resultados B los resultados de las estimaciones con R B.2.2, B.2.3 y Gretl B.3.1, B.3.2 para poder realizar la comparación con los resultados obtenidos de la programación ad-hoc.

Apéndice D

Anexo con Programación en software R.

A lo largo de este trabajo de investigación se fueron realizando los cálculos en diferentes software de forma de tener una mejor comprensión del tipo de cálculo que hace cada uno y las diferencias en análisis y conclusiones que puede representar para un investigador el tipo de software que decide utilizar.

En el Anexo de Resultados se presentaron los resultados completos de la especificación del modelo sin la variable temperatura (Escenario 1), obtenidos a partir de la programación ad-hoc en R y en Gretl.

En este anexo se presenta la programación en R desarrollada específicamente para el presente trabajo. Hacer la programación ad-hoc para los cálculos no sólo representa una valiosa instancia de aprendizaje y profunda comprensión del método de estimación planteado en este trabajo, sino que también representa una contribución a futuros investigadores en esta temática que puedan hacer uso de esta alternativa de programación realizada.

D.1. Programación en R

D.1.1. Pruebas de Raíz Unitaria

```
#####  
## CANTIDAD DE SUPERGAS ##  
#####  
  
## ADF-----  
adf_csg=ur.df(csg,lags=12, type='none');summary(adf_csg)  
adf_csg=ur.df(csg,lags=12, type='drift');summary(adf_csg)  
adf_csg=ur.df(csg,lags=12, type='trend');summary(adf_csg)  
par(mfrow=c(1,2));acf(adf_csg@res); pacf(adf_csg@res)  
# necesito poner 12 lags para captar toda la autocorrelacion  
  
adf_dcsg=ur.df(dcsg,lags=11, type='none');summary(adf_dcsg)  
adf_dcsg=ur.df(dcsg,lags=11, type='drift');summary(adf_dcsg)  
adf_dcsg=ur.df(dcsg,lags=11, type='trend');summary(adf_dcsg)  
pacf(adf_dcsg@res)
```



```
sdcsdg=diff(csg,12)
adf_sdcsdg=ur.df(sdcsg,lags=12, type='trend')
summary(adf_sdcsdg)

## ZA-----
za_csg=ur.za(csg, model='intercept', lag=11);summary(za_csg);plot(za_csg)
za_csg=ur.za(csg, model='trend', lag=14);summary(za_csg);plot(za_csg)
za_csg=ur.za(csg, model='both', lag=14);summary(za_csg);plot(za_csg)
par(mfrow=c(1,2));acf(za_csg@res); pacf(za_csg@res)
# necesito poner 14 lags para captar toda la autocorrelacion
plot(za_csg)

za_dcsg=ur.za(dcsg, model='both', lag=11);summary(za_dcsg)
za_dcsg=ur.za(dcsg, model='intercept', lag=11);summary(za_dcsg)
plot(za_dcsg)

#####
## CANTIDAD DE ENERGIA ELECTRICA ##
#####

## ADF-----
adf_cee=ur.df(cee,lags=24, type='none');summary(adf_cee)
adf_cee=ur.df(cee,lags=24, type='drift');summary(adf_cee)
adf_cee=ur.df(cee,lags=24, type='trend');summary(adf_cee)
par(mfrow=c(1,2));acf(adf_cee@res); pacf(adf_cee@res)
# necesito poner 24 lags para captar toda la autocorrelacion

adf_dcee=ur.df(dcee,lags=23, type='none');summary(adf_dcee)
adf_dcee=ur.df(dcee,lags=23, type='drift');summary(adf_dcee)
adf_dcee=ur.df(dcee,lags=23, type='trend');summary(adf_dcee)
pacf(adf_dcee@res)

## ZA-----
za_cee=ur.za(cee, model='both', lag=24); summary(za_cee);plot(za_cee)
za_cee=ur.za(cee, model='trend', lag=24); summary(za_cee);plot(za_cee)
za_cee=ur.za(cee, model='intercept', lag=24); summary(za_cee);plot(za_cee)

par(mfrow=c(1,2)); acf(za_cee@res); pacf(za_cee@res)
plot(za_cee)

za_dcee=ur.za(dcee, model='both', lag=23);summary(za_dcee)
za_dcee=ur.za(dcee, model='trend', lag=23);summary(za_dcee)
za_dcee=ur.za(dcee, model='intercept', lag=23);summary(za_dcee)

#####
## INDICE DE SALARIO REAL ##
#####

## ADF-----
adf_isr=ur.df(isr,lags=13, type='none');summary(adf_isr)
adf_isr=ur.df(isr,lags=13, type='drift');summary(adf_isr)
adf_isr=ur.df(isr,lags=13, type='trend');summary(adf_isr)
par(mfrow=c(1,2));acf(adf_isr@res); pacf(adf_isr@res)
# necesito poner 13 lags para captar toda la autocorrelacion

adf_disr=ur.df(disr,lags=12, type='none');summary(adf_disr)
adf_disr=ur.df(disr,lags=12, type='drift');summary(adf_disr)
adf_disr=ur.df(disr,lags=12, type='trend');summary(adf_disr)
pacf(adf_disr@res)

adf_disr=ur.df(diff(disr),lags=12, type='none');summary(adf_disr)

## ZA-----

za_isr=ur.za(isr, model='both', lag=24);summary(za_isr)
za_isr=ur.za(isr, model='trend', lag=13);summary(za_isr)
za_isr=ur.za(isr, model='intercept', lag=13);summary(za_isr)
plot(za_isr)
```

```

cbind(seq(1:length(isr)),isr)# posible quiebre en 6:2002

# miro despues del quiebre
za_isr=ur.za(isr[31:156], model='both', lag=24);summary(za_isr)
za_isr=ur.za(isr[31:156], model='trend', lag=24);summary(za_isr)
za_isr=ur.za(isr[31:156], model='intercept', lag=24);summary(za_isr)

za_disr=ur.za(disr, model='both', lag=24); summary(za_disr)
za_disr=ur.za(disr, model='trend', lag=23); summary(za_disr)
plot(za_disr)
plot(disr)

#####
## PRECIO DEL SUPERGAS ##
#####
## ADF-----
adf_psg=ur.df(psg, lags=12, type='none');summary(adf_psg)
adf_psg=ur.df(psg, lags=12, type='drift');summary(adf_psg)
adf_psg=ur.df(psg, lags=12, type='trend');summary(adf_psg)
par(mfrow=c(1,2));acf(adf_psg@res); pacf(adf_psg@res)
# necesito poner 12 lags para captar toda la autocorrelacion

adf_dpsg=ur.df(dpsg, lags=11, type='none');summary(adf_dpsg)
adf_dpsg=ur.df(dpsg, lags=11, type='drift');summary(adf_dpsg)
adf_dpsg=ur.df(dpsg, lags=11, type='trend');summary(adf_dpsg)

pacf(adf_dpsg@res)

## ZA-----
za_psg=ur.za(psg, model='both', lag=12);summary(za_psg)
za_psg=ur.za(psg, model='trend', lag=12);summary(za_psg)
za_psg=ur.za(psg, model='intercept', lag=12);summary(za_psg)
plot(za_psg)

za_dpsg=ur.za(dpsg, model='both', lag=8);summary(za_dpsg)

par(mfrow=c(1,2));acf(za_psg4@res); pacf(za_psg4@res)
plot(za_dpsg)
cbind(seq(1:length(dpsg)),dpsg)# posible quiebre en 51: 2004

#####
## PRECIO DE ENERGIA ELECTRICA ##
#####
## ADF-----

adf_pee=ur.df(pee, lags=12, type='none');summary(adf_pee)
adf_pee=ur.df(pee, lags=12, type='drift');summary(adf_pee)
adf_pee=ur.df(pee, lags=12, type='trend');summary(adf_pee)
par(mfrow=c(1,2));acf(adf_pee@res); pacf(adf_pee@res)
# necesito poner 12 lags para captar toda la autocorrelacion

adf_dpee=ur.df(dpee, lags=11, type='none');summary(adf_dpee)
adf_dpee=ur.df(dpee, lags=11, type='drift');summary(adf_dpee)
adf_dpee=ur.df(dpee, lags=11, type='trend');summary(adf_dpee)

pacf(adf_dpee@res)

## ZA-----
za_pee=ur.za(pee, model='both', lag=12); summary(za_pee)
za_pee=ur.za(pee, model='trend', lag=12); summary(za_pee)
za_pee=ur.za(pee, model='intercept', lag=12); summary(za_pee)
plot(za_pee)

za_dpee=ur.za(dpee, model='both', lag=8); summary(za_dpee)
za_dpee=ur.za(dpee, model='intercept', lag=8); summary(za_dpee)
plot(za_dpee)

```

D.1.2. Determinación de la Cantidad de Rezagos del VAR

```
K=5
p=5
T=dim(base)[1]-p;T

var1=VAR(base, p = 1, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
var2=VAR(base, p = 2, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
var3=VAR(base, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
var4=VAR(base, p = 4, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
var5=VAR(base, p = 5, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))

as.matrix(roots(var1))
matrix(round(roots(var2),3),nrow=5,ncol=2)
matrix(round(roots(var3),3),nrow=5,ncol=3)

# VAR(1)
# Matriz de varianzas y covarianzas, determinante y loglik
N=var1$obs ;p=1
omega=crossprod(residuals(var1))/N; round(omega,6)
tc1=(1-sum(diag(omega%%solve(cov(diff(base))))))/K
detcov=det(omega);detcov
detcov1=detcov
c=T*(K/2)- (T*(K/2)*log(2*pi))
logLmax1=-(0.5*T)*log(detcov1)+c;logLmax1

aic1=log(detcov1)+(K^2*p)*(2/T);aic1
sc1=log(detcov1)+(K^2*p)*(log(T)/T);sc1
HQ1=log(detcov1)+(K^2*p)*(2*log(log(T))/T);HQ1

# VAR(2)
# Matriz de varianzas y covarianzas, determinante y loglik
N=var2$obs ;p=2
omega=crossprod(residuals(var2))/N; round(omega,6)
detcov=det(omega);detcov
detcov2=detcov
c=T*(K/2)- (T*(K/2)*log(2*pi))
logLmax2=-(0.5*T)*log(detcov2)+c;logLmax2

aic2=log(detcov2)+(K^2*p)*(2/T);aic2
sc2=log(detcov2)+(K^2*p)*(log(T)/T);sc2
HQ2=log(detcov2)+(K^2*p)*(2*log(log(T))/T);HQ2

# VAR(3)
# Matriz de varianzas y covarianzas, determinante y loglik
N=var3$obs;p=3 ;T=N
omega=crossprod(residuals(var3))/N; round(omega,6)
detcov=det(omega);detcov
detcov3=detcov
c=T*(K/2)- (T*(K/2)*log(2*pi))
logLmax3=-(0.5*T)*log(detcov3)+c;logLmax3

aic3=log(detcov3)+(K^2*p)*(2/T);aic3
sc3=log(detcov3)+(K^2*p)*(log(T)/T);sc3
HQ3=log(detcov3)+(K^2*p)*(2*log(log(T))/T);HQ3

# VAR(4)
# Matriz de varianzas y covarianzas, determinante y loglik
N=var4$obs;p=4 ;T=N
omega=crossprod(residuals(var4))/N; round(omega,6)
detcov=det(omega);detcov
detcov4=detcov
c=T*(K/2)- (T*(K/2)*log(2*pi))
logLmax4=-(0.5*T)*log(detcov4)+c;logLmax4

aic4=log(detcov4)+(K^2*p)*(2/T);aic4
sc4=log(detcov4)+(K^2*p)*(log(T)/T);sc4
HQ4=log(detcov4)+(K^2*p)*(2*log(log(T))/T);HQ4
```

```

# VAR(5)
# Matriz de varianzas y covarianzas, determinante y loglik
N=var5$obs;p=5 #;T=N
omega=crossprod(residuals(var5))/N; round(omega,6)
detcov=det(omega);detcov
detcov5=detcov
c=T*(K/2)- (T*(K/2)*log(2*pi))
logLmax5=-(0.5*T)*log(detcov5)+c;logLmax5
LR.4vs5=round(T*(log(detcov4)-log(detcov5)),3)

LR.test=c(LR.=c(0),
LR.1vs2=round(T*(log(detcov1)-log(detcov2)),3),
LR.2vs3=round(T*(log(detcov2)-log(detcov3)),3),
LR.3vs4=round(T*(log(detcov3)-log(detcov4)),3))
LR.test

J.B.test=c(
normality.test(var1)$jb.mul$JB$statistic[[1]],
normality.test(var2)$jb.mul$JB$statistic[[1]],
normality.test(var3)$jb.mul$JB$statistic[[1]],
normality.test(var4)$jb.mul$JB$statistic[[1]])
J.B.test

ic=t(rbind(round(c(aic1,sc1,HQ1),3),round(c(aic2,sc2,HQ2),3),
round(c(aic3,sc3,HQ3),3),round(c(aic4,sc4,HQ4),3)))
ic=rbind(c(logLmax1,logLmax2,logLmax3,logLmax4),ic)
ic=rbind(ic,J.B.test,LR.test)
colnames(ic)=c("p=1","p=2","p=3","p=4")
rownames(ic)=c("MaxLogLik","AIC","SC","H-Q","J.B.test","LR.test")
ic
$

```

D.1.3. Definición de la matriz de datos para el Caso 2 con $p = 3$

```

#.....
#DEFINICION DE LA MATRIZ DE DATOS PARA EL CASO 2 JOHANSEN: solo cte restringida
#.....
# Ecuacion a estimar en un VECM derivado a partir de un VAR : Z0 = PI*ZK + GAMMA*Z1 + epsilon
p=p; p # cantidad de rezagos determinados para el VAR
K= ncol(base);K # cantidad de variables
N=nrow(base);N # cantidad de datos

# definicion de la dummy estacionales centradas
season = 12
s <- season - 1
  dum <- (diag(season) - 1/season)[, -season]
  dums <- dum
  while (nrow(dums) < N) {
    dums <- rbind(dums, dum)
  }
  dums <- dums[1:N, ]
  colnames(dums) <- paste("sd", 1:ncol(dums), sep = "")

dim(dums)# variables estacionales centradas

# Z: Base con rezagos
Z=as.data.frame(embed(diff(base),p));dim(Z)
colnames(Z)[1:K]=paste(colnames(base), ".d", sep = "")
colnames(Z)[(K+1):(K*2)]=paste(colnames(base), ".d.l1", sep = "")
colnames(Z)[(K+K+1):(K*3)]=paste(colnames(base), ".d.l2", sep = "")
colnames(Z)#head(Z)

# Z0: Base con [Delta y_{t}]
Z0=as.matrix(Z[,1:K]);dim(Z0);colnames(Z0)

# ZK: Base con [y_{t-1}]

```

```
ZK=cbind(base[p:(nrow(base)-(1)),],cte=1);dim(ZK)
colnames(ZK) <- c(paste(colnames(base), ".l1", sep = ""), "cte")
ZK=as.matrix(ZK); colnames(ZK)

# Z1: Base con [Delta y_{t-1}] + dummies centradas, intervenciones, exogenas.
Z1=cbind(exog[(p+1):156,],dums[(p+1):156,]);dim(Z1) # con intervenciones
#Z1=cbind(dums[(p+1):156,]);dim(Z1) #sin intervenciones
Z1=as.matrix(cbind(Z[,-(1:K)],Z1))
Z1=as.matrix(Z1);colnames(Z1)
```

D.1.4. Estimación de α y β mediante RRR sin restricciones

```
#.....
## ESTIMACION de alpha y beta mediante el método de regresion de rango reducido
#.....
N=nrow(Z1);N
k=ncol(ZK);k
# sin restricciones
S00 <- crossprod(Z0)/N
S11 <- crossprod(Z1)/N
SKK <- crossprod(ZK)/N
S01 <- crossprod(Z0, Z1)/N
S0K <- crossprod(Z0, ZK)/N
SK0 <- crossprod(ZK, Z0)/N
S10 <- crossprod(Z1, Z0)/N
S1K <- crossprod(Z1, ZK)/N
SK1 <- crossprod(ZK, Z1)/N
S11inv <- solve(S11)
SKKinv <- solve(SKK)
R01 <- Z0 - t(S01 %*% S11inv %*% t(Z1))
R0K <- Z0 - t(S0K %*% SKKinv %*% t(ZK))
RK1 <- ZK - t(SK1 %*% S11inv %*% t(Z1))
S0K.1 <- S0K - S01 %*% S11inv %*% S1K
S00.1 <- S00 - S01 %*% S11inv %*% S10
SK0.1 <- SK0 - SK1 %*% S11inv %*% S10
SKK.1 <- SKK - SK1 %*% S11inv %*% S1K
Ctemp <- chol(SKK.1, pivot = TRUE)
pivot <- attr(Ctemp, "pivot")
oo <- order(pivot)
C <- t(Ctemp[, oo])
Cinv <- solve(C)
S00.1inv <- solve(S00.1)
valeigen <- eigen(Cinv %*% SK0.1 %*% S00.1inv %*% S0K.1 %*% t(Cinv))
lambda <- valeigen$values
e <- valeigen$vector
V <- t(Cinv) %*% e
W <- S0K.1 %*% V %*% solve(t(V) %*% SKK.1 %*% V)
Vn <- V
for (j in 1:k){Vn[,j] <- sapply(j, function(x) V[, x]/V[j, x])}
Wn <- S0K.1 %*% Vn %*% solve(t(Vn) %*% SKK.1 %*% Vn)

colnames(V) <- colnames(ZK); colnames(Vn)<-colnames(V)
rownames(V) <- colnames(ZK); rownames(Vn) <- colnames(V)
colnames(W) <- colnames(ZK); colnames(Wn)<-colnames(V)
rownames(W) <- colnames(ZK)[1:K]; rownames(Wn) <- colnames(V)[1:K]

round(V,6) # beta no normalizado
round(W,6) # alpha no normalizado
round(Vn,6) # beta normalizado
round(Wn,6) # alpha normalizado
round(lambda,6) # valores propios
```

D.1.5. Estimación del Rango de Cointegración: Test de Johansen

```
#.....
# ESTIMACION DEL RANGO MEDIANTE TEST DE JOHANSEN
#.....
#Valores Criticos:

cv.caso1=matrix(c(2.95, 4.07, 5.22, 6.77,
  10.47, 12.28, 14.00, 16.17,
  21.79, 24.21, 26.45, 29.21,
  37.05, 40.10, 42.86, 46.23,
  56.29, 59.96, 63.27, 67.26,
  79.53, 83.82, 87.67, 92.28),nrow=6,ncol=4,byrow = TRUE)
cvals=cv.caso1

cv.caso2=matrix(c(7.60, 9.14, 10.63, 12.53,
  17.98, 20.16, 22.18, 24.69,
  32.25, 35.07, 37.64, 40.78,
  50.50, 53.94, 57.05, 60.81,
  72.74, 76.81, 80.46, 84.84,
  98.98, 103.68, 107.87, 112.88),nrow=6,ncol=4,byrow = TRUE)
cvals=cv.caso2

cv.caso3=matrix(c(2.71, 3.84, 5.02, 6.63,
  13.42, 15.41, 17.28, 19.62,
  27.16, 29.80, 32.23, 35.21,
  44.45, 47.71, 50.66, 54.23,
  65.73, 69.61, 73.10, 77.29,
  91.01, 95.51, 99.54, 104.36),nrow=6,ncol=4,byrow = TRUE)
cvals=cv.caso3

cv.caso4=matrix(c(10.68, 12.45, 14.12, 16.22,
  23.32, 25.73, 27.95, 30.67,
  39.73, 42.77, 45.53, 48.87,
  60.00, 63.66, 66.95, 70.91,
  84.27, 88.55, 92.38, 96.97,
  112.54, 117.45, 121.82, 127.04),nrow=6,ncol=4,byrow = TRUE)
cvals=cv.caso4

cv.caso5=matrix(c(2.71, 3.84, 5.02, 6.63,
  16.14, 18.30, 20.30, 22.81,
  32.15, 35.03, 37.65, 40.87,
  51.60, 55.08, 58.22, 62.01,
  75.00, 79.10, 82.77, 87.17,
  102.36, 107.09, 111.30, 116.33),nrow=6,ncol=4,byrow = TRUE)
cvals=cv.caso5

#-----
arrsel <- ncol(Z0)

# TEST DE LA TRAZA
idx=0:(arrsel-1)
n=N-dim(base)[2]-dim(exog)[2]
trace.test <- as.matrix(rev(sapply(idx, function(x) -N * sum(log(1 - lambda[(x + 1):K])))))
colnames(trace.test) <- "trace"

cval=cvals[1:arrsel,]
colnames(cval) <- c("0.9", "0.95", "0.975", "0.99")
rownames(cval) <- c(paste("r <= ", (arrsel - 1):1, " |", sep = ""), "r = 0 |")

cbind(trace.test,cval) # TEST DE LA TRAZA
#xtable(cbind(trace.test,cval))
```

D.1.6. Estimación del VECM sin restricciones

```
#.....
# ESTIMACION MCO de GAMMA USANDO EL BETA ESTIMADO MEDIANTE RRR
#.....
r=r # cantidad de relaciones de cointegracion determinadas en el test de Johansen
K <- ncol(Z0)
r <- as.integer(r)
beta <- matrix(V[, 1:r], ncol = r)
C1 <- diag(r)
C2 <- matrix(0, nrow = nrow(beta) - r, ncol = r)
C <- rbind(C1, C2)
betanorm <- beta %*% solve(t(C) %*% beta)
ECT <- ZK %*% betanorm
colnames(ECT) <- paste("ect", 1:r, sep = "")
colnames(betanorm) <- colnames(ECT)
rownames(betanorm) <- colnames(ZK)
data.mat <- data.frame(Z0, Z1, ECT)
text <- colnames(data.mat)[-c(1:(K))]
text1 <- paste(text, "", sep = "+", collapse = "")
text2 <- paste("~", substr(text1,1 , nchar(text1) - 1))
form1 <- formula(paste("Z0", text2, "-1"))
rlm <- lm(form1, data = data.mat)

round(betanorm,6) # beta normalizado para r relaciones de cointegracion
alphanorm <- S0K.1 %*% betanorm %*% solve(t(betanorm) %*% SKK.1 %*% betanorm)
round(alphanorm,6) # alpha normalizado para r relaciones de cointegracion

plot(ECT[,1],type="l",col="red");lines(ECT[,2],type="l",col="blue")

# Matriz de varianzas y covarianzas, determinante y loglik
omega=crossprod(residuals(rlm))/N; round(omega,8)
detcov=det(omega);detcov
c=N*(K/2)- (N*(K/2)*log(2*pi))
logLmax=-(0.5*N)*log(detcov)+c;logLmax

aic=log(detcov)+(K^2*p)*(2/N);aic
sc=log(detcov)+(K^2*p)*(log(N)/N);sc
HQ=log(detcov)+(K^2*p)*(2*log(log(N))/N);HQ

J <- ZK %*% betanorm ;dim(J)
S0j <- crossprod(Z0, J)/N
Sjj <- crossprod(J, J)/N
S1j <- crossprod(Z1, J)/N
Sj1 <- crossprod(J, Z1)/N
S01.j=S01-S0j %*% solve(Sjj) %*% Sj1
S11.j=S11-S1j %*% solve(Sjj) %*% Sj1
GAMMA <- S01.j %*% solve(S11.j)
OMEGA <- S00.1 - S0K.1 %*% betanorm %*% solve(t(betanorm) %*% SKK.1 %*% betanorm) %*% t(betanorm) %*% SK0.1

round(t(GAMMA),4)# coeficientes de la regresion
round(OMEGA,8) # Matriz de varianzas y covarianzas a partir de normalizacion

T1<-((N)^(-1))*(diag(rep(1,6))-betanorm%*%t(C))%*%solve(SKK.1)%*%t(diag(rep(1,6))-betanorm%*%t(C))
T2<-solve(t(alphanorm)%*%solve(OMEGA)%*%alphanorm)
T3<-kronecker(T1,T2)
round(sqrt(diag(T3)),6)
#ERRORES ESTANDAR BETA
sd.error=matrix(round(sqrt(diag(T3)),6),nrow=6,ncol=2,byrow=TRUE)
colnames(sd.error)=colnames(betanorm)
rownames(sd.error)=rownames(betanorm)
sd.error # Errores estándar de los beta normalizados
```

D.1.7. Test sobre los Residuos

```
#####
# TEST DE ESPECIFICACION
#####
#.....
# TEST DE AUTOCORRELACION DE LOS RESIDUOS (sin restricciones en alpha)
#.....
bgtest(lm(paste("Z0[,1]",text2, "- 1"), data = data.mat),order = 12,type = c("F"))
bgtest(lm(paste("Z0[,2]",text2, "- 1"), data = data.mat),order = 12,type = c("F"))
bgtest(lm(paste("Z0[,3]",text2, "- 1"), data = data.mat),order = 12,type = c("F"))
bgtest(lm(paste("Z0[,4]",text2, "- 1"), data = data.mat),order = 12,type = c("F"))
bgtest(lm(paste("Z0[,5]",text2, "- 1"), data = data.mat),order = 12,type = c("F"))
bgtest(rlm,order = 12,type = c("F"))

#.....
# TEST ARCH DE HOMOSCEDASTICIDAD DE LOS RESIDUOS
#.....

#x=residuos # para estimación con restricciones en alpha

x=residuals(rlm) # estimación sin restricciones

archlmtest <- function (x, lags, demean = FALSE)
{
  x <- as.vector(x)
  if(demean) x <- scale(x, center = TRUE, scale = FALSE)
  lags <- lags + 1
  mat <- embed(x^2, lags)
  arch.lm <- summary(lm(mat[, 1] ~ mat[, -1]))
  STATISTIC <- arch.lm$r.squared * length(resid(arch.lm))
  names(STATISTIC) <- "Chi-squared"
  PARAMETER <- lags - 1
  names(PARAMETER) <- "df"
  PVAL <- 1 - pchisq(STATISTIC, df = PARAMETER)
  METHOD <- "ARCH LM-test"
  result <- list(statistic = STATISTIC, parameter = PARAMETER,
    p.value = PVAL, method = METHOD, data.name =
  deparse(substitute(x)))
  class(result) <- "htest"
  return(result)
}
$
archlmtest(x[,1],lags=12)
archlmtest(x[,2],lags=12)
archlmtest(x[,3],lags=12)
archlmtest(x[,4],lags=12)
archlmtest(x[,5],lags=12)

#####
# TEST DE NORMALIDAD
#####
## multivariate normality test
#.....

#x=residuos # para estimación con restricciones en alpha

x=residuals(rlm)

obs=nrow(x)
K=ncol(x)
#function(x, obs, K, obj.name){
  P <- chol(crossprod(as.matrix(x)) / obs)
  resids.std <- x %%% solve(P)
  b1 <- apply(resids.std, 2, function(x) sum(x^3) / obs)
  b2 <- apply(resids.std, 2, function(x) sum(x^4) / obs)
  s3 <- obs * t(b1) %%% b1 / 6
  s4 <- obs * t(b2 - rep(3, K)) %%% (b2 - rep(3, K)) / 24
  STATISTIC <- s3 + s4
```



```

names(STATISTIC) <- "Chi-squared"
PARAMETER <- 2 * K
names(PARAMETER) <- "df"
PVAL <- 1 - pchisq(STATISTIC, df = PARAMETER)
METHOD <- "JB-Test (multivariate)"
result1 <- list(statistic = STATISTIC, parameter = PARAMETER, p.value = PVAL)
class(result1) <- "htest"
STATISTIC <- s3
names(STATISTIC) <- "Chi-squared"
PARAMETER <- K
names(PARAMETER) <- "df"
PVAL <- 1 - pchisq(STATISTIC, df = PARAMETER)
METHOD <- "Skewness only (multivariate)"
result2 <- list(statistic = STATISTIC, parameter = PARAMETER, p.value = PVAL)
class(result2) <- "htest"
STATISTIC <- s4
names(STATISTIC) <- "Chi-squared"
PARAMETER <- K
names(PARAMETER) <- "df"
PVAL <- 1 - pchisq(STATISTIC, df = PARAMETER)
METHOD <- "Kurtosis only (multivariate)"
result3 <- list(statistic = STATISTIC, parameter = PARAMETER, p.value = PVAL)
class(result3) <- "htest"
result <- list(JB = result1, Skewness = result2, Kurtosis = result3)
#return(result)
#}
result

#.....
## univariate normality test
#.....
residuos=residuals(rlm)

resultado=matrix(ncol=3,nrow=5)
for(i in 1:5){
x=residuos[,i]
obs=length(x)
#function(x, obs){
  x <- as.vector(x)
  m1 <- sum(x) / obs
  m2 <- sum((x - m1)^2) / obs
  m3 <- sum((x - m1)^3) / obs
  m4 <- sum((x - m1)^4) / obs
  b1 <- (m3 / m2^(3 / 2))^2
  b2 <- (m4/m2^2)-3
  STATISTIC <- obs * b1 / 6 + obs * (b2)^2 / 24
  names(STATISTIC) <- "Chi-squared"
  PARAMETER <- 2
  names(PARAMETER) <- "df"
  PVAL <- 1 - pchisq(STATISTIC, df = 2)
  METHOD <- "JB-Test (univariate)"
  result <- list(statistic = STATISTIC, parameter = PARAMETER, p.value = PVAL)
  class(result) <- "htest"
resultado[i,1]=as.numeric(result[1])
resultado[i,2]=as.numeric(result[2])
resultado[i,3]=as.numeric(result[3])
}
colnames(resultado)=c("Chi-squared","df","p-value")
rownames(resultado)=c("res.d.csg","res.d.cee","res.d.isr","res.d.psg","res.d.pee")
resultado

```

D.1.8. Predicción e Indicadores de Errores de Predicción

```

#####
# CALCULOS DE LOS INDICADORES DE ERRORES DE PREDICCIÓN

```

```
#####
# bases hasta 2013
b=serie[1:168,];colnames(base);dim(b) #base
expred=cbind(exogenas[13:180,]);colnames(expred);dim(expred) #exog
colnames(e);dim(e) #exog
# definicion de la dummy estacionales centradas
N=nrow(b)
season=12
season = as.integer(season)
s <- season - 1
  dum <- (diag(season) - 1/season)[, -season]
  dums <- dum
  while (nrow(dums) < N) {
    dums <- rbind(dums, dum)
  }
  dums <- dums[1:N, ]
  colnames(dums) <- paste("sd", 1:ncol(dums), sep = "")

dim(dums)# variables estacionales centradas

p=3

data <- embed(b, dimension = p + 1);dim(data)
temp1 <- NULL
  for (i in 1:p) {
    temp <- paste(colnames(base), ".l", i, sep = "")
    temp1 <- c(temp1, temp)
  }
  colnames(data) <- c(colnames(base),temp1)

ex=expred[(p+1):nrow(expred),];dim(ex)
dum=dums[(p+1):nrow(dums),];dim(dum)

datamat=ts(cbind(data[, -c(1:ncol(b))],constant=1,dum,ex),frequency=12,start=c(2000,4));colnames(datamat)

#-----
# VEC 2 VAR, transformación de los coeficientes estimados en el VECM a las matrices del VAR.

coeffs=coef(rlm)
PI <- W[, 1:r] %*% t(V[, 1:r])
detcoeffs <- matrix(PI[, ncol(base) + 1], nrow = 1, ncol = ncol(base), byrow = TRUE)
rownames(detcoeffs) <- "constant"
  colnames(detcoeffs) <- colnames(base)
  PI <- PI[, -(ncol(base) + 1)]
  rhs <- cbind(1, Z1)
  colnames(rhs) <- c("constant", colnames(Z1))

  seas <- eval(season) - 1
  season <- paste("sd", 1:seas, sep = "")
  detcoeffs <- rbind(detcoeffs, coeffs[season, ])

  dumnames <- colnames(exog)
  tmp <- rownames(detcoeffs)
  detcoeffs <- rbind(detcoeffs, coeffs[dumnames, ])
  rownames(detcoeffs) <- c(tmp, dumnames)

detcoeffs <- t(detcoeffs)
Gamma <- t(coeffs[-which(rownames(coeffs) %in% c(colnames(detcoeffs),colnames(ECT))), ])
rownames(Gamma) <- colnames(base)

A <- list()
if (p > 2) {
  idx.end <- seq(from = ncol(base), by = ncol(base), length.out = p - 1)
  idx.start <- idx.end - ncol(base) + 1
  A[[1]] <- Gamma[, idx.start[1]:idx.end[1]] + PI + diag(ncol(base))
  rownames(A[[1]]) <- colnames(base)
  colnames(A[[1]]) <- paste(colnames(base), ".l1", sep = "")
  for (i in 2:(p - 1)) {
    A[[i]] <- Gamma[, idx.start[i]:idx.end[i]] -
      Gamma[, idx.start[i - 1]:idx.end[i - 1]]
  }
}
```

```

        rownames(A[[i]]) <- colnames(base)
        colnames(A[[i]]) <- paste(colnames(base), ".l", i, sep = "")
    }
    A[[p]] <- -1 * Gamma[, tail(idx.start, 1):tail(idx.end, 1)]
    rownames(A[[p]]) <- colnames(base)
    colnames(A[[p]]) <- paste(colnames(base), ".l", p, sep = "")
    names(A) <- paste("A", 1:p, sep = "")
}
#-----
coef.var.csg=as.matrix(c(A$A1[, ], A$A2[, ], A$A3[, ], detcoeffs[1, ]))
coef.var.cee=as.matrix(c(A$A1[, ], A$A2[, ], A$A3[, ], detcoeffs[2, ]))
coef.var.isr=as.matrix(c(A$A1[, ], A$A2[, ], A$A3[, ], detcoeffs[3, ]))
coef.var.psg=as.matrix(c(A$A1[, ], A$A2[, ], A$A3[, ], detcoeffs[4, ]))
coef.var.pee=as.matrix(c(A$A1[, ], A$A2[, ], A$A3[, ], detcoeffs[5, ]))
coef.var=cbind(coef.var.csg, coef.var.cee, coef.var.isr, coef.var.psg, coef.var.pee)
$
dim(datamat)
dim(coef.var)
n.ahead=12

K=5
T=153
n.ahead=12
basenueva=datamat;dim(basenueva)
fcast=matrix(NA,nrow=12,ncol=K)

for(h in 1:(n.ahead+1)){
  fcast[h,]=basenueva[(T+h), ]%*%coef.var
  basenueva[(T+h+1), 1:K]=c(fcast[h, ])
  basenueva[(T+h+1), (K+1):(K*2)]=basenueva[(T+h), 1:K]
  basenueva[(T+h+1), ((K*2)+1):(K*3)]=basenueva[(T+h-1), 1:K]
}

cbind(serie[157:168, ], fcast)

forecast=fcast
base.n.ahead=serie[(nrow(base)+1):(nrow(base)+n.ahead), ]

ME=NULL
MSE=NULL
RMSE=NULL
MPE=NULL
MAE=NULL
MAPE=NULL
for(i in 1:K){
  ME[i]=(1/n.ahead)*(sum(base.n.ahead[, i]-forecast[, i]))
  MSE[i]=(1/n.ahead)*(sum((base.n.ahead[, i]-forecast[, i])^2))
  RMSE[i]=sqrt(MSE[i])
  MPE[i]=(1/n.ahead)*sum((base.n.ahead[, i]-forecast[, i])/base.n.ahead[, i])*100
  MAE[i]=(1/n.ahead)*sum(abs((base.n.ahead[, i]-forecast[, i])))
  MAPE[i]=(1/n.ahead)*sum(abs((base.n.ahead[, i]-forecast[, i])/base.n.ahead[, i])*100
}

ErrorPrediccion=round(cbind(as.matrix(ME), as.matrix(MSE), as.matrix(RMSE),
as.matrix(MAE), as.matrix(MPE), as.matrix(MAPE)), 4)

colnames(ErrorPrediccion)=c("ME", "MSE", "RMSE", "MAE", "MPE", "MAPE")
rownames(ErrorPrediccion)=c("csg", "cee", "isr", "psg", "pee")
ErrorPrediccion

```

D.1.9. Pruebas de hipótesis sobre los β

```

#####
## PRUEBAS DE HIPOTESIS SOBRE LOS BETA
#####

```

```

p
r
# LUEGO DE ESTIMAR SIN RESTRICCIONES SE GUARDO LA VERSION U
ZK=ZKu
Z0=Z0u
Z1=Z1u

## RESTRICCIONES EN BETA ##

resultado1=matrix(ncol=2,nrow=6)#caso con cte o tend restringida

k=ncol(ZK);k
for (i in 1:k){
  ZK=ZKu[, -i];head(ZK)

  S00 <- crossprod(Z0)/N
  S11 <- crossprod(Z1)/N
  SKK <- crossprod(ZK)/N
  S01 <- crossprod(Z0, Z1)/N
  S0K <- crossprod(Z0, ZK)/N
  SK0 <- crossprod(ZK, Z0)/N
  S10 <- crossprod(Z1, Z0)/N
  S1K <- crossprod(Z1, ZK)/N
  SK1 <- crossprod(ZK, Z1)/N
  S11inv <- solve(S11)
  SKKinv <- solve(SKK)
  R01 <- Z0 - t(S01 %%% S11inv %%% t(Z1))
  R0K <- Z0 - t(S0K %%% SKKinv %%% t(ZK))
  RK1 <- ZK - t(SK1 %%% S11inv %%% t(Z1))
  S0K.1 <- S0K - S01 %%% S11inv %%% S1K
  S00.1 <- S00 - S01 %%% S11inv %%% S10
  SK0.1 <- SK0 - SK1 %%% S11inv %%% S10
  SKK.1 <- SKK - SK1 %%% S11inv %%% S1K
  Ctemp <- chol(SKK.1, pivot = TRUE)
  pivot <- attr(Ctemp, "pivot")
  oo <- order(pivot)
  C <- t(Ctemp[, oo])
  Cinv <- solve(C)
  S00.1inv <- solve(S00.1)
  valeigen <- eigen(Cinv %%% SK0.1 %%% S00.1inv %%% S0K.1 %%% t(Cinv))
  lambda <- valeigen$values
  e <- valeigen$vector
  V <- t(Cinv) %%% e
  W <- S0K.1 %%% V %%% solve(t(V) %%% SKK.1 %%% V)

  lambdar=lambda

#####
## PRUEBA DE HIPOTESIS CON TEST RAZON VEROSIMILITUD
## H0) beta=0, si pvalue<0.05 RH0
#####
T=N
idx=1:r
LR <- as.matrix(rev(sapply(idx, function(x) T * sum(log((1 - lambdar[(x):r])/(1 - lambdau[(x):r]))))))
LR=LR[r]
nrestric=1
df=nrestric*r
pvalue1=1-pchisq(LR, df=df);round(pvalue1,6)

resultado1[i,1]=round(LR,2)
resultado1[i,2]=round(pvalue1,6)
}
rownames(resultado1)=c("H0)beta.CSG=0", "H0)beta.CEE=0", "H0)beta.ISR=0",
"H0)beta.psg=0", "H0)beta.pee=0", "H0)beta.cte=0")
colnames(resultado1)=c("LR", "valor.p")
resultado1

```

D.1.10. Pruebas de hipótesis sobre los α

```
#####
## PRUEBAS DE HIPOTESIS SOBRE LOS ALPHA
#####

# LUEGO DE ESTIMAR SIN RESTRICCIONES GUARDAR LA VERSION U

ZK=ZKu
Z0=Z0u
Z1=Z1u

## RESTRICCIONES EN ALPHA ##

resultado=matrix(ncol=2,nrow=5)

# si quiero restringir alpha hay que particionar Z0

for(i in 1:5){
  Z0=Z0u[, -i];colnames(Z0)
  Z1=cbind(Z1u,Z0u[,i]);colnames(Z1)
  ZK=ZKu; colnames(ZK)

  S00 <- crossprod(Z0)/N
  S11 <- crossprod(Z1)/N
  SKK <- crossprod(ZK)/N
  S01 <- crossprod(Z0, Z1)/N
  S0K <- crossprod(Z0, ZK)/N
  SK0 <- crossprod(ZK, Z0)/N
  S10 <- crossprod(Z1, Z0)/N
  S1K <- crossprod(Z1, ZK)/N
  SK1 <- crossprod(ZK, Z1)/N
  S11inv <- solve(S11)
  SKKinv <- solve(SKK)
  R01 <- Z0 - t(S01 %*% S11inv %*% t(Z1))
  R0K <- Z0 - t(S0K %*% SKKinv %*% t(ZK))
  RK1 <- ZK - t(SK1 %*% S11inv %*% t(Z1))
  S0K.1 <- S0K - S01 %*% S11inv %*% S1K
  S00.1 <- S00 - S01 %*% S11inv %*% S10
  SK0.1 <- SK0 - SK1 %*% S11inv %*% S10
  SKK.1 <- SKK - SK1 %*% S11inv %*% S1K
  Ctemp <- chol(SKK.1, pivot = TRUE)
  pivot <- attr(Ctemp, "pivot")
  oo <- order(pivot)
  C <- t(Ctemp[, oo])
  Cinv <- solve(C)
  S00.1inv <- solve(S00.1)
  valeigen <- eigen(Cinv %*% SK0.1 %*% S00.1inv %*% S0K.1 %*% t(Cinv))
  lambda <- valeigen$values
  e <- valeigen$vector
  V <- t(Cinv) %*% e
  W <- S0K.1 %*% V %*% solve(t(V) %*% SKK.1 %*% V)

  lambdar=lambda

#####
## PRUEBA DE HIPOTESIS CON TEST RAZON VEROSIMILITUD
## H0) alpha=0, si pvalue<0.05 RH0
#####
T=N
idx=1:r
LR <- as.matrix(rev(sapply(idx, function(x) T * sum(log((1 - lambdar[(x):r])/(1 - lambdau[(x):r]))))))
LR=as.numeric(LR[r])
nrestric=1
df=nrestric*r
pvalue=1-pchisq(LR, df=df);round(pvalue,6)

resultado[i,1]=round(LR,2)
```

```

resultado[i,2]=round(pvalue,6)
}
rownames(resultado)=c("H0)alpha.CSG=0", "H0)alpha.CEE=0", "H0)alpha.ISR=0", "H0)alpha.psg=0", "H0)alpha.pee=0")
colnames(resultado)=c("LR", "valor.p")
resultado

```

D.1.11. Estimación del VECM con restricciones en los α

```

#####
## Estimacion MCO de GAMMA USANDO BETA RRR
#####
# RESTRINJO LOS PRECIOS.

Z0=Z0u[, -c(4,5)];colnames(Z0)
ZK=ZKu; colnames(ZK)
Z1=cbind(Z1u,Z0u[,4],Z0u[,5]);colnames(Z1)=c(colnames(Z1u),colnames(Z0u[,c(4,5)]));colnames(Z1)

#.....
## ESTIMACION de alpha y beta mediante el método de regresion de rango reducido
#.....
N=nrow(Z1);N
k=ncol(ZK);k

S00 <- crossprod(Z0)/N
S11 <- crossprod(Z1)/N
SKK <- crossprod(ZK)/N
S01 <- crossprod(Z0, Z1)/N
S0K <- crossprod(Z0, ZK)/N
SK0 <- crossprod(ZK, Z0)/N
S10 <- crossprod(Z1, Z0)/N
S1K <- crossprod(Z1, ZK)/N
SK1 <- crossprod(ZK, Z1)/N
S11inv <- solve(S11)
SKKinv <- solve(SKK)
R01 <- Z0 - t(S01 %*% S11inv %*% t(Z1))
R0K <- Z0 - t(S0K %*% SKKinv %*% t(ZK))
RK1 <- ZK - t(SK1 %*% S11inv %*% t(Z1))
S0K.1 <- S0K - S01 %*% S11inv %*% S1K
S00.1 <- S00 - S01 %*% S11inv %*% S10
SK0.1 <- SK0 - SK1 %*% S11inv %*% S10
SKK.1 <- SKK - SK1 %*% S11inv %*% S1K
Ctemp <- chol(SKK.1, pivot = TRUE)
pivot <- attr(Ctemp, "pivot")
oo <- order(pivot)
C <- t(Ctemp[, oo])
Cinv <- solve(C)
S00.1inv <- solve(S00.1)
valeigen <- eigen(Cinv %*% SK0.1 %*% S00.1inv %*% S0K.1 %*% t(Cinv))
lambda <- valeigen$values
e <- valeigen$vector
V <- t(Cinv) %*% e
W <- S0K.1 %*% V %*% solve(t(V) %*% SKK.1 %*% V)

r=r # cantidad de relaciones de cointegracion determinadas en el test de Johansen
K <- ncol(Z0)
r <- as.integer(r)
beta <- matrix(as.numeric(Vn[, 1:r]), ncol = r)
C1 <- diag(r)
C2 <- matrix(0, nrow = nrow(beta) - r, ncol = r)
C <- rbind(C1, C2)
betanorm <- beta %*% solve(t(C) %*% beta)
ECT <- ZK %*% betanorm #asi lo hace pkge var
colnames(ECT) <- paste("ect", 1:r, sep = "")
colnames(betanorm) <- colnames(ECT)
rownames(betanorm) <- colnames(ZK)

```

```
data.mat <- data.frame(Z0, Z1, ECT)

alphanorm <- S0K.1 %%% betanorm %%% solve(t(betanorm) %%% SKK.1 %%% betanorm)
round(betanorm,6)
round(alphanorm,6)

OMEGA <- S00.1 - S0K.1 %%% betanorm %%% solve(t(betanorm) %%% SKK.1 %%% betanorm) %%% t(betanorm) %%% SK0.1
round(OMEGA,8) # Matriz de varianzas y covarianzas a partir de normalizacion

T1<-(N)^(-1))*(diag(rep(1,6))-betanorm%%t(C))%%solve(SKK.1)%t(diag(rep(1,6))-betanorm%%t(C))
T2<-solve(t(alphanorm)%%solve(OMEGA)%alphanorm)
T3<-kronecker(T1,T2)
round(sqrt(diag(T3)),6)
#ERRORES ESTANDAR BETA
sd.error=matrix(round(sqrt(diag(T3)),6),nrow=6,ncol=2,byrow=TRUE)
colnames(sd.error)=colnames(betanorm)
rownames(sd.error)=rownames(betanorm)
sd.error # Errores estándar de los beta normalizados

colnames(Z0);colnames(Z1);colnames(ZK)
ZK=ZKu
Z0=Z0u
Z1=Z1u
colnames(Z0)
colnames(ECT)
colnames(Z1)

#p=3
rlm.1.2.3<-lm(Z0[,c(1,2,3)] ~ -1 + ECT + Z1 + Z0[,c(4,5)])
summary(rlm.1.2.3)

rlm.4.5 <- lm(Z0[,c(4,5)]~ -1 + Z1)
summary(rlm.4.5)

residuos=data.frame(cbind(residuals(rlm.1.2.3),residuals(rlm.4.5)))

# Matriz de varianzas y covarianzas, determinante y loglik
omega=crossprod(as.matrix(residuos))/N; round(omega,8)
detcov=det(omega);detcov
K=k-1
c=N*(K/2)- (N*(K/2)*log(2*pi))
logLmax=-(0.5*N)*log(detcov)+c;logLmax

aic=log(detcov)+(K^2*p)*(2/N);aic
sc=log(detcov)+(K^2*p)*(log(N)/N);sc
HQ=log(detcov)+(K^2*p)*(2*log(log(N))/N);HQ
```

D.1.12. Test sobre Causalidad de Granger

```
# CAUSALIDAD DE GRANGER
-----
# CSG
#-----
# psg
colnames(base)
b=cbind(csg=base[,1],psg=base[,4]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="psg", boot=TRUE, boot.runs=1000)#
causality(var1,cause="csg", boot=TRUE, boot.runs=1000)#
#pee
colnames(base)
b=cbind(csg=base[,1],pee=base[,5]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="pee", boot=TRUE, boot.runs=1000)#
causality(var1,cause="csg", boot=TRUE, boot.runs=1000)#
```

```

#isr
colnames(base)
b=cbind(csg=base[,1],isr=base[,3]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="isr", boot=TRUE, boot.runs=1000)#
causality(var1,cause="csg", boot=TRUE, boot.runs=1000)#
#-----
# CEE
#-----
# psg
colnames(base)
b=cbind(cee=base[,2],psg=base[,4]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="psg", boot=TRUE, boot.runs=1000)#
causality(var1,cause="cee", boot=TRUE, boot.runs=1000)#
#pee
colnames(base)
b=cbind(cee=base[,2],pee=base[,5]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="pee", boot=TRUE, boot.runs=1000)#
causality(var1,cause="cee", boot=TRUE, boot.runs=1000)#
#isr
colnames(base)
b=cbind(cee=base[,2],isr=base[,3]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="isr", boot=TRUE, boot.runs=1000)#
causality(var1,cause="cee", boot=TRUE, boot.runs=1000)#

#-----
# ISR
#-----
# psg
colnames(base)
b=cbind(isr=base[,3],psg=base[,4]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="psg", boot=TRUE, boot.runs=1000)#
causality(var1,cause="isr", boot=TRUE, boot.runs=1000)#
#pee
colnames(base)
b=cbind(isr=base[,3],pee=base[,5]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="pee", boot=TRUE, boot.runs=1000)#
causality(var1,cause="isr", boot=TRUE, boot.runs=1000)#

#-----
# psg
#-----
#pee
colnames(base)
b=cbind(psg=base[,4],pee=base[,5]);colnames(b)
var1=VAR(b, p = 3, type = c("const"),season = 12, exogen = exog,ic = c("AIC", "HQ", "SC", "FPE"))
causality(var1,cause="pee", boot=TRUE, boot.runs=1000)#
causality(var1,cause="psg", boot=TRUE, boot.runs=1000)#

```

D.1.13. Test de Chow

```

base=serie[1:156,];colnames(base);dim(base)
exog=cbind(exogenas[13:168,]);colnames(exog);dim(exog)
data=base
ex=exog
p=3
r=2

SS=as.numeric()
BP=as.numeric()

```



```

for (i in 1:4) {
  tb=12*(i+3)

  T=nrow(data)-p
  T1=tb
  T2=T-tb

#-----
# ESTIMACION DEL MODELO EN LA MUESTRA COMPLETA #
#-----

p=p; p # cantidad de rezagos determinados para el VAR
K= ncol(base);K # cantidad de variables
N=nrow(base);N # cantidad de datos

# definicion de la dummy estacionales centradas
season = 12
s <- season - 1
  dum <- (diag(season) - 1/season)[, -season]
  dums <- dum
  while (nrow(dums) < N) {
    dums <- rbind(dums, dum)
  }
  dums <- dums[1:N, ]
  colnames(dums) <- paste("sd", 1:ncol(dums), sep = "")

dim(dums)# variables estacionales centradas

# Z: Base con rezagos
Z=as.data.frame(embed(diff(base),p));dim(Z)
colnames(Z)[1:K]=paste(colnames(base), ".d", sep = "")
colnames(Z)[(K+1):(K*2)]=paste(colnames(base), ".d.l1", sep = "")
colnames(Z)[(K+K+1):(K*3)]=paste(colnames(base), ".d.l2", sep = "")
colnames(Z)#head(Z)

# Z0: Base con [Delta y_{t}]
Z0=as.matrix(Z[,1:K]);dim(Z0);colnames(Z0)

# ZK: Base con [y_{t-1}]
ZK=cbind(base[p:(nrow(base)-(1)),],cte=1);dim(ZK)
colnames(ZK) <- c(paste(colnames(base), ".l1", sep = ""),"cte")
ZK=as.matrix(ZK); colnames(ZK)

# Z1: Base con [Delta y_{t-1}] + dummies centradas, intervenciones, exogenas.
Z1=cbind(exog[(p+1):156,],dums[(p+1):156,]);dim(Z1) # con intervenciones
#Z1=cbind(dums[(p+1):156,]);dim(Z1) #sin intervenciones
Z1=as.matrix(cbind(Z[,-(1:K)],Z1))
Z1=as.matrix(Z1);colnames(Z1)

#.....
## ESTIMACION de alpha y beta mediante el método de regresion de rango reducido
#.....
N=nrow(Z1);N
T=N
k=ncol(ZK);k
# sin restricciones
  S00 <- crossprod(Z0)/N
  S11 <- crossprod(Z1)/N
  SKK <- crossprod(ZK)/N
  S01 <- crossprod(Z0, Z1)/N
  S0K <- crossprod(Z0, ZK)/N
  SK0 <- crossprod(ZK, Z0)/N
  S10 <- crossprod(Z1, Z0)/N
  S1K <- crossprod(Z1, ZK)/N
  SK1 <- crossprod(ZK, Z1)/N
  S11inv <- solve(S11)
  SKKinv <- solve(SKK)
  R01 <- Z0 - t(S01 %*% S11inv %*% t(Z1))
  R0K <- Z0 - t(S0K %*% SKKinv %*% t(ZK))
  RK1 <- ZK - t(SK1 %*% S11inv %*% t(Z1))

```

```

S0K.1 <- S0K - S01 %%% S11inv %%% S1K
S00.1 <- S00 - S01 %%% S11inv %%% S10
SK0.1 <- SK0 - SK1 %%% S11inv %%% S10
SKK.1 <- SKK - SK1 %%% S11inv %%% S1K
Ctemp <- chol(SKK.1, pivot = TRUE)
pivot <- attr(Ctemp, "pivot")
oo <- order(pivot)
C <- t(Ctemp[, oo])
Cinv <- solve(C)
S00.1inv <- solve(S00.1)
valeigen <- eigen(Cinv %%% SK0.1 %%% S00.1inv %%% S0K.1 %%% t(Cinv))
lambda <- valeigen$values
e <- valeigen$vector
V <- t(Cinv) %%% e
W <- S0K.1 %%% V %%% solve(t(V) %%% SKK.1 %%% V)
Vn <- V
for (j in 1:k){Vn[,j] <- sapply(j, function(x) V[, x]/V[j, x])}
Wn <- S0K.1 %%% Vn %%% solve(t(Vn) %%% SKK.1 %%% Vn)

r=r # cantidad de relaciones de cointegracion determinadas en el test de Johansen
K <- ncol(Z0)
r <- as.integer(r)
beta <- matrix(V[, 1:r], ncol = r)
C1 <- diag(r)
C2 <- matrix(0, nrow = nrow(beta) - r, ncol = r)
C <- rbind(C1, C2)
betanorm <- beta %%% solve(t(C) %%% beta)
ECT <- ZK %%% betanorm
colnames(ECT) <- paste("ect", 1:r, sep = "")
colnames(betanorm) <- colnames(ECT)
rownames(betanorm) <- colnames(ZK)
data.mat <- data.frame(Z0, Z1, ECT)
text <- colnames(data.mat)[-c(1:(K))]
text1 <- paste(text, "", sep = "+", collapse = "")
text2 <- paste("~", substr(text1,1 , nchar(text1) - 1))
form1 <- formula(paste("Z0", text2, "-1"))
rlm <- lm(form1, data = data.mat)

# Matriz de varianzas y covarianzas
OMEGA=crossprod(residuals(rlm),residuals(rlm))/N

u=residuals(rlm)
OMEGA1.2=(crossprod(u[1:tb,],u[1:tb,])/T1) + (crossprod(u[(tb+1):T,],u[(tb+1):T,])/T2)

#-----
# ESTIMACION DEL MODELO EN N1 CUANDO TB=01/2004 #
#-----

base=data[1:tb,]
exog=ex[1:tb,]
exog=ex[,c(which(colSums(exog)!=0)))]

p=p; p # cantidad de rezagos determinados para el VAR
K= ncol(base);K # cantidad de variables
N=nrow(base);N # cantidad de datos

# definicion de la dummy estacionales centradas
season = 12
s <- season - 1
dum <- (diag(season) - 1/season)[, -season]
dums <- dum
while (nrow(dums) < N) {
  dums <- rbind(dums, dum)
}
dums <- dums[1:N, ]
colnames(dums) <- paste("sd", 1:ncol(dums), sep = "")

dim(dums)# variables estacionales centradas

# Z: Base con rezagos

```

```
Z=as.data.frame(embed(diff(base),p));dim(Z)
colnames(Z)[1:K]=paste(colnames(base), ".d", sep = "")
colnames(Z)[(K+1):(K*2)]=paste(colnames(base), ".d.l1", sep = "")
colnames(Z)[(K+K+1):(K*3)]=paste(colnames(base), ".d.l2", sep = "")
colnames(Z)#head(Z)

# Z0: Base con [Delta y_{t}]
Z0=as.matrix(Z[,1:K]);dim(Z0);colnames(Z0)

# ZK: Base con [y_{t-1}]
ZK=cbind(base[p:(nrow(base)-(1)),],cte=1);dim(ZK)
colnames(ZK) <- c(paste(colnames(base), ".l1", sep = ""),"cte")
ZK=as.matrix(ZK); colnames(ZK)

# Z1: Base con [Delta y_{t-1}] + dummies centradas, intervenciones, exogenas.
Z1=cbind(exog[(p+1):N,],dums[(p+1):N,]);dim(Z1) # con intervenciones
#Z1=cbind(dums[(p+1):N,]);dim(Z1) #sin intervenciones
Z1=as.matrix(cbind(Z[,-(1:K)],Z1))
Z1=as.matrix(Z1);colnames(Z1)

#.....
## ESTIMACION de alpha y beta mediante el método de regresion de rango reducido
#.....
N=nrow(Z1);N
k=ncol(ZK);k
# sin restricciones
S00 <- crossprod(Z0)/N
S11 <- crossprod(Z1)/N
SKK <- crossprod(ZK)/N
S01 <- crossprod(Z0, Z1)/N
S0K <- crossprod(Z0, ZK)/N
SK0 <- crossprod(ZK, Z0)/N
S10 <- crossprod(Z1, Z0)/N
S1K <- crossprod(Z1, ZK)/N
SK1 <- crossprod(ZK, Z1)/N
S11inv <- solve(S11)
SKKinv <- solve(SKK)
R01 <- Z0 - t(S01 %*% S11inv %*% t(Z1))
R0K <- Z0 - t(S0K %*% SKKinv %*% t(ZK))
RK1 <- ZK - t(SK1 %*% S11inv %*% t(Z1))
S0K.1 <- S0K - S01 %*% S11inv %*% S1K
S00.1 <- S00 - S01 %*% S11inv %*% S10
SK0.1 <- SK0 - SK1 %*% S11inv %*% S10
SKK.1 <- SKK - SK1 %*% S11inv %*% S1K
Ctemp <- chol(SKK.1, pivot = TRUE)
pivot <- attr(Ctemp, "pivot")
oo <- order(pivot)
C <- t(Ctemp[, oo])
Cinv <- solve(C)
S00.1inv <- solve(S00.1)
valeigen <- eigen(Cinv %*% SK0.1 %*% S00.1inv %*% S0K.1 %*% t(Cinv))
lambda <- valeigen$values
e <-valeigen$vector
V <- t(Cinv) %*% e

r=r # cantidad de relaciones de cointegracion determinadas en el test de Johansen
K <- ncol(Z0)
r <- as.integer(r)
beta <- matrix(V[, 1:r], ncol = r)
C1 <- diag(r)
C2 <- matrix(0, nrow = nrow(beta) - r, ncol = r)
C <- rbind(C1, C2)
betanorm <- beta %*% solve(t(C) %*% beta)
ECT <- ZK %*% betanorm
colnames(ECT) <- paste("ect", 1:r, sep = "")
colnames(betanorm) <- colnames(ECT)
rownames(betanorm) <- colnames(ZK)
data.mat <- data.frame(Z0, Z1, ECT)
text <- colnames(data.mat)[-c(1:(K))]
text1 <- paste(text, "", sep = "+", collapse = "")
```

```

    text2 <- paste("~", substr(text1,1 , nchar(text1) - 1))
    form1 <- formula(paste("Z0", text2, "-1"))
    rlm <- lm(form1, data = data.mat)

# Matriz de varianzas y covarianzas
OMEGA1=crossprod(residuals(rlm),residuals(rlm))/N

#-----
# ESTIMACION DEL MODELO EN N2 CUANDO TB=01/2004 #
#-----
p=3
r=2

base=data[(tb+1):nrow(data),]
exog=ex[(tb+1):nrow(data),]
exog=exog[,c(which(colSums(exog)!=0))]

p=p; p # cantidad de rezagos determinados para el VAR
K= ncol(base);K # cantidad de variables
N=nrow(base);N # cantidad de datos

# definicion de la dummy estacionales centradas
season = 12
s <- season - 1
    dum <- (diag(season) - 1/season)[, -season]
    dums <- dum
    while (nrow(dums) < N) {
        dums <- rbind(dums, dum)
    }
    dums <- dums[1:N, ]
    colnames(dums) <- paste("sd", 1:ncol(dums), sep = "")

dim(dums)# variables estacionales centradas

# Z: Base con rezagos
Z=as.data.frame(embed(diff(base),p));dim(Z)
colnames(Z)[1:K]=paste(colnames(base), ".d", sep = "")
colnames(Z)[(K+1):(K*2)]=paste(colnames(base), ".d.l1", sep = "")
colnames(Z)[(K+K+1):(K*3)]=paste(colnames(base), ".d.l2", sep = "")
colnames(Z)#head(Z)

# Z0: Base con [Delta y_{t}]
Z0=as.matrix(Z[,1:K]);dim(Z0);colnames(Z0)

# ZK: Base con [y_{t-1}]
ZK=cbind(base[p:(nrow(base)-(1)),],cte=1);dim(ZK)
colnames(ZK) <- c(paste(colnames(base), ".l1", sep = ""),"cte")
ZK=as.matrix(ZK); colnames(ZK)

dim(exog)
dim(dums)
# Z1: Base con [Delta y_{t-1}] + dummies centradas, intervenciones, exogenas.
Z1=cbind(exog[(p+1):N,],dums[(p+1):N,]);dim(Z1) # con intervenciones
# se rompe choleski dependiendo el año
Z1=as.matrix(cbind(Z1,Z[,-(1:K)])) # uso este en 2004, 2006, 2007
#Z1=as.matrix(cbind(Z[,-(1:K)],Z1)) # uso este en 2005
#Z1=as.matrix(cbind(Z[,-(1:K)],Z1[,,-1]))# uso este en 2003
Z1=as.matrix(Z1);colnames(Z1)

#.....
## ESTIMACION de alpha y beta mediante el método de regresion de rango reducido
#.....
N=nrow(Z1);N
k=ncol(ZK);k
# sin restricciones
    S00 <- crossprod(Z0)/N
    S11 <- crossprod(Z1)/N
    SKK <- crossprod(ZK)/N
    S01 <- crossprod(Z0, Z1)/N
    S0K <- crossprod(Z0, ZK)/N

```

```

SK0 <- crossprod(ZK, Z0)/N
S10 <- crossprod(Z1, Z0)/N
S1K <- crossprod(Z1, ZK)/N
SK1 <- crossprod(ZK, Z1)/N
S11inv <- solve(S11)
SKKinv <- solve(SKK)
R01 <- Z0 - t(S01 %%% S11inv %%% t(Z1))
R0K <- Z0 - t(S0K %%% SKKinv %%% t(ZK))
RK1 <- ZK - t(SK1 %%% S11inv %%% t(Z1))
S0K.1 <- S0K - S01 %%% S11inv %%% S1K
S00.1 <- S00 - S01 %%% S11inv %%% S10
SK0.1 <- SK0 - SK1 %%% S11inv %%% S10
SKK.1 <- SKK - SK1 %%% S11inv %%% S1K
Ctemp <- chol(SKK.1, pivot = TRUE)
pivot <- attr(Ctemp, "pivot")
oo <- order(pivot)
C <- t(Ctemp[, oo])
Cinv <- solve(C)
S00.1inv <- solve(S00.1)
valeigen <- eigen(Cinv %%% SK0.1 %%% S00.1inv %%% S0K.1 %%% t(Cinv))
lambda <- valeigen$values
e <- valeigen$vector
V <- t(Cinv) %%% e
r=r # cantidad de relaciones de cointegracion determinadas en el test de Johansen
K <- ncol(Z0)
r <- as.integer(r)
beta <- matrix(V[, 1:r], ncol = r)
C1 <- diag(r)
C2 <- matrix(0, nrow = nrow(beta) - r, ncol = r)
C <- rbind(C1, C2)
betanorm <- beta %%% solve(t(C) %%% beta)
ECT <- ZK %%% betanorm
colnames(ECT) <- paste("ect", 1:r, sep = "")
colnames(betanorm) <- colnames(ECT)
rownames(betanorm) <- colnames(ZK)
data.mat <- data.frame(Z0, Z1, ECT)
text <- colnames(data.mat)[-c(1:(K))]
text1 <- paste(text, "", sep = "+", collapse = "")
text2 <- paste("~", substr(text1,1 , nchar(text1) - 1))
form1 <- formula(paste("Z0", text2, "-1"))
rlm <- lm(form1, data = data.mat)

# Matriz de varianzas y covarianzas
OMEGA2=crossprod(residuals(rlm),residuals(rlm))/N

SS[i]=(T1+T2)*(log(det(OMEGA1.2))- log(det((T1*OMEGA1+T2*OMEGA2)/(T1+T2))))
BP[i]= (T1+T2)*log(det(OMEGA1.2)) - T1*log(det(OMEGA1)) - T2*log(det(OMEGA2))
}

SS
BP

df=(2*k*r)-r^2+(p-1)*k^2+k
pvalue=1-pchisq(SS, df=df);round(pvalue,6)

```

Apéndice E

Anexo con Tablas de Valores Críticos

Cuadro E.0.1: Valores Críticos para el Test de Dickey-Fuller Aumentado (ADF).

Especificación	1 %	5 %	10 %
Modelo (a) (ec. A.17 / ec. A.20) $H_0 : \vartheta_a = 1$	-2,58	-1,95	-1,62
Modelo (b) (ec. A.18 / ec. A.21) $H_0 : \vartheta_b = 1$	-3,46	-2,88	-2,57
Modelo (c) (ec. A.19 / ec. A.22) $H_0 : \vartheta_c = 1$	-3,99	-3,43	-3,13
ADF con constante dado $\vartheta_i = 1$			
τ_1	3,19	2,53	2,16
ϕ_1	6,52	4,63	3,81
ADF con cte y tend $\vartheta_i = 1$			
τ_2	3,74	3,09	2,73
τ_3	3,49	2,79	2,38
ϕ_2	6,22	4,75	4,07
ϕ_3	8,43	6,49	5,47

Nota: Valores críticos en muestras de tamaño $T \leq 250$.

Fuente: Banerjee et al. (1993) [\[6\]](#).

Cuadro E.0.2: Valores Críticos para el Test de Zivot y Andrews (ZA) [\[40\]](#).

Especificación	1 %	5 %	10 %
ZA con constante (du)	-5,34	-4,80	-4,58
ZA con tendencia (dt)	-4,93	-4,42	-4,11
ZA con constante y tendencia (du y dt)	-5,57	-5,08	-4,82

Bibliografía

- [1] Aliaga Lordemann, J. & A. Capriles (2011). “Análisis de la Sustitución de Fuentes Energéticas en Bolivia”. *Instituto de Investigaciones Socioeconómicas*, D.T. núm. 06/11.
- [2] Amengual, D. & Cubas, G. (2002). “Imposición óptima a las naftas y el gasoil: un análisis empírico para Uruguay 1988-2001”. *XVII Jornada Anual de Economía*, Banco Central del Uruguay.
- [3] Anderson, T.W. & Rubin, H. (1949). “Estimation of the Parameters of a Single Equation in a Complete System of Stochastic Equations”. *The Annals of Mathematical Statistics* vol. 20 (n.1) (46-63).
- [4] Anderson, T.W. (1951). “Estimating linear restrictions on regression coefficients for multivariate normal distributions”. *The Annals of Mathematical Statistics*. vol. 22 (327-351).
- [5] “Balance Energético Nacional 2011, Uruguay”. Ministerio de Industria, Energía y Minería, Dirección Nacional de Energía (MIEM - DNE).
- [6] Banerjee, A.; Dolado, J.J.; Galbraith, J.W.; & Hendry, D.F. (1993). “Co-Integration, Error-Correction, and the Econometric Analysis of Non-Stationary Data”. *Advanced Texts in Econometrics*, Oxford University Press.
- [7] Cordano, A.V. (2005). “La Demanda Agregada de Combustibles Líquidos en Perú”, OSINERG (Organismo Supervisor de la Inversión en Energía), D.T. núm.12, 2005.
- [8] Davidson, J.E.H.; Hendry, D.F.; Srba, F. & Yeo, S. (1978). “Econometric Modelling of the Aggregate Time-series Relationship Between Consumer’s Expenditure and Income in the United Kingdom”. *Economic Journal* vol. 88 (661-692).
- [9] Dickey, D.A. & Fuller, W.A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *J. Am. Statist. Assoc.* vol. 74 (427-431).
- [10] Enders, W. (2015). “Applied Econometric Time Series”. Fourth edition, John Wiley & Sons.
- [11] Engle, R.F.; Hendry, D.F. & Richard, J.F. (1983). “Exogeneity”. *Econometrica* vol. 51 (n.2) (277-304).
- [12] Engle, R.F. & Granger, C.W.J. (1987). “Co-Integration and Error Correction: Representation, Estimation, and Testing”. *Econometrica* vol. 55 (n.2) (251-276).

- [13] Ericsson, N.R.; Hendry, D.F. & Mizon, G.E. (1998). "Exogeneity, Cointegration, and Economic Policy Analysis". Board of Governors of the Federal Reserve System. International Finance *Discussion Papers* núm. 616.
- [14] Granger, C.W.J.(1969). "Investigating Causal Relations by Econometric Models and Cross-spectral Methods". *Econometrica* vol. 37 (n.3) (424-438).
- [15] Granger, C.W.J. & Newbold, P. (1974). "Spurious Regressions in Econometrics". *Journal of Econometrics* vol. 26 (1045-1066).
- [16] Hendry, D.F. & Anderson, G.J. (1977). "Testing dynamic specification in small simultaneous systems: An application to a model of Building Society behaviour in the United Kingdom". In M.D. Intriligator (Ed.), *Frontiers in Quantitative Economics* vol. 3 (361-383).
- [17] Hendry, D.F. (1995). "Dynamic Econometrics". *Oxford University Press*. (ISBN 0-19-828317-2)
- [18] Hendry, D.F. & Juselius, K. (1999). "Explaining Cointegration Analysis: Part I". Economics Department, University of Oxford.
- [19] Hendry, D.F. & Juselius, K. (2000). "Explaining Cointegration Analysis: Part II". Economics Department, University of Oxford.
- [20] Hendry, D.F. (2004). "Causality and Exogeneity in Non-stationary Economic Time Series". Economics Department, University of Oxford.
- [21] Hyndman, R.J. & Koehler, A.B. (2006). "Another look at measures of forecast accuracy". *International Journal of Forecasting* vol.22 (679-688).
- [22] Izenman, A.J. (1972). "Reduced-Rank Regression for the Multivariate Linear Model, its relationship to certain classical multivariate techniques, and its application to the analysis of multivariate data". Ph.D. dissertation, University of California, Berkeley.
- [23] Izenman, A.J. (1975). "Reduced-Rank Regression for the Multivariate Linear Model". *Journal of Multivariate Analysis* vol.5 (248-264).
- [24] Izenman, A.J. (2008). "Modern Multivariate Statistical Techniques". Springer Texts in Statistics.
- [25] Johansen, S. & Juselius, K. (1990). "Maximum Likelihood Estimation and Inference on Cointegration - with Applications to the Demand for Money". *Oxford Bulletin of Economics and Statistics* vol. 52 (n.2) (169-210).
- [26] Johansen, S. (1994). "The role of the constant and linear terms in cointegration analysis of nonstationary variables". *Econometric Reviews* vol. 13:2 (205-229).
- [27] Johansen, S. (1995). "Likelihood-Based Inference in Cointegrated Vector Autoregressive Models". *Advanced Texts in Econometrics*, Oxford University.
- [28] Johansen, S. (2004). "Cointegration: an overview". Department of Applied Mathematics and Statistics University of Copenhagen.

BIBLIOGRAFÍA

- [29] Juselius, K. (2006). "The Conintegrated VAR Model. Methodology and Applications". *Advanced Texts in Econometrics*, Oxford University Press.
- [30] Koopman, T.C. & Hood, W.C. (1951). "The Estimation of Simultaneous Linear Economic Relations". *Cowles Commission Discussion Paper*: Statistics núm. 363.
- [31] Kurozumi, E. (2007). "The Wald-Type Test of a normalization of cointegrating vectors". *J. Japan Statistic Soc.* vol. 37 (n.2) (191-205).
- [32] Landaveri, R. (2008). "Caracterización del Consumo de Energía a nivel de Usos: Sector Residencial", Balance Nacional en Energía Util de Uruguay 2006. MIEM-DNETN (Ministerio de Industria Energía y Minería - Dirección Nacional de Energía y Tecnología Nuclear).
- [33] "Liquefied Petroleum Gas Market Outlook 2008-2017". México, Gobierno Federal - Ministerio de Energía, 2008.
- [34] Lütkepohl, H. (2004). "Applied Time Series Econometrics". Cambridge University Press.
- [35] Lütkepohl, H. (2005). "New Introduction to Multiple Time Series Analysis". *Springer* 2005.
- [36] Medinaceli Monrroy, S.M. (2004). "Subsidios al Precio del Gas Licuado de Petróleo en Bolivia". Cámara Boliviana de Hidrocarburos y Energía. <http://www.cbh.org.bo/archivos/docs/subsidioalpreciodelglp.pdf>
- [37] Mohammadi, H. (2009). "Electricity prices and fuel costs: Long-run relations and short-run dynamics". *Energy Economics* - vol. 31 (n.3) (503-509).
- [38] Panagiotidis, T. & Rutledge, E. (2007). "Oil and gas markets in the UK: Evidence from a cointegrating approach". *Energy Economics* - vol. 29 (n.2) (329-347).
- [39] Perron, P. (1989). "The Great Crash, the Oil Price Shock and the Unit Root Hypothesis". *Econometrica* vol 57 (n.6) (1361-1401).
- [40] Pfaff, B. (2008). "Analysis of Integrated and Cointegrated Time Series with R". Second edition, *Springer* 2008.
- [41] Ramanathan, R. (1999). "Short and Long Run Elasticities of Gasoline Demand in India: An Empirical Analysis Using Cointegration Techniques". *Energy Economics* vol. 21 (n.4) (321-330).
- [42] Rodriguez, M.F. (2006). "Estimación de la Demanda de Combustibles en República Dominicana". Unidad de Análisis Económico del Secretariado Técnico de la Presidencia. Texto de discusión 6.
- [43] Rodriguez, S. & da Silva, N. (2010). "Temperatura y desempeño predictivo de los modelos de demanda de GLP, análisis de sensibilidad". Documento de trabajo del Instituto de Estadística de Facultad de Ciencias Económicas y Administración.
- [44] Sargan, J. D. (1964). "Wages and Prices in the United Kingdom: a Study in Econometric Methodology, in *Econometric Analysis for National Economic Planning*". London: Butterworths

- [45] Sims, C.A. (1980). "Macroeconomics and Reality". *Econometrica* vol. 48 (n.1) (1-48).
- [46] Suriñach, J.; Artís, M.; López, E. & Sansó, A. (1995). "Análisis Económico Regional, nociones básicas de la teoría de la Cointegración".
- [47] Varian, H. (2011). "Microeconomía Intermedia. Un enfoque actual". Octava edición.
- [48] Yule, G.U. (1921). "On the time-correlation problem, with special reference to the variate-difference correlation method". *Journal of the Royal Statistical Society* vol. 84 (497-526).
- [49] Zivot, E. & Andrews, D.W.K. (1992). "Further Evidence on the Great Crash, the Oil Price Shock, and the Unit Root Hypothesis". *Journal of Business & Economic Statistics* vol. 10 (n.3) (251-270).