

Pronóstico de inflación en Argentina: ¿Modelos individuales o pooling de pronósticos?

Laura D'Amato / Lorena Garegnani / Emilio Blanco
BCRA

Julio de 2008



ie | BCRA
INVESTIGACIONES ECONÓMICAS

Banco Central de la República Argentina
ie | Investigaciones Económicas

Julio, 2008
ISSN 1850-3977
Edición Electrónica

Reconquista 266, C1003ABF
C.A. de Buenos Aires, Argentina
Tel: (5411) 4348-3719/21
Fax: (5411) 4000-1257
Email: investig@bcra.gov.ar
Pag.Web: www.bcra.gov.ar

Las opiniones vertidas en este trabajo son exclusiva responsabilidad de los autores y no reflejan necesariamente la posición del Banco Central de la República Argentina. La serie Documentos de Trabajo del BCRA está compuesta por material preliminar que se hace circular con el propósito de estimular el debate académico y recibir comentarios. Toda referencia que desee efectuarse a estos Documentos deberá contar con la autorización del o los autores.

Pronóstico de inflación en Argentina: ¿Modelos Individuales o Pooling de Pronósticos?*

Laura D´Amato
BCRA

Lorena Garegnani
BCRA

Emilio Blanco
BCRA

Julio 2008

Resumen

El pronóstico de la inflación juega un papel central en la formulación de la política monetaria. Al mismo tiempo la evidencia empírica internacional reciente sugiere que con el descenso de la inflación en los últimos años, como un fenómeno bastante extendido, la dinámica conjunta de esta variable y sus potenciales predictores, como el dinero o distintas medidas del grado utilización de los recursos, ha cambiado y la inflación se ha tornado más impredecible. Utilizando como benchmark un modelo univariado, evaluamos la capacidad predictiva de algunos modelos causales asociados a distintas teorías de la inflación, como la curva de Phillips y un V AR monetario. También estudiamos la capacidad predictiva de modelos que utilizan como predictores factores que resumen la variabilidad conjunta de un gran número de series del ciclo económico. Comparamos su desempeño relativo utilizando un conjunto de tests paramétricos y no paramétricos propuestos por Diebold y Mariano (1995). Encontramos que si bien el modelo univariado es en general el de mejor desempeño, a medida que se extiende el horizonte de pronóstico, los modelos multivariados se acercan al desempeño de los univariados. En particular un V AR monetario llega a superar al modelo ARMA univariado para el horizonte de un año. Sin embargo, cuando se calculan tests para evaluar la significatividad estadística de las diferencias en capacidad predictiva de los modelos, tomando como benchmark un modelo ARMA univariado, las diferencias no resultan estadísticamente significativas. Finalmente se combinan los modelos estimados mediante un pool de pronósticos. Los resultados indican que alguna de las combinaciones de pronósticos supera al mejor pronóstico individual para un horizonte de un año. Teniendo en cuenta que el horizonte de un año es el relevante para la toma de decisiones de política económica, la posibilidad de combinar modelos tanto univariados como multivariados para pronóstico es interesante porque permite además responder a preguntas específicas de política económica.

Clasificación JEL: C32, E31, E37.

* Las opiniones expresadas en este trabajo son de los autores y no necesariamente reflejan las del BCRA ni de sus autoridades. Correspondencia: ldamato@bcra.gov.ar

1. Introducción

El pronóstico de la inflación juega un papel central en la formulación de la política monetaria. Al mismo tiempo la evidencia empírica internacional reciente sugiere que con el descenso de la inflación en los últimos años, como un fenómeno bastante extendido, la dinámica conjunta de esta variable y sus potenciales predictores, como el dinero o distintas medidas del grado utilización de los recursos, ha cambiado y la inflación se ha tornado más impredecible. Los modelos univariados suelen superar en capacidad de pronóstico a los basados en las distintas teorías de la inflación como la curva de Phillips. Tradicionalmente la curva de Phillips desempeñó en los países industriales un papel predominante en el pronóstico de inflación y como señalan Stock y Watson (1999), Atkenson y Ohanian (2001) y Canova, (2002) parecía tener mejor desempeño en términos de su error de pronóstico que distintos modelos alternativos. En años recientes ha surgido evidencia, particularmente para los Estados Unidos, de que la curva de Phillips se tornó inestable partir de la década de los 80's y también, quizás debido a ello, su capacidad de pronóstico se debilitó, siendo superada en general por los modelos univariados.

Clements y Hendry (2006) sugieren que esta dificultad de los modelos causales puede estar asociada a la presencia de cambios de régimen que afectan principalmente los componentes determinísticos de los modelos y proponen una estrategia de modelación basada en una batería de modelos que permiten lidiar con esa dificultad. Otra estrategia propuesta por la literatura de pronóstico es trabajar con combinaciones o pooling de pronósticos, teoría desarrollada inicialmente por Bates y Granger (1969). Hendry y Clements (2002) estudian el *pooling* o combinación de pronósticos para modelos no estacionarios debido a quiebres en el intercepto o en una tendencia determinística, y encuentran que un promedio simple de pronósticos puede contrarrestar, para valores plausibles de los parámetros, la inestabilidad de los pronósticos individuales y actuar como una corrección sobre el intercepto. Una estrategia alternativa es utilizar modelos que incorporen un número muy grande de predictores, como proponen Stock y Watson (1999, 2006) entre otros, mediante el uso de técnicas estadísticas que permiten construir medidas resumidas (factores) de la variabilidad de un gran conjunto de series económicas.

Evaluamos el desempeño de distintos modelos de pronóstico de inflación para Argentina algunos de los cuales hacen uso de estas técnicas de pronóstico. También comparamos su desempeño relativo utilizando un conjunto de tests propuestos por Diebold y Mariano (1995). No tenemos evidencia de trabajos anteriores que hayan desarrollado modelos de pronóstico de inflación en Argentina y comparado su desempeño relativo utilizando tests estadísticos. Utilizando como benchmark un modelo univariado, evaluamos la capacidad predictiva de algunos modelos causales asociados a distintas teorías de la inflación, como la curva de Phillips y un *VAR* monetario. También estudiamos la capacidad predictiva de


modelos que utilizan factores que resumen la variabilidad de un gran número de series del ciclo económico como predictores. En base a los quiebres identificados en D'Amato, Garegnani y Sotes (2007), nos enfocamos en la búsqueda de modelos que tengan buen desempeño para pronóstico, restringiendo el análisis al período 1993-2006.

El trabajo está organizado del siguiente modo: en la sección siguiente describimos brevemente la dinámica de la inflación en Argentina, en la sección 3 se revisan los desarrollos recientes en la literatura de pronóstico. En la sección 4 se presentan los resultados en cuanto a capacidad predictiva de los modelos y su evaluación. Finalmente, la sección 5 concluye.

2. La dinámica de la inflación en Argentina


La dinámica inflacionaria en Argentina ha tenido características particulares, aunque con algunos rasgos comunes con otras economías de la región. Durante los años 70 y 80, la inflación fue un fenómeno bastante extendido en América Latina. El financiamiento monetario de los desequilibrios fiscales fue un rasgo común a todas estas experiencias inflacionarias. En Argentina la inflación se mantuvo en niveles muy elevados durante los 80's, pese a sucesivos intentos de estabilización. Hacia el fin de la década esa dinámica derivó en un episodio hiperinflacionario. En 1991 se adoptó un esquema de caja de conversión, la Convertibilidad, que fue exitoso en producir una reducción permanente en la tasa de inflación. La inflación comenzó a estabilizarse en niveles reducidos hacia 1993. Si bien el cambio en el régimen cambiario fue percibido como permanente y la inflación permaneció en niveles muy bajos, el impuesto inflacionario fue sustituido por la emisión de deuda en los mercados internacionales, quedando pendiente una reforma fiscal. En 2001, como producto de desequilibrios tanto fiscales como externos y de una persistente apreciación real de la moneda, se desató una aguda crisis financiera y externa que condujo al abandono del régimen de Convertibilidad en enero de 2002. La devaluación produjo un cambio abrupto de precios relativos y un consecuente salto en la tasa de inflación, que alcanzó un pico en abril de 2002, para luego retornar a niveles cercanos a los de la Convertibilidad. No obstante permanecer en niveles bajos, la inflación comenzó a acelerarse levemente hacia fines de 2004, cuando la economía entró en un período de fuerte crecimiento.

Gráfico 1



La simple observación de la evolución temporal de la inflación sugiere la presencia de quiebres estructurales que dificultan la obtención de un modelo estable en los parámetros con fines de pronóstico si se considera la muestra completa. Al respecto, D'Amato, Garegnani y Sotes (2007) proveen evidencia de cambios significativos tanto en la media como en el componente autorregresivo de la inflación entre los períodos de alta inflación y baja inflación. Si bien al restringir la muestra al período de baja inflación es posible detectar un quiebre en 2002, luego del abandono de la Convertibilidad, la magnitud del salto en la inflación y su retorno a niveles más cercanos a los del período previo, permiten tratar el período de la crisis como un cambio transitorio en la media que se revierte parcialmente, teniendo la inflación una media algo superior a la de la Convertibilidad en el período 2003-2006. De ese modo, el período de baja inflación entre 1993 y 2006 puede ser modelado para pronóstico, controlando por dicho quiebre.

Gráfico 2



Evaluamos los modelos para distintos horizontes de pronóstico relevantes para la política monetaria: un año, que suele ser el horizonte para el que se fija la meta de la política monetaria, ya sea sobre la tasa de inflación o como en Argentina en la actualidad, sobre la expansión de un agregado monetario relevante. A su vez se examina la capacidad de pronóstico de los modelos en horizontes más cortos: 6 y 3 meses, también de relevancia para el seguimiento del ciclo y la toma de decisiones de la política monetaria.

3. Los modelos de pronóstico en la literatura

Los modelos econométricos causales ofrecen muchas veces una representación del proceso generador de los datos (PGD) satisfactoria en términos de los comportamientos sugeridos por la teoría económica. Sin embargo estos modelos suelen tener pobre desempeño en el pronóstico de series de tiempo relevantes, cuando se lo compara con el de los modelos autorregresivos. Una razón para ello es que estos últimos parecen ajustar mejor a cambios no anticipados en el proceso generador de los datos, dado su carácter adaptativo intrínseco.

En los años recientes la literatura sobre pronóstico ha avanzado en varias direcciones para lidiar con estas dificultades. Por un lado, autores como Clements y Hendry (2006) proponen una batería de modelos para pronóstico que permiten considerar quiebres en la media y cambios de tendencia determinística. También en los últimos años se ha extendido el uso de modelos que utilizan un número grande de predictores para pronósticos siguiendo dos caminos: (i) el *pooling* de pronósticos, que combina mediante distintos tipos de ponderaciones, un número

considerable de modelos y (ii) los *factor models*, que permiten encontrar medidas resumidas de la variabilidad de un gran número de series relevantes del ciclo económico. En el primer caso el camino elegido va en la dirección de preservar los modelos causales y eventualmente lograr un mejor pronóstico ampliando el conjunto de predictores. En el segundo caso se considera un gran conjunto de series del ciclo económico y mediante las técnicas de estadísticas multivariadas de análisis factorial o de componentes principales se extrae un número reducido de factores subyacentes a esas series que explican una porción significativa de su variabilidad. La evidencia empírica indica que estas variables adicionan información relevante.

3.1. Pooling de pronósticos

El *pooling* o combinación de pronósticos implica combinar dos o más pronósticos provenientes de modelos que usan distintos predictores para producir un pronóstico. Esta técnica fue originalmente desarrollada por Bates y Granger (1969) y la idea básica es la siguiente:¹

Sea $\{Y_{i,t+h}^h, i = 1, \dots, n\}$ un panel de n pronósticos. El pronóstico combinado o pool de pronósticos estará dado por la combinación lineal

$$Y_{t+h/t}^h = w_0 + \sum_{i=1}^n w_{it} Y_{i,t+h/t}^h$$

donde w_{it} es el peso del i ésimo pronóstico en el período t .

Bates y Granger (1969) muestran que los pesos que minimizan el error cuadrático medio de pronóstico (ECMP) están dados por la proyección a la población de $Y_{t+h/t}^h$ en una constante y los pronósticos individuales. Frecuentemente se omite la constante e imponiendo $\sum_{i=1}^n w_{it} = 1$ se tiene que si cada uno de los pronósticos es insesgado, $Y_{t+h/t}^h$ también lo es. En la medida que ninguno de los pronósticos es generado por el verdadero modelo, la combinación óptima de pronósticos reparte el peso en una combinación múltiple de pronósticos. El mínimo *RMSE* combinando esos pronósticos será variable en el tiempo si las matrices de varianzas y covarianzas de $(Y_{t+h/t}^h, \{Y_{i,t+h/t}^h\})$ cambian en el tiempo.

En la práctica, los ponderadores óptimos no son viables, porque las matrices de varianzas y covarianzas son desconocidas. Granger y Ramanathan (1984) proponen estimar los ponderadores utilizando mínimos cuadrados ordinarios o mínimos cuadrados restringidos, si se impone $w_0 = 0$ y $\sum_{i=1}^n w_{it} = 1$, aunque si n es grande se espera que las estimaciones tengan un desempeño pobre, simplemente por el hecho de que al estimarse un gran número de parámetros se

¹Una descripción detallada de la técnica de pooling de pronóstico y los principales desarrollos de esta literatura puede encontrarse en Stock y Watson (2006) y aún en más detalle en Timmerman (2006).

está introduciendo incertidumbre muestral. Si n es proporcional al tamaño de la muestra, el estimador de MCO no es consistente y las combinaciones que lo utilizan no son asintóticamente óptimas. Por esa razón la investigación en la combinación o *pooling* de pronósticos se ha focalizado en imponer más estructura a la combinación de pronósticos. Entre las posibles técnicas utilizadas se tienen:

(i) *Combinación simple de pronósticos* que reporta una medida del centro de la distribución del panel de pronósticos. Los pesos están igualmente distribuidos, es decir, $w_{it} = 1/n$. La combinación mediana o la media truncada son combinaciones simples menos sensibles a la presencia de observaciones extremas.

(ii) *Pesos basados en el error cuadrático medio (RMSE)*, en este caso el pronóstico combinado utiliza ponderadores que dan peso a los pronósticos dependiendo inversamente de sus ECMP descontados

$$w_{it} = m_{it}^{-1} / \sum_{j=1}^n m_{jt}^{-1}, \quad \text{donde } m_{it} = \sum_{s=T_0}^{t-h} \rho^{t-h-s} \left(Y_{s+h}^h - \widehat{Y}_{s+h/s}^h \right)^2$$

donde ρ es un factor de descuento.

Utilizamos aquí una variante de los pesos basados en el RMSE propuesta por Marcellino (2002).

(iii) *Shrinkage de pronósticos*, técnica que involucra una convergencia de los ponderadores hacia algún valor a priori que usualmente suele ser pesos iguales.

Diebold y Pauly (1990) proponen usar

$$w_{it} = \lambda \widehat{w}_{it} + (1 - \lambda)(1/n)$$

donde \widehat{w}_{it} es el coeficiente estimado en una regresión de MCO de Y_{s+h}^h en $\widehat{Y}_{1,s+h/s}^h, \dots, \widehat{Y}_{n,s+h/s}^h$ para $s = T_0, \dots, t - h$, donde T_0 es la primera fecha del pronóstico combinado y λ controla por el grado de *shrinkage* hacia pesos iguales.

3.2. Dynamic Factor Models

El desarrollo de los *Dynamic Factor models* se basa en el análisis factorial y el análisis de componentes principales, técnicas de larga data en el análisis estadístico multivariado. La idea que subyace a estas técnicas es que la covariación entre un gran número n de series económicas en sus rezagos y adelantos puede ser representada por un número reducido de factores q no observados, con $n > q$. Las perturbaciones a esos factores podrían representar en este contexto, shocks sobre la demanda o la oferta agregada.

Se tiene entonces que el vector de n series observadas del ciclo puede ser explicada por los rezagos distribuidos de q factores comunes más las n perturbaciones idiosincráticas que eventualmente podrían estar serialmente correlacionadas y

también correlacionadas entre los i

$$X_{it} = \lambda_i(L)'f_t' + u_{it} \quad (1)$$

Donde f_t es un vector $q \times 1$ de factores no observados, λ es un vector $q \times 1$ de polinomios de rezagos de *dynamic factor loadings* y los u_{it} son las perturbaciones idiosincráticas, que se supone no están serialmente correlacionadas con los factores en todos los rezagos y adelantos, es decir $E(f_t u_{it}) = 0$ para todo i, s .

El objetivo es entonces estimar $E(y_{t+1}/X_t)$ modelando a y_{t+1} según

$$y_{t+1} = \beta_t' F_t + \varepsilon_{t+1} \quad (2)$$

Si los polinomios de rezagos $\lambda_{it}(L)$ en (1) y $\beta(L)$ en (2) son de orden finito p , Stock y Watson (2002a) muestran que los factores (FT) pueden ser estimados por el método de componentes principales y y_{t+1} modelarse según

$$Y_{t+1} = \beta' F_t + \varepsilon_{t+1} \quad (3a)$$

donde $F_t = [f_t', f_{t-1}', \dots, f_{t-p}']$ es un vector de dimensión $r = (p+1)\bar{r}$ y p es el número máximo de rezagos, y \bar{r} el número de predefinido de factores a ser extraídos de los datos. Una breve descripción de la técnica estadística multivariada de componentes principales se presenta en el *Apéndice A*.

4. Los resultados empíricos

Dados los grandes cambios que experimentó la tasa media de inflación en Argentina y la volatilidad asociada a este fenómeno, nos inclinamos por considerar para el pronóstico una muestra comprendida entre 1993:1 y 2006:12. Si bien este período incluye dos sub-períodos bastante diferentes tanto en términos del régimen monetario vigente como de la dinámica de la inflación, consideramos que esos cambios no son de una magnitud que dificulte de manera importante la estimación y el pronóstico de inflación.

Evaluamos la capacidad predictiva de un conjunto de modelos de pronóstico que incluye: un modelo *ARMA* y varios modelos multivariados: un *VAR* monetario bivariado, una curva de Phillips híbrida y dos modelos que proyectan la inflación en base a factores obtenidos estos últimos utilizando el método de componentes principales.

En general la estructura de rezagos fue elegida siguiendo los criterios convencionales de Akaike y Schwarz.

Para evaluar la capacidad de pronóstico de los modelos se calcularon el error cuadrático medio (*RMSE*), el error medio absoluto (*MAE*), el error medio absoluto porcentual (*MAPE*) también el ratio del *RMSE* de cada modelo respecto del elegido como benchmark que es el modelo *ARMA*.

Se encontró que un $ARMA(1, 12)$ parece ser una representación adecuada para la inflación en el período 1993 -2006. Se utilizaron variables dummy para controlar por observaciones extremas.

Respecto de los modelos causales, se eligieron dos que incorporan variables cuya elección refleja teorías alternativas de la inflación. Por un lado curva de Phillips neo-keynesiana híbrida² especificada para una economía abierta pequeña, que incorpora como determinantes de la inflación, además de la brecha del producto, la depreciación nominal y una medida de la inflación internacional, y adiciona a la inflación esperada un término de la inflación rezagada.

Por otro lado se estima un modelo VAR monetario que incluye la inflación y el cambio en el agregado monetario $M2$, como una medida del dinero transaccional. En este caso el modelo refleja la noción de que el dinero debería ser un determinante de la tasa de inflación en el largo plazo.

Adicionalmente a los modelos mencionados se estimaron modelos en base a factores, siguiendo la metodología descrita en la sección 2.1. Los factores obtenidos a través del método de componentes principales³ resumen la variabilidad conjunta de un gran número de series económicas que fueron agrupadas según se trata de series asociadas a la demanda agregada en factores de demanda, las asociadas a la oferta en factores de oferta y un conjunto de series nominales que incluye agregados monetarios, precios, tasas de interés y recaudación tributaria, entre otras cuya variabilidad se resumió en factores a los que llamamos nominales. Sólo los modelos estimados en base a los factores totales y nominales resultaron satisfactorios para explicar la dinámica de la inflación. Todas estas series fueron también utilizadas en forma conjunta para construir factores a los que denominamos factores totales.⁴ En general no se utilizó más allá del cuarto componente principal, de acuerdo a lo sugerido por la literatura. El modelo estimado es del tipo

$$Y_{t+1} = \beta F_t + \varepsilon_{t+1} \quad (3b)$$

donde $F_t = [f'_t, f'_{t-1} \dots f'_{t-p}]$ es un vector de dimensión $r = (p+1)\bar{r}$ donde p es el número máximo de rezagos, y \bar{r} el número de predefinido de factores a ser extraídos de los datos, que en nuestro caso es 4.

Un detalle de los modelos estimados se presenta en el Apéndice C.

4.1. La capacidad predictiva de los modelos estimados

Para comparar el desempeño de los distintos modelos reportamos cuatro tipos de estadísticos: el error cuadrático medio ($RMSE$), el error absoluto medio

²Galí y Gertler (1999) proponen una curva de Phillips neo-keynesiana híbrida, que incorpora un término rezagado de la inflación. El modelo utilizado aquí para pronóstico fue estimado por D'Amato y Garegnani (2006) y está en línea con el de Galí y Getler, pero extendido al caso de una economía abierta pequeña.

³Ver el Apéndice A para una descripción detallada del método de componentes principales.

⁴Ver Apéndice B para una descripción de las series que se consideraron para obtener los distintos factores.

(MAE), el error porcentual absoluto medio ($MAPE$) y el estadístico $U - Theil$, que compara el $RMSE$ de cada modelo con el del mejor modelo univariado elegido como benchmark. Los resultados se muestran en la *Tabla 1*.

Tabla 1: capacidad predictiva de modelos individuales

RMSE					
Período de pronóstico	ARMA(1,1)	Curva de Phillips-GMM	VAR	Factores totales	Factores nominales
2006:10-2006:12	0.0027	0.0036	0.0031	0.0034	0.0046
2006:7-2006:12	0.0026	0.0039	0.0028	0.0034	0.0043
2006:1-2006:12	0.0033	0.0037	0.0032	0.0036	0.0039
MAE					
Período de pronóstico	ARMA(1,1)	Curva de Phillips	VAR	Factores totales	Factores nominales
2006:10-2006:12	0.0024	0.0035	0.0031	0.0029	0.0043
2006:7-2006:12	0.0022	0.0033	0.0027	0.0028	0.0038
2006:1-2006:12	0.0027	0.0032	0.0025	0.0027	0.0031
MAPE					
Período de pronóstico	ARMA(1,1)	Curva de Phillips	VAR	Factores totales	Factores nominales
2006:10-2006:12	27.33	43.69	36.67	32.96	49.61
2006:7-2006:12	26.93	40.49	35.32	34.95	47.74
2006:1-2006:12	36.15	45.08	31.39	31.51	36.67
estadístico U-Theil					
Período de pronóstico	ARMA(1,1)	Curva de Phillips	VAR	Factores totales	Factores nominales
2006:10-2006:12	1	1.33	1.15	1.23	1.67
2006:7-2006:12	1	1.53	1.09	1.30	1.66
2006:1-2006:12	1	1.12	0.97	1.08	1.18

Una pregunta inmediata es si el modelo univariado supera en forma sistemática a los modelos causales y los multivariados en su capacidad de pronóstico. La respuesta es algo mixta. En un horizonte muy corto, como un trimestre o un semestre, el modelo $ARMA$ supera en forma sistemática al resto de los modelos (el estadístico $U - Theil$ supera 1). Cuando se extiende el horizonte a un año el VAR monetario supera al $ARMA$ (estadístico $U - Theil$ 0.97). En un horizonte de un año el VAR monetario está muy cerca del mejor modelo univariado y supera al modelo $ARMA$.

En forma resumida los resultados indican una complementariedad entre los modelos de pronóstico que puede ser explotada en la medida que se la identifique. Los modelos univariados tienen un muy buen desempeño en horizontes muy cortos. A medida que se extiende el horizonte de pronóstico, los modelos multivariados, tanto aquellos cuyo uso se sustenta en la teoría como los que utilizan factores como medidas resumen de la variabilidad conjunta de distintos indicadores del ciclo, se acercan en su desempeño a los modelos univariados y eventualmente los superan.

4.2. Comparando la capacidad predictiva de modelos alternativos

La evaluación de la capacidad predictiva de los modelos de pronóstico es importante no sólo porque en general son los pronósticos un insumo fundamental para la toma de decisiones de política, sino también porque implica una elección entre hipótesis económicas alternativas.

Como enfatizan Diebold y Mariano (1995), una revisión de la literatura empírica sobre pronóstico permite observar que la evaluación de la capacidad de pronóstico de modelos alternativos se basa usualmente en la comparación de estimaciones puntuales, sin una evaluación de la incertidumbre muestral. El uso de tests estadísticos se dificulta debido a que usualmente existen problemas de correlación serial o contemporánea entre pronósticos de los errores de pronóstico.

Diebold y Mariano proponen un conjunto de tests para evaluar la hipótesis nula de ausencia de diferencias en la capacidad predictiva de dos modelos de pronóstico alternativos. Los tests se basan en la evaluación de la presencia de diferencias significativas entre los modelos y los datos. Los tests propuestos por Diebold y Mariano permiten, en algunos casos, errores de pronóstico no normales, serialmente correlacionados y también correlacionados entre sí en forma contemporánea.

Evaluamos aquí los modelos descritos en la subsección anterior utilizando algunos de los tests propuestos por Mariano y Diebold. Debido a que el ejercicio de pronóstico que se desarrolla considera horizontes no superiores a un año, la evaluación para todos los horizontes se basa principalmente en tests no paramétricos. En el caso de los pronósticos a un año también se evalúa la hipótesis de no diferencia de capacidad predictiva con tests paramétricos.

En muchas aplicaciones en las que se comparan las capacidades predictivas de diferentes modelos la función de pérdida de cada modelo puede representarse por el error de pronóstico o bien en forma general por una función directa del mismo. En este trabajo se considera al propio error de pronóstico como función de pérdida del respectivo modelo. La hipótesis nula de igual capacidad predictiva para dos pronósticos será la distancia entre ambos errores de pronóstico. Para los tres horizontes de pronóstico considerados se utilizan tests adecuados al caso de pocas observaciones de errores de pronóstico: Dos de estos tests están basados en los diferenciales de pérdida observados (el test del signo) o en sus rango (test de signo de rangos de Wilcoxon). Para el caso de un año se complementan los tests previos con tests paramétricos que provee la literatura: un simple test F y el test de Morgan-Granger-Newbold (MGN). En el caso de estos dos últimos tests la función de pérdida está definida como el cuadrado de la distancia entre ambos errores de pronóstico.⁵

Los tests no paramétricos, de signo y de rango de signo de Wilcoxon permiten trabajar con todos los horizontes. En la *Tabla 2* se reporta el número de

⁵En el Apéndice D se presenta una descripción de los tests implementados.

diferencias positivas observadas para los pronósticos de todos los modelos comparados con el modelo *ARMA*. Por ejemplo, en el caso de la curva de Phillips y para un horizonte de 1 año, el número 5 en la columna del test de signos indica que de las 12 diferencias del error de pronóstico de la curva de Phillips respecto del *ARMA*, 5 son positivas. De acuerdo a una distribución binomial con parámetros $T = 12$ y $1/2$, bajo la hipótesis nula, ambos modelos no se diferencian en su capacidad predictiva. Este resultado se repite para el resto de los modelos y horizontes de pronóstico. En el caso del test de signos de Wilcoxon la versión estudentizada permite utilizar la distribución normal estándar y al 5% de significatividad no se rechaza la hipótesis de igual capacidad predictiva, con excepción del modelo de factores nominales para el horizonte de 1 año. El rechazo implica en este caso que el modelo *ARMA* supera en capacidad predictiva al de factores nominales.⁶

Los tests paramétricos requieren del cumplimiento de algunos supuestos respecto de los errores de pronóstico: (i) que la función de pérdida sea cuadrática; (ii) que los errores de pronóstico tengan media 0; (iii) que tengan una distribución normal; (iv) que no estén correlacionados serialmente y (v) que no se correlacionen contemporáneamente entre sí. El test MGN permite correlación contemporánea entre los errores de pronóstico. En el caso del test F, cuando se comparan los valores del estadístico observado con los valores críticos para una $F(12,12)$, se encuentra que no se rechaza la hipótesis nula al 5%. Los resultados del test MGN no son muy diferentes cuando se evalúa la hipótesis nula considerando la distribución t de student con $T-1$ grados de libertad. Es decir, para ambos tests la capacidad predictiva de los modelos no es estadísticamente distinta respecto del modelo *ARMA*.

⁶El test se calculó para los horizontes de 6 y 12 meses, dado que requiere simetría en la función de pérdida.

Tabla 2
Comparación de capacidad predictiva respecto de Modelo ARMA

Modelo de pronóstico	Test de Signo (1)	Test de signo de rangos de Wilcoxon (2)	Test F	Test de Morgan-Granger-Newbold
<i>Curva de Phillips</i>				
3 meses	2			
6 meses	4	-1.3628		
1 año	5	-0.3922	1.3845	1.0635
<i>VAR monetario</i>				
3 meses	2			
6 meses	3	-1.5724		
1 año	5	-0.4707	0.9362	0.1390
<i>Factores totales</i>				
3 meses	2			
6 meses	4	-1.3628		
1 año	7	0.4707	1.4020	0.4186
<i>Factores nominales</i>				
3 meses	3			
6 meses	6	-0.9435		
1 año	10	2.3534	1.7828	0.4844

(1) Parámetros de la distribución binomial T (cantidad de períodos a pronosticar) y 1/2

(2) Estadístico basado en Wilcoxon es su versión asintótica normal *estudentizada*

En resumen, los tests indican que ningún modelo supera para todos los horizontes al resto en capacidad predictiva. Este resultado sugeriría la posibilidad de trabajar con una combinación o *pooling* de pronósticos, teniendo en cuenta que cada uno de los modelos considerados puede contener información relevante para el pronóstico. También se puede pensar que estos modelos pueden ser complementarios en el pronóstico en el sentido que permiten responder a distintas preguntas y a guiar diferentes decisiones de política. Por ejemplo, el *VAR* monetario permite responder a un pregunta relevante como cuál es el rezago con que los impulsos monetarios se transmiten a los precios o la curva de Phillips es informativa acerca del impacto de cambios en la brecha del producto sobre la tasa de inflación. Timmermann (2003) señala que, a menos que uno pueda identificar ex-ante un modelo con mejor capacidad predictiva que sus competidores, la combinación de pronósticos ofrece ganancias de diversificación que la hacen atractiva por sobre los pronósticos derivados de un modelo individual.

Considerar una combinación de estos pronósticos presenta ventajas en varios sentidos: (i) la combinación de pronósticos ofrece diversificación. Intuitivamente, si se tiene una función de pérdida cuadrática, aún cuando uno de los modelos supere al otro en capacidad predictiva, una combinación lineal de ellos, al generar una pérdida menor puede ser preferida; (ii) para economías sujetas a cambios estructurales la combinación de pronósticos provee una mejor predicción por sobre el mejor modelo individual. En general, las velocidades de adaptación a cambios estructurales de los modelos suele diferir. En ese sentido combinar modelos con distinta adaptabilidad al cambio puede superar a los modelos individuales (iii) La combinación de pronóstico puede ser vista como un modo de hacer más robusto el pronóstico frente al sesgo de especificación y los errores

de medición de las variables de los pronósticos individuales. Por ejemplo, si dos pronósticos tiene sesgos diferentes, en direcciones opuestas, es fácil pensar que la combinación puede generar un mejora en el pronóstico.⁷

En base a lo sugerido por Marcellino (2002), construimos combinaciones lineales de pronósticos en base a promedios ponderados, con ponderadores calculados del siguiente modo

$$\hat{y}_{t+h} = \sum_{m=1}^M k_{m,h,t} \hat{y}_{t+h,m}, \text{ con } k_{m,h,t} = \left(\frac{1}{RMSE_{m,h,t}} \right)^w / \sum_{j=1}^M \left(\frac{1}{RMSE_{j,h,t}} \right)^w \quad (4)$$

donde m indexa los modelos, $k_{m,h,t}$ denota los ponderadores y $RMSE$ es el error cuadrático medio.

Los ponderadores de cada modelo son elegidos de manera inversamente proporcional a sus estadísticos de capacidad predictiva en el caso de $w=1$ en la ecuación 4. También consideramos el caso de $w = 5$, en el que una mayor ponderación se asigna a los modelos con mejor capacidad predictiva.

En nuestro caso las combinaciones se realizaron para todos los modelos y usando para las ponderaciones los tres estadísticos de capacidad predictiva antes mencionados: $RMSE$, MAE y $MAPE$.

En la *Tabla 3* se presentan: los $RMSE$, los MAE , los $MAPE$ y el $U-Theil$ para combinaciones ponderadas con $w = 1$ y $w = 5$ usando como ponderadores los respectivos $RMSE$, MAE y $MAPE$ de cada modelo. El estadístico $U-Theil$ se computa relativo al $ARMA$.

⁷Para una revisión detallada de las ventajas de la combinación de pronósticos ver Hendry y Clements (2002). Marcellino (2002) y Timmermann (2006).

Tabla 3

RMSE						
Forecast Period	w=1			w=5		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
2006:10-2006:12	0.0032	0.0032	0.0031	0.0028	0.0028	0.0028
2006:7-2006:12	0.0030	0.0030	0.0030	0.0027	0.0027	0.0027
2006:1-2006:12	0.0034	0.0034	0.0034	0.0032	0.0033	0.0034
MAE						
Forecast Period	w=1			w=5		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
2006:10-2006:12	0.0030	0.0030	0.0030	0.0024	0.0024	0.0023
2006:7-2006:12	0.0027	0.0027	0.0027	0.0023	0.0023	0.0023
2006:1-2006:12	0.0027	0.0027	0.0027	0.0026	0.0026	0.0026
MAPE						
Forecast Period	w=1			w=5		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
2006:10-2006:12	34.61	34.47	34.16	27.15	26.20	24.99
2006:7-2006:12	55.79	55.69	55.81	46.37	45.40	45.50
2006:1-2006:12	32.53	32.45	32.44	31.28	30.92	30.95
estadístico U-Theil						
Forecast Period	w=1			w=6		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
2006:10-2006:12	1.160	1.156	1.154	1.031	1.025	1.024
2006:7-2006:12	1.180	1.179	1.181	1.051	1.047	1.050
2006:1-2006:12	1.010	1.012	1.019	0.973	0.984	1.020

Los resultados indican que la combinación de pronósticos supera al mejor pronóstico individual para un horizonte de un año y con ponderadores más que inversamente proporcionales de los mejores modelos individuales. Este resultado es de utilidad a los fines prácticos pues el horizonte de un año es el relevante para la toma de decisiones de política económica. La posibilidad de combinar modelos tanto univariados como multivariados permite además responder a preguntas específicas de política económica.

5. Conclusiones

Estimamos una variedad de modelos de inflación a los fines de pronóstico que incluyen desde modelos univariados, modelos causales basados en teorías alternativas de la inflación y modelos basados en el uso de factores o medidas resumidas de la variabilidad conjunta de un gran número de series económicas. Encontramos que si bien el modelo univariado es en general el de mejor desempeño, a medida que se extiende el horizonte de pronóstico, los modelos multivariados se acercan al desempeño de los univariados. En particular un *VAR* monetario llega a superar al modelo *ARMA* univariado para el horizonte de un año, si se comparan las estimaciones puntuales de distintos estadísticos calculados para evaluar la capacidad predictiva de los modelos. Sin embargo, cuando se calculan tests para evaluar la significatividad estadística de las diferencias en capacidad predictiva de los modelos, tomando como benchmark un modelo *ARMA* univariado, las diferencias no resultan significativas. Finalmente se combinan los modelos estimados mediante un pool de pronósticos utilizando como

ponderadores los inversos de los $RMSE$, $MAPE$ y MAE de los respectivos modelos. Los resultados indican que alguna de las combinaciones de pronósticos supera al mejor pronóstico individual para un horizonte de un año. Teniendo en cuenta que el horizonte de un año es el relevante para la toma de decisiones de política económica, la posibilidad de combinar modelos tanto univariados como multivariados para pronóstico es interesante porque permite además responder a preguntas específicas de política económica.

Referencias

- [1] Ahumada, H. y L. Garegnani, (2007), "Forecasting a monetary aggregate in a changing environment: Argentina after 2002", mimeo.
- [2] Atkenson, A. y L. Ohanian, (2001), "Are Phillips Curve Useful for Forecasting Inflation". *Federal Reserve Bank of Minneapolis, Quarterly Review*, 25 (1), 2-11.
- [3] Canova, F. (2002), "G-7 Inflation Forecasts", *European Central Bank*, WP N°151.
- [4] Bates, J.M. y C.W.I. Granger, (1969), "The combination of forecasts", *Operations Research Quarterly* 20, 451-468.
- [5] Clements, M. y D. Hendry, (2006) "Forecasting with breaks." *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann, eds., Capítulo 12, Vol. 1, North-Holland.
- [6] D'Amato, L., L. Garegnani y J.Sotes, (2007), "Inflation persistence and changes in the monetary regime: The argentine case", BCRA Working Paper N° 23, Sep. 2007.
- [7] D'Amato, L. y L. Garegnani, (2006), "The Short -run Dynamics of Inflation: Estimating a "Hybrid New Keynesian Phillips Curve" for Argentina", en colaboración con Lorena Garegnani. *Monetaria*, Volumen X, CEMLA.
- [8] Diebold, F.X. y R.S. Mariano, (1995), "Comparing Predictive Accuracy", *Journal of Business & Economic Statistics* 13, 253-263.
- [9] Diebold F.X. y P. Pauly, (1990), "Structural change and the combination of forecasts", *Journal of Forecasting*, 6, 503-508.
- [10] Galí J. y M. Gertler, (1999), "Inflation Dynamics: A structural econometric analysis", *Journal of Monetary Economics*, vol. pp. 195-222.
- [11] Granger y Ramanathan, (1984), "Improved methods of forecasting", *Journal of Forecasting*, 3, 197-204.
- [12] Elliot, G., C. Granger y A. Timmermann, eds., (2006), *Handbook of Economic Forecasting*, Vol. 1, North-Holland.
- [13] Kendall, M. (1975), *Multivariate Analysis*, Charles Griffin & Company Ltd.
- [14] Hendry, D.F. y Clements, M.P., (2002), "Pooling of forecasts", *Econometrics Journal* 5, 1-26.
- [15] Marcellino, M., (2002), "Forecasting pooling for short time series of macroeconomic variables", *Oxford Bulletin of Economics and Statistics* 66, 91-112.

- [16] Morgan, W.A. (1939-1940), ".^A test for the Significance of the Difference Between Two Variances in a Sample from a Normal Bivariate Population", *Biometrika*, 31, 13-19.
- [17] Press, S.J., (1972), *Applied Multivariate Analysis*, Holt, Rinehart y Witson, Inc.un
- [18] Stock, J. y M. Watson, (2006), "Forecasting with many predictors", en *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann, eds., Capítulo 10, Vol. 1, North-Holland.
- [19] —————, (2005), "Why has U.S. Inflation become harder to forecast?", WP N°12324, *NBER*.
- [20] —————, (2002a), "Macroeconomic Forecasting using diffusion indexes", *Journal of Business and Economic Statistics* 20, 147-162.
- [21] —————, (1999), "Forecasting Inflation", *Journal of Monetary Economics*,44:293-3
- [22] Timmermann, A., (2006), "Forecast combinations", en *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann, eds., Capítulo 10, Vol. 1, North-Holland.

A. El método de componentes principales

La metodología de componentes principales permite obtener una medida sintética de la variabilidad conjunta de una colección de variables aleatorias relacionadas, a partir de calcular aquellas combinaciones lineales de estas variables cuya varianza es máxima.⁸

Dado un conjunto de n variables aleatorias que se conoce están relacionadas, se espera que un número relativamente reducido de combinaciones lineales de éstas –los componentes principales– pueda explicar una gran proporción de su variabilidad total. En ese sentido, el método permite resumir en un conjunto reducido de $q < n$ componentes principales y sus varianzas la información contenida en un vector $X : nx1$ de variables aleatorias y su matriz de varianzas y covarianzas Σ

Dado un vector de variables aleatorias $X : nx1$ con $E(X) = \Phi$, $var(X) = \Sigma$ es posible definir $\alpha \equiv (\alpha_i)$ como un vector de ponderadores desconocidos de los componentes de X y z como un vector tal que

$$z_1 = X'\alpha \text{ con } z = \sum_{i=1}^n \alpha_i X_i$$

Si los elementos de X están medidos en las mismas unidades es posible imponer:

$$\alpha'\alpha = \sum_{i=1}^n \alpha_i = 1$$

De esta manera es posible encontrar un vector de ponderadores α tal que maximice $var(z_1) = \alpha'\Sigma\alpha$, sujeto a $\alpha'\alpha = 1$

Entonces el problema de:

$$\begin{aligned} & \underset{\alpha}{\text{máx}}(\alpha'\Sigma\alpha) \\ & \text{s.a. } \alpha'\alpha = 1 \end{aligned} \tag{1}$$

puede escribirse como

$$L = \alpha'\Sigma\alpha - \lambda(\alpha'\alpha - 1)$$

Diferenciando L con respecto a α e igualando a 0 se tiene que

$$\frac{\partial L}{\partial \alpha} = 2\Sigma\alpha - 2\lambda\alpha = 0$$

y

$$(\Sigma - \lambda I)\alpha = 0 \tag{2}$$

⁸Para una descripción detallada de la técnica de análisis multivariado de componentes principales ver Press (1972) y Kendall (1975).

y dado que

$$\alpha \neq 0$$

Existe una solución si

$$|\Sigma - \lambda I| = 0 \tag{3}$$

Esto implica que λ es una raíz característica de la matriz de varianzas y covarianzas de X , Σ , y α es un vector característico de esa matriz. Dado que Σ es una matriz $n \times n$ existen n raíces características λ que satisfacen 3 y n combinaciones lineales ortogonales asociadas a n vectores característicos α . Teniendo en cuenta 2

$$\Sigma\alpha = \lambda\alpha$$

y premultiplicando por α'

$$\alpha'\Sigma\alpha = \lambda\alpha'\alpha = \lambda$$

El mayor valor de λ es aquel que maximiza la varianza de z . La solución al problema 1 está dada por (α_1, λ_1) ; y z_1 se conoce como el primer componente principal de ese conjunto de variables aleatorias.

B. Detalle de las series del ciclo utilizadas para el cálculo de factores

Todas las series utilizadas han sido desestacionalizadas utilizando el programa X-12 ARIMA y posteriormente estandarizadas.

Factor de demanda	
Series	Factor
ISE (indicador sintético de energía) desestacionalizado	Demanda/consumo
Supermercados Volumen de ventas a precios constantes (desestacionalizada)	Demanda/consumo
Centros de Compras Volumen de ventas a precios constantes (desestacionalizada)	Demanda/consumo
Estadísticas de Servicios Públicos - Índice Sintético General	Demanda/consumo
Importaciones desestacionalizadas	Demanda/consumo
Automotores al Merc. Interno ventas unidades	Demanda/consumo
Automotores Prod. Nac. al Merc. Interno ventas unidades	Demanda/consumo
Automóviles Importaciones unidades	Demanda/consumo
Ventas Azúcar Miles tns.	Demanda/consumo
Ventas Cerveza Miles hls.	Demanda/consumo
Ventas Vino Miles hls.	Demanda/consumo
Ventas Gaseosas Miles hls.	Demanda/consumo
Ventas Cigarrillos Mill. paquet.	Demanda/consumo
Ventas Productos Farmacéut. Mill. unidad.	Demanda/consumo
Ventas Naftas Miles m3	Demanda/consumo
Ventas Cemento Desp.al merc.int. Miles tns.	Demanda/consumo
Ventas Asfalto Miles TN	Demanda/consumo
Ventas Automóviles Unidades	Demanda/consumo
Ventas Automóviles Utilitarios Unidades	Demanda/consumo
Ventas Automóviles Carga y Pasaj. Unidades	Demanda/consumo
Ventas Energía Demandada GWh	Demanda/consumo

Factor de oferta

UCI FIEL industria manufacturera	Producción/Oferta
UCI FIEL bienes de consumo no durables	Producción/Oferta
UCI FIEL bienes de consumo durables	Producción/Oferta
UCI FIEL bienes de capital	Producción/Oferta
UCI FIEL bienes de uso intermedio	Producción/Oferta
Encuesta FIEL situacion general industria manufacturera	Producción/Oferta
Encuesta FIEL situacion general bienes de consumo no durables	Producción/Oferta
Encuesta FIEL situacion general bienes de consumo durables	Producción/Oferta
Encuesta FIEL situacion general bienes de capital	Producción/Oferta
Encuesta FIEL situacion general bienes de uso intermedio	Producción/Oferta
Encuesta FIEL perspectiva proximos meses industria manufacturera	Producción/Oferta
Encuesta FIEL perspectiva proximos meses bienes de consumo no durables	Producción/Oferta
Encuesta FIEL perspectiva proximos meses bienes de consumo durables	Producción/Oferta
Encuesta FIEL perspectiva proximos meses bienes de capital	Producción/Oferta
Encuesta FIEL perspectiva proximos meses bienes de uso intermedio	Producción/Oferta
Encuesta FIEL tendencia de demanda industria manufacturera	Producción/Oferta
Encuesta FIEL tendencia de demanda bienes de consumo no durables	Producción/Oferta
Encuesta FIEL tendencia de demanda bienes de consumo durables	Producción/Oferta
Encuesta FIEL tendencia de demanda bienes de capital	Producción/Oferta
Encuesta FIEL tendencia de demanda bienes de uso intermedio	Producción/Oferta
Encuesta FIEL nivel de stocks industria manufacturera	Producción/Oferta
Encuesta FIEL nivel de stocks bienes de consumo no durables	Producción/Oferta
Encuesta FIEL nivel de stocks bienes de consumo durables	Producción/Oferta
Encuesta FIEL nivel de stocks bienes de capital	Producción/Oferta
Encuesta FIEL nivel de stocks bienes de uso intermedio	Producción/Oferta

Factor de oferta (continuación)

Automóviles Exportaciones unidades	Producción/Oferta
EMI (estimador mensual de industria) desestacionalizado	Producción/Oferta
EMAE (estimador mensual de actividad económica) desestacionalizado	Producción/Oferta
IPI (índice de producción industrial) nivel general	Producción/Oferta
IPI (índice de producción industrial) bienes de consumo no durables	Producción/Oferta
IPI (índice de producción industrial) bienes de consumo durables	Producción/Oferta
IPI (índice de producción industrial) bienes de uso intermedio	Producción/Oferta
IPI (índice de producción industrial) bienes de capital	Producción/Oferta
IPI (índice de producción industrial) alimentos y bebidas	Producción/Oferta
IPI (índice de producción industrial) cigarrillos	Producción/Oferta
IPI (índice de producción industrial) insumos textiles	Producción/Oferta
IPI (índice de producción industrial) pasta y papel	Producción/Oferta
IPI (índice de producción industrial) combustible	Producción/Oferta
IPI (índice de producción industrial) químicos y plásticos	Producción/Oferta
IPI (índice de producción industrial) minerales no metálicos	Producción/Oferta
IPI (índice de producción industrial) siderurgia	Producción/Oferta
IPI (índice de producción industrial) metalmeccánica	Producción/Oferta
IPI (índice de producción industrial) automóviles	Producción/Oferta
Total Automotores producción unidades	Producción/Oferta
Automóviles producción unidades	Producción/Oferta
Cemento Despachos Totales	Producción/Oferta

Factor de oferta (continuación)

Producción Hierro Primario Miles Tn.	Producción/Oferta
Producción Acero Crudo Miles Tn.	Producción/Oferta
Producción Petróleo Crudo Miles M3	Producción/Oferta
Producción Petróleo Procesado Miles M3	Producción/Oferta
Producción Gas Natural Mill. M3	Producción/Oferta
Producción Harina de Trigo Miles Tns.	Producción/Oferta
Producción Aceites Vegetales Miles Tns.	Producción/Oferta
Producción Subproductos Oleaginosos Miles Tns.	Producción/Oferta
Producción Galletitas y Bizcochos Miles Tns.	Producción/Oferta
Producción Faena Carne Vacuna Miles cab.	Producción/Oferta
Producción Faena Aves Mills. aves	Producción/Oferta
Producción Bebidas Espirituosas Miles Litros	Producción/Oferta
Producción Hilados Celulósicos Tns.	Producción/Oferta
Producción Pastas Para Papel Miles Tns.	Producción/Oferta
Producción Papel para Diarios Toneladas	Producción/Oferta
Producción Jabones Tocad y Lavar Toneladas	Producción/Oferta
Producción Neumáticos Miles Unid.	Producción/Oferta
Producción Urea Miles Tns.	Producción/Oferta
Producción Soda Caústica Miles Tns.	Producción/Oferta
Producción P.V.C. Miles Tns.	Producción/Oferta
Producción Etileno Miles Tns.	Producción/Oferta
Producción Polietileno Miles Tns.	Producción/Oferta
Producción Polipropil. Miles Tns.	Producción/Oferta
Producción Sec-Butanol Ton.	Producción/Oferta
Producción Isopropanol Ton.	Producción/Oferta
Producción Acido Sulfúrico Miles Tns.	Producción/Oferta
Producción Cloro Miles Tns.	Producción/Oferta
Producción Naftas Miles M3	Producción/Oferta
Producción Gas Oil Miles M3	Producción/Oferta
Producción Fuel Oil Miles Tns.	Producción/Oferta
Producción Caucho Sint. Ton.	Producción/Oferta
Producción Negro de Humo Ton.	Producción/Oferta
Producción Pinturas para Construcción Ton.	Producción/Oferta
Producción Cemento Portland Miles Ton.	Producción/Oferta
Producción Hierro redondo p/hormigón Ton.	Producción/Oferta
Producción Automotores Utilitarios Unidades	Producción/Oferta
Producción Automotores Carga y Pasaj. Unidades	Producción/Oferta
Producción Lam. Frío Miles Tn.	Producción/Oferta
Producción Laminados en Caliente No Planos Miles Tn.	Producción/Oferta
Producción Laminados en Caliente Planos Miles Tn.	Producción/Oferta
Producción Zink Electrolítico Ton.	Producción/Oferta
Producción Tractores Unidades	Producción/Oferta

Factor nominal

Tasas Depositos en pesos En Caja	Tasas/Precios/Nom
Tasas A Plazo Fijo 30 a 59 d.	Tasas/Precios/Nom
Tasas 60 d. o más	Tasas/Precios/Nom
Tasas Depositos en dolares En Caja	Tasas/Precios/Nom
Tasas A Plazo Fijo 30 a 59 d.	Tasas/Precios/Nom
Tasas 60 d. o más	Tasas/Precios/Nom
ITCRM dic2001=100	Tasas/Precios/Nom
IPC Nivel general	Tasas/Precios/Nom
IPC alimentos y bebidas	Tasas/Precios/Nom
IPC indumentaria	Tasas/Precios/Nom
IPC vivienda y serv. básicos	Tasas/Precios/Nom
IPC equipamiento y mantenimiento del hogar	Tasas/Precios/Nom
IPC atención médica y gastos para la salud	Tasas/Precios/Nom
IPC transporte y comunicaciones	Tasas/Precios/Nom
IPC esparcimiento	Tasas/Precios/Nom
IPC educación	Tasas/Precios/Nom
IPC otros bienes y servicios varios	Tasas/Precios/Nom
Indice de precios internos al por mayor (IPIM) Nivel general	Tasas/Precios/Nom
IPIM Productos nacionales Total	Tasas/Precios/Nom
IPIM Productos nacionales Primarios	Tasas/Precios/Nom
IPIM Productos nacionales Manufacturados y Energía eléctrica	Tasas/Precios/Nom
IPIM Productos Importados	Tasas/Precios/Nom
Indice de precios internos básicos al por mayor (IPIB) Nivel general	Tasas/Precios/Nom
IPIB Productos nacionales Total	Tasas/Precios/Nom
IPIB Productos nacionales Primarios	Tasas/Precios/Nom
IPIB Productos nacionales Manufacturados y Energía eléctrica	Tasas/Precios/Nom
IPIB Productos Importados	Tasas/Precios/Nom
Indice de precios básicos del productor (IPP) Nivel general	Tasas/Precios/Nom
IPP Productos nacionales Primarios	Tasas/Precios/Nom
IPP Productos nacionales Manufacturados y Energía eléctrica	Tasas/Precios/Nom
Recaudación Tributaria IVA dgi	Tasas/Precios/Nom
Recaudación Tributaria derechos importación	Tasas/Precios/Nom
ByM privado fin de mes	Tasas/Precios/Nom
M1 amplio privado fin de mes	Tasas/Precios/Nom
M2 amplio privado fin de mes	Tasas/Precios/Nom
M3 amplio privado fin de mes	Tasas/Precios/Nom
Merval al cierre del mes	Tasas/Precios/Nom
Merval promedio mensual	Tasas/Precios/Nom
ByM total promedio de mes	Tasas/Precios/Nom
M1 amplio total promedio de mes	Tasas/Precios/Nom
M2 amplio total promedio de mes	Tasas/Precios/Nom
M3 amplio total promedio de mes	Tasas/Precios/Nom
Recaudación Tributaria IVA dga	Tasas/Precios/Nom

C. Modelos de pronóstico

En la *Tabla C* se presentan los modelos de pronóstico estimados

Tabla C

ARMA(1,12)		Curva de Phillips		Modelos de pronóstico		Factores totales		Factores nominales		
variable dependiente: inflación		variable dependiente: inflación		var.dep.	D(LM2)	D(LIPC)				
C	0.0012	INFLA(-1)	0.57714	D(LM2(-1))	0.0669	-0.0009	C	C	0.00491	
	0.0005		0.06337		-0.0866	-0.0170			0.00034	
INFLA(-1)	0.4605	INFLA(1)	0.18159	D(LM2(-2))	0.0687	0.0458	FT1	FN1	0.00294	
	0.0587		0.04029		-0.0680	-0.0134		FN1(-1)	0.00015	
DUM0219	0.0149	GAP(-1)	0.00972	D(LM2(-3))	-0.0865	0.0325	FT1(-1)	FN1(-1)	-0.00066	
	0.0020		0.00299		-0.0742	-0.0146			0.00017	
DJM024	0.0654	DEVNOM(-1)	0.02346	D(LM2(-4))	0.0643	-0.0006	FT2	FN1(-3)	0.00032	
	0.0037		0.00891		-0.0733	-0.0144		FN1(-2)	0.00012	
DUM025	-0.0182	DIPPUSA(-1)	0.21346	D(LIPC(-1))	-0.0273	0.3293	FT2(-3)	FN2	0.00558	
	0.0055		0.05667		-0.3322	-0.0652		FN2(-3)	0.00013	
MA(12)	0.4854	D021	0.01983	D(LIPC(-2))	-0.3874	0.1482	FT3(-3)	FN2(-3)	-0.00026	
	0.0768		0.00578		-0.2741	-0.0538			0.00016	
		D024	0.06581	D(LIPC(-3))	0.6492	0.0381	FT4	FN4	-0.00106	
			0.00254		-0.2592	-0.0509			0.00016	
		D025	-0.02662	D(LIPC(-4))	0.4841	0.0539	FT4(-3)			
			0.00605		-0.2148	-0.0422				
		D031	0.01320	C	0.0824	0.0014				
			0.00214		-0.0051	-0.0010				
				D0219	-0.0561	0.0039				
					-0.0146	-0.00239				
				D0112	0.2721	0.0025				
					-0.0199	-0.0039				
				D017	-0.0767	-0.0039				
					-0.0184	-0.0036				
				D022	0.1228	0.0084				
					-0.0343	-0.0067				
				D024	0.0571	0.0624				
					-0.0311	-0.0061				
				D013	-0.0529	0.0038				
					-0.0182	-0.0036				
				D0110	-0.0484	0.0024				
					-0.0193	-0.0038				
				D021	0.3036	0.0144				
					-0.0355	-0.0070				
				D018	-0.0845	0.0012				
					-0.0195	-0.0038				
Sample (adj.): 1993M01 2005M12		Sample (adj.): 1994M02 2005M12		Sample (adj.): 1994M02 2005M12			Sample (adj.): 1997M05 2005M12	Sample (adj.): 1994M02 2005M12		
Inc. obs.: 156 after adj.		Inc. obs.: 143 after adj.		Inc. obs.: after adj.			Inc. obs.: 104 after adj.	Inc. obs.: 143 after adj.		
R-sq	0.8757	R-sq	0.8896	R-sq	0.8878	0.9163	R-sq	R-sq	0.9348	
Adj R-sq	0.8715	Adj R-sq	0.8831	Adj R-sq	0.8643	0.8988	Adj R-sq	Adj R-sq	0.9307	
S.E. of reg	0.0039	S.E. of reg	0.0039	Sum sq. res.	0.0401	0.0015	Sum sq. resid.	Sum sq. resid.	0.0011	
SSR	0.0023	J-statistic	0.11391	S.E. equation	0.0173	0.0034	Log likelihood	Log likelihood	447.1775	
Log likelihood	646.9661			F-statistic	37.8511	52.4099	D-W stat	D-W stat	1.8559	
D-W stat	1.7273			Log likelihood	446.0620	711.4081	Akaike inf crit	Akaike inf crit	-8.4650	
Akaike inf c	-8.217513			Akaike AIC	-5.1173	-8.3731	Schwarz crit.	Schwarz crit.	-8.2870	
Schwarz c	-8.100211			Schwarz SC	-4.5669	-7.8227	F-statistic	F-statistic	231.6595	
F-statistic	211.3005			Log likelihood		1157.5180				
				Akaike information criterion		-13.4910				
				Schwarz criterion		-12.3902				

D. Tests para comparar capacidad predictiva

D.1. Tests para muestras finitas

1. Test de Signo

Dado el diferencial de pérdidas d_t , entre dos modelos i y j , definido como

$$d_t = [g(e_{it}) - g(e_{jt})]$$

La hipótesis nula del test es que la mediana del diferencial de pérdidas es 0

$$med(g(e_{it}) - g(e_{jt})) = 0$$

Suponiendo que el diferencial de pérdidas es una variable *iid*, el número de diferenciales positivos en una muestra de tamaño T sigue una distribución

binomial con parámetros $T, \frac{1}{2}$ bajo la hipótesis nula. El estadístico del test es entonces

$$S_1 = \sum_{t=1}^T I_+(d_t)$$

donde

$$\begin{aligned} I_+(d_t) &= 1 && \text{si } d_t > 0 \\ &= 0 && \text{de lo contrario} \end{aligned}$$

La significatividad del estadístico puede verificarse en la tabla de la distribución binomial acumulada.

2. Test de signo de rangos de Wilcoxon

Este test no paramétrico requiere de simetría en el diferencial de pérdidas. Nuevamente se supone que el diferencial de pérdidas es *iid*.

El estadístico del test es la suma de los rangos del valor absoluto de las diferencias positivas.

$$S_2 = \sum_{t=1}^T I_+(d_t) \text{ rango}(|d_t|)$$

La distribución estudentizada del estadístico S_2 se distribuye asintóticamente como una normal estándar.

$$S_{2std} = \frac{S_2 - \frac{T(T+1)}{4}}{\sqrt{\frac{T(T+1)(2T+1)}{24}}} \approx N(0, 1)$$

3. Test F

Si (i) la pérdida es cuadrática; (ii) los errores de pronóstico tiene media 0 y (iii) tienen una distribución normal; (iv) no están correlacionados serialmente y (v) no se correlacionan contemporáneamente entre sí, el ratio de las varianzas muestrales sigue la distribución F bajo la hipótesis nula de no diferencia de capacidad predictiva. El estadístico a evaluar

$$F = \frac{\frac{e_i \hat{e}_i}{T}}{\frac{e_j \hat{e}_j}{T}} = \frac{e_i \hat{e}_i}{e_j \hat{e}_j}$$

se distribuye como una $F(T, T)$.

4. Test de Morgan-Granger-Newbold

Granger y Newbold (1977) buscan solucionar el problema de la correlación contemporánea entre los errores de pronóstico en base a una transformación ortogonal propuesta por Morgan (1939). Definiendo $x_t = (e_{it} + e_{jt})$ y $z_t = (e_{it} - e_{jt})$. Manteniendo los supuestos (i) a (iv), la hipótesis nula de igual capacidad predictiva entre los modelos i y j es equivalente a una correlación 0 entre x y z , es decir $\rho_{zx} = 0$. El estadístico

$$MNG = \frac{\widehat{\rho}_{zx}}{\sqrt{\frac{1 - \widehat{\rho}_{zx}^2}{T-1}}}$$

se distribuye como una t de Student con $T-1$ grados de libertad.