



Munich Personal RePEc Archive

Akaike or Schwarz? Which One is a Better Predictor of Chilean GDP?

Medel, Carlos A.

Central Bank of Chile

14 January 2012

Online at <https://mpra.ub.uni-muenchen.de/35950/>
MPRA Paper No. 35950, posted 16 Jan 2012 10:42 UTC

¿Akaike o Schwarz? ¿Cuál utilizar para predecir el PIB chileno?*

Carlos A. Medel Vera
Gerencia de Investigación Económica
Banco Central de Chile

January 13, 2012

Abstract

Schwarz. En este trabajo se evalúa la capacidad predictiva de los criterios de información de Akaike y Schwarz con modelos autorregresivos integrados de medias móviles, utilizando datos sectoriales del PIB chileno. En términos de la raíz del error cuadrático medio y después de la estimación de más de un millón de modelos, los resultados indican que, en promedio, los modelos basados en el criterio de Schwarz presentan un mejor rendimiento predictivo que aquellos escogidos con el de Akaike, para los cuatro horizontes analizados. Asimismo, la significancia estadística de estas diferencias indica que la superioridad en favor del criterio de Schwarz se observa principalmente en los mayores horizontes de proyección.

*Se agradecen los comentarios de Carlos Alvarado, Michael Pedersen, Sergio Salgado, a los asistentes del seminario de Universidad Santo Tomás, un árbitro anónimo, y de manera especial los comentarios y ayuda de Pablo Pincheira. Las ideas y opiniones presentadas en este trabajo no necesariamente representan la visión del Banco Central de Chile o de sus autoridades. Los errores u omisiones son responsabilidad exclusiva del autor. E-mail: cmedel@bcentral.cl.

1 Introducción

La precisión de los pronósticos es un elemento crucial para el éxito de la mayoría de las decisiones económicas, sin embargo, no existe hoy en día una metodología econométrica sistemáticamente superior en capacidad predictiva. Una manera común de realizar proyecciones económicas consiste en la estimación del modelo verdadero de una variable basado en un criterio de ajuste a los datos, más allá de lo que pueden sugerir sus fundamentales. Como cualquier otra estimación econométrica con muestras finitas, puede ser sensible en mayor o menor medida al tamaño de muestra disponible, y a las transformaciones y características de los datos. En este trabajo se evalúa la capacidad predictiva de modelos autoregresivos integrados de medias móviles (ARIMA)¹ construidos dentro de muestra de acuerdo a los criterios de información de Akaike y Schwarz (en adelante AIC y BIC, respectivamente)² para determinar cual de los dos posee el mejor rendimiento fuera de muestra. Como se mostrará, el rendimiento predictivo está determinado por el criterio de selección de modelos. Existen otros criterios de ajuste de similar espíritu, sin embargo, se prescinde de su utilización dado que AIC y BIC arrojan generalmente los resultados dentro de muestra de mayor y menor parametrización, respectivamente (Lütkepohl, 1985; Granger y Jeon, 2004). Las estimaciones se realizan con datos sectoriales del PIB chileno. De esta forma, en este trabajo se desea probar la hipótesis nula que *los modelos escogidos con BIC poseen una mejor capacidad predictiva que los escogidos con AIC para los datos sectoriales chilenos*.

El ejercicio consiste en la estimación de una familia exhaustiva de modelos ARIMA de orden desconocido pero finito para cada una de las series consideradas, computando en cada caso los criterios de información. Por cada criterio se utiliza para proyectar aquel modelo que minimiza el criterio de información —el de mejor ajuste. Luego, se realizan proyecciones desde 1 hasta 4 trimestres adelante, para cada una de las transformaciones estacionarias de los datos. Finalmente, se construye una serie con la mínima raíz del error cuadrático medio obtenida por cada criterio de información. Los modelos son re-estimados cada vez que una ventana móvil de tamaño fijo avanza en la muestra de evaluación, capturando sólo la dinámica reciente.

Después de la estimación de más de un millón de modelos, los resultados indican que los modelos basados en BIC presentan una menor raíz del error cuadrático medio que aquellos escogidos con AIC, para los cuatro horizontes analizados. Igualmente, la significancia estadística de estas diferencias calculada con el test de Giacomini y White (2006), indica que la superioridad predictiva de BIC es robusta principalmente para los mayores horizontes de proyección bajo ciertas transformaciones para alcanzar estacionariedad.

El resto del trabajo continúa de la siguiente manera. En la sección 2 se analizan los

¹Para mayores detalles ver Box y Jenkins (1970). Una compilación reciente de las distintas extensiones de la metodología ARMA se encuentra en Holan, Lund, y Davis (2010).

²Mayores detalles se presentan en Akaike (1974), Shibata (1976), Rissanen (1978), Schwarz (1978), y Stone (1979).

resultados obtenidos en la literatura relacionada. En la sección 3 se describen los datos y sus transformaciones estacionarias. En la sección 4 se describen las estrategias de estimación y métodos de evaluación, para luego, en la sección 5 presentar los resultados. Finalmente, se concluye en la sección 6.

2 Criterios de información

Ambos criterios de información se derivan de una minimización insesgada del valor esperado del criterio de Kullback–Leibler (ver Kullback y Leibler, 1951), es decir, en la minimización de una medida asimétrica de diferencias entre una función de distribución de probabilidades verdadera y otra estimada. En ambos casos, la medida utilizada es una función dependiente de la función de máxima verosimilitud y penalizando por el número de regresores estimados. Formalmente, los criterios se definen como:

$$\begin{aligned} \text{AIC} &: -2(\ell/T) + 2(k/T), \\ \text{BIC} &: -2(\ell/T) + k \log(T)/T, \end{aligned}$$

donde ℓ es el valor del logaritmo de la función de máxima verosimilitud, k es el número de regresores del modelo, y T el número de observaciones incluidas en la estimación. Conjuntamente, estas ecuaciones implican que $BIC \leq AIC$ cuando $T \geq 8$, dado que BIC penaliza con mayor severidad la inclusión de regresores. Así, teóricamente se sostiene que BIC elige un menor número de regresores que AIC, lo que empíricamente se observa, por ejemplo, en Lütkepohl (1985), Nickelsburg (1985), Yi y Judge (1988), Granger y Jeon (2004), Raffalovich et al. (2008), Shittu y Asemota (2009), entre otros.

La mayoría de los trabajos que analizan y comparan distintos criterios de información se realizan con el objetivo de encontrar un criterio dominante en la búsqueda del modelo verdadero en un contexto tanto univariado como multivariado, por ejemplo, Sawa (1978), Amemiya (1980), Pötscher y Srinivasan (1991), Poskitt (1994), Salau (2002), entre otros.³ En la mayoría de los casos se encuentra que BIC indica un mayor número de veces el modelo verdadero comparado con varios criterios, incluyendo AIC y otros de distinta naturaleza.⁴ En Lütkepohl (1985) se comparan fuera de muestra más de diez criterios de selección de modelos encontrando que el mejor rendimiento predictivo se alcanza con BIC; resultado compartido por Clark (2004).

Varios trabajos comparan la sensibilidad de ambos criterios frente al tamaño de muestra utilizado. Algunas propiedades asintóticas de ambos criterios son discutidas, por ejemplo, en Geweke y Meese (1981) y en Pötscher y Srinivasan (1991). Por un lado, con probabilidad igual a uno BIC eligirá el modelo autoregresivo verdadero cuando

³Sobre la determinación del orden autoregresivo en el contexto de VARs, ver Nishi (1988), Granger, King, y White (1995), y Sin y White (1996).

⁴Sin embargo, la sobreparametrización asociada a AIC resulta ser beneficiosa para la correcta estimación de las funciones impulso-respuesta (Kilian, 2001).

el tamaño de muestra tienda a infinito, toda vez que la búsqueda se realice con un orden mayor o igual al verdadero. En Lütkepohl (1985) se encuentra que si bien BIC vence fuera de muestra a otros criterios, esta superioridad decae mientras mayor es el horizonte de predicción. Por otro lado, Bhansali y Downham (1977) y Shibata (1976, 1980) muestran que AIC no es consistente en modelos autoregresivos, por lo que se obtiene una parametrización distinta frente a diferentes tamaños muestrales. Siguiendo esa línea, varios trabajos enfatizan el sesgo por muestra pequeña. Bhansali y Downham (1977), y Hurvich y Tsai (1993) proponen correcciones por muestra pequeña a AIC, mejorando sus propiedades asintóticas aunque no suficientes para dominar por completo a AIC (Akaike, 1979). Se destaca, sin embargo, que en este contexto existen divergentes definiciones para muestra pequeña: 45 observaciones para el caso de Sargent y Sims (1977), 14 en Miller, Supel, y Turner (1980), 15 en Nickelsburg (1982), 23 en Sims (1980), 68 en Fischer (1981), 56 en Gordon y King (1982), entre otras. En Sawyer (1979) se clasifica el rendimiento dentro de muestra de varios criterios con muestras asintóticamente grandes, ejercicio que muestra resultados mixtos en muestras pequeñas.⁵

Este trabajo comparte también los resultados expuestos en Granger y Jeon (2004). Utilizando 215 series macroeconómicas de los Estados Unidos, los autores encuentran evidencia de sobreparametrización de la modelación basada en AIC, y una mejor capacidad predictiva asociada a los modelos basados en BIC. Sin embargo, fuera de muestra los criterios no son superiores a un modelo $AR(4)$, ni a un promedio entre ellos. En Stock y Watson (2007) se presenta un ejercicio fuera de muestra comparativo entre modelos lineales y no lineales, incluyendo una modelación ARMA. La evidencia es mixta entre los criterios de información y transformaciones de los datos.

Para el caso del PIB chileno en particular, en Medel (2012) se realiza un ejercicio más amplio al realizado en este trabajo, considerando una mayor cantidad de especificaciones y distintas versiones de los datos. Se encuentra evidencia en favor de BIC aunque sin averiguar su significancia estadística. De manera opuesta, para el caso de la inflación chilena, en Cobb (2009) se encuentra evidencia predictiva en favor de AIC por sobre BIC, utilizando diversas especificaciones multivariadas para horizontes de corto plazo. Asimismo, en Pincheira y García (2009) se compara el rendimiento predictivo de diversos modelos ARIMA con una familia de modelos SARIMA extendidos, incluyendo especificaciones basadas en AIC y BIC, también encontrando que la modelación basada en AIC entrega predicciones más acertadas que aquellas provenientes de modelos escogidos con BIC.

3 Datos

Corresponden a las Cuentas Nacionales Trimestrales elaboradas por el Banco Central de Chile, tanto por el lado de la oferta como de la demanda. Los datos originales en niveles

⁵En el contexto de este trabajo se contempla un tamaño muestral de 40 observaciones antes de ajustes, sin tratamientos por muestra pequeña.

están denominados en millones de pesos de 2003. Para alcanzar la estacionariedad requerida para la modelación se utilizan las siguientes cinco transformaciones:

$$(i - iv) : \Delta^d y_t = \Delta^d [\log(Y_t) - \log(Y_{t-1})], \quad d = \{0, \dots, 3\},$$

$$(v) : y_t = (Y_t/Y_{t-4}) \cdot 100 - 100,$$

donde Y_t es la serie en niveles. En adelante, estas transformaciones se denominan $d1$, $d2$, $d3$, $d4$ y $\%$. Todas ellas son transformaciones estacionarias de las serie en niveles; cada una con una función de autocorrelación distinta.

La muestra completa disponible abarca desde 1986.I hasta 2010.IV (100 observaciones). Así, la primera estimación con una ventana móvil fija de 40 observaciones abarca desde 1986.I hasta 1995.IV. Se utilizan 40 observaciones antes de ajustes para capturar solamente la dinámica más reciente, dejando además los grados de libertad suficientes para que la estimación sea insesgada. La muestra remanente utilizada para la evaluación fuera de muestra cubre el período comprendido entre 1996.I y 2010.III (59 observaciones). El ejercicio se realiza con la primera versión de los datos conocidos hasta 2010.IV, no contemplando revisiones de estos (es decir, no en tiempo-real).

Se consideran tres niveles de desagregación, comenzando con el PIB como el nivel de mayor agregación. En la Tabla 1 se presenta esquemáticamente la desagregación del PIB por el lado de la demanda, y en la Tabla 2 por el lado de la oferta. En el apéndice se presentan los estadísticos típicos de todas las series para cada una de las transformaciones.

Tabla 1: PIB chileno por el lado de la demanda

$$pib = di + de = c + i + g + (x - m) =$$

$$(ch + cd) + (meq + coo + ve) + g + (xb + xs - mb - ms)$$

<i>ch</i>	Consumo privado: habitual	<i>c</i>	Consumo privado	<i>di</i>	Demanda interna	<i>pib</i>	Producto
<i>cd</i>	Consumo privado: durable		(<i>ch + cd</i>)		(<i>c + i + g</i>)		interno
<i>meq</i>	Maquinarias y equipos	<i>i</i>	Inversión	<i>de</i>	Demanda externa		bruto
<i>coo</i>	Construcción y obras		(<i>meq + coo + ve</i>)		(<i>x - m</i>)		(<i>di + de</i>)
<i>ve</i>	Variación de existencias (*)	<i>g</i>	Consumo de gobierno				
<i>g</i>	Consumo de gobierno		(<i>g</i>)				
<i>xb</i>	Exportaciones de bienes	<i>x</i>	Exportaciones				
<i>xs</i>	Exportaciones de servicios		(<i>xb + xs</i>)				
<i>mb</i>	Importaciones de bienes (**)	<i>m</i>	Importaciones (**)				
<i>ms</i>	Importaciones de servicios (**)		(<i>mb + ms</i>)				

(*) No considerada en el análisis. (**) Importaciones son restadas. Fuente: Banco Central de Chile.

Tabla 2: PIB chileno por el lado de la oferta

$pib = pib\ rn + pib\ resto + otros = (ega + pes + min) + (com + ind + con + agr + tra + fin + per + pro + adm) + (iva + cif - ib)$					
<i>pib</i>	Producto	<i>pib rn</i>	PIB Recursos naturales	<i>ega</i>	Electricidad, gas y agua
	interno		$(ega + pes + min)$	<i>pes</i>	Pesca
	bruto	<i>pib resto</i>	PIB Resto	<i>min</i>	Minería
	$(pib\ rn +$		$(com + ind + con +$	<i>com</i>	Comercio
	<i>pib resto +</i>		<i>agr + tra + fin +</i>	<i>ind</i>	Industria
	<i>otros)</i>		<i>per + pro + adm)</i>	<i>con</i>	Construcción
		<i>otros</i>	Otros sectores	<i>agr</i>	Agropecuaria y silvícola
			$(-ib + iva + dim)$	<i>tra</i>	Transporte y comunicaciones
				<i>fin</i>	Servicios financieros y empresariales
				<i>per</i>	Servicios personales
				<i>pro</i>	Propiedad y vivienda
				<i>adm</i>	Administración pública
				<i>ib</i>	Imputaciones bancarias (*)
				<i>iva</i>	Impuesto al valor agregado
				<i>dim</i>	Derechos de importación

(*) Imputaciones bancarias son restadas. Fuente: Banco Central de Chile.

4 Estrategia de estimación

4.1 Modelación ARIMA

Los modelos $ARIMA(p, d, q)$ corresponden a todas las combinaciones posibles del par $(p, q) \subseteq \{0, 1, 2, 3, 4\}^2$, considerando sólo términos correlativos para p y q , y las transformaciones mencionadas ($d1, d2, d3, d4, \%$). Las especificaciones se pueden sintetizar en:

$$y_t = \mu + \sum_{i=0}^p \rho_i y_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j} + \varepsilon_t, \quad (A1)$$

donde μ , ρ_i y θ_j son parámetros a ser estimados, y ε_t es un ruido blanco. Se considera una especificación ARIMA debido a la exhaustividad con la que puede capturar la dinámica lineal del tipo de series consideradas, dada la frecuencia y máximo rezago considerado. En Medel (2012) se utiliza la misma muestra del mismo conjunto de datos encontrando que la especificación ARIMA arroja los mejores resultados predictivos para series sin tratamiento estacional.

El ejercicio consiste en la estimación de la ecuación A1, para cada una de las series consideradas, computando en cada caso los criterios de información. Por cada criterio se utiliza para proyectar aquel modelo que minimiza el criterio de información –el de mejor ajuste. Se realizan proyecciones desde 1 hasta 4 trimestres adelante, con cada una de las transformaciones estacionarias de los datos. Posteriormente, se construye una serie con la mínima raíz del error cuadrático medio obtenida por cada criterio

de información. Así, los resultados se presentan en términos de la transformación que arroja el mejor ajuste un mayor número de veces en promedio, dada la serie, criterio, y horizonte. Los modelos son re-estimados –encontrando una especificación y transformación distinta– cada vez que una ventana móvil de tamaño fijo avanza en la muestra de evaluación, capturando sólo la dinámica reciente. Todas las estimaciones son realizadas con el *add-in* ARIMASel para Eviews 7.1.

Contabilizando 5 transformaciones, 34 variables, 4 horizontes, 2 criterios, 20 posibles combinaciones de modelos, para 59 ventanas móviles, el número de modelos estimados alcanza:

$$5 \times 34 \times 4 \times 2 \times 20 \times 59 = 1,604,800 \text{ modelos.}$$

Este número es ligeramente inferior debido a que en pocas ocasiones la función de máxima verosimilitud no fue computable.

4.2 Evaluación de la capacidad predictiva

Se basa en la comparación de la raíz cuadrada del error cuadrático medio (RECM), y la inferencia realizada con una modificación del test de Giacomini y White (2006). La RECM es calculada como:

$$RECM_{h,i} = \left[\frac{1}{T} \sum_{t=1}^T (y_{t+h}^i - \hat{y}_{t+h|t}^i)^2 \right]^{\frac{1}{2}},$$

donde h es el horizonte de proyección ($h = \{1, 2, 3, 4\}$), $\hat{y}_{t+h|t}$ es la proyección de y_{t+h} , h trimestres adelante, T es el tamaño de la ventana de evaluación (59 observaciones), e i corresponde a cada variable ($i = \{ch, cd, \dots, pib\}$). A pesar de las transformaciones utilizadas para la modelación, todos los resultados son presentados y analizados en términos de variación anual de las series en niveles ($y_t = (Y_t/Y_{t-4} - 1) \cdot 100$), es decir, medida en puntos porcentuales.

4.3 Inferencia estadística

Se realiza con el test de Giacomini y White (2006) a una cola con una modificación en el cálculo de la varianza para horizontes mayores a un trimestre, y considerando una función de pérdida cuadrática, definida como la diferencia de ECM entre ambos criterios:

$$d_h^i = \frac{1}{T} \sum_{t=1}^T \left[(y_{t+h}^i - \hat{y}_{t+h|t}^{i,AIC})^2 - (y_{t+h}^i - \hat{y}_{t+h|t}^{i,BIC})^2 \right].$$

La hipótesis nula del test es: *los modelos escogidos con BIC poseen una mejor capacidad predictiva que los escogidos con AIC*. Formalmente, la hipótesis nula y alternativa del test corresponden a:

$$\begin{aligned}
HN & : E [d_h] \leq 0, \\
HA & : E [d_h] > 0,
\end{aligned}$$

donde,

$$E [d_h] = \frac{1}{S} \sum_{i=1}^S d_h^i = \frac{1}{S} \frac{1}{T} \sum_{i=1}^S \sum_{t=1}^T \left[(y_{t+h}^i - \hat{y}_{t+h|t}^{i,AIC})^2 - (y_{t+h}^i - \hat{y}_{t+h|t}^{i,BIC})^2 \right],$$

con $\#i = S = 34$, y $T = 59$, dado un horizonte h . El estadístico y su distribución teórica, en tanto, son:

$$GW_h = \hat{\sigma}_{d_h}^{-1} \cdot E [d_h] \sim N(0, 1),$$

donde $\hat{\sigma}_{d_h}$ es un estimador de la varianza de d_h^i corregido por autocorrelación y heteroscedasticidad (Newey y West, 1987). La hipótesis nula se rechaza si $GW_h > \xi > 0$, donde ξ es un valor crítico proveniente de una distribución normal estándar. Rechazar la hipótesis nula implica que BIC posee un mejor rendimiento predictivo que AIC.

Dado que las estimaciones son realizadas completamente por un programa computacional sin intervención, en algunos casos se generan proyecciones fuera de lo normal. Lo anterior provoca que en algunos casos las diferencias de ajuste de las proyecciones obtenidas con ambos criterios generan también valores fuera de lo normal. Sin embargo, dado que la manera de intervenir tiene implicancias para la inferencia (Mélard y Pasteels, 2000), se opta por no intervenir el proceso de predicción y comparar el rendimiento de los criterios directamente.

5 Resultados

5.1 Comparación RECM

Los resultados de comparación de RECM se presentan en la Tabla 3 para $h = 1$ y $h = 2$, y en la Tabla 4 para $h = 3$ y $h = 4$. En esas tablas, el estadístico presentado corresponde a:

$$RECM \text{ Relativo}_{h,i} = \frac{RECM_{h,i}^{AIC}}{RECM_{h,i}^{BIC}},$$

por lo que, suponiendo falsa la hipótesis nula (BIC es superior a AIC), el estadístico es mayor o igual a la unidad. Se observa que para $h = 1$ el 54% del total de las veces se cumple que $RECM \text{ Relativo} > 1$, mientras que para $h = 2$ un 49%, y un 55% para cada uno de los restantes horizontes. La última fila de cada tabla indica el porcentaje de veces en que $RECM \text{ Relativo} > 1$ para cada transformación de los datos. Estos resultados sugieren que los mejores resultados predictivos se obtienen con BIC. Dado que este resultado no pondera ni estandariza la magnitud de las diferencias, entonces se aplica un test para averiguar su significancia, cuyos resultados se presentan en la siguiente subsección.

Tabla 3: Resultados RECM Relativo series de oferta y demanda, $h=1$ y $h=2$

	$h=1$					$h=2$				
	$d1$	$d2$	$d3$	$d4$	%	$d1$	$d2$	$d3$	$d4$	%
<i>ch</i>	0.974	0.982	1.047	0.970	1.047	1.014	0.994	1.019	0.988	1.052
<i>cd</i>	1.341	0.990	0.984	0.999	1.080	0.659	0.998	1.006	1.033	1.019
<i>meq</i>	0.394	0.996	1.016	0.963	1.064	0.533	0.994	1.012	1.033	1.413
<i>coo</i>	1.193	0.939	0.950	1.048	1.026	0.916	1.002	0.990	0.974	1.013
<i>g</i>	1.084	0.991	1.256	1.000	0.977	0.379	1.022	1.264	1.013	0.988
<i>xb</i>	1.062	0.893	0.980	0.981	1.005	0.950	0.923	0.980	0.997	1.005
<i>xs</i>	0.879	0.942	1.091	0.888	1.001	1.026	0.986	1.114	1.005	0.999
<i>(mb)</i>	1.005	1.000	0.909	0.932	1.395	1.160	0.992	0.904	1.085	1.231
<i>(ms)</i>	1.187	1.235	0.957	1.002	1.131	1.065	0.986	0.937	1.009	1.051
<i>c</i>	1.005	0.940	1.061	0.898	0.999	0.976	0.945	0.930	0.970	1.006
<i>i</i>	2.514	0.929	1.284	1.551	0.985	1.258	0.816	1.708	1.347	0.988
<i>x</i>	0.936	0.876	0.927	0.970	0.931	1.090	1.001	0.963	1.037	0.970
<i>(m)</i>	1.428	1.880	0.978	1.279	0.974	0.974	1.744	0.891	1.335	1.408
<i>di</i>	1.512	0.977	0.874	0.964	1.133	1.205	0.894	1.024	1.096	1.117
<i>de</i>	0.980	0.974	1.101	0.980	0.967	1.031	0.965	0.963	0.982	0.998
<i>pib</i>	0.902	0.950	0.987	1.080	0.795	0.830	0.921	1.021	1.033	0.841
<i>ega</i>	0.931	0.957	1.000	0.928	1.006	0.944	0.878	0.689	0.987	1.204
<i>min</i>	0.308	0.894	0.971	1.040	1.028	0.664	0.940	0.994	1.313	1.051
<i>pes</i>	0.841	1.013	1.023	1.050	0.918	0.925	1.028	0.987	1.050	0.915
<i>agr</i>	0.796	1.730	0.970	0.957	1.138	0.939	2.874	1.000	1.058	1.128
<i>ind</i>	3.655	1.032	0.931	1.165	0.943	3.445	0.973	1.007	1.123	1.114
<i>com</i>	0.998	1.012	1.077	0.939	0.931	0.986	0.993	1.074	0.972	0.926
<i>con</i>	0.866	1.013	0.937	0.876	1.798	0.876	0.980	0.957	0.996	1.837
<i>tra</i>	1.291	1.058	1.439	1.178	1.011	1.079	0.821	1.503	1.183	0.927
<i>fin</i>	0.941	0.829	1.024	1.005	0.960	0.836	0.982	1.188	0.918	1.022
<i>per</i>	1.008	0.978	1.145	1.023	1.000	0.980	1.191	1.198	0.926	1.003
<i>pro</i>	7.367	1.151	1.029	0.957	1.010	7.912	0.956	1.101	1.001	1.002
<i>pub</i>	1.165	1.001	0.821	1.330	1.011	0.936	0.978	0.889	1.286	0.951
<i>(ib)</i>	1.125	1.013	0.867	0.976	0.941	0.891	0.938	1.041	0.955	1.004
<i>iva</i>	0.932	0.929	0.799	1.078	0.847	0.889	0.990	1.065	1.091	0.954
<i>dim</i>	0.919	1.011	0.878	1.020	0.968	1.184	1.044	1.026	1.099	1.056
<i>pib rn</i>	1.311	1.080	0.965	0.989	1.023	1.087	0.994	1.064	1.357	1.015
<i>pib resto</i>	0.950	0.987	1.132	1.048	1.102	0.986	0.987	0.944	1.016	1.091
<i>otros</i>	0.826	1.005	1.008	1.014	0.617	0.810	0.960	0.946	1.053	0.812
% (*)	50.0%	55.9%	47.1%	50.0%	64.7%	38.2%	23.5%	52.9%	67.6%	64.7%

(*) Porcentaje de veces en que RECM Relativo >1 para cada transformación. Fuente: Elaboración propia.

Tabla 4: Resultados RECM Relativo series de oferta y demanda, $h=3$ y $h=4$

	$h=3$					$h=4$				
	$d1$	$d2$	$d3$	$d4$	%	$d1$	$d2$	$d3$	$d4$	%
<i>ch</i>	0.983	0.982	0.929	0.985	2.46	0.954	0.933	0.968	1.022	0.993
<i>cd</i>	1.999	0.990	1.001	1.019	6.79	0.698	0.985	1.022	0.986	1.009
<i>meq</i>	0.595	0.996	0.991	1.052	6.19	0.542	0.995	1.176	1.302	1.725
<i>coo</i>	1.044	0.939	1.050	1.036	6.14	0.890	1.019	1.006	1.068	1.144
<i>g</i>	0.616	0.991	1.123	1.014	2.97	0.976	0.906	0.950	0.969	0.977
<i>xb</i>	0.817	0.893	0.919	1.007	2.12	0.734	0.929	1.058	0.987	1.002
<i>xs</i>	1.132	0.942	1.095	0.919	2.26	1.831	0.998	1.144	0.913	1.000
(<i>mb</i>)	0.903	1.000	1.382	1.126	6.52	0.946	1.068	0.874	1.056	1.741
(<i>ms</i>)	0.844	1.235	0.963	1.008	3.76	1.131	1.162	1.019	1.027	0.914
<i>c</i>	0.876	0.940	0.903	1.050	2.46	1.016	0.961	1.061	0.989	1.001
<i>i</i>	1.406	0.929	1.178	1.473	6.79	1.505	0.866	1.301	1.659	1.023
<i>x</i>	1.141	0.876	1.017	0.957	6.19	0.906	1.031	0.985	0.987	0.869
(<i>m</i>)	1.152	1.880	0.994	0.966	6.14	1.092	1.596	0.961	1.605	1.380
<i>di</i>	1.361	0.977	0.868	1.056	2.97	1.235	1.012	0.935	1.071	0.928
<i>de</i>	0.936	0.974	1.098	0.980	2.12	0.822	0.932	1.050	0.993	1.022
<i>pib</i>	1.004	0.950	1.058	1.208	2.26	0.935	0.980	0.945	0.834	0.902
<i>ega</i>	0.993	0.957	0.985	0.983	6.52	0.967	0.922	1.167	1.009	1.014
<i>min</i>	0.256	0.894	0.899	1.311	3.76	0.564	0.796	0.978	1.804	1.000
<i>pes</i>	0.817	1.013	1.008	0.996	11.76	1.010	0.994	0.932	1.022	0.947
<i>agr</i>	0.865	1.730	0.986	1.082	5.86	0.943	2.390	1.042	1.105	1.156
<i>ind</i>	3.738	1.032	1.024	1.196	2.76	3.534	1.065	1.190	1.187	1.109
<i>com</i>	0.988	1.012	1.105	0.981	4.19	0.921	1.010	1.158	1.021	1.006
<i>con</i>	0.736	1.013	1.041	1.037	4.88	1.044	1.000	0.991	1.054	0.885
<i>tra</i>	1.123	1.058	1.097	1.134	1.85	1.054	0.700	1.306	1.148	1.008
<i>fin</i>	0.822	0.829	1.315	0.943	2.33	0.898	1.009	0.861	0.979	0.999
<i>per</i>	1.007	0.978	1.209	1.016	2.06	0.978	1.129	1.263	0.941	0.995
<i>pro</i>	7.614	1.151	0.935	0.989	0.08	7.943	0.927	1.044	1.057	1.016
<i>pub</i>	1.065	1.001	1.028	1.311	0.29	1.030	0.989	1.025	1.488	1.171
(<i>ib</i>)	1.080	1.013	1.033	0.927	2.35	1.011	1.014	1.003	1.013	0.868
<i>iva</i>	0.891	0.929	1.156	1.057	2.29	0.902	1.120	0.884	1.054	0.766
<i>dim</i>	1.169	1.011	1.046	0.965	8.58	1.144	1.041	1.149	0.969	0.899
<i>pib rn</i>	1.263	1.080	1.089	1.524	2.91	1.180	1.182	1.136	1.175	1.050
<i>pib resto</i>	1.031	0.987	0.925	1.029	2.44	1.083	0.957	0.924	0.993	1.023
<i>otros</i>	0.979	1.005	1.026	0.947	2.50	0.940	0.971	1.057	1.085	0.640
% (*)	50.0%	44.1%	64.7%	61.8%	55.9%	47.1%	44.1%	61.8%	64.7%	55.9%

(*) Porcentaje de veces en que RECM Relativo > 1 para cada transformación. Fuente: Elaboración propia.

5.2 Test de Giacomini y White

La estimación de los estadísticos GW_h y el $t - Statistic$ se presentan en la Tabla 5. Con un nivel de significancia de 10%, se encuentra evidencia de superioridad en la

capacidad predictiva para la mayoría de los casos de BIC por sobre AIC –rechazo de la HN– en todas las transformaciones excepto $d1$, $d3$ para $h = 1$ y 2 , y $d4$ para $h = 1$. En otras palabras, se encuentra evidencia significativa en favor de BIC un 65% de los casos. Se destaca que del total de los casos evaluados existen cinco en los cuáles el estadístico es negativo: los cuatro posibles con $d1$ y uno con $d4$.

Tabla 5: Resultados test de Giacomini y White

	$d1$	$d2$	$d3$	$d4$	%
$h=1$					
Estadístico GW ₁	-120.235	7.949*	0.359	-0.610	62.425*
<i>t-Statistic</i>	-1.149	2.052	0.147	-0.055	2.200
$h=2$					
Estadístico GW ₂	-82.956	9.650*	2.425	18.867*	63.407*
<i>t-Statistic</i>	-1.414	1.289	0.606	3.306	2.681
$h=3$					
Estadístico GW ₃	-141.162	5.912*	4.923*	14.678*	23.181*
<i>t-Statistic</i>	-1.043	1.282	1.792	2.439	1.847
$h=4$					
Estadístico GW ₄	-0.769	0.358*	0.278*	0.976*	1.100*
<i>t-Statistic</i>	-0.705	1.347	2.712	3.056	1.595

(*) HN rechazada al 10%: superioridad del BIC.

Fuente: Elaboración propia.

6 Resumen y conclusiones

El objetivo de este trabajo es averiguar la existencia de diferencias estadísticamente significativas entre la capacidad predictiva de modelos ARIMA elegidos con BIC y AIC, utilizando datos sectoriales del PIB chileno de la oferta y la demanda. El análisis se realizó considerando desde 1 hasta 4 períodos adelante, y transformando las series para lograr la estacionariedad requerida para la modelación. Después de un alto número de estimaciones, se concluye que al momento de predecir los componentes del PIB chileno existe evidencia significativa para algunos horizontes y transformaciones estacionarias en favor de BIC por sobre AIC.

Referencias

1. Akaike, H., 1974, "A New Look at the Statistical Model Identification," *IEEE Transactions on Automatic Control* **19**(6): 716–723.
2. Akaike, H., 1979, "A Bayesian Extension of the Minimum AIC Procedure of Autoregressive Model Fitting," *Biometrika* **66**(2): 237–242.
3. Amemiya, T., 1980, "Selection of Regressors," *International Economic Review* **21**(2): 331–354.

4. Bhansali, R.J., y D.Y. Downham, 1977, "Some Properties of the Order of an Autoregressive Model Selected by a Generalization of Akaike's EPF Criterion," *Biometrika* **64**(3): 547–551.
5. Box, G., y G. Jenkins, 1970, *Time Series Analysis: Forecasting and Control*, Holden-Day, San Francisco, USA.
6. Clark, T.E., 2004, "Can Out-of-Sample Forecast Comparisons Help Prevent Overfitting?," *Journal of Forecasting* **23**(2): 115–139.
7. Cobb, M., 2009, "Forecasting Chilean Inflation from Disaggregate Components," Documento de Trabajo 545, Banco Central de Chile.
8. Fischer, S., 1981, "Relative Shocks, Relative Price Volatility, and Inflation," *Brooking Papers on Economic Activity* **2**: 381–431.
9. Geweke, J., y R. Meese, 1981, "Estimating Regression Models of Finite but Unknown Order," *International Economic Review* **22**(1): 55–70.
10. Giacomini, R., y H. White, 2006, "Tests of Conditional Predictive Ability," *Econometrica* **74**(6): 1545–1578.
11. Gordon, R.J., y S.R. King, 1982, "The Output Cost of Desinflation in Traditional and Vector Autoregressive Models," *Brooking Papers on Economic Activity* **13**(1): 205–244.
12. Granger, C.W.J, y Y. Jeon, 2004, "Forecasting Performance of Infomation Criteria with Many Macro Series," *Journal of Applied Statistics* **31**(10): 1227–1240.
13. Granger, C.W.J., M. King, y H. White, 1995, "Comments on Testing Economic Theories and the use of Model Selection Criteria," *Journal of Econometrics* **67**(1): 173–187.
14. Holan, S.H., R. Lund, y G. Davis, 2010, "The ARMA Alphabet Soup: A Tour of ARMA Model Variants," *Statistics Surveys* **4**: 232–274.
15. Hurvich, C.M., y C.-L. Tsai, 1993, "A Corrected Akaike Information Criterion for Vector Autoregressive Model Selection," *Journal of Time Series Analysis* **14**: 271–279.
16. Kilian, L., 2001, "Impulse Response Analysis in Vector Autoregressions with Unknown Lag Order," *Journal of Forecasting* **20**(3): 161–179.
17. Kullback, S., y R.A. Leibler, 1951, "On Information and Sufficiency," *Annals of Mathematical Statistics* **22**: 79–86.
18. Lütkepohl, H., 1985, "Comparison of Criteria for Estimating the Order of a Vector Autoregressive Process," *Journal of Time Series Analysis* **6**(1): 35–52.

19. Medel, C.A., 2012, "How Informative are the In-Sample Information Criteria to Forecasting? The Chilean GDP Case," *manuscrito*, Banco Central de Chile.
20. Mélard, G., y J.-M. Pasteels, 2000, "Automatic ARIMA Modeling Including Interventions, using Time Series Expert Software," *International Journal of Forecasting* **16**(4): 497–508.
21. Miller, P., T.M. Supel, y T.H. Turner, 1980, "Estimating the Effects of the Oil-Price Shock," *Quarterly Review*, Federal Reserve Bank of Minneapolis.
22. Newey, W., y K. West, 1987, "A Simple, Positive Semi-definite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix," *Econometrica* **55**(3): 703–708.
23. Nickelsburg, G., 1985, "Small-Sample Properties of Dimensionality Statistics for Fitting VAR Models to Aggregate Economic Data –A Monte Carlo Study," *Journal of Econometrics* **28**(2): 183–192.
24. Nishi, R., 1988, "Maximum Likelihood Principle and Model Selection when the True Model is Unspecified," *Journal Multivariate Analysis* **27**: 392–403.
25. Pincheira, P., y A. García, 2009, "Forecasting Inflation in Chile with an Accurate Benchmark," Documento de Trabajo 514, Banco Central de Chile.
26. Poskitt, D.S., 1994, "A Note on Autoregressive Modelling," *Econometric Theory* **10**: 884–890.
27. Pötscher, B.M., y S. Srinivasan, 1991, "A Comparison of Order Estimation Procedures for ARMA Models," *Statistica Sinica* **4**: 29–50.
28. Raffalovich, L.E., G.D. Deane, D. Armstrong, y H.-S. Tsao, 1980, "Model Selection Procedures in Social Research: Monte-Carlo Simulation Results," *Journal of Applied Statistics* **35**(10): 1094–1114.
29. Rissasen, J., 1978, "Modeling by Shortest Data Description," *Automatica* **14**(5): 465–471.
30. Sargent, T., y C. Sims, 1977, "Business Cycle Modeling Without Pretending to Have too Much a priori Economic Theory," Working Papers 55, Federal Reserve Bank of Minneapolis.
31. Sawa, T., 1978, "Information Criteria for Discriminating Among Alternative Regression Models," *Econometrica* **46**(6): 1273–1282.
32. Sawyer, K.R., 1979, "Model Selection Criteria: Parsimony in the Context of Nested Models," Australian National University, Canberra.

33. Salau, M.O., 2002, "On the Accuracy and Asymptotic Convergence of Widely used Estimators for Autoregressive Models", *Advances in Modeling and Analysis* **2**: 1–18.
34. Schwarz, G.E., 1978, "Estimating the Dimension of a Model," *Annals of Statistics* **6**(2): 461–464.
35. Shibata, R., 1976, "Selection of the Order of and Autoregressive Model by Akaike Information Criterion," *Biometrika* **63**(1): 117–126.
36. Shibata, R., 1980, "Asymptotically Efficient Selection of the Order of the Model for Estimating Parameters of a Linear Process," *Annals of Statistics* **8**(1): 147–164.
37. Shittu, O.I., y M.J. Asemota, 2009, "Comparison of Criteria for Estimating the Order of Autoregressive Process: A Monte Carlo Approach," *European Journal of Scientific Research* **30**(3): 409–416.
38. Sims, C., 1980, "Macroeconomics and Reality," *Econometrica* **48**(1): 1–48.
39. Sin, C.Y., y H. White, 1996, "Information Criteria for Selecting Possibly Misspecified Parametric Models," *Journal of Econometrics* **71**: 207–223.
40. Stock, J., y M. Watson, 2007, *A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series*, en Engle, R.E. y H. White (eds.), *Cointegration, Causality, and Forecasting: A Festschrift in Honour of Clive W.J. Granger*, Oxford University Press.
41. Stone, M., 1979, "Comments on Model Selection Criteria of Akaike and Schwarz," *Journal of the Royal Statistical Society –Series B (Methodological)* **41**(2): 276–278.
42. Yi, G., y G. Judge, 1988, "Statistical Model Selection Criteria," *Economic Letters* **28**(1): 47–51.

Apéndice

Estadísticos típicos de las series

Tabla 1A: Estadísticos típicos de las series de demanda, muestra completa

	Media (Desviación estándar)					Máximo (Mínimo)				
	<i>d1</i>	<i>d2</i>	<i>d3</i>	<i>d4</i>	%	<i>d1</i>	<i>d2</i>	<i>d3</i>	<i>d4</i>	%
<i>ch</i>	0.014 (0.054)	0.000 (0.100)	0.001 (0.194)	-0.003 (0.381)	0.058 (0.029)	0.135 (-0.084)	0.172 (-0.203)	0.331 (-0.358)	0.670 (-0.634)	0.157 (-0.018)
<i>cp</i>	0.033 (0.152)	-0.006 (0.247)	0.003 (0.449)	-0.021 (0.845)	0.139 (0.209)	0.582 (-0.341)	0.637 (-0.695)	1.019 (-1.002)	1.267 (-1.909)	0.769 (-0.361)
<i>meq</i>	0.031 (0.114)	-0.002 (0.175)	-0.005 (0.313)	-0.009 (0.584)	0.147 (0.207)	0.310 (-0.384)	0.382 (-0.423)	0.714 (-0.746)	1.215 (-1.199)	0.645 (-0.319)
<i>coo</i>	0.014 (0.080)	0.000 (0.120)	-0.002 (0.199)	-0.005 (0.349)	0.062 (0.096)	0.203 (-0.176)	0.263 (-0.235)	0.342 (-0.438)	0.702 (-0.617)	0.327 (-0.218)
<i>g</i>	0.011 (0.117)	-0.001 (0.197)	-0.001 (0.350)	-0.007 (0.652)	0.041 (0.023)	0.199 (-0.182)	0.357 (-0.184)	0.517 (-0.536)	0.663 (-1.046)	0.086 (-0.039)
<i>xb</i>	0.017 (0.102)	-0.002 (0.154)	0.004 (0.241)	-0.004 (0.392)	0.073 (0.071)	0.235 (-0.213)	0.364 (-0.363)	0.639 (-0.613)	1.076 (-0.981)	0.246 (-0.065)
<i>xs</i>	0.016 (0.383)	0.014 (0.580)	-0.011 (0.954)	0.003 (1.686)	0.130 (0.291)	1.290 (-1.236)	2.287 (-2.242)	2.643 (-3.177)	5.206 (-5.270)	1.693 (-0.462)
(<i>mb</i>)	0.031 (0.074)	-0.001 (0.100)	-0.001 (0.164)	-0.003 (0.285)	0.128 (0.136)	0.195 (-0.260)	0.300 (-0.215)	0.465 (-0.287)	0.658 (-0.743)	0.413 (-0.224)
(<i>ms</i>)	0.020 (0.112)	-0.003 (0.176)	0.004 (0.302)	-0.004 (0.551)	0.077 (0.101)	0.380 (-0.226)	0.541 (-0.400)	0.762 (-0.941)	1.480 (-1.703)	0.473 (-0.279)
<i>c</i>	0.016 (0.058)	0.000 (0.109)	0.000 (0.210)	-0.004 (0.412)	0.063 (0.039)	0.138 (-0.093)	0.173 (-0.208)	0.344 (-0.369)	0.699 (-0.652)	0.181 (-0.051)
<i>i</i>	0.022 (0.071)	-0.001 (0.109)	-0.003 (0.198)	-0.007 (0.372)	0.098 (0.132)	0.219 (-0.235)	0.268 (-0.297)	0.485 (-0.553)	0.730 (-0.913)	0.368 (-0.256)
<i>x</i>	0.017 (0.099)	0.001 (0.146)	0.001 (0.227)	-0.002 (0.368)	0.077 (0.069)	0.261 (-0.203)	0.286 (-0.376)	0.552 (-0.533)	1.013 (-0.654)	0.271 (-0.072)
(<i>m</i>)	0.029 (0.069)	-0.002 (0.095)	0.001 (0.158)	-0.004 (0.281)	0.116 (0.118)	0.233 (-0.219)	0.255 (-0.188)	0.388 (-0.414)	0.549 (-0.802)	0.349 (-0.192)
<i>di</i>	0.018 (0.056)	-0.002 (0.098)	0.000 (0.185)	-0.005 (0.359)	0.069 (0.067)	0.159 (-0.118)	0.204 (-0.220)	0.357 (-0.418)	0.707 (-0.716)	0.212 (-0.100)
<i>de</i>	0.015 (0.064)	-0.001 (0.122)	0.000 (0.240)	-0.005 (0.474)	0.059 (0.033)	0.117 (-0.099)	0.193 (-0.199)	0.370 (-0.346)	0.704 (-0.685)	0.157 (-0.039)
<i>pib</i>	0.013 (0.040)	-0.001 (0.069)	0.000 (0.126)	-0.005 (0.238)	0.054 (0.037)	0.094 (-0.082)	0.164 (-0.127)	0.272 (-0.210)	0.396 (-0.482)	0.163 (-0.045)

Fuente: Elaboración propia.

Tabla 1B: Estadísticos típicos de las series de actividad, muestra completa

	Media (Desviación estándar)					Máximo (Mínimo)				
	<i>d1</i>	<i>d2</i>	<i>d3</i>	<i>d4</i>	%	<i>d1</i>	<i>d2</i>	<i>d3</i>	<i>d4</i>	%
<i>ega</i>	0.011 (0.070)	-0.001 (0.090)	0.002 (0.143)	-0.001 (0.247)	0.047 (0.141)	0.203 (-0.219)	0.246 (-0.215)	0.333 (-0.295)	0.564 (-0.618)	0.483 (-0.387)
<i>min</i>	0.010 (0.069)	0.000 (0.117)	-0.001 (0.215)	-0.004 (0.408)	0.043 (0.064)	0.155 (-0.144)	0.204 (-0.298)	0.468 (-0.433)	0.826 (-0.691)	0.181 (-0.086)
<i>pes</i>	0.010 (0.283)	-0.008 (0.434)	0.002 (0.707)	-0.011 (1.215)	0.065 (0.141)	0.661 (-0.524)	0.967 (-0.869)	1.567 (-1.724)	2.750 (-3.048)	0.458 (-0.374)
<i>agr</i>	0.002 (0.516)	-0.007 (0.729)	-0.003 (1.041)	-0.009 (1.509)	0.052 (0.048)	0.903 (-0.892)	1.070 (-1.076)	1.915 (-1.948)	2.511 (-2.307)	0.177 (-0.097)
<i>ind</i>	0.010 (0.041)	-0.001 (0.066)	0.001 (0.118)	-0.003 (0.221)	0.039 (0.051)	0.116 (-0.130)	0.163 (-0.197)	0.356 (-0.282)	0.591 (-0.565)	0.187 (-0.122)
<i>com</i>	0.016 (0.083)	-0.001 (0.136)	0.001 (0.241)	-0.005 (0.445)	0.067 (0.060)	0.204 (-0.108)	0.293 (-0.232)	0.460 (-0.525)	0.811 (-0.985)	0.236 (-0.092)
<i>con</i>	0.013 (0.074)	0.000 (0.113)	-0.002 (0.190)	-0.005 (0.337)	0.056 (0.085)	0.178 (-0.149)	0.210 (-0.245)	0.347 (-0.456)	0.736 (-0.620)	0.304 (-0.190)
<i>tra</i>	0.020 (0.033)	0.000 (0.055)	0.000 (0.101)	-0.003 (0.190)	0.080 (0.044)	0.091 (-0.082)	0.165 (-0.130)	0.296 (-0.217)	0.460 (-0.512)	0.212 (-0.030)
<i>fin</i>	0.016 (0.044)	-0.001 (0.073)	0.001 (0.132)	-0.004 (0.248)	0.065 (0.045)	0.129 (-0.093)	0.136 (-0.197)	0.321 (-0.307)	0.628 (-0.480)	0.170 (-0.043)
<i>per</i>	0.012 (0.216)	-0.003 (0.370)	0.001 (0.673)	-0.013 (1.274)	0.036 (0.015)	0.357 (-0.361)	0.706 (-0.396)	1.102 (-1.036)	1.534 (-2.137)	0.071 (-0.017)
<i>pro</i>	0.006 (0.003)	0.000 (0.003)	0.000 (0.004)	0.000 (0.005)	0.026 (0.009)	0.012 (-0.013)	0.025 (-0.021)	0.026 (-0.022)	0.041 (-0.022)	0.040 (-0.006)
<i>pub</i>	0.004 (0.006)	0.000 (0.009)	0.002 (0.016)	0.000 (0.028)	0.018 (0.013)	0.019 (-0.026)	0.026 (-0.041)	0.067 (-0.068)	0.135 (0.105)	0.040 (-0.022)
<i>(ib)</i>	0.016 (0.041)	0.000 (0.058)	0.000 (0.088)	-0.001 (0.136)	0.065 (0.049)	0.107 (-0.096)	0.173 (-0.116)	0.289 (-0.193)	0.340 (-0.458)	0.186 (-0.046)
<i>iva</i>	0.012 (0.034)	-0.001 (0.058)	-0.002 (0.108)	-0.004 (0.204)	0.051 (0.034)	0.079 (-0.068)	0.117 (-0.110)	0.215 (-0.171)	0.330 (-0.372)	0.134 (-0.042)
<i>dim</i>	0.033 (0.086)	-0.004 (0.128)	0.000 (0.221)	-0.007 (0.402)	0.140 (0.151)	0.256 (-0.177)	0.318 (-0.360)	0.538 (-0.658)	1.055 (-1.196)	0.448 (-0.201)
<i>pib rn</i>	0.010 (0.053)	-0.001 (0.086)	0.000 (0.153)	-0.001 (0.284)	0.043 (0.056)	0.196 (-0.096)	0.265 (-0.169)	0.341 (-0.428)	0.593 (-0.725)	0.218 (-0.087)
<i>pib resto</i>	0.013 (0.037)	-0.001 (0.064)	0.000 (0.119)	-0.004 (0.228)	0.052 (0.035)	0.080 (-0.070)	0.129 (-0.116)	0.222 (-0.196)	0.340 (-0.419)	0.142 (-0.045)
<i>otros</i>	0.013 (0.034)	-0.001 (0.057)	0.000 (0.105)	-0.004 (0.199)	0.052 (0.034)	0.078 (-0.068)	0.112 (-0.110)	0.204 (-0.167)	0.316 (-0.357)	0.136 (-0.045)
<i>pib</i>	0.013 (0.040)	-0.001 (0.069)	0.000 (0.126)	-0.005 (0.238)	0.054 (0.037)	0.094 (-0.082)	0.164 (-0.127)	0.272 (-0.210)	0.396 (-0.482)	0.163 (-0.045)

Fuente: Elaboración propia.