

**BANCO CENTRAL DE COSTA RICA
DEPARTAMENTO DE INVESTIGACIONES ECONOMICAS
DIE-01-2004-DI
DOCUMENTO DE INVESTIGACIÓN
MARZO 2004**

***MODELOS VAR Y VECM PARA EL PRONÓSTICO DE CORTO PLAZO
DE LAS IMPORTACIONES DE COSTA RICA***

Eilyn Arias C.
Carlos Torres G.

Documento de trabajo del Banco Central de Costa Rica, elaborado por el
Departamento de Investigaciones Económicas

Las ideas expresadas en este documento son responsabilidad del autor y no necesariamente
Representan la opinión del Banco Central de Costa Rica

TABLA DE CONTENIDO

I.	INTRODUCCIÓN	2
II.	SUSTENTO TEÓRICO	3
III.	ESTIMACIÓN EMPÍRICA.....	5
3.1.	Aspectos Metodológicos.....	5
3.2.	Análisis Gráfico Preliminar	6
3.3.	Análisis de Integración (pruebas ADF)	6
3.4.	Especificación Empírica del VAR.....	7
3.5.	Diagnóstico Econométrico del VAR	9
3.6.	Especificación Empírica del VECM.....	12
3.7.	Diagnóstico Econométrico del VECM	12
IV.	RESULTADOS Y CAPACIDAD DE PRONÓSTICO DE LOS MODELOS.....	15
V.	CONSIDERACIONES FINALES.....	17
VI.	REFERENCIAS BIBLIOGRÁFICAS.....	18
	ANEXOS.....	19
	Anexo 1 Pruebas de raíz unitaria (ADF).....	20
	Anexo 2 Modelos VAR estimados	22
	Anexo 3 Pruebas de autocorrelación.....	23
	Anexo 4 Prueba de Normalidad multivariada de los residuos.....	24
	Anexo 5 Función Impulso-Respuesta acumulada.....	24
	Anexo 6 Raíces del polinomio característico.....	25
	Anexo 7 Pruebas de causalidad de Granger.....	25
	Anexo 8 Prueba de Johansen	26
	Anexo 9 Modelo VECM sin restricción.....	27
	Anexo 10 Función de impulso respuesta (FIR).....	27
	Anexo 11 Pruebas de autocorrelación.....	28
	Anexo 12 Prueba de normalidad multivariada de los residuos.....	28
	Anexo 13 Modelo VECM restringido.....	29
	Anexo 14 Función de impulso respuesta (FIR).....	29
	Anexo 15 Función de impulso respuesta (FIR) acumulada.....	29
	Anexo 16 Pruebas de autocorrelación.....	29
	Anexo 17 Prueba de normalidad multivariada.....	30

MODELOS VAR Y VECM PARA EL PRONÓSTICO DE CORTO PLAZO DE LAS IMPORTACIONES DE COSTA RICA¹

Resumen

En el documento se estiman modelos VAR y VECM para el pronóstico de corto plazo de las importaciones de Costa Rica. Estos modelos se plantean como herramientas de pronóstico alternativas a un modelo ARIMA utilizado actualmente.

Los resultados de las distintas pruebas econométricas efectuadas a dichos modelos minimizan la posibilidad de que los pronósticos se basen en relaciones funcionales espurias.

Considerando todo el periodo de pronóstico, se observó que en general los VECM alcanzaron un mayor poder de pronóstico, especialmente el VECM sin restricción, comparados con el ARIMA y los VAR estimados.

Aunque el modelo ARIMA venía mostrando una tendencia a la sobrestimación del pronóstico, las últimas proyecciones revelaron una mejora en su capacidad de proyección. Concordante con el objetivo planteado en el documento, este último resultado sugiere una actitud de prudencia en la consideración de las distintas técnicas de proyección, para no adoptar una sola sino que concebirlas como complementarias; incluso continuar desarrollando otras posibilidades que permitan asesorar de la mejor forma a las autoridades en la tarea de predecir el comportamiento de las importaciones.

Clasificación JEL: C1; C3; C5

¹ Los autores agradecen las observaciones de Mauricio Mayorga y Manrique Sáenz.

I. INTRODUCCIÓN

El Departamento Investigaciones Económicas (DIE) del Banco Central de Costa Rica (BCCR), ha venido empleando un modelo univariado ARIMA para pronosticar mensualmente el valor CIF de las importaciones de Costa Rica, excluyendo el valor de las compras externas de la Industria de Alta Tecnología².

Tal modelo es sencillo de calcular y, en general, ha tenido un desempeño satisfactorio en el pronóstico de esa variable³. En efecto, el error medio de pronóstico, expresado como porcentaje de las diferencias absolutas entre el valor observado y el pronosticado (*mean absolute percentage error, MAPE*), fue 5.3% entre noviembre del 2001 y julio del 2003⁴. No obstante, se considera que ese resultado es susceptible de mejorar mediante otras herramientas de pronóstico de corto plazo, tal como los modelos de vectores autorregresivos (VAR), los modelos de corrección de errores (ECM) y los modelos de vectores de corrección de errores (VECM).

En ese sentido, el objetivo de este estudio es estimar modelos VAR y VECM, que sirvan como herramientas de pronóstico de corto plazo alternativas al modelo ARIMA mencionado y que brinden mayores elementos de juicio a las autoridades sobre la evolución futura de las importaciones.

Cabe mencionar que para el pronóstico de más largo plazo, los modelos ARIMA, VAR y VECM son generalmente superados por los modelos estructurales más complejos. Precisamente, el DIE cuenta también con un modelo estructural trimestral de importaciones, para generar proyecciones de mediano plazo⁵.

Los resultados principales de este estudio son:

- Los resultados de las diferentes pruebas econométricas realizadas a los modelos VAR y VECM estimados minimizan la posibilidad de que sus pronósticos se basen en relaciones funcionales espurias.
- Considerando todo el periodo de pronóstico, se observa que, en general, los VECM alcanzaron un mayor poder de pronóstico, especialmente el VECM sin restricción, comparados con el ARIMA existente y los VAR estimados.
- Aunque el modelo ARIMA mostraba una tendencia a la sobrestimación del pronóstico, las últimas proyecciones revelaron una mejora en su capacidad de proyección.
- No obstante, Concordante con el objetivo originalmente planteado, los resultados anteriores sugieren una actitud de prudencia en la consideración de las distintas técnicas de proyección, para no adoptar una sola sino que concebirlas como complementarias;

² Dicho pronóstico se suministra a la sección Balanza de Pagos y sirve como un criterio adicional al juicio de experto de los funcionarios de esa sección, para darle seguimiento al comportamiento de las importaciones y para estimar un flujo de caja, para efectos de la programación monetaria del BCCR.

³ A pesar de su sencillez, se le señalan ciertas limitaciones; entre ellas, que no toma en cuenta otros factores que afectan a la variable modelada.

⁴ Véase Informe Técnico DIE-74-2003-IT, del 8 de setiembre del 2003.

⁵ Véanse DIE-51-2003-IT del 16 de junio del 2003 y DIE-53-2003-IT del 18 de junio del 2003.

incluso continuar desarrollando otras posibilidades que permitan asesorar de la mejor forma a las autoridades en la tarea de pronosticar el comportamiento de las importaciones.

El documento está estructurado en tres secciones: la sección II menciona el sustento teórico de los modelos VAR y VECM, así como el modelo que respalda la escogencia de las variables consideradas; la sección III describe la estimación empírica de estos modelos; la sección IV resume los resultados y evalúa la capacidad de pronóstico de los modelos y la sección V contiene las consideraciones finales.

II. SUSTENTO TEÓRICO

El modelo VAR es una herramienta de series de tiempo multivariado, la cual fue utilizada para el análisis macroeconómico originalmente por Sims a inicios de la década del ochenta⁶.

En el VAR todas las variables son consideradas como endógenas, pues cada una de ellas se expresa como una función lineal de sus propios valores rezagados y de los valores rezagos de las restantes variables del modelo. Lo anterior permite capturar más apropiadamente los comovimientos de las variables y la dinámica de sus interrelaciones de corto plazo, lo cual no es detectable con modelos univariados como los ARIMA. El VAR es también una técnica poderosa para generar pronósticos confiables en el corto plazo, aunque se le señalan ciertas limitaciones⁷.

El modelo VECM es también una herramienta que pertenece al contexto de series de tiempo multivariado, pero se caracteriza por contener variables cointegradas; es decir, variables que guardan una relación de equilibrio de largo plazo entre ellas.

Los VECM han refinado el análisis VAR, pues incluye tanto la dinámica de ajuste de las variables en el corto plazo, cuando ocurre un *shock* inesperado que hace que éstas se aparte transitoriamente de su relación de equilibrio de largo plazo, como el restablecimiento de la relación de equilibrio en el largo plazo, siendo especialmente útil la información que brinda sobre la velocidad de ajuste hacia tal equilibrio; por tanto, el VECM brinda mayor información que el VAR (Fernandez-Corugedo, 2003).

En general, estos modelos han tomado popularidad entre los investigadores y han tenido un buen desempeño en el pronóstico de corto plazo de muchas variables económicas.

La escogencia de las variables empleadas en los modelos mencionados se sustenta teóricamente en una función de demanda típica como la siguiente:

$$M^d = f(p, y; \theta) \tag{1}$$

⁶ Véase Sims (1980).

⁷ Entre otros problemas, los VAR omiten la posibilidad de considerar relaciones no lineales entre las variables y no toma en cuenta problemas de heterocedasticidad condicional ni cambio estructural en los parámetros estimados (Banco de Guatemala, 2002).

Donde:

- M^d Demanda por importaciones del resto del mundo, aproximada por el logaritmo del valor CIF, en miles de dólares corrientes, de las importaciones totales de Costa Rica, excluyendo las importaciones de la Industria de Alta Tecnología (*lmsi*).
- p Precio relativo de los bienes importados respecto a los bienes domésticos sustitutos de los bienes importados, aproximado por el logaritmo del índice de tipo de cambio real bilateral con Estados Unidos (principal socio comercial) (*litcerb*).
- y Variable de ingreso o poder de compra (escala)⁸, aproximado mediante el logaritmo de la serie original del Indicador Mensual de Actividad Económica (IMAE), excluyendo el valor agregado de la Industria Electrónica de Alta Tecnología (*limaesi*).
- θ Otras variables que se asumen constantes (gustos y preferencias de los agentes, política arancelaria, etc.).

Conviene prevenir que aunque la ecuación (1) establece una relación funcional desde las variables explicativas (exógenas) hacia la variable explicada (endógena), en el caso de las técnicas VAR y VECM se asume que las variables involucradas son endógenas, por lo que no es posible establecer una relación funcional unidireccional.

Para este caso particular, el VAR puede representarse en forma reducida como:

$$x_t = \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \beta_k x_{t-k} + Bz_t + u_t \quad (2)$$

Donde:

- x_t Vector columna que contiene las tres variables endógenas contemporáneas mencionadas (*lmsi*, *litcerb* y *limaesi*).
- x_{t-i} Vector columna con las tres variables endógenas anteriores, rezagadas, para $i=1, 2, \dots, k$.
- z_t Vector de variables determinísticas exógenas.
- β_i, B Matrices de coeficientes de regresión a estimar, para $i=1, 2, \dots, k$.
- u_t Vector de innovaciones, las cuales se suponen no serialmente correlacionadas.

Por su parte, el VECM se puede representar como

$$\Delta x_t = \Pi x_{t-k} + \Gamma_1 \Delta x_{t-1} + \Gamma_2 \Delta x_{t-2} + \dots + \Gamma_{k-1} \Delta x_{t-(k-1)} + Bz_t + u_t \quad (3)$$

Donde:

⁸ Se supone que la actividad económica requiere un cierto componente importado.

$\Pi = \left(\sum_{j=1}^k \beta_j \right) - I_g$ Matriz que resulta del producto de dos submatrices: α y β' . De β se obtienen los vectores de cointegración y de α los parámetros de ajuste de cada ecuación del VECM, donde I_g es la matriz identidad.

$\Gamma_i = \left(\sum_{j=1}^i \beta_j \right) - I_g$ Matriz de coeficientes de regresión a estimar.

u_t Vector de errores no serialmente correlacionados.
 Δ denota variables en diferencias

III. ESTIMACIÓN EMPÍRICA

El VAR de la ecuación (2) y el VECM de la ecuación (3) son los modelos que se estiman a continuación.

3.1. Aspectos Metodológicos

La estimación empírica de los modelos utiliza una muestra de datos mensuales del periodo: enero de 1992 a abril del 2003 (136 observaciones). Para efectos de comparación de los resultados, este periodo muestral es similar al utilizado por el modelo ARIMA mencionado al inicio.

Lo datos originales provienen de la sección Estadísticas Básicas de Importación del BCCR; de la Dirección General de Aduanas, perteneciente al Ministerio de Hacienda y de las Estadísticas Financieras Internacionales del Fondo Monetario Internacional.

Para calcular el logaritmo del índice del tipo de cambio real bilateral (*litcerb*), se adoptó parcialmente la definición empleada en el modelo estructural trimestral de importaciones⁹. De esta forma, el *litcerb* se calculó como el logaritmo de la siguiente expresión¹⁰:

$$itcerb = \frac{itcnp * ippusa}{ipc} \quad (4)$$

Donde:

itcerb Índice de tipo de cambio real bilateral (Costa Rica-Estados Unidos)
itcnp Índice del tipo de cambio nominal promedio (de compra y venta de divisas).
ippusa Índice de precios al productor de Estados Unidos.
ipc Índice de precios al consumidor de Costa Rica.

⁹ Véase Informe Técnico DIE-51-2003-IT, del 16 de junio del 2003.




¹⁰ La ecuación (4) incorpora el *ipc* de Costa Rica, en lugar del índice de precios al productor del país (*ipper*), con el fin de capturar mejor el precio de los bienes no transables del país. De esta forma, el precio relativo de los bienes transables internacionales (aproximados por el *ippusa*) respecto a los no transables (aproximados por el *ipc*) reflejará más apropiadamente los incentivos a la reasignación de recursos entre estos sectores y al consumo de no transables sustitutos de los transables.

Todos estos índices, así como la variable *limaesi* fueron ajustados para tener base común 1995=100.

3.2. Análisis Gráfico Preliminar

Un análisis gráfico preliminar de las variables consideradas revela una clara tendencia positiva en el tiempo de *lmsi* y *limaesi* (Gráficos 1 y 3).

También se observa que el *litcerb*, calculado en la ecuación (4), tiene una tendencia negativa; éste y el índice de tipo de cambio real bilateral calculado por el BCCR (*itcereua*), adjuntado para efectos de comparación, mantienen un comportamiento similar, aunque a partir de 1996 se nota una divergencia que ha tendido a ensancharse en el tiempo (Gráfico 2).



3.3. Análisis de Integración (pruebas ADF)

Uno de los requisitos usuales de la técnica VAR es que las variables se incorporen al modelo en forma estacionaria¹¹, por ello se estudió el grado de integración de éstas. Al respecto, según las pruebas de Dickey-Fuller Aumentadas (ADF), todas las variables fueron estacionarias con constante y con tendencia; al 5% y 10% de significancia¹² (Anexo 1). La significancia del

¹¹ Sin embargo, Enders (1995) menciona que existe discusión en cuanto a si las variables de un VAR necesitan ser estacionarias.

¹² Incluso la variable *limaesi* fue estacionaria al 1%.

término de tendencia en estas pruebas corrobora el comportamiento tendencial de las variables apreciado en el análisis gráfico preliminar.

3.4. Especificación Empírica del VAR

Aunque las pruebas ADF detectaron que el término de tendencia fue significativo en el caso de todas las variables empleadas; éstas no se incluyeron diferenciadas en el VAR porque cointegran¹³ (en niveles), lo que significa que contienen información útil en sus niveles¹⁴. Más bien, se consideraron las siguientes dos opciones para especificar el VAR:

- incorporar las variables endógenas en niveles (*lmsi*, *litcerb* y *limaesi*) y, complementariamente, introducir una constante y una tendencia determinística (*c*, *@trend*, respectivamente) como variables exógenas; pues se argumenta que los datos necesitan incorporar ese último componente, para imitar el verdadero proceso generador de datos (Enders, 1995). Aunque este procedimiento no es utilizado ampliamente por los investigadores, es contemplado por los programas econométricos¹⁵ y se ha empleado empíricamente a nivel internacional¹⁶. De hecho, Fernandez-Corugedo (2003) menciona que la tendencia temporal, en una serie estacionaria en tendencia, puede ser anulada al incluir una tendencia determinística como uno de los regresores del modelo.
- incorporar las variables endógenas sin su tendencia (*lmsi_sin_tend*, *litcerb_sin_tend* y *limaesi_sin_tend*), pues ésta es la recomendación teórica tradicional cuando se tienen series estacionarias alrededor de una tendencia determinística (Soto, 2002)¹⁷. Cuando se utiliza esta segunda opción las series cumplen con el requisito del comportamiento estacionario, como se observa en los gráficos 4, 5 y 6 y se verifica en las pruebas correspondientes.

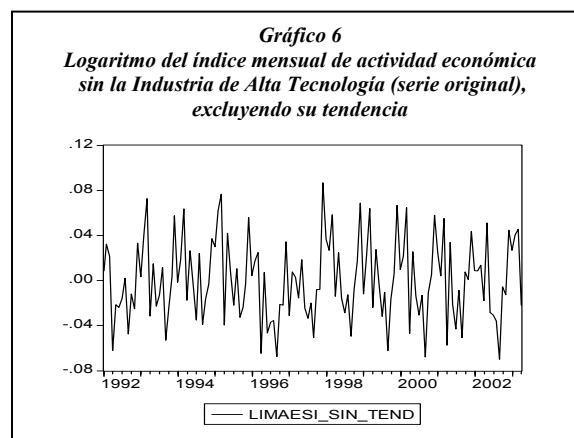
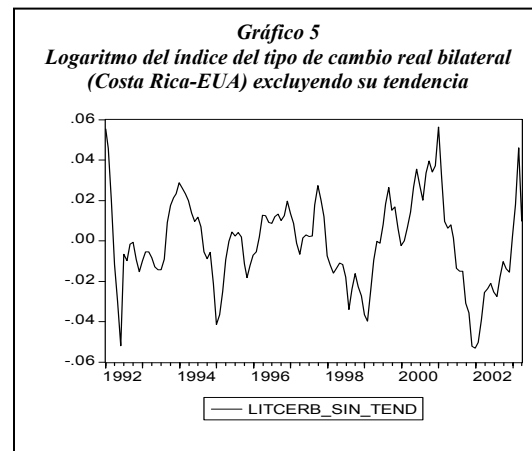

¹³ La cointegración se deduce del hecho de que si las tres variables son estacionarias con constante y con tendencia, una estimación econométrica de la ecuación (1) puede despejar el error de regresión asociado y expresarlo como una combinación lineal de ellas, resultando también estacionario, si ha de preservarse el “balance” econométrico de la ecuación.

¹⁴ En efecto, como señala Soto (2002) “*un VAR en primeras diferencias finito no es una adecuada representación de un sistema que cointegra*”. El principal argumento en contra de la diferenciación es que ésta desecha la información de los comovimientos en los datos, tal como posibles relaciones de cointegración entre ellos (Enders, 1995). Además, Enders (1995) cita que Sims (1980) se ha manifestado en contra de la diferenciación, aún si las variables tienen una raíz unitaria, pues argumenta que el objetivo del análisis VAR es la determinación de las interrelaciones entre las variables, no la estimación de sus parámetros.

¹⁵ Tanto el programa econométrico Eviews (1994-2000) como Rats (2001) consideran la posibilidad de incluir variables de tendencia determinística (así como constantes y *dummies* estacionales) dentro de las variables exógenas del VAR.

¹⁶ En Enders y Sandler (1993) se usa un VAR para estimar el impacto del terrorismo en el turismo en España durante el periodo 1970-1988. En este estudio se incluyó una variable de tendencia temporal en el VAR y los autores señalan que esta alternativa fue la que rindió el mejor diagnóstico estadístico.

¹⁷ Para identificar la tendencia y removerla se utilizó el filtro de Hodrick-Prescott.



No se consideraron *dummies* estacionales para dar oportunidad de que la estacionalidad del IMAE explique la estacionalidad de las importaciones y para ajustarse a un VAR parsimonioso que minimice la pérdida de grados de libertad¹⁸, lo cuál es un problema crítico de esta técnica de estimación¹⁹.

Para la opción del VAR con las variables en niveles (en adelante denominado VAR1), se especificó una estructura óptima de dos meses de rezago en las variables endógenas, mientras que para el VAR con las variables sin su tendencia (VAR2) se especificó un mes de rezago. Ambos rezagos óptimos determinados según el Criterio de Información de Schwarz.

Contemplando las recomendaciones y resultados anteriores, se especificaron los dos VAR, con datos observados al mes de abril del 2003 (Anexo 2).

¹⁸ Cuando se trabaja con datos mensuales y se quiere modelar la estacionalidad, se deben incorporar once variables *dummy*.

¹⁹ Al respecto, Cavaliere (2003) menciona que la inclusión de muchos rezagos o variables (problema de *overfitting*) pueden guiar a un mal pronóstico, debido a que aumenta la probabilidad de obtener un VAR espurio.

3.5. Diagnóstico Econométrico del VAR

Como la técnica VAR es relativamente flexible y está dominada por la endogeneidad de las variables, no se acostumbra analizar los coeficientes de regresión estimados ni sus significancias estadísticas; tampoco la bondad del ajuste (R^2 ajustado) de las ecuaciones individuales. Pero sí es usual que se verifique que se cumple la ausencia de correlación serial de los residuos de las ecuaciones individuales del modelo y la distribución normal multivariada de éstos. A veces se exige que las variables reflejen comportamientos consistentes con lo esperado teóricamente, cuando se les somete a *shocks* simulados. Algunos investigadores efectúan pruebas adicionales, como la estabilidad del modelo, la significancia conjunta de las variables consideradas, su dirección de causalidad, la cointegración de los residuos de las regresiones individuales y la Descomposición de la Varianza del error de pronóstico (DV). A continuación se examinan todas esas pruebas.

Autocorrelación

Los correlogramas de los residuos de cada uno de las tres ecuaciones del VAR y las correlaciones entre combinaciones de variables contemporáneas y rezagadas del modelo evidenciaron problemas de autocorrelación para el VAR1²⁰ pero sí para el VAR2 (Anexo 3).

Normalidad

En los dos modelos VAR, los residuos de las ecuaciones de importaciones y del IMAE tienen una distribución normal, pero tomadas en conjunto con el tipo de cambio real no siguen una distribución normal multivariada (Anexo 4). No obstante, Fernandez-Corugedo (2003) argumenta que es más importante que el VAR cumpla con la prueba de errores no autocorrelacionados que con la de normalidad multivariada.

Función de Impulso-Respuesta (FIR)

En cuanto al comportamiento de las variables cuando se les somete a *shocks* (incremento sorpresivo) simulados en algunas otras, la Función Impulso-Respuesta (FIR) traza la respuesta de las variables endógenas contemporáneas y futuras a una innovación en una de ellas, asumiendo que esa innovación desaparece en los periodos subsiguientes y que todas las otras innovaciones permanecen sin cambio (Cavaliere, 2003).

Como se aprecia en el Gráfico 7, la FIR generalizada²¹ del VAR1 muestra, como se esperaba, que las importaciones se reducen luego de un *shock* en el tipo de cambio real y se incrementan luego de un *shock* en el IMAE²². También se verificó en ese gráfico la significancia estadística de la FIR, al considerar los límites de confianza de dos desviaciones estándar en torno a ésta²³.

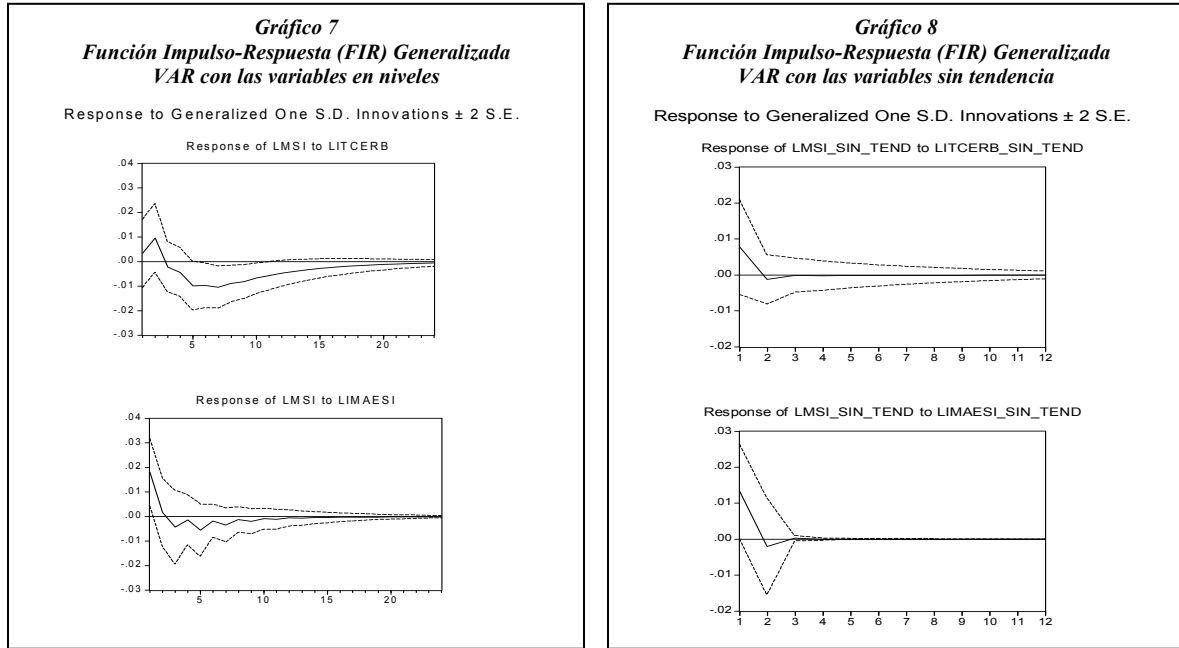
²⁰ Sin embargo la prueba LM de correlación serial de los residuos del VAR, rechazó la hipótesis nula de ausencia de correlación serial para el segundo rezago.

²¹ Se empleó la FIR generalizada para obviar el problema de considerar ordenamientos alternativos de las variables en el VAR, ya que ésta es invariante a ese efecto.

²² Estas reacciones son más evidentes cuando se considera la FIR acumulada (Anexo 5).

²³ En efecto, se observa que en algunos periodos posteriores a la ocurrencia del *shock*, el eje horizontal no se encuentra contenido entre los límites mencionados.

En el Gráfico 8, la FIR generalizada del VAR2 mostró que las importaciones no reaccionan (tienen un efecto nulo en términos estadísticos) ante *shocks* simulados en el tipo de cambio real, pues el eje horizontal se mantiene dentro de los límites de confianza en todo momento, pero tienen el efecto positivo (inmediato) esperado debido a un *shock* en el IMAE²⁴.



Estabilidad

Los dos modelos VAR satisfacen las condiciones de estabilidad, pues no se observaron comportamientos explosivos de la FIR ante innovaciones de las variables del modelo, lo que descarta la presencia de raíces unitarias en su representación de media móvil²⁵ (Anexo 6).

La implicancia económica de la condición de estabilidad es asegurar que la dinámica del VAR sea consistente con un comportamiento no explosivo de las importaciones y con un pronóstico dinámico de esta variable acorde con ese comportamiento.

²⁴ Se contemplan solo el efecto acumulado de corto plazo (10 meses posteriores al *shock*) puesto que el VAR es una herramienta de corto plazo a la que no debe exigirse resultados en un plazo mayor para el que está diseñado (Soto, 2002).

²⁵ De hecho, las FIR mostraron efectos transitorios que las hace retornar al eje horizontal en el largo plazo (Gráficos 7 y 8) y raíces del polinomio característico en módulo menores que uno (raíces inversas del polinomio característico AR dentro del círculo unitario)

Significancia conjunta (Prueba F)

El estadístico F fue alto en el VAR1, lo que corrobora la significancia conjunta de las variables que lo integran, pero en el VAR2 fue alto solo para la ecuación del tipo de cambio real (Anexo 2).

Causalidad de Granger

La prueba de causalidad de Granger aplicable al análisis autorregresivo multivariado (denominada prueba de Wald para exogeneidad en bloque) determina si una variable endógena puede ser tratada como exógena. También ayuda a determinar cuán útiles son algunas variables para mejorar el pronóstico de otras²⁶.

En el caso del VAR1, la ecuación de importaciones revela que el bloque de los valores rezagados del tipo de cambio real y del IMAE ayuda a mejorar el pronóstico de las importaciones generado por el modelo (es decir, los rezagos de *litcerb* y *limaesi* Granger causan o preceden temporalmente a los valores presentes de *lmsi*), por lo que ésta última variable no puede considerarse como exógena²⁷. Este resultado sustenta el requisito de endogeneidad de la variable *lmsi* y sugiere que es provechosa la inclusión de *litcerb* y *limaesi* en el VAR.

Sin embargo, en el VAR2 no se puede rechazar la hipótesis de que los rezagos de *litcerb_sin_tend* y *limaesi_sin_tend* no mejoran el pronóstico de *lmsi_sin_tend* generado por el modelo.

Prueba de Cointegración

La prueba ADF y las tablas de Engel-Granger y Engel-Yoo verificaron la estacionariedad de los residuos de regresión individual, tanto del VAR1 como del VAR2.

Descomposición de la varianza (DV)

En cuanto a la DV, ésta indica el porcentaje del error de pronóstico que es explicado por el error de las restantes variables endógenas del VAR.

Tanto la DV de *lmsi* como de *lmsi_sin_tend* muestra que la mayor proporción del error de pronóstico asociado a cada una de estas variables se explica principalmente por sus propios errores²⁸, lo que significa que la incertidumbre asociada a la predicción de estas variables proviene esencialmente de sus propios *shocks*²⁹. Este resultado sugiere que *lmsi* y *lmsi_sin_tend* pueden considerarse como variables relativamente menos endógenas respecto a las restantes; sin que esto signifique que los VAR estén mal modelado o identificados, pues es común que algunas variables sean menos endógenas que otras (Soto, 2002).

²⁶ Véase EViews (1994), Enders (1995) y Hamilton (1994).

²⁷ En efecto, la probabilidad conjunta asociada al estadístico chi-cuadrado fue inferior al 5%, lo que rechaza la hipótesis de que los valores rezagados de esas variables no mejoran el desempeño del pronóstico de *lmsi* (Anexo 7).

²⁸ Entorno al 88% y 99% en el mediano plazo, respectivamente.

²⁹ Se utilizó el siguiente ordenamiento de las variables del VAR: *lmsi*, *litcerb* y *limaesi*.

Para resumir, en general el VAR1 ostenta las mejores características econométricas en relación con el VAR2, según los resultados de las distintas pruebas examinadas.

3.6. Especificación Empírica del VECM

Como se mencionó en la prueba ADF del inciso III.3, las tres variables endógenas (*lmsi*, *litcerb* y *limaesi*) fueron estacionarias con constante y con tendencia, por lo tanto, forman un sistema cointegrado, cuyas relaciones (vectores) de cointegración pueden encontrarse con la prueba de Johansen³⁰, la cual no rechazó la hipótesis nula de existencia de al menos 2 vectores de cointegración (Anexo 8).

Lettal y Ludvigson (2001) mencionan que consideraciones teóricas llevan a que la relación de equilibrio de largo plazo entre las variables del modelo no tenga tendencia determinística, aunque cada serie individual pueda tenerla, como es el caso específico considerado. Además, sostienen que criterios estadísticos sugieren que modelar una tendencia determinística en la relación de cointegración no es apropiado.

Contemplando el resultado de la prueba de Johansen y la recomendación de los autores mencionados, se especificó el VECM con 2 rezagos de las variables en diferencia, sin tendencia determinística y con 2 ecuaciones (vectores) de cointegración (Anexo 9).

3.7. Diagnóstico Econométrico del VECM

También la técnica VECM está afectada por la endogeneidad de las variables, por lo que tampoco se analizan los coeficientes de regresión estimados, sus significancias estadísticas, ni los R^2 ajustados. Pero si es usual que se examine si el modelo corrige los desequilibrios de corto plazo que se presentan y la velocidad o eficiencia con que lleva a cabo tal corrección. También puede chequearse que las variables reflejen comportamientos consistentes con lo esperado teóricamente, cuando se simulan *shocks* sobre éstas. A continuación se examinan estos y otros tópicos econométricos.

Corrección del desequilibrio y su velocidad

En la ecuación de cointegración 1 (*CointEq1*) del Anexo 9, se observa que el término de corrección de error de la ecuación *D(LITCER)* no fue significativamente diferente de cero en términos estadísticos, lo que significa que esta ecuación no contribuye a la restauración de la relación de equilibrio de las series en el largo plazo, cuando éste es perturbado por la ocurrencia de un *shock* inesperado en el corto plazo que hace que éstas se desvíen temporalmente de él. Sin embargo, las otras dos ecuaciones si contribuyen a la consecución del equilibrio en el largo plazo. En particular, la ecuación *D(LMSI)* corrige un 32.8% del desequilibrio por periodo (mes) y la ecuación *D(LIMAESI)* un 10.0%.

Lo anterior significa que las desviaciones a partir de la tendencia (de largo plazo) compartida por las tres variables (cointegradas) del modelo se describen mejor como movimientos transitorios de las importaciones y del IMAE, que como movimientos transitorios del tipo de cambio real. Es

³⁰Ésta prueba se efectuó suponiendo variables estacionarias en tendencia.

decir, cuando esta última variable se desvía de su razón habitual con las restantes, son las importaciones y el IMAE las que proyectan el ajuste hasta que la relación de equilibrio se restaure de nuevo.

Por su parte, en la ecuación de cointegración 2 (*CointEq2*), se muestra que los términos de corrección de error de las ecuaciones *D(LMSI)* y de *D(LIMAESI)* tampoco fueron significativos y no contribuye a la restauración de la relación de equilibrio de largo plazo. Aunque la ecuación *D(LITCER)* si corrige un 15% del desequilibrio de corto plazo en cada mes.

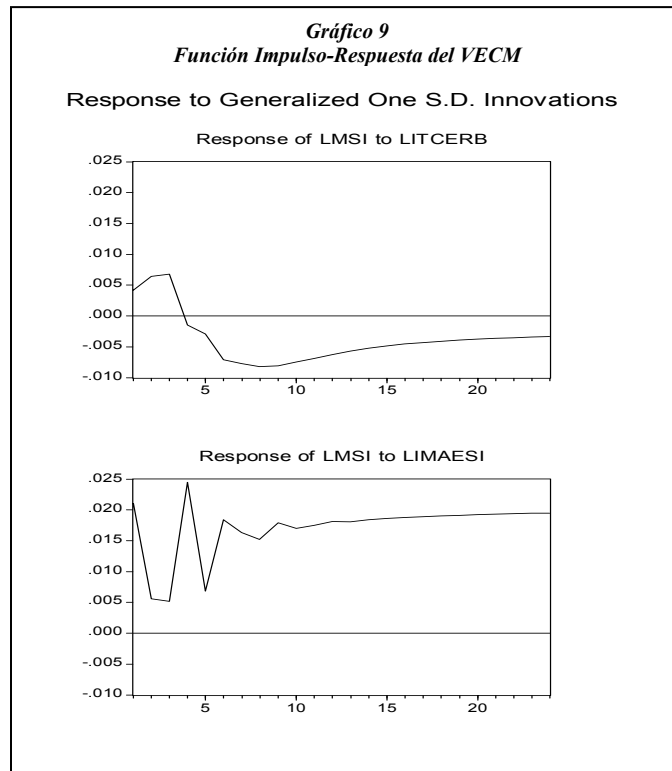
Así, las desviaciones con respecto a la tendencia común de las variables son mejor descritas como movimientos transitorios en el tipo de cambio real, que como movimientos transitorios en las importaciones y en el IMAE. En forma equivalente, cuando estas últimas variables se desvían de su razón habitual con la restante, es tipo de cambio real el que proyecta el ajuste hasta que la relación de equilibrio se restaure nuevamente.

El análisis individual de las ecuaciones de cointegración revela que el modelo VECM en su conjunto posee una dinámica de corrección complementaria, pues aunque luego de la ocurrencia de un shock la ecuación del tipo de cambio real no contribuye a la restauración del equilibrio de largo plazo en la ecuación de cointegración 1, lleva la carga de la recuperación del tal equilibrio en la ecuación 2.

*Función Impulso-Respuesta (FIR)*³¹

Como se observa en el Gráfico 9, la FIR de las importaciones ante un *shock* en el tipo de cambio real muestra su efecto negativo esperado hasta el cuarto mes posterior a su ocurrencia y continua siendo negativo en los meses posteriores. La FIR de las importaciones ante un shock en el IMAE también presenta el efecto positivo esperado, el cual se mantiene a lo largo del periodo.

³¹ El Programa econométrico Eviews no genera límites de confianza para la FIR del VECM.



En cuanto a las FIR acumuladas, éstas presentan las evoluciones esperadas en el mediano plazo: negativa a partir del séptimo mes para el *shock* del tipo de cambio real y positiva desde un inicio para el *shock* del IMAE (Anexo 10).

Pruebas econométricas adicionales

No se detectaron problemas de autocorrelación en los residuos, según los correlogramas y las pruebas *Portmanteau* y LM (Anexo 11). No obstante, los residuos no se distribuyen como una Normal multivariante (Anexo 12), aunque lo principal es que no haya autocorrelación, como lo menciona Fernandez-Corrugedo (2003).

En vista de que algunos errores de corrección del VECM no fueron significativos en términos estadísticos, se estimó un modelo restringido alternativo, suponiendo que éstos eran cero³², pues la evidencia sugiere que ésta práctica genera estimaciones más estables de las descomposiciones transitorias y permanentes de los *shocks* (Gonzalo y Ng, 2001). De hecho, la prueba de hipótesis de este supuesto no fue rechazada, como lo muestra la relativamente alta probabilidad asociada (61%) al estadístico Chi cuadrado (Anexo 13).

³² Gonzalo y Ng (2001) recomiendan restringir los valores de los errores de corrección cuando éstos no son significativos al nivel del 5%.

La FIR y la FIR acumulada de las importaciones ante *shocks* en el tipo de cambio real y en el IMAE muestran esencialmente los mismos efectos que en el modelo sin restricción (Anexos 14 y 15). Tampoco se detectaron problemas de autocorrelación en los residuos (Anexo 16)³³.

Se observa que las velocidades de corrección del modelo restringido fueron menores que las del modelo sin restringir, siendo este último modelo más eficiente en ese sentido.

Para resumir, en general el modelo VECM sin restricción fue el que ostentó las mejores características econométricas, según las distintas pruebas analizadas.

IV. RESULTADOS Y CAPACIDAD DE PRONÓSTICO DE LOS MODELOS

Cuando se utilizan modelos VAR y VECM, los pronósticos de la variables de interés fuera de la muestra se calculan iterando hacia delante los modelos en forma reducida.

Para este caso particular se utilizó un pronóstico dinámico, que consiste en estimar los modelos con datos observados hasta una fecha dada y utilizarlo para pronosticar varios “pasos” fuera de muestra, en un proceso mediante el cual los pronósticos sucesivos se basan en los anteriores³⁴.

Asimismo, se resolvieron los modelos en forma estocástica, con el fin de obtener límites de confianza para las proyecciones.

Para determinar la capacidad de pronóstico de los modelos se utilizaron dos medidas alternativas: la raíz del error cuadrático medio (*Root Mean Squared Error-RMSE*-) y el promedio de los errores, medido como el porcentaje de la diferencia (en valor absoluto) entre el valor observado y el pronosticado (*Mean Absolute Percentage Error-MAPE*-)³⁵.

Los resultados de las dos versiones del VAR y del VECM, a partir de mayo del 2003, comparativos con el modelo ARIMA mencionado al inicio, se presentan en el Cuadro 1.

³³No obstante, éstos siguen sin distribirse como una normal multivariante (Anexo 17).

³⁴ Así, con los modelos VAR y VECM estimados con información observada al mes de abril del 2003 se pronosticaron las importaciones de los meses de mayo, junio y julio del 2003. Para generar los siguientes pronósticos (junio, julio y agosto), se actualizan las variables endógenas de los modelos, con los datos observados más recientes pero sin reestimarlos y así sucesivamente.

³⁵ Véase la definición de estos indicadores en Torres (2003).

Cuadro 1
Comparación de pronósticos según modelos ARIMA, VAR y VECM
Datos en millones de US dólares y porcentajes

Mes	Dato observado (Y)	Dato Pronosticado (Y [^])					Dato observado - pronosticado (Y-Y [^])					RMSE					MAPE				
		ARIMA	VAR1	VAR2	VECM sin restric.	VECM rest.	ARIMA	VAR1	VAR2	VECM sin restric.	VECM rest.	ARIMA	VAR1	VAR2	VECM sin restric.	VECM rest.	ARIMA	VAR1	VAR2	VECM sin restric.	VECM rest.
May-03	528.10	582.55	496.79	428.13	532.27	534.04	-54.45	31.31	99.97	-4.17	-5.94	38.87	29.69	101.34	18.47	18.03	6.8%	4.7%	18.9%	2.6%	2.8%
Jun-03	519.60	555.27	523.50	432.96	527.72	529.26	-35.67	-3.90	86.64	-8.12	-9.66										
Jul-03	550.47	567.64	509.86	435.10	519.80	521.37	-17.17	40.61	115.37	30.67	29.10										
Jun-03	519.60	557.73	534.52	432.50	535.14	537.38	-38.13	-14.92	87.10	-15.54	-17.78	31.24	22.95	96.22	19.30	19.49	5.2%	3.5%	17.9%	3.4%	3.5%
Jul-03	550.47	544.32	514.04	435.12	522.90	525.06	6.15	36.43	115.35	27.57	25.41										
Ago-03	520.50	558.39	526.03	437.55	531.24	533.84	-37.89	-5.53	82.95	-10.74	-13.34										
Jul-03	550.47	552.53	522.81	436.29	525.62	528.05	-2.06	27.66	114.18	24.86	22.42	33.40	21.50	86.89	19.35	20.12	4.6%	3.4%	15.8%	3.5%	3.8%
Ago-03	520.50	530.77	520.70	437.28	531.81	534.57	-10.27	-0.20	83.22	-11.31	-14.07										
Sep-03	491.7	548.59	516.64	439.87	511.13	514.37	-56.89	-24.94	51.83	-19.43	-22.67										
Ago-03	520.5	541.55	563.44	434.91	530.03	532.52	-21.05	-42.94	85.59	-9.53	-12.02	33.00	52.47	99.11	40.91	40.37	5.7%	8.8%	17.0%	6.4%	6.5%
Sep-03	491.7	542.55	517.20	439.27	523.95	526.46	-50.85	-25.50	52.43	-32.25	-34.76										
Oct-03	580.78	565.34	504.86	441.53	518.42	521.31	15.44	75.92	139.25	62.36	59.47										
Sep-03	491.7	548.06	500.54	440.87	526.34	528.99	-56.36	-8.84	50.83	-34.64	-37.29	41.58	71.69	104.50	49.75	49.06	7.2%	9.6%	17.1%	8.8%	8.8%
Oct-03	580.78	563.99	479.79	442.01	519.55	522.28	16.79	100.99	138.77	61.23	58.50										
Nov-03	N.D.	538.40	481.85	444.53	507.97	511.11	N.D.	N.D.	N.D.	N.D.	N.D.										
Oct-03	580.78	565.164	525.12	543.40	524.02	527.05	15.62	55.66	37.38	56.76	53.73	15.62	55.66	37.38	56.76	53.73	2.7%	9.6%	6.4%	9.8%	9.3%
Nov-03	N.D.	513.282	510.58	539.97	500.87	504.06	N.D.	N.D.	N.D.	N.D.	N.D.										
Dic-03	N.D.	543.132	516.60	543.69	494.72	498.41	N.D.	N.D.	N.D.	N.D.	N.D.										
PROMEDIO												31.84	26.32	98.78	18.89	18.76	5.3%	4.1%	18.4%	3.0%	3.1%

RMSE : Raíz del error cuadrático medio.

MAPE : Error medio de pronóstico, expresado como porcentaje de las diferencias absolutas entre el valor observado y el pronosticado.

ND : No disponible

Fuente: Elaboración propia.

Aunque el modelo ARIMA muestra una tendencia a la sobrestimación del pronóstico, como lo denotan los signos negativos de la columna (Y-Y[^]), considerando los datos observados más recientes y las últimas proyecciones de octubre del 2003 se obtuvo un mejor resultado (menor RMSE y MAPE) con este modelo en relación con los restantes.

No obstante, cuando se contempla todo el periodo de proyección, se aprecia que en general los modelos VECM son los que alcanzan una mayor capacidad de pronóstico, tanto según la *RMSE* (en torno a 18 millones de US dólares) como según el *MAPE* (en torno a 3%).

Por su parte, la versión del VAR en niveles (VAR1) también alcanzó una buena capacidad de pronóstico, con una *RMSE* de 26.3 millones y un *MAPE* de 4.1%, mientras que el modelo ARIMA tuvo una menor capacidad de proyección que solo supera a la del modelo VAR con las variables sin tendencia (VAR2).

Los resultados anteriores confirman empíricamente la superioridad del enfoque multivariado y la complementariedad del equilibrio de largo plazo y la dinámica de ajuste de corto plazo asociados a los VAR y a los VECM. En efecto, los modelos VAR y VECM son más apropiados por ser multivariados mientras que el ARIMA es univariado. En particular, también se verificó empíricamente que los VECM son técnicas más completas pues consideran tanto la dinámica de ajuste de corto plazo como el equilibrio de largo plazo, mientras que el VAR solo toma en cuenta la dinámica de corto plazo.

V. CONSIDERACIONES FINALES

Los resultados de las diferentes pruebas econométricas realizadas a los modelos VAR y VECM estimados minimizan la posibilidad de que sus pronósticos se basen en relaciones funcionales espurias.

A lo largo de todo el periodo de pronóstico analizado se observó que en general los VECM alcanzaron un mayor poder de pronóstico, especialmente el VECM sin restricción, comparados con el modelo ARIMA existente y con las dos opciones VAR propuestas, pues obtuvieron una menor raíz del error cuadrático medio (RMSE) y un menor error medio de pronóstico (MAPE).

Aunque el modelo ARIMA venía mostrando una tendencia a la sobrestimación del pronóstico, como lo denotan los signos negativos de la columna $(Y - \hat{Y})$ la última cifra observada de octubre reveló que este modelo proyectó ese dato con bastante precisión³⁶, razón por la cual la RMSE y el MAPE reflejan una mejora en su capacidad de proyección.

Concordante con el objetivo planteado al inicio, este resultado sugiere una actitud de prudencia en la consideración de las distintas técnicas de proyección, para no adoptar una sola sino que concebirlas como una batería de técnicas complementarias; incluso continuar desarrollando otras posibilidades que permitan asesorar de la mejor forma a las autoridades en la tarea de predecir el comportamiento de las importaciones.

³⁶ Los pronósticos de octubre del ARIMA erraron (en promedio) el valor observado en 16 millones de dólares, mientras que los del VECM sin restricción y restringido lo hicieron en 60 y 57 y los del VAR1 y VAR2 en 78 y 105 millones de dólares, respectivamente (Cuadro 1).

VI. REFERENCIAS BIBLIOGRÁFICAS

- Banco de Guatemala (2002), “Vectores autorregresivos (VARs)”, Notas Monetarias.
- Campbell y Perron (1991) Pitfalls and opportunities: What Macroeconomists should know About Unit Roots, Technical Working Papers No. 100, National Bureau of Economic Research (NBER), Abril
- Cavaliere (2003) “Vector autoregression models”, Study Centre Gerzensee CBC Course.
- Enders (1995) Applied Econometric Time Series. New York, John Wiley and Sons.
- Enders y Sandler (1993) "Effectiveness of Anti-Terrorism Policies: A VAR-Intervention Analysis", American Political Science Review, December 1993.*
- EViews (1994) User’s Guide, Quantitative Micro Software, LLC.
- Fernandez-Corugedo (2003) “Exercise on unit roots (including structural breaks), estimating a VECM and the implications of the VECM”. Curso “Modelos Macroeconómicos para la Política Monetaria”, “Center for Central Banking Studies (CCBS), Bank of England” , CEMLA y el Banco Central de la República de Argentina. Mimeo, octubre
- Gonzalo y Ng (2001) “A systematic Framework for Analyzing the Dynamic Effects of Permanent and Transitory Shocks”. Journal of Econometric Dynamic and Control, 25 (10) 1527-1546.
- Hamilton (1994). Time Series Analysis. Princeton: Princeton University Press.
- Lettau y Ludvigson (2001) “Consumption Aggregate Wealth, and Expected Stock Returns”, The Journal of finance, Vol LVI, No. 3, june
- Rats (2001) Reference Manual, Versión 5, Editorial Estima
- Sims C (1980) “Macroeconomics and Reallity”. Econometrica, vol.48.
- Soto (2002) “Vectores autorregresivos”, Notas de clase de Teoría Econométrica III, Instituto de Economía, Pontificia Universidad Católica de Chile.
- Torres (2003), “Cálculo de los errores de pronóstico del modelo mensual univariante de corto plazo de las importaciones CIF de Costa Rica, excluyendo la Industria de Alta Tecnología”. Informe Técnico DIE-74-2003-IT, Departamento Investigaciones Económicas, Banco Central de Costa Rica, setiembre.

ariasce@bccr.fi.cr
torresgc@bccr.fi.cr

ANEXOS

Anexo 1

Pruebas de raíz unitaria (ADF)

Null Hypothesis: LMSI has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 3 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.441183	0.0504
Test critical values:		
1% level	-4.029041	
5% level	-3.444222	
10% level	-3.146908	

*MacKinnon (1996) one-sided p-values.
 Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(LMSI)
 Method: Least Squares
 Date: 09/02/03 Time: 16:06
 Sample(adjusted): 1992:05 2003:04
 Included observations: 132 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LMSI(-1)	-0.323988	0.094150	-3.441183	0.0008
D(LMSI(-1))	-0.744882	0.107599	-6.922777	0.0000
D(LMSI(-2))	-0.432191	0.114030	-3.790163	0.0002
D(LMSI(-3))	-0.166939	0.083954	-1.988452	0.0489
C	1.837807	0.524258	3.505539	0.0006
@TREND(1992:01)	0.001540	0.000540	2.850841	0.0051
R-squared	0.574151	Mean dependent var		0.007343
Adjusted R-squared	0.557252	S.D. dependent var		0.116868
S.E. of regression	0.077763	Akaike info criterion		-2.225914
Sum squared resid	0.761932	Schwarz criterion		-2.094877
Log likelihood	152.9103	F-statistic		33.97585
Durbin-Watson stat	2.029371	Prob(F-statistic)		0.000000

Null Hypothesis: LITCERB has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.939436	0.0130
Test critical values:		
1% level	-4.027959	
5% level	-3.443704	
10% level	-3.146604	

*MacKinnon (1996) one-sided p-values.
 Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(LITCERB)
 Method: Least Squares
 Date: 09/02/03 Time: 16:07
 Sample(adjusted): 1992:03 2003:04
 Included observations: 134 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LITCERB(-1)	-0.134756	0.034207	-3.939436	0.0001
D(LITCERB(-1))	0.320771	0.085352	3.758231	0.0003
C	0.625487	0.159488	3.921839	0.0001
@TREND(1992:01)	-7.67E-05	3.57E-05	-2.145751	0.0338
R-squared	0.180016	Mean dependent var		-0.000976
Adjusted R-squared	0.161093	S.D. dependent var		0.011262
S.E. of regression	0.010315	Akaike info criterion		-6.281026
Sum squared resid	0.013832	Schwarz criterion		-6.194523
Log likelihood	424.8287	F-statistic		9.513233
Durbin-Watson stat	1.898230	Prob(F-statistic)		0.000010

Null Hypothesis: LIMAESI has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Fixed)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.485270	0.0001
Test critical values:		
1% level	-4.027959	
5% level	-3.443704	
10% level	-3.146604	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LIMAESI)

Method: Least Squares

Date: 09/02/03 Time: 16:08

Sample(adjusted): 1992:03 2003:04

Included observations: 134 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LIMAESI(-1)	-0.590891	0.107723	-5.485270	0.0000
D(LIMAESI(-1))	-0.275582	0.084951	-3.244007	0.0015
C	2.636378	0.479839	5.494300	0.0000
@TREND(1992:01)	0.001813	0.000339	5.342927	0.0000
R-squared	0.450721	Mean dependent var		0.002756
Adjusted R-squared	0.438045	S.D. dependent var		0.047064
S.E. of regression	0.035281	Akaike info criterion		-3.821560
Sum squared resid	0.161816	Schwarz criterion		-3.735057
Log likelihood	260.0445	F-statistic		35.55792
Durbin-Watson stat	2.036575	Prob(F-statistic)		0.000000

Anexo 2 Modelos VAR estimados

VAR con las variables en niveles				VAR con las variables sin tendencia			
Vector Autoregression Estimates Date: 09/12/03 Time: 09:28 Sample(adjusted): 1992:03 2003:04 Included observations: 134 after adjusting endpoints Standard errors in () & t-statistics in []				Vector Autoregression Estimates Date: 10/29/03 Time: 15:00 Sample(adjusted): 1992:02 2003:04 Included observations: 135 after adjusting endpoints Standard errors in () & t-statistics in []			
	LMSI	LITCERB	LIMAESI		LMSI SIN_TE ND	LITCERB SIN_T END	LIMAESI SIN_ D
LMSI(-1)	0.076766 (0.07911) [0.97035]	-0.005989 (0.01021) [-0.58670]	0.011198 (0.03516) [0.31845]	LMSI SIN_TEND(-1)	-0.125117 (0.08717) [-1.43529]	0.004178 (0.01206) [0.34655]	-0.009687 (0.04014) [-0.24135]
LMSI(-2)	0.439916 (0.07649) [5.75144]	-0.011037 (0.00987) [-1.11822]	0.004689 (0.03400) [0.13793]	LITCERB SIN_TEND (-1)	-0.029790 (0.30308) [-0.09829]	0.849724 (0.04191) [20.2729]	-0.051868 (0.13955) [-0.37168]
LITCERB(-1)	0.903719 (0.67145) [1.34593]	1.193278 (0.08664) [13.7722]	-0.062932 (0.29844) [-0.21087]	LIMAESI SIN_TEND (-1)	-0.010496 (0.19136) [-0.05485]	-0.004902 (0.02646) [-0.18523]	0.121677 (0.08811) [1.38098]
LITCERB(-2)	-1.510775 (0.68623) [-2.20156]	-0.348618 (0.08855) [-3.93690]	0.023774 (0.30501) [0.07795]	C	0.000778 (0.00664) [0.11708]	-0.000490 (0.00092) [-0.53322]	-1.10E-05 (0.00306) [-0.00359]
LIMAESI(-1)	0.011723 (0.19653) [0.05965]	0.009172 (0.02536) [0.36168]	0.126726 (0.08735) [1.45075]	R-squared	0.016227	0.758858	0.015719
LIMAESI(-2)	-0.355783 (0.19756) [-1.80085]	-0.005235 (0.02549) [-0.20535]	0.272541 (0.08781) [3.10365]	Adj. R-squared	-0.006303	0.753336	-0.006822
C	7.077360 (1.92570) [3.67522]	0.798656 (0.24849) [3.21399]	2.774152 (0.85593) [3.24109]	Sum sq. resids	0.778751	0.014894	0.165094
@TREND	0.003033 (0.00085) [3.57225]	-1.21E-05 (0.00011) [-0.11037]	0.001727 (0.00038) [4.57801]	S.E. equation	0.077102	0.010663	0.035500
R-squared	0.884478	0.929133	0.921873	F-statistic	0.720249	137.4162	0.697366
Adj. R-squared	0.878061	0.925196	0.917532	Log likelihood	156.4287	423.5098	261.1330
Sum sq. resids	0.816536	0.013597	0.161316	Akaike AIC	-2.258203	-6.214960	-3.809378
S.E. equation	0.080501	0.010388	0.035781	Schwarz SC	-2.172121	-6.128878	-3.723295
F-statistic	137.8151	235.9983	212.3928	Mean dependent	0.000851	-0.001378	8.40E-05
Log likelihood	151.5974	425.9796	260.2517	S.D. dependent	0.076860	0.021469	0.035380
Akaike AIC	-2.143244	-6.238501	-3.764950	Determinant Residual Covariance	8.17E-10		
Schwarz SC	-1.970239	-6.065496	-3.591945	Log Likelihood (d.f. adjusted)	837.8325		
Mean dependent	5.950060	4.606993	4.668317	Akaike Information Criteria	-12.23456		
S.D. dependent	0.230531	0.037981	0.124598	Schwarz Criteria	-11.97631		
Determinant Residual Covariance	8.48E-10						
Log Likelihood (d.f. adjusted)	829.0759						
Akaike Information Criteria	-12.01606						
Schwarz Criteria	-11.49704						

Anexo 3 Pruebas de autocorrelación

VAR con las variables en niveles

VAR Residual Serial Correlation LM Tests
H0: no serial correlation at lag order h
Date: 09/26/03 Time: 10:47
Sample: 1992:01 2003:04
Included observations: 134

Lags	LM-Stat	Prob
1	16.12649	0.0643
2	34.93107	0.0001

Probs from chi-square with 9 df.

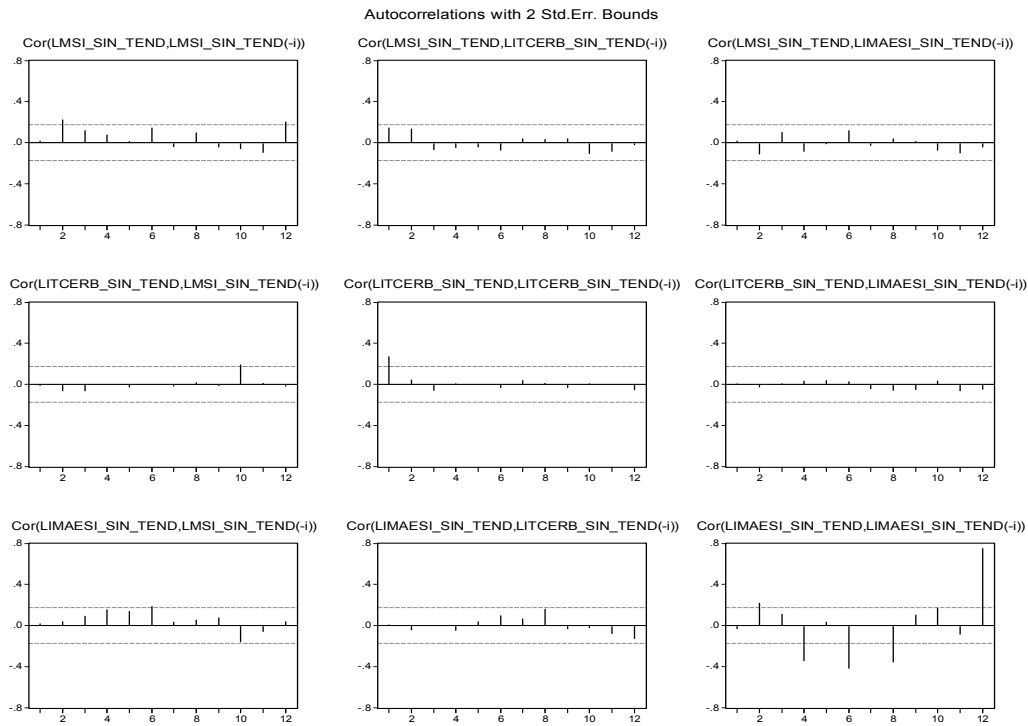
VAR con las variables sin tendencia

VAR Residual Serial Correlation LM Tests
H0: no serial correlation at lag order h
Date: 11/07/03 Time: 10:30
Sample: 1992:01 2003:04
Included observations: 135

Lags	LM-Stat	Prob
1	33.16534	0.0001
2	22.86027	0.0065

Probs from chi-square with 9 df.

VAR con las variables sin tendencia



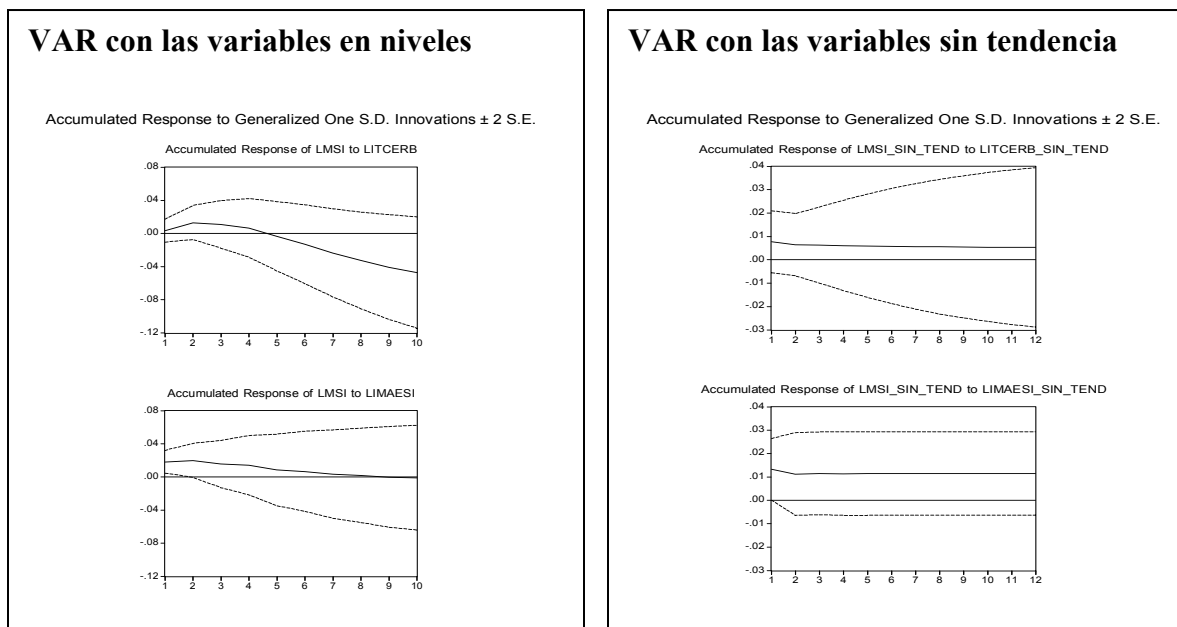
Anexo 4

Prueba de Normalidad multivariada de los residuos

VAR con las variables en niveles					VAR con las variables sin tendencia				
VAR Residual Normality Tests Orthogonalization: Cholesky (Lutkepohl) H0: residuals are multivariate normal Date: 09/03/03 Time: 08:57 Sample: 1992:01 2003:04 Included observations: 134					VAR Residual Normality Tests Orthogonalization: Cholesky (Lutkepohl) H0: residuals are multivariate normal Date: 11/07/03 Time: 10:41 Sample: 1992:01 2003:04 Included observations: 135				
Component	Skewness	Chi-sq	df	Prob.	Component	Skewness	Chi-sq	df	Prob.
1	-0.463021	4.788000	1	0.0287	1	-0.219881	1.087820	1	0.2970
2	0.481751	5.183207	1	0.0228	2	0.132056	0.392372	1	0.5311
3	0.194148	0.841819	1	0.3589	3	0.214735	1.037502	1	0.3084
Joint		10.81303	3	0.0128	Joint		2.517694	3	0.4721
Component	Kurtosis	Chi-sq	df	Prob.	Component	Kurtosis	Chi-sq	df	Prob.
1	3.075295	0.031654	1	0.8588	1	2.523266	1.278424	1	0.2582
2	5.757846	42.46525	1	0.0000	2	4.114554	6.987541	1	0.0082
3	2.252135	3.122766	1	0.0772	3	2.206439	3.542285	1	0.0598
Joint		45.61967	3	0.0000	Joint		11.80825	3	0.0081
Component	Jarque-Bera	df	Prob.	Component	Jarque-Bera	df	Prob.		
1	4.819654	2	0.0898	1	2.366244	2	0.3063		
2	47.64846	2	0.0000	2	7.379913	2	0.0250		
3	3.964585	2	0.1378	3	4.579787	2	0.1013		
Joint		56.43270	6	0.0000	Joint		14.32594	6	0.0262

Anexo 5

Función Impulso-Respuesta acumulada



Anexo 6

Raíces del polinomio característico

VAR con las variables en niveles	VAR con las variables sin tendencia																						
Roots of Characteristic Polynomial Endogenous variables: LMSI LITCERB LIMAESI Exogenous variables: C @TREND Lag specification: 1 2 Date: 09/26/03 Time: 10:51	Roots of Characteristic Polynomial Endogenous variables: LMSI_SIN_TEND LITCERB_SIN_TEND LIMAESI_SIN_TEND Exogenous variables: C Lag specification: 1 1 Date: 11/07/03 Time: 11:30																						
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Root</th> <th style="text-align: left;">Modulus</th> </tr> </thead> <tbody> <tr><td>0.841270</td><td>0.841270</td></tr> <tr><td>-0.636751</td><td>0.636751</td></tr> <tr><td>0.592220</td><td>0.592220</td></tr> <tr><td>0.530377 - 0.196152i</td><td>0.565487</td></tr> <tr><td>0.530377 + 0.196152i</td><td>0.565487</td></tr> <tr><td>-0.460723</td><td>0.460723</td></tr> </tbody> </table>	Root	Modulus	0.841270	0.841270	-0.636751	0.636751	0.592220	0.592220	0.530377 - 0.196152i	0.565487	0.530377 + 0.196152i	0.565487	-0.460723	0.460723	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Root</th> <th style="text-align: left;">Modulus</th> </tr> </thead> <tbody> <tr><td>0.849946</td><td>0.849946</td></tr> <tr><td>-0.125398</td><td>0.125398</td></tr> <tr><td>0.121735</td><td>0.121735</td></tr> </tbody> </table>	Root	Modulus	0.849946	0.849946	-0.125398	0.125398	0.121735	0.121735
Root	Modulus																						
0.841270	0.841270																						
-0.636751	0.636751																						
0.592220	0.592220																						
0.530377 - 0.196152i	0.565487																						
0.530377 + 0.196152i	0.565487																						
-0.460723	0.460723																						
Root	Modulus																						
0.849946	0.849946																						
-0.125398	0.125398																						
0.121735	0.121735																						
No root lies outside the unit circle. VAR satisfies the stability condition.	No root lies outside the unit circle. VAR satisfies the stability condition.																						

Anexo 7

Pruebas de causalidad de Granger

VAR con las variables en niveles	VAR con las variables sin tendencia																																
VAR Pairwise Granger Causality/Block Exogeneity Wald Tests Sample: 1992:01 2003:04 Included observations: 134	VAR Pairwise Granger Causality/Block Exogeneity Wald Tests Date: 10/29/03 Time: 15:30 Sample: 1992:01 2003:04 Included observations: 135																																
Dependent variable: LMSI	Dependent variable: LMSI SIN_TEND																																
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Exclude</th> <th style="text-align: left;">Chi-sq</th> <th style="text-align: left;">df</th> <th style="text-align: left;">Prob.</th> </tr> </thead> <tbody> <tr><td>LITCERB</td><td>7.313654</td><td>2</td><td>0.0258</td></tr> <tr><td>LIMAESI</td><td>3.332314</td><td>2</td><td>0.1890</td></tr> <tr><td>All</td><td>10.26859</td><td>4</td><td>0.0361</td></tr> </tbody> </table>	Exclude	Chi-sq	df	Prob.	LITCERB	7.313654	2	0.0258	LIMAESI	3.332314	2	0.1890	All	10.26859	4	0.0361	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Exclude</th> <th style="text-align: left;">Chi-sq</th> <th style="text-align: left;">df</th> <th style="text-align: left;">Prob.</th> </tr> </thead> <tbody> <tr><td>LITCERB_SIN_TEND</td><td>0.009661</td><td>1</td><td>0.9217</td></tr> <tr><td>LIMAESI_SIN_TEND</td><td>0.003008</td><td>1</td><td>0.9563</td></tr> <tr><td>All</td><td>0.012239</td><td>2</td><td>0.9939</td></tr> </tbody> </table>	Exclude	Chi-sq	df	Prob.	LITCERB_SIN_TEND	0.009661	1	0.9217	LIMAESI_SIN_TEND	0.003008	1	0.9563	All	0.012239	2	0.9939
Exclude	Chi-sq	df	Prob.																														
LITCERB	7.313654	2	0.0258																														
LIMAESI	3.332314	2	0.1890																														
All	10.26859	4	0.0361																														
Exclude	Chi-sq	df	Prob.																														
LITCERB_SIN_TEND	0.009661	1	0.9217																														
LIMAESI_SIN_TEND	0.003008	1	0.9563																														
All	0.012239	2	0.9939																														
Dependent variable: LITCERB	Dependent variable: LITCERB SIN_TEND																																
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Exclude</th> <th style="text-align: left;">Chi-sq</th> <th style="text-align: left;">df</th> <th style="text-align: left;">Prob.</th> </tr> </thead> <tbody> <tr><td>LMSI</td><td>2.017486</td><td>2</td><td>0.3647</td></tr> <tr><td>LIMAESI</td><td>0.149634</td><td>2</td><td>0.9279</td></tr> <tr><td>All</td><td>2.182946</td><td>4</td><td>0.7022</td></tr> </tbody> </table>	Exclude	Chi-sq	df	Prob.	LMSI	2.017486	2	0.3647	LIMAESI	0.149634	2	0.9279	All	2.182946	4	0.7022	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Exclude</th> <th style="text-align: left;">Chi-sq</th> <th style="text-align: left;">df</th> <th style="text-align: left;">Prob.</th> </tr> </thead> <tbody> <tr><td>LMSI_SIN_TEND</td><td>0.120097</td><td>1</td><td>0.7289</td></tr> <tr><td>LIMAESI_SIN_TEND</td><td>0.034311</td><td>1</td><td>0.8530</td></tr> <tr><td>All</td><td>0.136725</td><td>2</td><td>0.9339</td></tr> </tbody> </table>	Exclude	Chi-sq	df	Prob.	LMSI_SIN_TEND	0.120097	1	0.7289	LIMAESI_SIN_TEND	0.034311	1	0.8530	All	0.136725	2	0.9339
Exclude	Chi-sq	df	Prob.																														
LMSI	2.017486	2	0.3647																														
LIMAESI	0.149634	2	0.9279																														
All	2.182946	4	0.7022																														
Exclude	Chi-sq	df	Prob.																														
LMSI_SIN_TEND	0.120097	1	0.7289																														
LIMAESI_SIN_TEND	0.034311	1	0.8530																														
All	0.136725	2	0.9339																														
Dependent variable: LIMAESI	Dependent variable: LIMAESI SIN_TEND																																
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Exclude</th> <th style="text-align: left;">Chi-sq</th> <th style="text-align: left;">df</th> <th style="text-align: left;">Prob.</th> </tr> </thead> <tbody> <tr><td>LMSI</td><td>0.149556</td><td>2</td><td>0.9279</td></tr> <tr><td>LITCERB</td><td>0.118801</td><td>2</td><td>0.9423</td></tr> <tr><td>All</td><td>0.390186</td><td>4</td><td>0.9833</td></tr> </tbody> </table>	Exclude	Chi-sq	df	Prob.	LMSI	0.149556	2	0.9279	LITCERB	0.118801	2	0.9423	All	0.390186	4	0.9833	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: left;">Exclude</th> <th style="text-align: left;">Chi-sq</th> <th style="text-align: left;">df</th> <th style="text-align: left;">Prob.</th> </tr> </thead> <tbody> <tr><td>LMSI_SIN_TEND</td><td>0.058251</td><td>1</td><td>0.8093</td></tr> <tr><td>LITCERB_SIN_TEND</td><td>0.138149</td><td>1</td><td>0.7101</td></tr> <tr><td>All</td><td>0.198661</td><td>2</td><td>0.9054</td></tr> </tbody> </table>	Exclude	Chi-sq	df	Prob.	LMSI_SIN_TEND	0.058251	1	0.8093	LITCERB_SIN_TEND	0.138149	1	0.7101	All	0.198661	2	0.9054
Exclude	Chi-sq	df	Prob.																														
LMSI	0.149556	2	0.9279																														
LITCERB	0.118801	2	0.9423																														
All	0.390186	4	0.9833																														
Exclude	Chi-sq	df	Prob.																														
LMSI_SIN_TEND	0.058251	1	0.8093																														
LITCERB_SIN_TEND	0.138149	1	0.7101																														
All	0.198661	2	0.9054																														

Anexo 8 Prueba de Johansen

Sample(adjusted): 1992:04 2003:04
 Included observations: 133 after adjusting endpoints
 Trend assumption: Linear deterministic trend (restricted)
 Series: LMSI LITCERB LIMAESI
 Lags interval (in first differences): 1 to 2

Unrestricted Cointegration Rank Test

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	5 Percent Critical Value	1 Percent Critical Value
None **	0.163495	55.76107	42.44	48.45
At most 1 **	0.140212	32.01756	25.32	30.45
At most 2	0.085761	11.92527	12.25	16.26

*(**) denotes rejection of the hypothesis at the 5%(1%) level
 Trace test indicates 2 cointegrating equation(s) at both 5% and 1% levels

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	5 Percent Critical Value	1 Percent Critical Value
None	0.163495	23.74351	25.54	30.34
At most 1 *	0.140212	20.09229	18.96	23.65
At most 2	0.085761	11.92527	12.25	16.26

*(**) denotes rejection of the hypothesis at the 5%(1%) level
 Max-eigenvalue test indicates no cointegration at both 5% and 1% levels

Unrestricted Cointegrating Coefficients (normalized by b*S11*b=I):

LMSI	LITCERB	LIMAESI	@TREND(92:02)
-13.59102	-26.74831	18.68707	-0.008211
4.708391	16.81046	35.26872	-0.118724
-3.386558	30.66438	-1.733558	0.034965

Unrestricted Adjustment Coefficients (alpha):

D(LMSI)	0.021715	-0.017719	0.010221
D(LITCERB)	0.001945	-0.001032	-0.002646
D(LIMAESI)	-0.007400	-0.012167	0.000161

1 Cointegrating Equation(s): Log likelihood 827.4542

Normalized cointegrating coefficients (std.err. in parentheses)

LMSI	LITCERB	LIMAESI	@TREND(92:02)
1.000000	1.968087	-1.374957	0.000604
	(0.61243)	(0.58913)	(0.00186)

Adjustment coefficients (std.err. in parentheses)

D(LMSI)	-0.295129	
	(0.09313)	
D(LITCERB)	-0.026438	
	(0.01267)	
D(LIMAESI)	0.100573	
	(0.04444)	

2 Cointegrating Equation(s): Log likelihood 837.5003

Normalized cointegrating coefficients (std.err. in parentheses)

LMSI	LITCERB	LIMAESI	@TREND(92:02)
1.000000	0.000000	-12.26490	0.032319
		(2.62555)	(0.00820)
0.000000	1.000000	5.533261	-0.016115
		(1.21352)	(0.00379)

Adjustment coefficients (std.err. in parentheses)

D(LMSI)	-0.378556	-0.878701
	(0.09589)	(0.21062)
D(LITCERB)	-0.031298	-0.069382
	(0.01334)	(0.02931)
D(LIMAESI)	0.043284	-0.006603
	(0.04435)	(0.09741)

Anexo 9 Modelo VECM sin restricción

Vector Error Correction Estimates
 Sample(adjusted): 1992:04 2003:04
 Included observations: 133 after adjusting endpoints
 Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	CointEq2
LMSI(-1)	1.000000	0.000000
LITCERB(-1)	0.000000	1.000000
LIMAESI(-1)	-1.528562 (0.16721) [-9.14142]	0.178756 (0.06312) [2.83204]
C	1.186280	-5.441225



Error Correction:	D(LMSI)	D(LITCERB)	D(LIMAESI)
CointEq1	-0.328314 (0.09630) [-3.40921]	-0.021458 (0.01269) [-1.69156]	0.099936 (0.04619) [2.16352]
CointEq2	-0.474954 (0.30317) [-1.56660]	-0.152177 (0.03994) [-3.81048]	0.051768 (0.14542) [0.35600]
D(LMSI(-1))	-0.679588 (0.10246) [-6.63265]	0.016159 (0.01350) [1.19726]	-0.067960 (0.04915) [-1.38285]
D(LMSI(-2))	-0.266329 (0.08423) [-3.16201]	0.003766 (0.01110) [0.33942]	-0.043876 (0.04040) [-1.08605]
D(LITCERB(-1))	1.097170 (0.68491) [1.60192]	0.335973 (0.09022) [3.72388]	-0.107308 (0.32852) [-0.32664]
D(LITCERB(-2))	0.856233 (0.73801) [1.16018]	0.028059 (0.09722) [0.28862]	-0.253681 (0.35399) [-0.71664]
D(LIMAESI(-1))	-0.265356 (0.19994) [-1.32717]	0.006777 (0.02634) [0.25730]	-0.638076 (0.09590) [-6.65343]
D(LIMAESI(-2))	-0.398368 (0.18652) [-2.13583]	0.002952 (0.02457) [0.12013]	-0.226363 (0.08946) [-2.53025]
C	0.017279 (0.00700) [2.46732]	-0.000673 (0.00092) [-0.72928]	0.006102 (0.00336) [1.81657]

R-squared	0.570613	0.171445	0.399464
Adj. R-squared	0.542911	0.117990	0.360720
Sum sq. resid	0.771047	0.013379	0.177390
S.E. equation	0.078855	0.010387	0.037823
F-statistic	20.59798	3.207264	10.31027
Log likelihood	153.7798	423.3738	251.4947
Akaike AIC	-2.177140	-6.231185	-3.646536
Schwarz SC	-1.981552	-6.035598	-3.450949
Mean dependent	0.006735	-0.000775	0.002811
S.D. dependent	0.116635	0.011060	0.047305

Determinant Residual Covariance	8.89E-10
Log Likelihood	833.7584
Trace Likelihood	810.7700

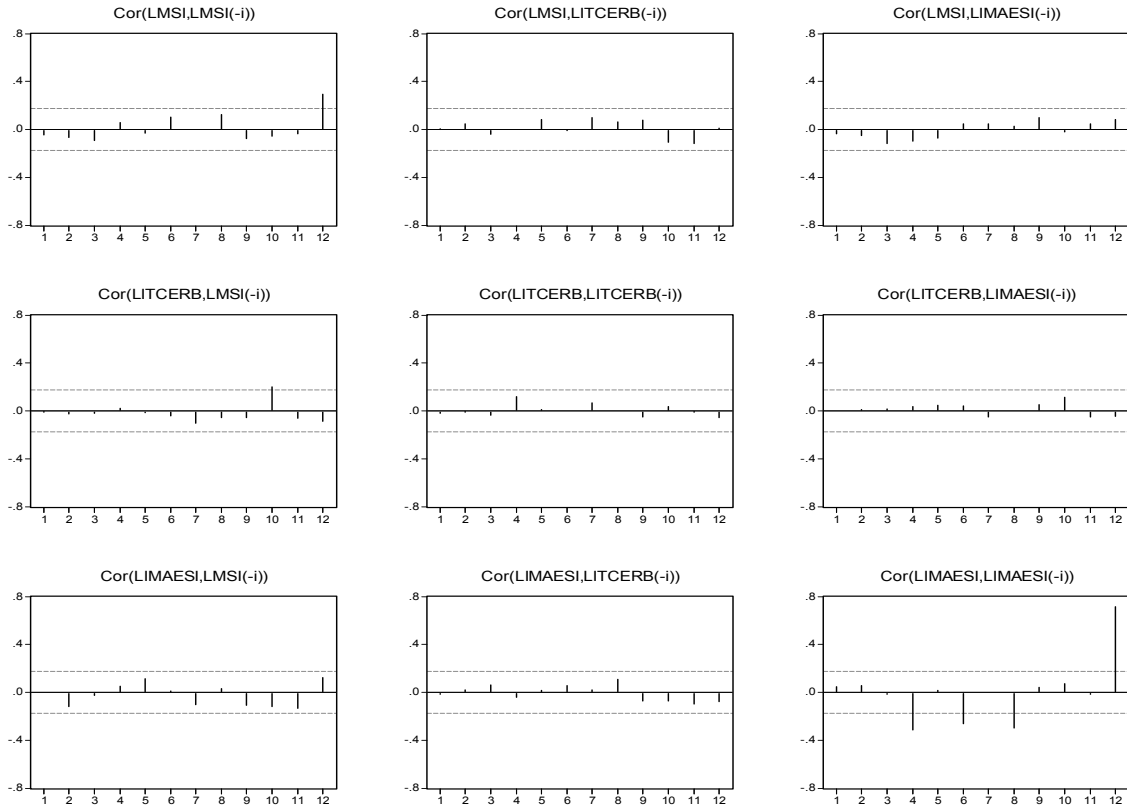
Anexo 10 Función de Impulso-Respuesta (FIR) acumulada

Accumulated Response to Generalized One S.D. Innovations



Anexo 11 Pruebas de autocorrelación

Autocorrelations with 2 Std.Err. Bounds



VEC Residual Portmanteau Tests for Autocorrelations

H0: no residual autocorrelations up to lag h

Date: 12/02/03 Time: 16:14

Sample: 1992:01 2003:04

Included observations: 133

Lags	Q-Stat	Prob.	Adj Q-Stat	Prob.	df
1	0.886471	NA*	0.893186	NA*	NA*
2	5.138470	NA*	5.210102	NA*	NA*
3	8.869991	0.4494	9.027735	0.4347	9

*The test is valid only for lags larger than the VAR lag order.
df is degrees of freedom for (approximate) chi-square distribution

VEC Residual Serial Correlation LM Tests

H0: no serial correlation at lag order h

Date: 12/02/03 Time: 16:16

Sample: 1992:01 2003:04

Included observations: 133

Lags	LM-Stat	Prob
1	15.59718	0.0758
2	14.51935	0.1050

Probs from chi-square with 9 df.

Anexo 12 Prueba de normalidad multivariada de los residuos

VEC Residual Normality Tests

Orthogonalization: Cholesky (Lutkepohl)

H0: residuals are multivariate normal

Sample: 1992:01 2003:04

Included observations: 133

Component	Skewness	Chi-sq	df	Prob.
1	-0.363261	2.925085	1	0.0872
2	0.381483	3.225907	1	0.0725
3	0.201843	0.903082	1	0.3420
Joint		7.054073	3	0.0702

Anexo 13 Modelo VECM restringido

Vector Error Correction Estimates
Sample(adjusted): 1992:04 2003:04
Included observations: 133 after adjusting endpoints
Standard errors in () & t-statistics in []

Cointegration Restrictions:
A(2,1)=0,A(1,2)=0,A(3,2)=0
Convergence achieved after 5 iterations.
Not all cointegrating vectors are identified
LR test for binding restrictions (rank = 2):
Chi-square(1) 0.259299
Probability 0.610602

Cointegrating Eq:	CointEq1	CointEq2
LMSI(-1)	-14.95007	7.638894
LITCERB(-1)	-17.14942	52.44060
LIMAESI(-1)	19.67454	-2.984681
C	76.10158	-273.0952



Error Correction:	D(LMSI)	D(LITCERB)	D(LIMAESI)
CointEq1	0.021655 (0.00636) [3.40639]	0.000000 (0.00000) [NA]	-0.006845 (0.00306) [-2.23957]
CointEq2	0.000000 (0.00000) [NA]	-0.002851 (0.00075) [-3.81507]	0.000000 (0.00000) [NA]
D(LMSI(-1))	-0.680022 (0.10247) [-6.63603]	0.016646 (0.01350) [1.23321]	-0.067664 (0.04919) [-1.37560]
D(LMSI(-2))	-0.266828 (0.08425) [-3.16692]	0.004100 (0.01110) [0.36945]	-0.043794 (0.04044) [-1.08285]
D(LITCERB(-1))	1.095122 (0.68415) [1.60071]	0.332018 (0.09012) [3.68417]	-0.113082 (0.32840) [-0.34434]
D(LITCERB(-2))	0.849150 (0.73678) [1.15251]	0.024800 (0.09705) [0.25554]	-0.261696 (0.35366) [-0.73996]
D(LIMAESI(-1))	-0.266540 (0.19916) [-1.33833]	0.004516 (0.02623) [0.17213]	-0.641385 (0.09560) [-6.70915]
D(LIMAESI(-2))	-0.398935 (0.18627) [-2.14167]	0.001741 (0.02454) [0.07096]	-0.228094 (0.08941) [-2.55102]
C	0.017282 (0.00700) [2.46817]	-0.000673 (0.00092) [-0.73010]	0.006103 (0.00336) [1.81588]

R-squared	0.570729	0.171685	0.398723
Adj. R-squared	0.543035	0.118245	0.359931
Sum sq. resid	0.770838	0.013375	0.177609
S.E. equation	0.078844	0.010386	0.037846
F-statistic	20.60776	3.212683	10.27846
Log likelihood	153.7978	423.3931	251.4127
Akaike AIC	-2.177411	-6.231475	-3.645303
Schwarz SC	-1.981823	-6.035887	-3.449716
Mean dependent	0.006735	-0.000775	0.002811
S.D. dependent	0.116635	0.011060	0.047305

Determinant Residual Covariance	8.89E-10
Log Likelihood	833.6287
Log Likelihood (d.f. adjusted)	819.7539
Akaike Information Criteria	-11.83089
Schwarz Criteria	-11.11373



Anexo 14 Función Impulso-Respuesta (FIR)

Response to Generalized One S.D. Innovations

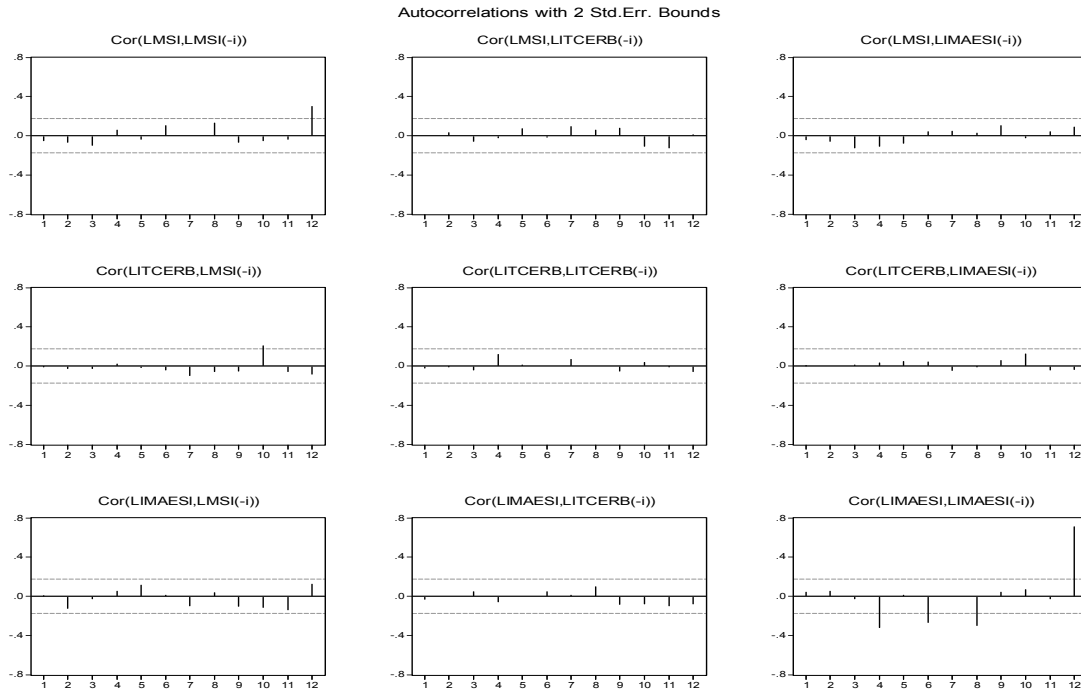


Anexo 15 Función de Impulso-Respuesta (FIR) acumulada

Accumulated Response to Generalized One S.D. Innovations



Anexo 16 Pruebas de autocorrelación



VEC Residual Portmanteau Tests for Autocorrelations
H0: no residual autocorrelations up to lag h
Date: 12/03/03 Time: 09:37
Sample: 1992:01 2003:04
Included observations: 133

Lags	Q-Stat	Prob.	Adj Q-Stat	Prob.	df
1	0.977649	NA*	0.985055	NA*	NA*
2	5.046119	NA*	5.115639	NA*	NA*
3	8.937981	0.4430	9.097313	0.4283	9

*The test is valid only for lags larger than the VAR lag order.
df is degrees of freedom for (approximate) chi-square distribution

VEC Residual Serial Correlation LM Tests
H0: no serial correlation at lag order h
Date: 12/03/03 Time: 09:37
Sample: 1992:01 2003:04
Included observations: 133

Lags	LM-Stat	Prob
1	15.59157	0.0759
2	14.55147	0.1040

Probs from chi-square with 9 df.

Anexo 17 Prueba de Normalidad multivariada

VEC Residual Normality Tests
Orthogonalization: Cholesky (Lutkepohl)
H0: residuals are multivariate normal
Sample: 1992:01 2003:04
Included observations: 133

Component	Skewness	Chi-sq	df	Prob.
1	-0.356334	2.814591	1	0.0934
2	0.366213	2.972816	1	0.0847
3	0.186539	0.771329	1	0.3798
Joint		6.558736	3	0.0874

Component	Kurtosis	Chi-sq	df	Prob.
1	2.943790	0.017509	1	0.8947
2	5.330679	30.10268	1	0.0000
3	2.448462	1.685741	1	0.1942
Joint		31.80593	3	0.0000

Component	Jarque-Bera	df	Prob.
1	2.832100	2	0.2427
2	33.07550	2	0.0000
3	2.457070	2	0.2927
Joint	38.36467	6	0.0000