

# ***Modelos econométricos de predicción macroeconómica en la Argentina\****

George McCandless, Ma. Florencia Gabrielli y Tomás E. Murphy

*Gerencia de Investigaciones Económico-Financieras  
Área de Economía y Finanzas*

*Banco Central de la República Argentina*

Resumen:

*El objetivo de este trabajo es el de evaluar el desempeño de distintos modelos econométricos –ARIMA y VAR- en la generación de predicciones de corto y mediano plazo para algunas variables reales de la economía –el PIB, las Importaciones y la Inversión-. En el caso de los modelos VAR, además de las variables estudiadas, se probó incluir también al MERVAL –como otra variable endógena- de dos formas distintas para intentar mejorar la performance de este tipo de modelos. Se realizaron, entonces, predicciones de uno (one step) y dos (two steps) pasos adelante, que fueron evaluadas utilizando como herramienta de comparación tanto el error absoluto de predicción como la raíz del error cuadrático medio.*

---

\* Se agradece especialmente a Elena Grubisic por los comentarios y el asesoramiento técnico brindado. Las opiniones expresadas en el presente trabajo no necesariamente coinciden con las del BCRA. Todos los errores quedan bajo la responsabilidad de los autores.

## I. Introducción

El objetivo de este trabajo es el de evaluar el desempeño de distintos modelos econométricos en la generación de predicciones de corto y mediano plazo para algunas variables reales de la economía argentina.<sup>1</sup> Por ello, se seleccionaron tres variables macroeconómicas clave (el *Producto Interno Bruto*, las *Importaciones de Bienes y Servicios Reales* y la *Inversión Bruta Real*) y se generaron predicciones de éstas utilizando distintos métodos estadísticos, cuyos resultados fueron comparados. El estudio se encuentra estructurado de este modo: en la primera parte, se describen las características generales de las variables estudiadas; en las dos secciones siguientes, se estiman distintas formulaciones *ARIMA* y *VAR* con el objetivo de determinar los modelos que serán utilizados para generar las predicciones; luego, se comparan los resultados de cada uno y, por último, se elaboran algunas conclusiones.

## II. Las variables

Se puede pensar en al menos dos factores que han limitado la profundización en el estudio de modelos de predicción macroeconómica para la Argentina. El más obvio probablemente sea el de la precariedad de la información, que se manifiesta tanto en una escasa antigüedad y desigual periodicidad de las series como en una generalizada falta de confiabilidad en los datos en sí. El otro factor reside en características particulares de la historia económica argentina: la concurrente inestabilidad monetaria que se extendió hasta fines de la década de 1980 no creaba un ambiente propicio para la elaboración de proyecciones macroeconómicas de un valor significativo. Con la década de 1990, sin embargo, llegaron tanto una relativa estabilidad económica, como diversos esfuerzos –oficiales y privados- para sistematizar la información que brindaron un ambiente propicio para el desarrollo del estudio de modelos de predicción.

En este estudio se encara el análisis de tres variables: el *Producto Interno Bruto* (PIB), las *Importaciones de Bienes y Servicios Reales* (IMPO) y la *Inversión Bruta Interna Fija* (INV\_BRUTA).<sup>2</sup> Éstas han sido seleccionadas no sólo por ser relevantes para comprender el funcionamiento de la macroeconomía argentina, sino también por tener

---

<sup>1</sup> Tradicionalmente, se han utilizado diversos tipos de modelos para generar predicciones macroeconómicas. Aunque muchas veces con grandes diferencias entre uno y otro, la gran mayoría de estos pueden ser clasificados dentro de dos categorías: modelos *estructurales* –aquellos con un fuerte componente de teoría económica en la forma en que son configurados- o modelos *econométricos* –aquellos que intentan explotar las propiedades estadísticas de las variables en cuestión-. El presente artículo trata exclusivamente con modelos que cuadran dentro de esta segunda aproximación. Sin embargo, si se desea tener una breve descripción de las características generales de los modelos estructurales puede consultarse al respecto –por ejemplo- Wallis [1989], Intriligator *et al.* [1996: 430-464] o Webb [1999].

<sup>2</sup> Todas las variables están en términos reales a precios de 1993, expresadas en millones de pesos y tienen una periodicidad trimestral.

–a diferencia de otras variables alternativas- una frecuencia y antigüedad adecuada para los fines de este estudio.<sup>3</sup> Sin embargo, como la calidad y precisión de las predicciones realizadas a partir de los modelos econométricos van a estar íntimamente ligadas con características particulares de las series, es importante llevar a cabo un examen cuidadoso de las mismas.

Aún sin siquiera echar una mirada a los datos es razonable suponer que a principios de la década del '90 se haya dado una alteración en su evolución. Más precisamente, es factible que a partir de la Ley de Convertibilidad –luego del severo proceso hiperinflacionario- se haya producido un quiebre a raíz de los cambios en las políticas que, como bien se sabe, pudo haber provocado cambios en los comportamientos de la gente, por lo que es probable que las formas reducidas también cambien bajo estos supuestos. La información expuesta en el **Gráfico 1**<sup>4</sup> parece atestiguar esta conjetura. Como era de esperar, entonces, a primera vista parece identificarse en las tres variables un claro cambio de tendencia a principios de los años noventa. Tanto el proceso de estabilización monetaria como la nueva apertura de la economía ejercieron influencia directa sobre la trayectoria de la inversión y las importaciones. Los efectos sobre el PIB, aunque más complejos de explicar, parecen también claros.<sup>5</sup> Esta particular evolución de las variables va a tener implicancias en la elaboración de los modelos econométricos. Dada la naturaleza del tipo de modelos con los cuales se está trabajando –que ponen un fuerte énfasis en las propiedades estadísticas de las variables-, va a ser importante tener en cuenta esta especial evolución de las series. Por ello, lo que resta del estudio se va a centrar en el análisis de las series desde 1991:3 hasta el presente, período en el cual, se estima, no se manifiestan cambios estructurales.<sup>6</sup>

Otra característica que es relevante estudiar es la de estacionariedad de las series. Como es sabido, gran parte del análisis de series de tiempo se basa en el estudio de series que tienen la particularidad de ser estacionarias, por lo cual no sólo es necesario determinar si las variables con las cuales se trabaja presentan esta característica, sino que –en caso contrario- se debe procesarlas para así obtener una serie que

---


<sup>3</sup> Muchas series, como las financieras, se comenzaron a recolectar ya entrados los años '90, por lo cual son pocas, en realidad, aquellas que poseen una antigüedad aceptable para un estudio de este tipo.

<sup>4</sup> Existe una serie de cuentas nacionales calculadas por el gobierno nacional que comienza en 1993 y que está expresada a precios de 1993. También existe una serie calculada a precios de 1986, pero que empieza en 1980. Lo que se hizo fue tomar las variaciones interanuales de las variables entre 1980 y 1992 en la segunda serie y aplicar las mismas a la serie que comienza en 1993, de esta manera se obtuvieron los valores para atrás.

<sup>5</sup> Existen varios trabajos que han profundizado en el estudio de la evolución del PIB luego de la reforma de principios de 1990. Véase, por ejemplo, Frenkel y González Rozada [1999].

<sup>6</sup> A modo de formalizar esto, en la próxima sección se evalúa la presencia de cambio estructural en los coeficientes (utilizando el *Test de Chow*) para los distintos modelos seleccionados en el período que atañe a esta preocupación.

**Gráfico 1:** PIB, Importaciones e Inversión Bruta en la Argentina (1980:1-2000:4)



Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

efectivamente tenga esa cualidad. Para determinar esto, entonces, se procedió a calcular el estadístico de *Dickey-Fuller Aumentado* (ADF), que permite identificar la presencia de raíces unitarias –es decir, que provocan que la serie sea del tipo *random walk*.<sup>7</sup> Los resultados están expuestos en la siguiente tabla.

**Tabla 1: Resultados del ADF test al 1%**

Serie	ADF	Valor Crítico	H <sub>0</sub> : Serie no estacionaria	
			Rechazo H <sub>0</sub>	No rechazo H <sub>0</sub>
PIB	Nivel	-1.64		X
	Log	-1.73		X
	Dif. Log	-5.36	X	
Inversión	Nivel	-2.45		X
	Log	-2.62		X
	Dif. Log	-5.08	X	
Importaciones	Nivel	-1.74		X
	Log	-2.25		X
	Dif. Log	-4.22	X	

Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

Como se puede apreciar, en todos los casos de los niveles y logaritmos de las variables no se puede rechazar la hipótesis nula de que la serie es no estacionaria. Al tomar las primeras diferencias,<sup>8</sup> sin embargo, para las nuevas series sí se puede rechazar la H<sub>0</sub>, lo cual indica que éstas son efectivamente estacionarias.<sup>9</sup>

<sup>7</sup> En términos formales se tiene que  $y_t = \rho y_{t-1} + u_t$ , donde  $u_t$  es ruido blanco. Luego,  $H_0 : \rho = 1$  (problema de raíces unitarias, serie no estacionaria) y  $ADF = \rho / SE(\rho)$ . En el caso de este estadístico, la H<sub>0</sub> plantea el caso de no estacionariedad. Por lo tanto, si en valor absoluto el valor crítico es mayor al valor del módulo del estadístico la regla de decisión dice que no se rechaza la H<sub>0</sub> y, por lo tanto, la serie en cuestión resulta no estacionaria. Si ocurre lo contrario (rechazo de H<sub>0</sub>), sin embargo, hay dos opciones posibles: la primera es que la serie sea estacionaria o integrada de orden cero [I(0)] que se da si el estadístico ADF tiene signo negativo, la segunda opción surge cuando el ADF es positivo indicando que la serie en cuestión es no estacionaria, integrada de orden  $d > 1$  o de orden superior a uno.

<sup>8</sup> Se decidió utilizar las primeras diferencias de los logaritmos –y no de los niveles- básicamente para evitar problemas de escala.

<sup>9</sup> Cuando se concluye que la serie es no estacionaria, lo que se hace es obtener la primera diferencia de la misma y testear nuevamente la estacionariedad. Si ahora se obtiene una serie estacionaria, entonces se dice que la serie original es integrada de orden uno [I(1)], de no ser así se vuelve a diferenciar nuevamente y si ahora recién se obtiene una serie estacionaria entonces la serie original es integrada de orden dos [I(2)] y así sucesivamente.

### III. Modelos ARIMA

Aunque esencialmente simples en su formulación, los modelos ARIMA han ganado desde los 70's un papel fundamental en la literatura sobre predicción. Originalmente introducida a través de los trabajos pioneros de Box y Jenkins, esta generalización de los modelos autorregresivos y de promedios móviles (ARMA) probó ser bastante efectiva a pesar de su sencilla computación y se instauró de este modo como una alternativa relevante a los modelos estructurales, por entonces muy extendidos en la práctica de predicciones. La forma tradicional de generar y aplicar modelos ARIMA es utilizando la metodología elaborada por Box y Jenkins. Si bien existen distintas variantes de cómo ésta se aplica, la forma más general es la que divide el proceso en cuatro pasos<sup>10</sup>: *identificación*, *estimación* del modelo,<sup>11</sup> *diagnóstico*<sup>12</sup> y la posterior *predicción*. En esta sección, entonces, se seguirá esa estructura para generar las predicciones de las variables en estudio.

#### ***Determinación y estimación de los modelos***

La lógica básica de estos modelos reside en intentar identificar<sup>13</sup> qué tipo de proceso estocástico genera la serie de tiempo en cuestión sin recurrir a variables explicativas externas. Se parte, entonces, de una formulación general: un modelo ARMA ( $p, q$ ) donde figuran tanto los rezagos de la variable estacionaria en cuestión ( $y_{t-i}$ , el componente autorregresivo) como de sus errores estocásticos ( $\varepsilon_{t-j}$ , el componente de promedios móviles):

$$y_t = c + \Phi_1 y_{t-1} + \Phi_2 y_{t-2} + \dots + \Phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Tomando como marco de referencia esta estructura,<sup>14</sup> se investigan las características de una determinada serie intentando definir el proceso que la pudo haber gene-

---

<sup>10</sup> Véase, por ejemplo, Gujarati [1995, Cáp. 22].

<sup>11</sup> Esta estimación se suele hacer utilizando *mínimos cuadrados ordinarios*, aunque puede darse el caso de que se deba recurrir a métodos de máxima verosimilitud. En el presente trabajo se muestran los resultados de aplicar los dos métodos.

<sup>12</sup> En este sentido, la metodología de Box-Jenkins requiere del criterio del analista al momento de la elección del modelo: se debe ver si el modelo elegido ajusta los datos *razonablemente* bien y, en caso contrario, buscar otro modelo. Es decir, al mismo tiempo es un proceso iterativo y subjetivo. Un test posible para objetivar la decisión es ver si los residuos estimados con el modelo son ruido blanco; si así fuera, se puede aceptar el ajuste particular al que se ha arribado, de lo contrario debe comenzar nuevamente el proceso.

<sup>13</sup> Si bien este es el nombre que le dan Box y Jenkins a la determinación de los valores  $p, d$  y  $q$ , de aquí en más se evitará utilizar esta palabra para describirlo ya que el término "identificación" tiene un significado muy distinto para los econométricos.

rado; es decir, se buscan los valores  $p$  y  $q$  de modo tal que –con la menor cantidad de parámetros posible– se pueda explicar las series estudiadas sin un elevado sacrificio en términos estadísticos. Sin embargo, dado que esta metodología requiere que la serie en cuestión sea estacionaria, normalmente es necesario diferenciarla  $d$  veces hasta obtener una serie integrada de orden 0. Ya en la sección previa se muestra que las tres series en estudio son integradas de orden 1, por lo cual se sabe que  $d=1$ . En lo que resta del análisis, entonces, se van a utilizar las series a las cuales se les aplicó los logaritmos y las diferencias (*DLPIB*, *DLIMPO* y *DLINV\_BRUTA*).

Para la determinación de los valores de  $p$  y  $q$  normalmente se comienza analizando las funciones de *autocorrelación* (ACF) y de *autocorrelación parcial* (PACF). Dado que los diferentes procesos estocásticos ARMA ( $p, q$ ) exhiben patrones típicos de ACF y PACF teóricas, si la serie bajo análisis sigue alguno de estos patrones satisfactoriamente puede suponerse que ésta está generada por éste. La Tabla 2 resume estos criterios.

**Tabla 2: Criterios para determinar el valor de los parámetros para un ARMA ( $p, q$ )**

Modelo	Patrón típico ACF	Patrón típico PACF
$AR(p)$	Cae exponencialmente o de forma sinusoidal convergente, o ambas.	Picos significativos hasta el rezago $p$ .
$MA(q)$	Picos significativos hasta el rezago $q$ .	Cae exponencialmente.
$ARMA(p,q)$	Cae exponencialmente.	Cae exponencialmente.

Fuente: Gujarati [1995: 742].

Para el caso de las series en cuestión, el **Gráfico 2** muestra los correlogramas muestrales correspondientes.<sup>15</sup> Se puede hacer, entonces, una serie de observaciones sobre las características de los patrones en referencia a los parámetros expuestos en la

<sup>14</sup> Los procesos con esta estructura que sean invertibles, en realidad, son equivalentes a procesos que incluyen un número infinito de observaciones. Dicho de otra forma, éste se podría representar como un MA ( $\equiv$ ) o, alternativamente, como un AR ( $\equiv$ ). Para mayor detalle, ver Leiva [1995: 105-107].



<sup>15</sup> Es importante destacar que en la práctica lo que uno observa son las funciones de autocorrelación y autocorrelación parcial *muestrales* y que los patrones descritos son los que corresponden a las funciones teóricas e ideales, por lo que las funciones estimadas no reflejarán en general el patrón exactamente, sino de manera aproximada. Lo que se está buscando es que las funciones muestrales reflejen con cierta precisión los patrones teóricos para estar de alguna manera seguros de que se está yendo en la dirección correcta en la construcción de los modelos ARIMA. Es por esto que modelar este tipo de procesos requiere de una gran habilidad de parte del econométrista.

**Gráfico 2:** *Correlogramas de las series diferenciadas de los logaritmos del PIB, las Importaciones y la Inversión Bruta*



**Funciones de Autocorrelación**

**Funciones de Autocorrelación Parcial**



**PIB**



**Importaciones**



**Inversión Bruta**



**Fuente:** *Elaboración propia en base a información del Ministerio de Economía.*

Tabla 2. Con respecto a las PACF, sí parece identificarse –aunque con distinta intensidad- algunos picos. Es más, como en casi todos los casos el último pico importante se encuentra en el cuarto rezago, se podría llegar a concluir que debe incluirse en los modelos un componente AR(4). En cuanto a las ACF, el patrón es mucho menos claro, con lo cual surgen ciertas dudas con respecto al componente MA. Como último punto, tal vez valga la pena señalar que en el caso de las importaciones los patrones son especialmente débiles, con lo cual es posible que se encuentren mayores dificultades en la determinación del modelo. Utilizando estos grandes lineamientos, se elaboraron estimaciones con distintas especificaciones que luego fueron evaluadas de acuerdo a su bondad de ajuste. Los resultados se pueden observar en la Tabla 3.

**Tabla 3: Selección de modelos ARIMA**

	Modelo	Observaciones
<b>PIB</b>	1. AR(1) MA(4)	R <sup>2</sup> más bajo que en los otros modelos.
	2. AR(1) AR(4)	El coeficiente del AR(1) no es significativo (al 94%).
	3. AR(1) AR(3) AR(4)	Un solo coeficiente resulta ser estadísticamente distinto de cero (AR(4)).
	4. MA(1) AR(4)	<b>ELEGIDO</b>
	5. AR(1) AR(4) MA(2)	El coeficiente del AR(1) no es significativo.
<b>Importaciones</b>	1. AR(1) AR(4)	El coeficiente del AR(1) no es significativo y el R <sup>2</sup> es bajo.
	2. AR(1) MA(3) MA(5) MA(7)	Un sólo coeficiente resulta ser estadísticamente distinto de cero (AR(1)) y el R <sup>2</sup> es bajo.
	3. AR(1) AR(5) MA(4)	Un sólo coeficiente resulta ser estadísticamente significativo (MA(4)).
	4. AR(4) MA(4)	Ninguno de los coeficientes resultó estadísticamente distinto de cero.
	5. AR(4) MA(1) MA(3) MA(5) MA(7)	<b>ELEGIDO</b>
<b>Inversión</b>	1. AR(1) AR(4)	El coeficiente del AR(1) es no significativo.
	2. AR(4) MA(1)	<b>ELEGIDO</b>
	3. AR(1) MA (4)	R <sup>2</sup> bajo y el coeficiente del AR(1) es no significativo.
	4. MA(1) MA(4)	R <sup>2</sup> bajo y el coeficiente del AR(1) es no significativo.
	5. AR(3) MA(4)	R <sup>2</sup> bajo.

Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

Como se puede apreciar, se utilizaron diferentes criterios en cada caso para determinar la superioridad de una estimación con respecto a otra. En el caso de DLPIB, por ejemplo, el modelo *AR(4) MA(1)* resultó ser parsimonioso, poseía coeficientes significativos a niveles convencionales, el  $R^2$  era relativamente alto (0.83) y, según el estadístico Q, los residuos parecían comportarse como ruido blanco. De modo equivalente, se seleccionaron los modelos para las otras variables, cuyas características generales se encuentran expuestas en la Tabla 4.

**Tabla 4: Modelos ARIMA elegidos<sup>16</sup>**

Variable	DLPIB	DLIMPO	DLIN_BRUTA
<i>AR(4)</i>	<b>0.9279752196</b> (16.49830)	<b>0.290470308</b> (2.73281)	<b>0.8800241012</b> (9.02881)
<i>MA(1)</i>	<b>0.3631660607</b> (2.12641)	<b>0.544968808</b> (3.86781)	<b>0.4895362844</b> (2.90039)
<i>MA(3)</i>		<b>-0.399786481</b> (-2.56840)	
<i>MA(5)</i>		<b>-0.403332573</b> (-2.93430)	
<i>MA(7)</i>		<b>-0.315433076</b> (-1.92471)	
$R^2$	0.827569	0.432135	0.614825
$R^2$ Ajustado	0.822006	0.351011	0.602400
Suma de residuos al cuadrado	0.016676	0.101199	0.119396
Q (8-2)*	7.007960	1.940043	5.984110
Nivel de signif. de Q	0.320112	0.584944	0.424972
Media de la var. dep.	0.006041	0.015827	0.005468
Error estándar de la var. dep.	0.054975	0.074626	0.098422
Estadístico de Durbin-Watson	1.761379	1.944807	1.798531
Iteraciones nec. para converg.	12	38	10

\* NOTA: Para DLIMPO es Q (8-5).

**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía, utilizando RATS 4.2. El método utilizado es el de Máxima verosimilitud, la muestra ajustada corresponde al período 1992:4 2000:4 y toma en cuenta 33 observaciones en cada caso (valores “t” entre paréntesis).*

<sup>16</sup> Vale la pena mencionar que aquí se ha utilizado el método de estimación de *máxima verosimilitud* (MV), ya que éste posee ciertas ventajas estadísticas –con respecto al tradicional método de *mínimos cuadrados* (MC)- cuando se trabaja con muestras pequeñas. En teoría, ambas técnicas convergen en el límite, haciendo indiferente la preferencia de una con respecto a la otra. Sin embargo, en casos como el que se analiza en este trabajo los resultados pueden ser distintos. Particularmente, en el caso de las importaciones los resultados fueron significativamente distintos, lo que dificulta su interpretación. A título ilustrativo, entonces, se incluye al final del artículo un Apéndice donde se detallan las estimaciones realizadas con MC.

En relación con lo que se había mencionado antes, efectivamente los modelos que se adecuan mejor al comportamiento de las series incluyen un componente AR(4).<sup>17</sup> Es interesante que, en general, el modelo ARMA(4,1) –o, para ser más precisos, el modelo ARIMA(4,1,1)– permite percibir buena parte del comportamiento de todas las series. Sin embargo, y como también fue señalado antes, en el caso de las importaciones se dan algunos inconvenientes, por lo cual se incorporaron otros componentes MA que lograron mejorar el desempeño del modelo. En definitiva, los modelos que van a ser utilizados para generar las predicciones son los siguientes:

$$\begin{cases} \text{DLPIB}_t = (0.93) \text{DLPIB}_{t-4} + (0.36) e_{t-1} + e_t \\ \text{DLIMPO}_t = (0.29) \text{DLIMPO}_{t-4} + (0.54) e_{t-1} + e_t + (-0.39) e_{t-3} + (-0.40) e_{t-5} + (-0.31) e_{t-7} + e_t \\ \text{DLINV_BRUTA}_t = (0.88) \text{DLINV_BRUTA}_{t-4} + (0.49) e_{t-1} + e_t \end{cases}$$

donde, en todos los casos,  $e_t$  son los residuos estimados.

### ***Diagnóstico de los modelos***


Antes de generar las predicciones, sin embargo, es relevante llevar a cabo un diagnóstico general de los modelos obtenidos. Para ello, en primer lugar se evaluó la significatividad individual de los residuos utilizando sus correlogramas. Como se puede ver en el **Gráfico 3**, prácticamente en todos los casos los residuos caen dentro de las bandas –las dos excepciones se dan en el 4° rezago de la ecuación del PIB y de la INV\_BRUTA –, por lo cual se puede asumir que estos valores son individualmente estadísticamente significativos. Para verificar, por otro lado, la existencia de autocorrelación en los residuos de orden mayor a uno, se utiliza el estadístico Q de Box-Pierce,<sup>18</sup> que plantea en su  $H_0$  que todos los coeficientes de autocorrelación son simultáneamente iguales a cero. En la Tabla 4 ya se reportaban tanto este estadístico como su respectivo nivel de significatividad para cada serie. Ahí se ve que en ninguno de los casos hay evidencia suficiente para rechazar la  $H_0$ , por lo que se puede considerar que no hay autocorrelación de orden superior a uno a niveles de confianza convencionales. Sin embargo, como se está trabajando con una cantidad muy restringida de datos, probablemente sea más conveniente probar el estadístico Ljung-Box (LB), que es una variante del estadístico Q con mejores (más poderosas en sentido estadístico) propiedades para muestras pequeñas. Como se puede ver en la Tabla 5, los resultados provistos por este estadístico corroboran aquellos obtenidos con el Q.

<sup>17</sup> Esto es razonable, ya que este componente permite incorporar en el modelo parte del factor estacional que es relevante en series con características cíclicas como las que se están estudiando aquí.


<sup>18</sup> Q que se distribuye asintóticamente como una  $\chi^2_{(m)}$ , donde m es el número de rezagos considerados en la  $H_0$ .

**Gráfico3:** *Correlogramas de los residuos*


**Modelo ARIMA PIB**



**Modelo ARIMA IMPORTACIONES**



**Modelo ARIMA INV BRUTA**



Fuente: *Elaboración propia en base a información del Ministerio de Economía.*

**Tabla 5: Test de Ljung-Box**

Serie	Estadístico $\chi^2_{(24)}$	P-value
<i>D(log PIB)</i>	14.5974	0.8426
<i>D(log IMPO)</i>	14.7596	0.8348
<i>D(log INVERSION)</i>	18.5905	0.6114

Fuente: *Elaboración propia en base a información del Ministerio de Economía.*

La impresión general, entonces, es que los residuos generados por las estimaciones ARIMA son puramente aleatorios. Por último, en el **Gráfico 4** puede verse como, de hecho, los residuos parecen comportarse como ruido blanco.

Ya elaborado el diagnóstico general de las estimaciones, otra cosa que es interesante de evaluar antes de seguir con las predicciones es la presencia de cambio estructural de la que ya se sospechaba en la sección previa. Utilizando las series completas (desde 1980) se aplicó un test de Chow (*breakpoint test*) a los modelos elegidos, bajo la  $H_0$  de estabilidad de los coeficientes en distintos sub-períodos.

**Tabla 6: Test de Chow de cambio estructural**


Fechas	PIB		Importaciones		Inversión	
	AR(4) MA(1)		AR(4) MA(1) MA(3)	MA(5) MA(7)	AR(4) MA(1)	
	F- Stat.	P-Value	F- Stat.	P-Value	F- Stat.	P-Value
1988.4	0.6560	0.5219	3.2291	<b>0.0112</b>	0.1890	0.8281
1989.1	0.5656	0.5705	2.4771	0.0402	0.2943	0.7459
1989.2	0.8499	0.4315	1.4366	0.2222	0.4656	0.6296
1989.3	0.8232	0.4430	1.4334	0.2233	0.2124	0.8091
1989.4	1.1359	0.3266	1.6503	0.1584	-0.4566	n.a.
1990.1	3.0386	0.0538	1.4755	0.2091	2.1709	0.1212
1990.2	1.6852	0.1924	1.3138	0.2684	3.0135	0.0551
1990.3	2.2566	0.1118	0.8806	0.4989	3.0218	0.0547
1990.4	2.5437	0.0853	1.4189	0.2284	4.1988	<b>0.0187</b>
1991.1	2.4298	0.0950	0.6819	0.6386	6.7013	<b>0.0021</b>
1991.2	1.6005	0.2086	0.7301	0.6033	4.3795	<b>0.0159</b>
1991.3	1.7270	0.1848	0.6437	0.6672	3.8072	0.0266
1991.4	1.6004	0.2086	0.3700	0.8675	3.4725	0.0361

Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*


En la Tabla 6 figuran los resultados del test para cada trimestre en un período de tres años dentro de los cuales se esperaba que el cambio estructural se manifestara. Los valores que figuran en negrita son los *p-values* que no rechazan la  $H_0$  al 2%.

**Gráfico 4:** *Comportamiento de los residuos*


**Residuos Modelo ARIMA PIB**



**Residuos Modelo ARIMA IMPO**



**Residuos Modelo ARIMA INV BRUTA**



**Fuente:** *Elaboración propia en base a información del Ministerio de Economía.*

Como se puede apreciar, para el caso del PIB la mayor probabilidad de que hayan cambios estructurales se encuentra en el primer trimestre de 1990, pero con una probabilidad superior a 5%, mientras que para las demás variables se ve que, en el cuarto trimestre de 1988 para las *importaciones* y desde el cuarto de 1990 hasta el segundo de 1991 para la *inversión*, se puede rechazar la  $H_0$  de ausencia de cambio estructural. Estos resultados corroboran, entonces, la idea que previamente se tenía y respalda un poco la decisión de comenzar el período de análisis recién en el tercer trimestre de 1991 (es decir, la primer fecha desde la cual en ninguna serie se manifiesta la presencia de variaciones estructurales).

### ***Predicción utilizando los modelos ARIMA***

El proceso que se utilizó para generar predicciones comparables, tanto en el caso de los ARIMA como en el de los VAR -que se estudiarán en la próxima sección-, es relativamente simple. Teniendo en cuenta que las series con las que se trabajó cubrían el período 1993:3-2000:4, el ejercicio que se practicó consistió en tomar los datos hasta el trimestre 1998:4 y, utilizando las estructuras determinadas -en este caso- por los ARIMA elegidos, se estimaron los nuevos coeficientes, se obtuvieron las nuevas ecuaciones y, con los datos de esta sub-muestra, se generaron los valores correspondientes al trimestre 1999:1. A partir de aquí se hicieron dos cosas. Por un lado, se repitió este proceso incluyendo cada vez un trimestre adicional, con lo cual se consiguió una serie de predicciones “*one step*” (es decir, predicciones de  $t+1$  utilizando sólo información hasta  $t$ ) para el período 1999:1-2001:1. Por otro lado, en cada momento se realizó -también- una segunda predicción: utilizando la ecuación que generó ya el valor *one step*, e incorporando este valor *one step* al cálculo, se produjo una predicción para el período siguiente. De esta forma, se elaboró también una segunda serie de predicciones, en este caso “*two steps*” (es decir, predicciones de  $t+2$  utilizando sólo información hasta  $t$ ), para el período 1999:2-2001:2.<sup>19</sup> Se dispone así de tres series comparables para cada variable: una real (1999:1-2000:4), una *one step* (1999:1-2000:4) y una *two steps* (1999:2-2000:4).

Aunque la evaluación de los resultados de las predicciones de los ARIMA va a ser tratada en mayor detalle más adelante, cuando se realice la comparación con los resultados de los demás modelos, vale la pena mencionar aquí a grandes rasgos cual fue la *performance* general de estos modelos. En este sentido, los gráficos que van del **Gráfico A1** al **A6** del Anexo pueden ser de gran ayuda. Estos exponen la evolución de las tres series para cada variable, tanto en diferencia de logaritmos como en niveles.<sup>20</sup> A primera vista, queda claro que las predicciones que se obtuvieron para el PIB son muy superiores a las que se obtuvieron para las otras variables. La Tabla 7, donde se exponen los errores absolutos medio de predicción (EAMP),

---

<sup>19</sup> Este último, que permite en este caso generar predicciones con seis meses de antelación, es particularmente útil si se considera la demora habitual con la que se producen los datos trimestrales de las Cuentas Nacionales.

<sup>20</sup> Es claro que, tal cual fueron diseñados los modelos, las predicciones inmediatamente generadas no son de las variables en sí, sino de las diferencias de sus logaritmos.

de los *niveles* para cada ejercicio, deja esto un poco más en claro. También se puede observar que, como era esperable, las estimaciones *two steps* son muy inferiores a las *one step* y, en el caso de la inversión generan en promedio un error del doble de la magnitud.

**Tabla 7: Errores absolutos medios de predicción de los niveles (%)**

Modelo	ONE STEP	TWO STEPS
<i>PIB</i>	2.0 %	2.9 %
<i>IMPO</i>	4.3 %	7.9 %
<i>INV_BRUTA</i>	4.6 %	9.4 %

Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

Estos datos son relevantes de tener en cuenta antes de seguir adelante. En cierta forma, el espíritu de la literatura que estudia la generación de predicciones utilizando modelos econométricos reside en intentar producir especificaciones que, a un bajo costo computacional, obtengan resultados comparables con aquellos de los modelos estructurales. En este sentido, los modelos ARIMA son –al utilizar únicamente datos de la misma variable que se está pronosticando– lo tecnológicamente más simple que se puede construir y representa, de este modo, un *benchmark* particularmente adecuado para evaluar los resultados de otro tipo de especificaciones.

#### IV. Modelos VAR

Como se mencionaba arriba, estos modelos econométricos surgen como una alternativa a los modelos estructurales. El enfoque estructural de modelos de ecuaciones simultáneas utiliza la teoría económica para describir las relaciones entre diferentes variables de interés. Así, se determina un modelo, éste es estimado y posteriormente utilizado para comprobar empíricamente la relevancia de la teoría. Desafortunadamente, la teoría económica en general no es lo suficientemente rica como para proveer una especificación precisa con respecto a la relación dinámica entre variables: algunas son tratadas como endógenas y otras como exógenas o predeterminadas (exógenas y endógenas rezagadas) y antes de estimar, se debe corroborar que las ecuaciones del sistema estén identificadas. Esta identificación, sin embargo, se logra asumiendo que algunas de las variables predeterminadas están presentes solamente en algunas de las ecuaciones. Con respecto a este punto, distintos autores, siguiendo un estudio pionero de Christopher Sims [1980], coinciden en que en la generación de modelos estructurales la determinación de una variable como exógena o endógena es en sí subjetiva y sugieren que si hay una verdadera simultaneidad entre un conjunto de variables, ellas deberían tratarse de la misma manera; es decir, que no debería existir a priori una distinción entre variables endógenas y exógenas.

## La lógica de los modelos VAR

Con ese espíritu surgen los modelos VAR (*Vector Autoregression*) como una alternativa a los modelos estructurales. Estos son comúnmente utilizados tanto para predecir sistemas de series temporales interrelacionadas como para analizar la dinámica generada ante el impacto de un *shock* aleatorio en alguna de las variables del sistema (esto se hace con lo que se da en llamar la *función impulso-respuesta* -IRF-). En esencia, su formulación matemática es relativamente simple:

$$Y_t = A_1 Y_{t-1} + \dots + A_p Y_{t-p} + B_t x_t + e_t$$

donde  $Y_t$  es un vector de  $k$  variables endógenas;  $x_t$  es un vector de  $d$  variables exógenas;  $A_1, \dots, A_p$  y  $B$  son las matrices de coeficientes a ser estimadas; y  $e_t$  es un vector innovación.<sup>21</sup> Dado que del lado derecho de cada ecuación sólo aparecen los rezagos de las variables endógenas, no hay simultaneidad, por lo cual la técnica de MC ordinarios es apropiada para realizar las estimaciones.<sup>22</sup> La elección del orden del VAR, es decir, la cantidad de rezagos con el que cuenta, se realiza frecuentemente de manera arbitraria, con la recomendación general de colocar suficientes rezagos como para asegurarse de que los residuos se comporten como ruido blanco. Sin embargo, si se elige una cantidad excesiva de rezagos, las estimaciones se tornan imprecisas. Es por ello que tradicionalmente se utiliza el denominado *test de razón de verosimilitud* (LR) para encontrar la longitud apropiada.<sup>23</sup> A partir de la estructura así determinada, luego de realizar un diagnóstico general de los modelos estimados, se generan las predicciones de una forma similar a la que se utilizó para los ARIMA.

Resta decir que uno de los principales atractivos de esta metodología reside en su simplicidad. Por un lado, esto la hace más dúctil, abriendo una amplia gama de posibilidades para el analista.<sup>24</sup> Por otro lado, sin embargo, esta simplicidad no viene sin ningún costo: entre otras cosas, distintos autores han criticado especialmente el aspecto a-teórico que propone el método VAR de predicción. Como en todas las

---

<sup>21</sup> Este vector innovación puede estar contemporáneamente correlacionado con cada una de los otros pero no está correlacionado con sus propios rezagos ni tampoco lo está con todas las variables del lado derecho de la ecuación.

<sup>22</sup> Cabe notar que el supuesto de que los disturbios no están serialmente correlacionados no es restrictivo debido a que cualquier correlación serial puede ser eliminada añadiendo más términos rezagos de las  $Y$ .

<sup>23</sup> El estadístico LR para la hipótesis de 2 rezagos contra 4 se computa como:  $LR = -2 (l_2 - l_4)$ , donde  $l_i$  es el logaritmo de la verosimilitud de un modelo que contiene  $i$  rezagos. El test estadístico LR se distribuye asintóticamente como una  $\chi^2$  con grados de libertad igual al número de restricciones que se consideran en el test.

<sup>24</sup> En este sentido, probablemente la más exitosa de las variantes generadas sea la del enfoque “*bayesiano*” sugerido por Litterman [1980].

disciplinas, existen tanto puntos a favor como en contra. La Tabla 8 resume un poco los argumentos generales de esta discusión.

**Tabla 8: Argumentos principales en la discusión sobre las bondades y problemas de la aplicación de VARs en predicciones**

Virtudes	Críticas
<ul style="list-style-type: none"> <li>• El <i>método</i> es simple; no es necesario determinar que variables son endógenas y cuales son predeterminadas.<sup>25</sup></li> <li>• La <i>estimación</i> es simple, el método usual de MC ordinarios se puede aplicar para cada ecuación por separado.</li> <li>• Los <i>pronósticos</i> obtenidos con esta metodología son, en muchos casos, mejores que aquellos que se derivan de modelos más complejos de ecuaciones simultáneas.</li> </ul>	<ul style="list-style-type: none"> <li>• La técnica del VAR <i>carece</i> de un marco teórico en el sentido de que utiliza menos información a priori sobre la relación entre las variables.</li> <li>• Al no estar especialmente diseñados para el <i>análisis de política</i>, su aplicabilidad práctica es relativamente limitada.</li> <li>• Como se incluye normalmente muchas variables y sus rezagos, a menos que el tamaño de la muestra sea grande, el costo en términos de <i>grados de libertad</i> suele ser grande.</li> <li>• Estrictamente, todas las variables endógenas deberían ser <i>conjuntamente estacionarias</i>, cosa que no siempre es posible.<sup>26</sup></li> <li>• Dado que los coeficientes del VAR son difíciles de interpretar, los que practican esta técnica usualmente estiman la <i>IRF</i>. Esta herramienta, sin embargo, ha sido cuestionada, con diversos argumentos teóricos, por varios autores.</li> </ul>

Fuente: Gujarati [1995:749-750].

### ***Estimación de los modelos***

Habiendo dado ya una idea sobre las características generales de los modelos VAR, en esta parte se los pone en práctica realizando tres ejercicios distintos. En primer lugar, y siguiendo la metodología tradicional, se elaboró un modelo en el que se incluía sólo las variables que se querían pronosticar, es decir, el PIB, las importaciones y la inversión bruta. En segundo lugar, y siguiendo los resultados obtenidos por Zellner y Hong [1989] al incluir “*leading indicators*” en el sistema (con el objetivo de incorporar el factor de las expectativas del mercado), se decidió incorporar en

<sup>25</sup> A pesar de que en los modelos VAR todas las variables con consideradas endógenas, existe la posibilidad de incluir ciertas variables en forma “exógenas” para permitir percibir factores estacionales y de tendencia.

<sup>26</sup> Si este no fuera el caso, se debería transformar la información apropiadamente. Como mencionara Harvey [1990: 83], los resultados obtenidos de datos transformados pueden ser insatisfactorios.

un modelo una cuarta variable: el Merval.<sup>27</sup> Es más, teniendo en cuenta este último factor y el hecho de que normalmente se tiene datos inmediatos del Merval mientras se tiene una demora en los otros, a modo ilustrativo –para comparar los resultados de las predicciones–, se realizó un último ejercicio que utilizó al máximo la información: empleó el dato contemporáneo para predecir los valores presentes y futuros de las variables. En términos algebraicos eso se podría describir de este modo:

$$X_t = f(X_{t-1}, X_{t-4}, M_t, M_{t-1}, M_{t-4})$$

$$M_{t+1} = g(X_{t-1}, X_{t-4}, M_t, M_{t-1}, M_{t-4})$$

donde  $X_t = \{X_t^{PIB}, X_t^{IMPO}, X_t^{INV-BRUTA}\}$ , y M representa al Merval. En todos los casos –es decir el análisis tradicional (VAR), el que incluyen un *leading indicator* (VAR LI) y el que aprovecha la máxima información (VAR MI)– se decidió utilizar no las variables originales, sino las diferencias de sus logaritmos, como se lo había hecho con los ARIMA.<sup>28</sup>

El primer modelo que se estima, entonces, es el VAR tradicional. Para la determinación del orden de éste se tomaron en cuenta varios factores. Por un lado, dado que se disponía de pocos grados de libertad, se consideró que la cantidad de coeficientes a estimar no debía ser grande y que probablemente se podría pensar en incluir tan sólo dos o tres rezagos. Por otro lado, teniendo en cuenta características generales de las series de tiempo, es esperable que tanto el primer rezago (es decir, la información más reciente) como el cuarto (es decir, la observación que percibe el factor estacional) tengan alguna influencia. Por último, razones empíricas pueden llevar a pensar –también– que el segundo rezago es relevante. De este modo, se establecieron tres modelos alternativos: dos modelos con dos rezagos– VAR(1,2) y VAR(1,4)– y uno con tres –VAR(1,2,4). Con el propósito de objetivar la decisión de la cantidad de rezagos a incluir, se procedió a aplicar el *test LR* comparando cada modelo con dos rezagos con el que presenta tres, y se llegó a la conclusión de que la mejor estructura estimada es la VAR\*(1,4).<sup>29</sup> La Tabla 9 muestra los resultados de esta estimación.

<sup>27</sup> Varios autores junto a Zellner y Hong han señalado que la inclusión de *leading indicators* puede ayudar significativamente en la obtención de mejores predicciones de las variables reales. La idea intuitiva atrás de esta decisión reside en que dado que estas variables “miran hacia adelante” (es decir, que utilizan a las expectativas en su mecanismo generador), en un mundo de expectativas racionales esto implica que agregan información relevante al sistema, si los mercados son eficientes.

<sup>28</sup> Con respecto a este punto, existen opiniones encontradas en la literatura. Si bien autores como Doan o Litterman consideran que la técnica se puede aplicar libremente a cualquier tipo de serie, sin importar si son integradas o no, otros como Hamilton sugieren que la posibilidad de que la series estén cointegradas podría afectar el modelo, por lo cual postulan que se debe o bien usar series estacionarias o modificar el modelo de alguna manera (elaborando lo que se conoce como Vector Error Correction). Teniendo en cuenta el costo en términos de grados de libertad que implica perder observaciones al hacer diferencia, en este trabajo se decidió, sin embargo, seguir la postura de Hamilton utilizando series estacionarias.

**Tabla 9: VAR con variables reales – VAR\*(1,4)-**

Variable	DLPIB	DLIMPO	DLINV_BRUTA
DLPIB(-1)	<b>0.241920920</b> (1.22595)	<b>1.266641952</b> (2.50791)	<b>0.996119776</b> (1.99437)
DLPIB(-4)	<b>0.713605612</b> (2.35628)	<b>0.006224049</b> (0.00803)	<b>0.521083886</b> (0.67978)
DLIMPO(-1)	<b>0.120363439</b> (1.17515)	<b>0.212388435</b> (0.81019)	<b>0.280234938</b> (1.08097)
DLIMPO(-4)	<b>-0.187262420</b> (-3.04622)	<b>-0.017261945</b> (-0.10971)	<b>-0.475953098</b> (-3.05892)
DLINV_BRUTA(-1)	<b>-0.087144507</b> (-0.55718)	<b>-0.148835750</b> (-0.37181)	<b>-0.092648705</b> (-0.23404)
DLINV_BRUTA(-4)	<b>0.097007391</b> (0.70084)	<b>0.041341768</b> (0.11670)	<b>0.652991028</b> (1.86386)
R <sup>2</sup>	0.866061	0.523859	0.732289
R <sup>2</sup> Ajustado	0.841258	0.435685	0.682713
Media de la var. dep.	0.006041	0.015827	0.005468
Error estándar de la var. dep.	0.054975	0.074626	0.098422
Error estándar de la estimación	0.021903	0.056060	0.055439
Suma de residuos al cuadrado	0.012953	0.084853	0.082984
Estadístico de Durbin-Watson	1.595052	1.627878	1.698878
Estadístico F	34.91689	5.941189	14.77104

**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía, utilizando RATS 4.2. El método utilizado es Mínimos Cuadrados, la muestra ajustada corresponde al período 1992:4 2000:4 y toma en cuenta 33 observaciones. Estadísticos t entre paréntesis.*

En forma similar, se determinó la configuración óptima del segundo modelo, el VAR LI. Como ya se mencionara arriba, en este caso se incluyó la variable MERVAL -expresada en diferencia de logaritmos para mantener la consistencia del sistema- y se evaluaron los resultados de las estimaciones utilizando las mismas estructuras pre-establecidas para el primer ejercicio. Aquí el modelo elegido tuvo el mismo aspecto que el anterior: VAR LI\*(1,4).<sup>30</sup> La Tabla 10 detalla las características de esta estimación.

<sup>29</sup> En una primera instancia se comparó el VAR(1,2) con el VAR(1,2,4), poniendo bajo la H<sub>0</sub> al VAR(1,2). El estadístico arrojó un valor de 15.48, cayendo en la zona de rechazo de H<sub>0</sub> (el valor crítico al 95% era de 16.9); sin embargo, con un nivel de confianza del 90% se rechaza H<sub>0</sub> y así parece ser preferible una estructura con tres rezagos para captar la dinámica del modelo, vale decir el denotado por VAR(1,2,4). Si se compara esta última estructura con la VAR(1,4), donde bajo H<sub>0</sub> se contempla al modelo de dos rezagos, aquí el estadístico correspondiente arroja un nivel de 3.31 por lo que H<sub>0</sub> no se puede rechazar ni al 90% ni al 95%. Luego en este caso la conclusión que se extrae es que una estructura de tres rezagos no es preferible a la de dos.

<sup>30</sup> En este caso los valores críticos al 90% y 95% son 23.5 y 26.3 respectivamente. El estadístico que resulta de comparar el VAR(1,4) y el VAR(1,2,4) arrojó un valor de 1.44 no rechazando la H<sub>0</sub> a

**Tabla 10: VAR con variables reales y MERVAL – VAR LI\*(1,4)-**

Variable	DLPIB	DLIMPO	DLINV_BRUTA	DLMERVAL
DLPIB (-1)	<b>0.238681692</b> (1.38925)	<b>1.252427457</b> (3.41029)	<b>0.987330896</b> (2.06647)	<b>-0.733450275</b> (-0.54423)
DLPIB (-4)	<b>0.803715030</b> (3.00208)	<b>0.244388252</b> (0.42705)	<b>0.626053143</b> (0.84088)	<b>1.767139238</b> (0.84148)
DLIMPO (-1)	<b>0.145555363</b> (1.60254)	<b>0.320749434</b> (1.65206)	<b>0.346646839</b> (1.37238)	<b>-0.527250525</b> (-0.74003)
DLIMPO (-4)	<b>-0.113864307</b> (-1.95686)	<b>0.219618606</b> (1.76571)	<b>-0.352402422</b> (-2.17779)	<b>-0.130179164</b> (-0.28521)
DLINV_BRUTA (-1)	<b>-0.110313627</b> (-0.80578)	<b>-0.245513794</b> (-0.83895)	<b>-0.151082305</b> (-0.39683)	<b>0.959696387</b> (0.89366)
DLINV_BRUTA (-4)	<b>0.047562701</b> (0.38785)	<b>-0.095029536</b> (-0.36252)	<b>0.590347540</b> (1.73104)	<b>-0.715914595</b> (-0.74423)
DLMERVAL (-1)	<b>0.075161348</b> (3.25002)	<b>0.246032030</b> (4.97692)	<b>0.129589314</b> (2.01496)	<b>-0.030357027</b> (-0.16734)
DLMERVAL (-4)	<b>0.000220152</b> (0.01038)	<b>-0.033462170</b> (-0.73778)	<b>-0.029948028</b> (-0.50754)	<b>-0.281167501</b> (-1.68932)
R <sup>2</sup>	0.906011	0.766941	0.773217	0.165212
R <sup>2</sup> Ajustado	0.879694	0.701684	0.709718	-0.068529
Media de la var. dep.	0.006041	0.015827	0.005468	-0.000220
Error estándar de la var. dep.	0.054975	0.074626	0.098422	0.144697
Error est. de la estimación	0.019068	0.040759	0.053027	0.149573
Suma de residuos al cuadrado	0.009090	0.041533	0.070298	0.559304
Estadístico de Durbin-Watson	1.795301	2.152246	2.059524	1.905822
Estadístico F	34.42704	11.75272	12.17680	0.706816

**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía, utilizando RATS 4.2. El método utilizado es Mínimos Cuadrados, la muestra ajustada corresponde al período 1992:4 2000:4 y toma en cuenta 33 observaciones. Estadísticos T entre paréntesis.*

En ambas estimaciones puede apreciarse que los test de bondad del ajuste para cada una de las ecuaciones tomadas individualmente presentan resultados satisfactorios. Por ejemplo, los valores de los R<sup>2</sup> para las ecuaciones de las variables estudiadas son relativamente altos mientras, como es de esperarse, el de la ecuación del MERVAL es relativamente bajo.<sup>31</sup> Los *test t*, por su parte, en general reportan buenos resultados en cuanto a la significatividad individual. Es importante destacar, con respecto a esto, que con varios rezagos de las mismas variables, cada coeficiente estimado puede no ser estadísticamente significativo, posiblemente debido a la

favor de una estructura con 2 rezagos. En cuanto a la comparación entre VAR(1,2) y VAR(1,2,4) el estadístico resultó ser 33.8 rechazando la estructura de dos rezagos.

<sup>31</sup> Esto último está mostrando el hecho de que el MERVAL precede a las variables reales y no viceversa.

existencia de multicolinealidad como se ve claramente en la salida de la regresión, aunque conjuntamente ellos pueden ser estadísticamente distintos de cero sobre la base del test F. Por dicho motivo, se debe observar el resultado que arroja el mencionado test: en este caso, indica que los coeficientes de cada una de las tres ecuaciones son conjuntamente significativos a niveles convencionales.<sup>32</sup>

En este momento, antes de recaer en el análisis de las predicciones generadas por estas especificaciones, probablemente valga la pena examinar esta inclusión del Merval en el modelo. A los efectos de comprender con mayor detalle la dinámica propia del sistema, se armaron las IRF (funciones de impulso-respuesta) de las variables reales ante un cambio en el Merval y la variación del Merval ante un shock en cada variable real. Como se puede observar en el **Gráfico 5**, la respuesta de las diferentes variables a un shock aleatorio en el Merval genera reacciones más marcadas en los periodos iniciales y tiende a desaparecer a partir del octavo periodo aproximadamente. Son bien conocidos tanto el hecho de que el SEMBI es un predictor del PIB (de tal manera que al aumentar el primero cae el segundo), como el que hay una fuerte correlación negativa entre Merval y SEMBI [Grubisic y Manteiga, 2000]. En este sentido, ambas variables son indicadoras a futuro (y son usadas como tales), de manera que el resultado de la respuesta del PIB a un impulso en Merval no debería ser sorprendente. Lo mismo puede decirse de las respuestas dadas por la inversión y las importaciones ante cambios en esta variable. Tampoco debería sorprender la escasa respuesta de Merval a impulsos en el PIB, porque dado que la primera precede a la segunda (y si se piensa que los mercados utilizan toda la información disponible), es de esperarse que no haya respuestas significativas como se ve en el gráfico mencionado. Esto podría estar sugiriendo que los mercados son eficientes, ya que las variables reales no son las que preceden al Merval, que es un *leading indicator*, y sí esta última precede a las variables reales como se esperaba.

### ***Predicción con los modelos VAR***


La mecánica de generación de predicciones con los modelos VAR es idéntica a la utilizada con los ARIMA. Para cada uno de los ejercicios realizados, entonces, se tiene dos series de predicciones: una *one step* y otra *two steps*. Gráficamente estas se muestran en el Anexo al final del artículo, en los **Gráficos A7, A8 y A9** para el modelo VAR y en los **Gráficos A10, A11 y A12** para el modelo VAR LI. Además, y como se mencionaba al principio de esta sección, se realizó un tercer ejercicio ilustrativo: se generaron predicciones con un modelo que incluía el máximo de información posible: los últimos datos de las variables estudiadas y el dato actual del Merval. Esto es un ejercicio razonable de hacer partiendo de la base de que,

---


<sup>32</sup> Se esperan estadísticos significativamente distintos de cero si se quiere rechazar la  $H_0$  de coeficientes conjuntamente iguales a cero. Para el caso del Merval es razonable obtener un F bajo, ya que esto está señalando que dicha variable no es explicada por variables reales y por sus propios rezagos.

**Gráfico 5: El Merval en la Función de Impulso-Respuesta**


**Respuestas a innovaciones en DLMERVAL**




**Respuesta de DLMERVAL ante innovaciones en las variables**




**Respuesta de DLPIB**




**Innovación en DLPIB**



**Respuesta de DLIMPO**



**Innovación en DLIMPO**



**Respuesta de DLINV\_BRUTA**

**Innovación en DLINV\_BRUTA**

Fuente: *Elaboración propia en base a información del Ministerio de Economía.*

dada la demora con la que se reciben los datos de las Cuentas Nacionales, normalmente se dispone de los datos de MERVAL con un período de anterioridad con respecto a las demás variables. Los **Gráficos A13, A14 y A15** dan cuenta de predicciones generadas por el VAR MI.

## V. Resultados

En el presente trabajo se utilizaron básicamente dos medidas para poder comparar los resultados de las predicciones. En la sección sobre los modelos ARIMA ya se adelantaba una de ellas: el promedio del error absoluto medio de predicción (EAMP), en porcentajes. Este es, probablemente, el más natural de elaborar: teniendo la serie de valores reales, se puede determinar el porcentaje de variación con respecto al valor pronosticado y obtener el promedio de estos porcentajes a lo largo de todo el período pronosticado. Por otro lado, el indicador alternativo que se utiliza es la raíz el error cuadrático medio (RECM), que promedia las raíces de los errores cuadráticos medios de las distintas variables. De este modo, esta última medida penaliza aquellas predicciones que –aun teniendo el mismo EAMP– cometen errores más grandes. El resumen de estos indicadores para los modelos que se han estudiado se encuentra en la Tabla 11.

**Tabla 11: Errores de predicción de los modelos analizados**

Modelo		PIB		IMPO		INVERSIÓN	
		1STEP	2STEP	1STEP	2STEP	1STEP	2STEP
<i>EAMP</i> (%)	<i>ARIMA</i> *	2.0 %	2.9 %	4.3 %	7.9 %	4.6 %	9.4 %
	<i>VAR</i> *	2.1 %	3.3 %	5.6 %	10.9 %	5.7 %	10.1 %
	<i>VAR LI</i> *	1.7 %	2.8 %	4.6 %	8.3 %	4.4 %	7.3 %
	<i>VAR MI</i> *	1.9 %	2.7 %	4.9 %	9.1 %	4.2 %	6.0 %
<i>RECM</i>	<i>ARIMA</i> *	1,603	2,355	445	805	704	1,450
	<i>VAR</i> *	1,722	2,664	584	1,125	886	1,561
	<i>VAR LI</i> *	1,407	2,257	461	823	659	1,181
	<i>VAR MI</i> *	1,391	2,186	502	921	620	899

**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*

Algunos resultados son interesantes. A primera vista se puede apreciar que, en forma bastante general, todas las metodologías generan predicciones relativamente buenas para el PIB. Utilizando el primer indicador, que nos permite comparar fácilmente resultados entre distintas variables, se ve que mientras los errores en el PIB son en promedio de alrededor de tan sólo 2% y 3% para *one* y *two steps*, las importaciones presentan diferencias cercanas al 5% y 9% y la inversión bruta entre el 5% y 8%, respectivamente. El desempeño de las importaciones y la inversión, por otro lado, es bastante similar, cosa que es remarcable –al menos, teniendo en cuenta las dificultades de ajuste de los modelos ARIMA para la primera de estas.

Con respecto a la comparación entre modelos, uno de los puntos para resaltar es la relativa eficiencia de los ARIMA por sobre los VAR. En ese sentido, la inclusión del Merval en el sistema mejora en forma notable el funcionamiento del VAR. Para el PIB y la inversión bruta, el VAR LI y el VAR MI son superiores a los otros modelos: es decir, para estas dos variables es importante la información adicional que brinda el Merval, por lo cual –en ambos casos- éste indicador bursátil se comporta como *leading indicator*. En términos generales, sin embargo, no es claro cual de los dos modelos minimiza el error de predicción, ya que los resultados difieren de acuerdo a cómo se mide este valor. De acuerdo al EAMP, el modelo VAR MI genera peores predicciones que el VAR LI. Por otro lado, si se utiliza el otro indicador se observa que el ordenamiento es distinto. Esto indica, al menos, que si bien en promedio el VAR LI se comporta mejor, éste también tiene una mayor disparidad con respecto al tamaño de los errores. En cuanto a las importaciones, se tiene que el mejor modelo es el ARIMA, ya que es el que minimiza cualquiera de los criterio adoptado. En este caso la información adicional que proviene de introducir las otras dos variables reales y el Merval, en las estructuras VAR, no ayudan al momento de predecir. Se podría pensar que hay más información útil a los efectos de la predicción en los rezagos de las importaciones, recogidos en el modelo ARIMA, que en el resto de las variables. Más aún, es interesante el hecho de que agregando el Merval, las predicciones empeoran en relación con las del ARIMA, aunque el modelo que reporta la peor *performance* predictiva para esta variable es el VAR.

## VI. Conclusiones

En líneas generales, en este trabajo se han elaborado distintos modelos econométricos con el objetivo último de generar predicciones de *one* y *two steps* de variables macroeconómicas reales de interés: el PIB, las importaciones y la inversión. Las técnicas econométricas utilizadas fueron la de Box-Jenkins -para la estimación de modelos ARIMA- y la metodología VAR. En el caso del VAR, se practicaron dos variantes en la estimación: una considerando sólo a las tres variables reales de interés (VAR) y otra agregando al Merval, por considerarlo un *leading indicator*, entre sus variables endógenas (VAR LI). A su vez, y a los efectos de aprovechar toda la información disponible en la elaboración de los pronósticos, también se diseñó un tercer modelo VAR (VAR MI) que captara el hecho de que en cada período se dispone “por adelantado” de un dato adicional de Merval.

Probablemente el resultado más interesante es que –en forma general- los modelos ARIMA funcionaron mejor que el VAR tradicional. En este sentido, la influencia del Merval en las subsiguientes variantes produce grandes mejoras en los resultados. Sin embargo, no es del todo claro cual de las dos variantes es superior, ya que el ordenamiento de su *performance* depende de la forma en que se está midiendo su eficiencia. De acuerdo al EAMP, que se fija en la eficiencia promedio general de

la predicción, el VAR LI genera mejores predicciones; sin embargo, de acuerdo al RECM, que penaliza más a los errores grandes, el VAR MI es más eficiente. El PIB, por su parte, fue la variable que se predijo con un mayor éxito, obteniéndose, para el primer *step*, errores menores al 2%. En todo caso, es interesante notar el comportamiento de la serie de importaciones. Esta variable, a diferencia de las otras, obtuvo su mejor resultado con el modelo ARIMA que, curiosamente, fue el que mayores dificultades produjo en el momento de su estimación.

Los resultados de este estudio son, en general, muy ilustrativos. Sin embargo, resta decir, no agotan todas las posibilidades de investigación en un área que tradicionalmente se ha relegado en la literatura local. En ese sentido, este trabajo forma parte de un proyecto más amplio donde se pretende tanto examinar el funcionamiento de estos modelos con otras variables económicas y otras frecuencias de datos, como evaluar la *performance* de otras modelizaciones alternativas, tales como los VARs *bayesianos* o los modelos de redes neuronales (*neural networks*). Eso, de todos modos, escapa al alcance de este artículo.

## VII. Referencias

**Ballabriga, Fernando, Luis J. Álvarez González y Javier Jareño Morago [1998];** “Un modelo macroeconómico BVAR para la economía española: Metodología y resultados”, Banco de España – Servicio de Estudios, *Estudios Económicos*, nro. 64.

**Clemen, Robert T. and Robert L. Winkler [1986];** “Combining Economic Forecasts”, en *Journal of Business & Economic Statistics*, vol. 4, nro. 1, January, pp. 39-46.

**Cochrane, John H. [1997];** *What do the VARs mean? Measuring the Output Effects of Monetary Policy*, Tesis Doctoral, University of Chicago, July.

**Doan, Thomas, Robert Litterman y Christopher Sims [1984];** “Forecasting and conditional projection using realistic prior distributions”, en *Econometric Reviews*, vol. 3, nro. 1, pp. 1-100.

**Espasa, Antoni and Daniel Peña [1990];** “Los modelos ARIMA, el estado de equilibrio en variables económicas y su estimación”, Banco de España – Servicio de Estudios, *Documentos de Trabajo*, nro. 9008.

**Fair, Ray C. y Robert J. Shiller [1990];** “Comparing Information in Forecasts from Econometric Models”, en *American Economic Review*, vol. 80, nro. 3, junio, págs. 375-389.

- Frenkel, Roberto y Martín González Rozada [1999]**; “Liberalización del balance de pagos. Efectos sobre el crecimiento, el empleo y los ingresos en la Argentina”, *Trabajo de investigación del CEDES*, Buenos Aires.
- Granger, C. W. J. [1989]**; *Forecasting in Business and Economics –Second Edition-* (San Diego, Academic Press).
- Grubisic, María Elena y Marilina Manteiga [2000]**; “Modelos de predicción de Agregados Monetarios (1993-199)”, en *Nota Técnica - Banco Central de la República Argentina*, nro. 9, agosto.
- Gujarati, Damodar N. [1995]**; *Basic Econometrics* (Mc.Graw Hill, New York).
- Hamilton, James D. [1994]**; *Times Series Analysis* (Princeton-NJ, Princeton University Press).
- Harvey, Andrew [1990]**; *The Econometric Analysis of Time Series* (The MIT Press, 2ed., Cambridge, Mass.).
- Intriligator, Michael D., Ronald G. Bodkin and Cheng Hsiao [1996]**; *Econometric Models, Techniques and Applications –Second Edition-* (New Jersey, Prentice Hall).
- Leiva, Ricardo A. [1995]**; *Introducción al análisis de series de tiempo* (Mendoza, Facultad de Ciencias Económicas de la Universidad Nacional de Cuyo)
- Litterman, Robert B. [1980]**; *Techniques for Forecasting with Vector Autoregressions*, Tesis doctoral, Universidad de Minnesota.
- Litterman, Robert B. [1984]**; “Specifying Vector Autoregressions for Macroeconomic Forecasting”, *Federal Reserve Bank of Minneapolis, Research Department Staff Report*, nro. 92, marzo.
- McNees, Stephen K. [1986]**; “Forecasting Accuracy of Alternative Techniques: A Comparison of U.S. Macroeconomic Forecasts”, en *Journal of Business & Economic Statistics*, vol. 4, nro. 1, enero, págs. 5-15.
- McNees, Stephen K. [1988]**; “On the future of Macroeconomic Forecasting”, en *International Journal of Forecasting*, vol. 4, nro. 3, págs. 359-362.
- McNees, Stephen K. [1990]**; “The role of judgment in macroeconomic forecasting accuracy”, en *International Journal of Forecasting*, vol. 6, num. 3, octubre, págs. 287-299.
- Sims, Christopher [1980]**; “Macroeconomics and reality”, en *Econometrica*, vol. 48, nro. 1, enero, págs. 1-48.

- Theil, H. [1971];** *Principles of Econometrics* (Nueva York, John Wiley).
- Tiao, G. and G. Box [1981];** “Modelling Multiple Time Series with Applications”, en *Journal of the American Statistical Association*, vol. 76, nro. 376, diciembre, págs. 802-816.
- Wallis, Kenneth F. [1989];** “Macroeconomic Forecasting: A Survey”, en *The Economic Journal*, 99, marzo, págs. 28-61.
- Webb, Roy H. [1999];** “Two Approaches to Macroeconomic Forecasting”, en *Federal Reserve Bank of Richmond Economic Quarterly*, vol. 85, num. 3, Verano, págs. 23-40.
- Zarazaga, Carlos y Fynn Kydland [1997];** “Is the Business Cycle of Argentina ‘Different?’”, en *Segundas Jornadas de Economía Monetaria e Internacional*, Universidad Nacional de La Plata, 8-9 de mayo de 1997.
- Zellner, Arnold y Chansik Hong [1989];** “Forecasting International Growth Rates Using Bayesian Shrinkage and Other Procedures”, en *Journal of Econometrics*, 40, págs. 183-202.

## VI. Apéndice: Modelos ARIMA según MC

Se mencionó en el artículo que los modelos de MC y de MV asintóticamente producen los mismos resultados. Sin embargo, con un número pequeños de observaciones las estimaciones difieren en forma sustancial. Es por ello que en este apéndice, a modo ilustrativo, se ha replicado el proceso de Box y Jenkins que se utilizó para generar los modelos ARIMA del trabajo, pero aplicando la técnica de MC. Las estimaciones se encuentran detalladas en la Tabla AP1.

**Tabla AP1: Modelos ARIMA (MC)**

Variable	DLPIB	DLIMPO	DLIN_BRUTA	
<b>AR(4)</b>	<b>0.978757</b> (26.08142)	<b>0.628984</b> (4.919240)	<b>0.911926</b> (9.699663)	
<b>AR(5)</b>		<b>-0.264246</b> (-2.153094)		
<b>MA(1)</b>	<b>0.615508</b> (4.858133)	<b>0.956162</b> (25.70900)	<b>0.543657</b> (3.302705)	
R <sup>2</sup>	0.838297	0.569291	0.622709	
R <sup>2</sup> Ajustado	0.833081	0.539587	0.610539	
Suma de residuos al cuadrado	0.015638	0.074850	0.116952	
Q (16)	10.05	16.03	16.22	
Nivel de signif. de Q	0.785	0.247	0.300	
Media de la var. dep.	0.006041	0.017875	0.005468	
Error estándar de la var. dep.	0.054975	0.074872	0.098422	
Estadístico de Durbin-Watson	2.204700	2.032267	1.879456	
Iteraciones nec. Para converg.	20	30	12	
Raíces invertidas AR	.99	.71 -.09+.92i -.09 -.92i	.45 -.97 -.00+.98i -.00-.98i	.98 -.98
Raíces invertidas MA	-.62	-.96	-.54	

**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía, utilizando RATS 4.2. El método utilizado es el de Mínimos cuadrados, la muestra ajustada corresponde a los períodos 1992:4 2000:4 ó 1993:1 2000:3 y toma en cuenta 33 ó 32 observaciones, según sea DLPIB y DLINV\_BRUTA ó DLIMPO, respectivamente (valores “t” entre paréntesis).*

Por ello, las aproximaciones empíricas resultan:

$$\begin{cases} \text{DLPIB}_t = (0.98) \text{DLPIB}_{t-4} + (0.61) e_{t-1} + e_t \\ \text{DLIMPO}_t = (0.63) \text{DLIMPO}_{t-4} + (-0.26) \text{DLIMPO}_{t-5} + (0.95) e_{t-1} + e_t \\ \text{DLINV\_BRUTA}_t = (0.91) \text{DLINV\_BRUTA}_{t-4} + (0.54) e_{t-1} + e_t \end{cases}$$

donde  $e_t$  son los residuos estimados. En cuanto a la significatividad individual de los residuos, se procedió a armar los correlogramas correspondientes en donde no se encontraron residuos individualmente significativos. Adicionalmente, el estadístico  $Q(16)$  que aparece en la tabla previa no rechaza la  $H_0$  en ninguno de los tres modelos. Por último, para analizar la presencia de autocorrelación en los residuos del modelo se procedió a aplicar el test LM, cuyos resultados se exponen a continuación en la Tabla AP2 donde, en todos los casos, se ve que la  $H_0$  no se rechaza a niveles convencionales.

**Tabla AP2: Test LM**

Serie	Estadístico F	P-value
$D(\log PIB)$	2.24	0.1242
$D(\log IMPO)$	0.12	0.8877
$D(\log INVERSION)$	0.38	0.6934

Fuente: *Elaboración propia en base a información del Ministerio de Economía.*

Al igual que se hizo con las estimaciones de MV, a los efectos de detectar la presencia de cambio estructural se procedió a aplicar el *Test de Chow* a las tres series bajo análisis modeladas, dando por resultado (Tabla AP3) que la probabilidad de que esto se produzca disminuye considerablemente si se comienzan a utilizar los datos a partir del tercer trimestre de 1991, lo cual es consistente con lo realizado en el trabajo.

**Tabla AP3: Test de Chow de cambio estructural**

Fechas	PIB		Importaciones		Inversión		
	AR(4)	MA(1)	AR(4)	AR(5)	MA(1)	AR(4)	MA(1)
	F- Stat.	P-Value	F- Stat.	P-Value	F- Stat.	P-Value	
1988.4	0.7344	0.4832	0.7631	0.5185	0.1356	0.8734	
1989.1	0.6564	0.5217	3.0059	0.0358	0.2033	0.8164	
1989.2	0.5660	0.5702	7.2750	<b>0.0003</b>	0.3164	0.7297	
1989.3	0.8503	0.4314	1.9759	0.1252	0.5392	0.5854	
1989.4	0.8238	0.4427	2.1424	0.1023	0.2719	0.7627	
1990.1	4.7925	<b>0.0100</b>	2.1396	0.1027	n.a.	n.a.	
1990.2	3.8539	0.0255	1.9931	0.1226	2.6489	0.0773	
1990.3	2.4007	0.0976	3.5243	0.0191	3.2081	0.0460	
1990.4	2.3649	0.1009	4.9484	<b>0.0035</b>	3.2589	0.0439	
1991.1	2.5754	0.0828	2.3869	0.0760	4.9389	<b>0.0097</b>	
1991.2	2.9083	0.0607	2.1178	0.1054	6.8612	<b>0.0018</b>	
1991.3	1.6444	0.2000	1.9825	0.1242	4.3954	0.0157	
1991.4	1.7275	0.1847	1.5213	0.2163	3.8558	0.0255	

Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

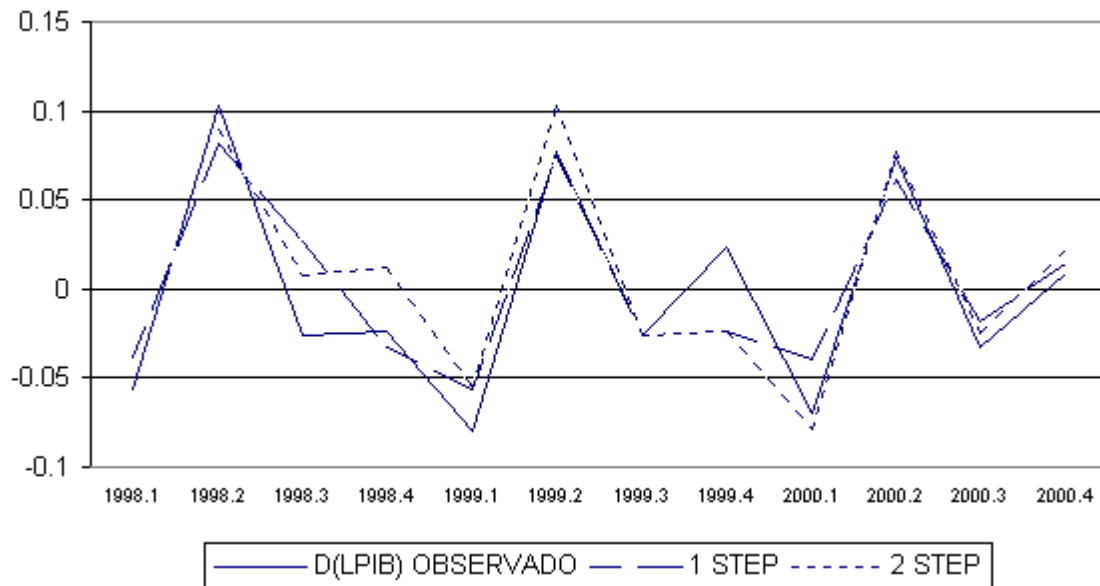
Hecho lo anterior, ahora se está en condiciones de pasar a la etapa de pronóstico. En los **Gráficos AP1 a AP6** se pueden ver las distintas *performances* de las predicciones *one step* y *two steps*, tanto como diferencia de logaritmos como en niveles. A continuación, en la Tabla AP4, se muestran los resultados obtenidos para cada serie.

**Tabla AP4: Errores absolutos medios de predicción de los niveles (%)**

Modelo	MC		MV	
	ONE STEP	TWO STEPS	ONE STEP	TWO STEPS
<b>PIB</b>	2.0 %	3.2 %	2.0 %	2.9 %
<b>IMPO</b>	4.5 %	8.6 %	4.3 %	7.9 %
<b>INV_BRUTA</b>	4.6 %	9.7 %	4.6 %	9.4 %


Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico AP1:** Predicciones “PIB – Dif. Logs”




**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico AP2:** Predicciones “PIB - Niveles”




**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico AP3:** Predicciones “IMPORTACIONES – Dif. Logs”




**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico AP4:** Predicciones “IMPORTACIONES - Niveles”




**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico AP5:** Predicciones “INVERSIÓN BRUTA – Dif. Logs”



**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*

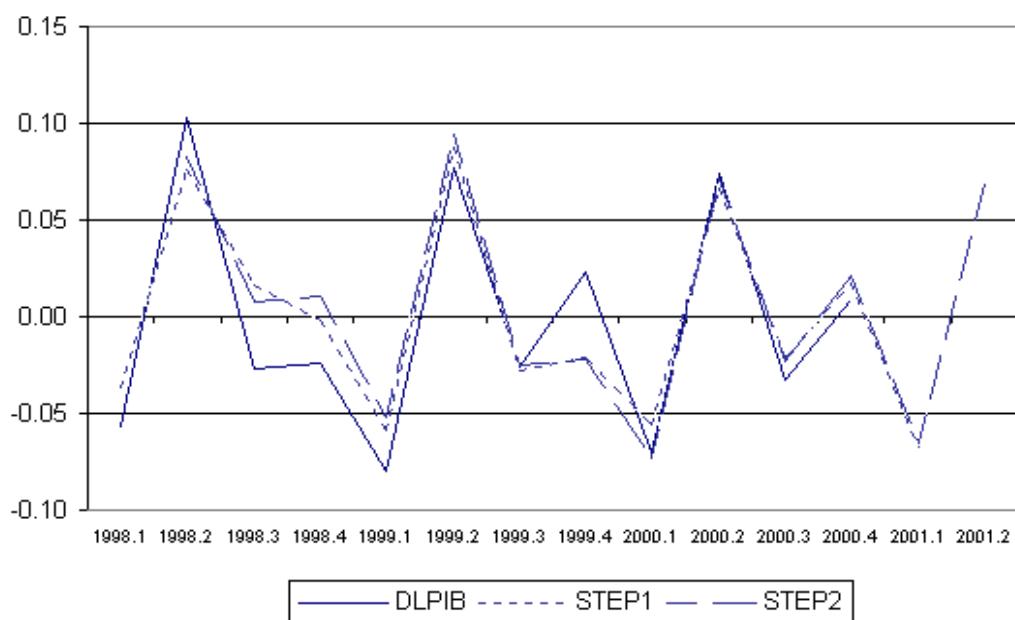
**Gráfico AP6:** Predicciones “INVERSIÓN BRUTA – Niveles”



**Fuente:** *Elaboración propia en base a datos del Ministerio de Economía.*


## VII. Anexo

**Gráfico A1:** Predicciones ARIMA - PIB Diferencia de Logaritmos




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A2:** Predicciones ARIMA - PIB Niveles




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A3:** Predicciones ARIMA - Importaciones Diferencia de Logaritmos




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A4:** Predicciones ARIMA - Importaciones Niveles




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A5:** Predicciones ARIMA - Inversión Bruta Diferencia de Logaritmos




**Fuente:** Elaboración propia en base a datos del Ministerio de Economía.

**Gráfico A6:** Predicciones ARIMA - Inversión Bruta Niveles




**Gráfico A7:** Predicciones VAR(1,4)\* - PIB Niveles




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A8:** Predicciones VAR(1,4)\* - Inversión Bruta Niveles




**Gráfico A9:** Predicciones VAR(1,4)\* - Importaciones Niveles




**Fuente:** Elaboración propia en base a datos del Ministerio de Economía.

**Gráfico A10:** Predicciones VAR LI(1,4)\* - PIB Niveles




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A11:** Predicciones VAR LI(1,4)\* - Inversión Bruta Niveles




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A12:** Predicciones VAR LI(1,4)\* - Importaciones Niveles




Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*

**Gráfico A13:** Predicciones VAR MI(1,4)\* - PIB Niveles




Fuente: Elaboración propia en base a datos del Ministerio de Economía.

**Gráfico A14:** Predicciones VAR MI(1,4)\* - Inversión Bruta Niveles



Fuente: Elaboración propia en base a datos del Ministerio de Economía.

**Gráfico A15:** Predicciones VAR MI(1,4)\* - Importaciones Niveles



Fuente: *Elaboración propia en base a datos del Ministerio de Economía.*