




**CENTRO DE
ESTUDIOS
MONETARIOS
LATINOAMERICANOS**

Asociación Regional de Bancos Centrales

MONETARIA

Volumen XXXIII, número 1

Enero-marzo de 2010



CEMLA

ASAMBLEA

Bancos Centrales Asociados (*vox et votum*)

Miembros Colaboradores (*vox*)

JUNTA DE GOBIERNO, 2009-2011

Presidente:

Banco de la República (Colombia)

Miembros:

Banco Central de la República Argentina

Banco Central do Brasil

Banco de México

Banco Central de Nicaragua

Central Bank of Trinidad and Tobago

Banco Central de Venezuela

COMITÉ EDITORIAL

Javier Guzmán Calafell

Director General

Luis Barbosa

Subdirector General

Fernando Sánchez Cuadros

Reuniones Técnicas de Banca Central

Ana-Laura Sibaja Jiménez

Servicios de Información

MONETARIA es una publicación trimestral del Centro de Estudios Monetarios Latinoamericanos, Durango n° 54, México, D. F., 06700. Impresa en los talleres de Master Copy, S. A. de C. V., Av. Coyoacán n° 1450, Col. Del Valle, México D. F., 03220. 380 ejemplares. ISSN 0185-1136.

MONETARIA

VOLUMEN XXXIII, NÚMERO 1, ENERO-MARZO DE 2010

Carlos Mora Gómez
Adolfo Rodríguez Vargas

1 Combinación de proyecciones de inflación:
nuevas metodologías

Oknan Bello Dinartes

41 Combinación de pronósticos de inflación en
Nicaragua

Miguel E. Dorta
José A. Zambrano

75 Pronósticos factoriales en Venezuela: inflación
y actividad económica

Eliana González M.
Alejandro Reyes G.

101 Una comparación empírica de diferentes en-
foques de combinación de pronósticos: el caso
de la inflación en Colombia

MONETARIA difunde estudios de investigadores de bancos centrales, instituciones financieras internacionales, universidades y otras instituciones; incluye temas especializados en economía y banca central, con un enfoque teórico o cuantitativo. Se publica en forma impresa y electrónica (www.cemla.org). Consultas dirigirse a: publicaciones@cemla.org. (Los trabajos firmados son responsabilidad de los autores y no coinciden necesariamente con el punto de vista del Centro de Estudios Monetarios Latinoamericanos.)

Carlos Mora Gómez
Adolfo Rodríguez Vargas

Combinación de proyecciones de inflación: nuevas metodologías

I. INTRODUCCIÓN

Ante la decisión de la Junta Directiva del Banco Central de Costa Rica (BCCR) de migrar a un régimen monetario de meta explícita de inflación, los pronósticos de inflación cada vez juegan un papel más importante en la programación macroeconómica del BCCR. Para darle seguimiento a la efectividad de su política, contrastando la evolución de la inflación en el corto y mediano plazo con el nivel meta anunciado, el BCCR realiza pronósticos mediante una batería de modelos. En la actualidad, los modelos utilizados para tal fin son: modelo univariable de inflación, modelo vector autorregresivo lineal de mecanismos de transmisión de la política monetaria, modelo impacto de los precios del petróleo en Costa Rica, Modelo

Publica el CEMLA, con la debida autorización, el estudio de C. Mora Gómez y A. Rodríguez Vargas, funcionarios del Banco Central de Costa Rica, presentado en la XIV Reunión de la Red de Investigadores de Bancos Centrales del Continente Americano, auspiciada por el Banco Central de Brasil, celebrada en Salvador, Bahía, del 11 al 13 de noviembre de 2009. Las ideas expresadas en este documento son responsabilidad de los autores y no necesariamente representan la opinión del Banco Central de Costa Rica.

de títulos fiscales, modelo de *pass-through* del tipo de cambio en Costa Rica y modelo ingenuo. La especificación y estimación de estos modelos individuales de pronóstico son revisadas periódicamente.

La literatura económica ha demostrado, en general, que es mejor usar una mezcla de los pronósticos en vez de uno solo de ellos (Bates y Granger, 1969). Para este fin, la División Económica dispone de un método de combinación lineal de pronósticos de inflación que incorpora la información de los diferentes modelos y produce un nuevo y mejor pronóstico (Hoffmaister *et al.*, 2001).

En vista de que la combinación utilizada en el BCCR ha estado vigente durante cerca de siete años y que la revisión más reciente de los modelos de pronóstico individual se realizó en 2008, es necesario considerar una actualización de la combinación de proyecciones de inflación.

Para que una combinación tenga un buen desempeño en términos de precisión es necesario un comportamiento adecuado de los errores de pronóstico de cada uno de los modelos utilizados, así como de la serie a pronosticar. Además, es deseable que se tome en consideración la posibilidad de cambios estructurales en los datos utilizados.

Para el periodo comprendido de 1991 a 2008, el promedio de la inflación interanual para Costa Rica se ubica en 13.5%. Durante ese lapso es posible identificar subperiodos en los que la evolución de esta variable muestra cambios. Tras el periodo 1991-1995, en el que hubo una inflación promedio superior a 18%, el nivel de inflación interanual mostró una tendencia a la baja entre 1996 y principios de 1998. Luego permaneció relativamente estable en alrededor de 10% hasta 2003, cuando empezó a repuntar nuevamente. Para el periodo 2004-2008 el promedio para el nivel de inflación se ubicó en 12.3%.

En este contexto, es recomendable evaluar la conveniencia de aplicar metodologías alternativas de combinación de proyecciones para el caso de la inflación que consideren posibles cambios estructurales y que permitan una mayor precisión del pronóstico que produce la combinación, en comparación con los resultados de la técnica utilizada actualmente.

A continuación se describe la estructura del resto de este trabajo. En la sección II se define algunas propiedades de los

pronósticos que son de interés a la hora de realizar combinaciones, se expone varias pruebas para verificar la presencia de dichas propiedades y se explica en detalle una serie de métodos de combinación de pronósticos. La sección III resume los aspectos metodológicos del cálculo de los pronósticos, así como de la implementación de los métodos de combinación. La sección IV presenta un análisis de los resultados y en la sección V se ofrecen algunas consideraciones y recomendaciones finales.¹

II. MARCO TEÓRICO

Los trabajos iniciales de Barnard (1963) y de Bates y Granger (1969) comprobaron que la combinación de pronósticos de una variable económica es mejor que los pronósticos individuales en términos del error cuadrático medio resultante. La evidencia de estos y otros autores promovió la investigación sobre diferentes técnicas de combinación de pronósticos. De esta forma, se pueden encontrar metodologías simples, como las basadas en modelos de regresión simple, hasta técnicas más elaboradas, para series no estacionarias, de modelos no lineales o de redes neuronales.

Al escoger los métodos de combinación que van a ser utilizados es importante que los pronósticos cumplan ciertas características. El insesgamiento y la eficiencia de los pronósticos, en particular, son de gran importancia en la elección del método de combinación. Además, para que una proyección se considere óptima para formar parte de una combinación, sus errores de pronóstico deben tener media cero, ser ruido blanco y distribuirse normalmente. Otros autores, señalan además que no debe existir cambios estructurales en el comportamiento de los datos (Melo y Núñez, 2004).

1. Características de los pronósticos

La prueba más utilizada para verificar el insesgamiento de una serie de pronósticos de la variable y_t , consiste en estimar la siguiente ecuación (Holden y Peel, 1989):

¹ Es importante mencionar que el código fuente de los programas utilizados en este estudio se documentó en Mora y Rodríguez, 2009 (DEC-DIE-003-2009).

$$(1) \quad y_t = \alpha + \beta f_t^j + \mu_t,$$

donde f_t^j es el pronóstico del j -ésimo modelo, α y β son constantes y μ_t es un término de error. La característica de insesgamiento se comprueba si no se rechaza la hipótesis conjunta $\alpha = 0$ y $\beta = 1$.

Para el caso de series no estacionarias, Holden y Peel (1989) sugieren basar la prueba en la ecuación:

$$(2) \quad y_t - f_t^j = \alpha + \mu_t.$$

Si la hipótesis $\alpha = 0$ no puede rechazarse, se concluiría que el pronóstico es insesgado. Además, si u_t no está serialmente correlacionado, el pronóstico es débilmente eficiente.

Para que la combinación de diferentes proyecciones sea eficiente se debe verificar la hipótesis de que alguno de los pronósticos domina a los demás. En este caso, eficiencia de un pronóstico significa que utiliza toda la información disponible y ningún modelo que utilice la misma información es más preciso. Cuando un pronóstico incorpora toda la información relevante de otros modelos de pronóstico, se dice que ese modelo los *abarca* o *incluye*.²

Las pruebas de inclusión de pronósticos permiten establecer si determinado pronóstico incorpora toda la información relevante de los pronósticos que provienen de modelos alternativos. En el caso de la prueba HLN de Harvey, Leybourne y Newbold,³ para los pronósticos rivales f_t^1 y f_t^2 , primero se define:

$$(3) \quad d_t = (e_t^1 - e_t^2)e_t^1$$

donde e_t^1 y e_t^2 son, respectivamente, el error de pronóstico τ pasos adelante del pronóstico f_t^1 y del pronóstico f_t^2 . Según la hipótesis nula de que el modelo 1 abarca al modelo 2 se tiene que $E(d_t) = 0$. La prueba se basa en la media muestral, dada por $\bar{d} = \frac{1}{T} \sum_{t=1}^T d_t$. Si se asume que d_t es estacionaria en covariancia, el estadístico HLN se distribuye asintóticamente mediante una normal estándar:

$$(4) \quad HLN = \frac{\bar{d}}{\sqrt{\hat{V}(\bar{d})}} \sim N(0, 1)$$

² Del inglés, *to encompass*.

³ Referida en Kışınbay (2007).

La expresión $\hat{V}(\bar{d})$ es un estimador consistente de la varianza asintótica de \bar{d} y está dada por:

$$(5) \quad \hat{V}(\bar{d}) \approx \frac{1}{T} \left(\gamma_0 + \sum_{i=1}^{\tau-1} \gamma_i \right)$$

donde se ha supuesto que los pronósticos τ pasos adelante muestran dependencia hasta el orden $\tau - 1$. Es necesario estimar cada i -ésima autocovarianza de \bar{d} , mediante: $\hat{\gamma}_i = \frac{1}{T} \sum_{t=i+1}^T (d_t - \bar{d})(d_{t-i} - \bar{d})$.

La prueba de Chong y Hendry (1986), para establecer si determinado pronóstico incorpora toda la información de otros pronósticos, supone una regresión de la forma:

$$(6) \quad y_{t+n} = \beta_1 f_{t,n}^1 + \beta_2 f_{t,n}^2 + \varepsilon_{t+n}$$

donde $f_{t,n}^i$ es el pronóstico i para el periodo $t + n$ hecho en el periodo t . Si el vector $(\beta_1, \beta_2) = (1, 0)$, no se rechaza la hipótesis que el pronóstico 1 incorpora al 2. Por su parte, si $(\beta_1, \beta_2) = (0, 1)$, entonces no se rechaza la hipótesis de que el modelo 2 incorpora al modelo 1. Para cualquier otro valor de (β_1, β_2) , se concluye que ningún modelo incorpora al otro, y por lo tanto ambos pronósticos contienen información útil sobre la variable y_{t+n} .

Cuando las series son integradas de orden uno, se estima la regresión:

$$(7) \quad (y_{t+n} - y_t) = \beta_1 (f_{t,n}^1 - y_t) + \beta_2 (f_{t,n}^2 - y_t) + \varepsilon_t$$

La verificación de la existencia de los vectores $(1, 0)$ o $(0, 1)$ indican que un pronóstico incorpora a otro.

Por su parte, Fair y Shiller (1989) proponen estimar la siguiente regresión, basada en pronósticos para s periodos adelante:

$$(8) \quad y_t - y_{t-s} = \beta_0 + \beta_1 (f_t^1 - y_{t-s}) + \beta_2 (f_t^2 - y_{t-s}) + \mu_t$$

Aquí f_t^i representa el pronóstico i para el periodo t , hecho en el periodo $t - s$. Las y indican los valores verdaderos de la variable pronosticada. Si $\beta_1 \neq 0$ y $\beta_2 = 0$, toda la información del modelo 2 está contenida en el modelo 1 y por ende el modelo 1 abarca al 2. Una conclusión análoga se sigue de $\beta_1 = 0$ y $\beta_2 \neq 0$. Si ambos parámetros difieren significativamente de 0, no puede decirse que algún modelo abarque al otro.

2. Métodos de combinación de pronósticos para series estacionarias

Para proyectar la serie estacionaria y_t mediante una combinación de pronósticos de K modelos, un primer paso es determinar las ponderaciones óptimas de los K pronósticos. Bates y Granger (1969). Señalan que si los pronósticos son insesgados, entonces la combinación:

$$(9) \quad y_t = \beta_1 f_t^1 + \beta_2 f_t^2 + \dots + \beta_K f_t^K$$

produce un pronóstico insesgado que posee un error cuadrático medio menor al de los pronósticos individuales, si se cumple que la suma de las ponderaciones es unitaria ($\beta_1 + \beta_2 + \dots + \beta_K = 1$). Estas ponderaciones son calculadas mediante mínimos cuadrados restringidos, no obstante, en la práctica no se puede asegurar que todos los pronósticos individuales sean insesgados.

Ante la dificultad de cumplir con la característica de insesgamiento de todos las series de pronósticos, Granger y Ramanathan (1984) muestran que la combinación:

$$(10) \quad y_t = \beta_0 + \beta_1 f_t^1 + \beta_2 f_t^2 + \dots + \beta_K f_t^K$$

proporciona un pronóstico combinado que en la mayoría de los casos es insesgado y con error cuadrático medio menor que cualquiera de los modelos individuales. Cabe señalar que en este método las ponderaciones ya no tienen que sumar la unidad.

3. Métodos de combinación de pronósticos para series no estacionarias

Muchas series económicas no son estacionarias y por lo tanto existen técnicas de combinación de pronósticos para variables integradas de orden uno que incorporan directamente el concepto de cointegración. Este es el caso de los métodos descritos a continuación. En este apartado y el siguiente se describen metodologías referenciadas en Melo y Núñez (2004).

La técnica de combinación de Coulson y Robins (1993), desarrollada para series no estacionarias, parte de la siguiente ecuación para cada uno de los n horizontes deseados:

$$(11) \Delta y_t = \gamma_0 + \gamma_1(f_{t|t-n}^1 - y_{t-1}) + \gamma_2(f_{t|t-n}^2 - y_{t-1}) + \dots + \gamma_K(f_{t|t-n}^K - y_{t-1}) + \varepsilon_t,$$

donde existe K modelos de pronóstico individuales que se utilizarán en la combinación, $f_{t|t-n}^i$ es el pronóstico de y_t según el modelo i ($i = 1 \dots K$) realizado con la información disponible hasta $t - n$, y ε_t es un proceso ruido blanco.

Cuando se han estimado los coeficientes de la ecuación (11), se procede a calcular la combinación de pronósticos:

$$(12) \quad \Delta \hat{y}_{t+n|t} = \hat{\gamma}_0 + \hat{\gamma}_1(f_{t+n|t}^1 - \hat{y}_{t+n-1|t}) + \hat{\gamma}_2(f_{t+n|t}^2 - \hat{y}_{t+n-1|t}) + \dots + \hat{\gamma}_K(f_{t+n|t}^K - \hat{y}_{t+n-1|t}) + \varepsilon_t$$

Para horizontes de un periodo, $\hat{y}_{t+n-1|t}$ es el valor de la variable en t y para horizontes mayores corresponde a un pronóstico realizado en periodos anteriores. Por último, se calcula el pronóstico combinado en niveles integrando los pronósticos anteriores:

$$(13) \quad \hat{y}_{t+n|t} = \Delta \hat{y}_{t+n|t} + \hat{y}_{t+n-1|t}$$

El método de Hallman y Kamstra (1989) también es utilizado para la combinación pronósticos con series no estacionarias. Estos autores proponen estimar el modelo que se presenta a continuación, para cada uno de los horizontes n :

$$(14) \quad y_t = \gamma_0 + \gamma_1 f_{t|t-n}^1 + \gamma_2 f_{t|t-n}^2 + \dots + \gamma_K f_{t|t-n}^K$$

$$\gamma_1 + \gamma_2 + \dots + \gamma_K = 1$$

Una vez estimados los coeficientes de la ecuación (14), se calcula la combinación de pronósticos:

$$(15) \quad \hat{y}_{t+n|t} = \hat{\gamma}_0 + \hat{\gamma}_1 f_{t+n|t}^1 + \hat{\gamma}_2 f_{t+n|t}^2 + \dots + \hat{\gamma}_K f_{t+n|t}^K$$

Aunque los métodos propuestos por Coulson y Robins y Hallman y Kamstra incorporan la característica de no estacionariedad de la serie en el procedimiento de combinación, estas técnicas no son idóneas para modelar posibles cambios estructurales. Debido a que los pronósticos deben tener un comportamiento adecuado, es una condición necesaria para la combinación óptima que no existan cambios estructurales en el comportamiento de los datos (Melo y Núñez, 2004).

Por ello, a continuación se presentan métodos que intentan

capturar los posibles cambios estructurales mediante parámetros variables en el tiempo.

4. Métodos de combinación de pronósticos en presencia de cambios estructurales

La técnica de mínimos cuadrados ponderados (MCP) (Diebold y Pauly, 1987) sugiere estimar un modelo de combinación de pronósticos con unas ponderaciones que dan un mayor peso a las últimas observaciones. De esta forma, el efecto de un posible cambio estructural es reducido ya que se diluye la influencia de las observaciones pasadas. Los coeficientes que se utilizan en la combinación se obtendrían por medio del vector de estimadores dado por:

$$(16) \quad \beta_{MCP} = (X'WX)^{-1}(X'WY),$$

donde W es la matriz de ponderaciones para las observaciones de la muestra y la matriz X corresponde a la información relacionada con las series de pronósticos a combinar f_i^i ($i = 1, 2, \dots, K$ y $t = 1, 2, \dots, T$). Para construir la matriz Diebold y Pauly (1987), proponen utilizar la *matriz t-lambda*, que incluye ponderaciones con una influencia decreciente de forma no lineal con respecto a las observaciones pasadas:⁴

$$(17) \quad W = \begin{bmatrix} 1^\lambda & 0 & \dots & 0 \\ 0 & 2^\lambda & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \vdots & T^\lambda \end{bmatrix}$$

El parámetro λ es estimado mediante una *búsqueda de malla*, para la cual se establece como función objetivo la raíz del error cuadrático medio de pronóstico (RECM). Así pues, para cada valor definido para el λ se calcula la matriz t-lambda, y a partir de ella se estiman los parámetros del modelo, luego los pronósticos combinados y finalmente la RECM. El valor óptimo de λ es el que minimiza la RECM. Una vez obtenido el λ *óptimo* se realiza la combinación definitiva utilizando el vector $\hat{\beta}_{MCP}$ resultante. Debe destacarse que la composición de la

⁴ Diebold y Pauly (1987), señalan que esta matriz ha dado mejores resultados que los obtenidos por otras matrices de ponderación alternativas.

matriz X y el vector Y , es decir, la conformación de los datos a utilizar en la regresión de combinación, depende del enfoque de combinación preferido. En este trabajo se utilizará los métodos de combinación de Coulson y Robins y de Hallman y Kamstra, referidos en la sección anterior.

Una forma alternativa de considerar parámetros cambiantes es por medio de modelos de estado-espacio (E-E) para las ecuaciones de combinación de pronósticos. El modelo E-E más sencillo supone que el vector de parámetros se comporta como una caminata aleatoria.

Así pues, la ecuación de medida es:

$$(18) \quad [Z_t] = H_t \begin{bmatrix} \gamma_t^0 \\ \gamma_t^1 \\ \gamma_t^2 \\ \vdots \\ \gamma_t^k \end{bmatrix} + [r_t]; \quad t = 1, 2, \dots, T,$$

mientras que la ecuación de transición está representada por:

$$(19) \quad \begin{bmatrix} \gamma_t^0 \\ \gamma_t^1 \\ \gamma_t^2 \\ \vdots \\ \gamma_t^k \end{bmatrix} = F \begin{bmatrix} \gamma_{t-1}^0 \\ \gamma_{t-1}^1 \\ \gamma_{t-1}^2 \\ \vdots \\ \gamma_{t-1}^k \end{bmatrix} + \begin{bmatrix} v_{0t} \\ v_{1t} \\ v_{2t} \\ \vdots \\ v_{kt} \end{bmatrix},$$

donde $[r_t]$ y el vector $[v_t]$ son procesos ruido blanco independientes. Para la metodología de Coulson y Robins se tiene que:

$$[Z_t] = [\Delta y_t], \quad F = [I_{k+1}] \quad \text{y} \quad H_t = [1 \ (f_t^1 - y_{t-1}) \ (f_t^2 - y_{t-1}) \ \dots \ (f_t^k - y_{t-1})].$$

Para la técnica Hallman y Kamstra la conformación de las matrices sería:

$$[Z_t] = [y_t], \quad F = [I_{k+1}] \quad \text{y} \quad H_t = [1 \ f_t^1 \ f_t^2 \ \dots \ f_t^k].$$

Así pues, la ecuación (19) establece que todas las ponderaciones son caminatas aleatorias. Los hiperparámetros del modelo estado espacio son la varianza de r_t y los elementos de la matriz de varianza y covarianza asociada al vector v_t . Dados los valores iniciales de los hiperparámetros y del vector de estado se procede a la optimización mediante métodos

de máxima verosimilitud y el filtro de Kalman.⁵

Adicionalmente, Deusch, Granger y Teräsvirta (1994) proponen dos métodos de combinación en presencia de cambio estructural de la serie a pronosticar: mediante modelos *switching* de regímenes y mediante modelos de transición suave.

Una forma general de los modelos de parámetros cambiantes está dada por:

$$(20) \quad y_t = x_t'(\beta + \lambda_y \lambda) + \varepsilon_t, \quad 0 \leq \lambda_t, \text{ para } t = 1, 2, \dots, T,$$

donde λ_t es la ruta de transición.

Cuando λ_t toma dos valores, 0 o 1, se tiene que existen dos regímenes, cada uno asociado a distintos parámetros del modelo. En el primer régimen, cuando $\lambda_t = 0$, se tiene que $(\beta + \lambda_y \gamma) = \beta$. Para el segundo régimen, con $\lambda_t = 1$, el resultado es que $(\beta + \lambda_y \gamma) = \beta + \gamma$. Así pues, en el caso de modelos *switching* como este, los coeficientes del modelo asumen dos valores distintos dependiendo del régimen vigente.

Ahora bien, si λ_t es una función continua entre 0 y 1, entonces los parámetros cambian gradualmente de un régimen a otro. Este caso corresponde a un modelo de *transición suave*. Los modelos de transición suave se especifican de la siguiente forma:⁶

$$(21) \quad y_t = (1 + e^{\gamma V_{t-1}})^{-1} (a_1 f_t^1 + a_2 f_t^2) + (1 - (1 + e^{\gamma V_{t-1}})^{-1}) (a_3 a_2 f_t^1 + a_4 a_2 f_t^2),$$

donde V_{t-1} es alguna función del error de pronóstico rezagado. Algunas formas alternativas de esta función son las siguientes:

$$(22) \quad \begin{aligned} V_{t-1} &= z_{t-1}^1, \\ V_{t-1} &= z_{t-1}^2, \\ V_{t-1} &= \hat{\alpha}_1 z_{t-1}^1 + \hat{\alpha}_2 z_{t-2}^1 + \dots + \hat{\alpha}_n z_{t-n}^1, \\ V_{t-1} &= \hat{\beta}_1 z_{t-1}^2 + \hat{\beta}_2 z_{t-2}^2 + \dots + \hat{\beta}_n z_{t-n}^2, \end{aligned}$$

⁵ Un caso especial del modelo E-E es cuando el único parámetro que varía en el tiempo es el intercepto (γ_t^0), lo cual podría adaptarse a casos en los que posibles cambios estructurales están asociados con variaciones en el nivel de la serie.

⁶ Estos modelos fueron desarrollados por Lin y Teräsvirta (1994). Aquí se sigue la exposición de Deusch, Granger y Teräsvirta (1994).

donde los $\hat{\alpha}_i$ son los coeficientes estimados del proceso autorregresivo :

$$(23) \quad z_{t,1} = \hat{\alpha}_1 z_{t-1}^1 + \hat{\alpha}_2 z_{t-2}^1 + \dots + \hat{\alpha}_n z_{t-n}^1,$$

y los $\hat{\beta}_i$ se definen análogamente. Estos modelos son más complicados que los de parámetros cambiantes, dado que el valor de γ que minimiza la medida de error dentro de muestra debe obtenerse mediante una búsqueda de malla. No obstante, se ha encontrado que en ocasiones dan mejores resultados que los de parámetros cambiantes (Deutsch, Granger y Teräsvirta, 1994). Esta técnica actualiza las ponderaciones con cada dato adicional de la muestra, por lo que es necesario contar con una estimación inicial de los parámetros.

Finalmente, cuando se compara entre varias técnicas de combinación de pronósticos los indicadores más utilizados son el error cuadrático medio (ECM) del pronóstico y la raíz del error cuadrático medio (RECM). Así pues, es fundamental determinar si la diferencia entre dos ECM de métodos de combinación alternativos es estadísticamente significativa. Para ello se puede aplicar a las combinaciones de pronósticos la prueba propuesta por Granger y Newbold (1977), que se explica enseguida.

En primer lugar, se obtienen los errores de pronóstico un paso delante del primer y del segundo modelo de pronóstico considerado: z_i^j , para $j = 1, 2$. Si estos errores son insesgados, no autocorrelacionados y presentan una distribución normal bivariada, se procede de la siguiente forma:

- Se construyen las series $S_i = z_i^1 + z_i^2$ y $D_i = z_i^1 - z_i^2$.
- Se estima una regresión con S_i como variable dependiente y D_i y una constante como regresoras.

Si se rechaza la hipótesis de que el coeficiente asociado a D_i es 0, la prueba señala que el ECM del modelo 1 es significativamente distinto al del modelo 2. Además, si se rechaza la hipótesis de que el término constante de la regresión es cero, entonces z_i^1 o z_i^2 son sesgados.

III. METODOLOGÍA

Los modelos considerados en este trabajo para obtener una

combinación de pronósticos de la inflación que tome en cuenta cambios estructurales son los utilizados por el Banco Central de Costa Rica para proyectar la inflación costarricense: modelo univariable de inflación (ARMA), modelo vector autorregresivo lineal de mecanismos de transmisión de la política monetaria (*Var_Me*), modelo impacto de los precios del petróleo en Costa Rica (*Var_Pe*), modelo de títulos fiscales (TF), modelo de *pass-through* del tipo de cambio en Costa Rica (PT) y modelo ingenuo (*Ingenuo*). Estos modelos se describen en el cuadro A.1, del anexo 1.

Para los seis modelos mencionados se calcularon pronósticos *rolling* mensuales en el periodo junio de 1996 a octubre del 2008,⁷ para horizontes de 3, 6, 12 y 24 meses. Los pronósticos *rolling* son una serie de pronósticos fuera de muestra donde el modelo es reestimado en cada periodo.

Como se mencionó en la sección anterior, es necesario conocer ciertas características tanto de la serie pronosticada como de los pronósticos mismos con el fin de determinar la forma más adecuada de realizar la combinación. Por lo tanto, como paso previo a la combinación, se verificó el insesgamiento de los pronósticos mediante la prueba de Holden y Peel y su eficiencia mediante las pruebas de inclusión de Chong y Hendry, y de Harvey, Leybourne y Newbold. Finalmente, a la serie de inflación se le aplicaron pruebas de raíz unitaria, algunas de las cuales permiten la posibilidad de cambio estructural. A partir de las conclusiones de esta serie de pruebas se determinaron los métodos de combinación apropiados.

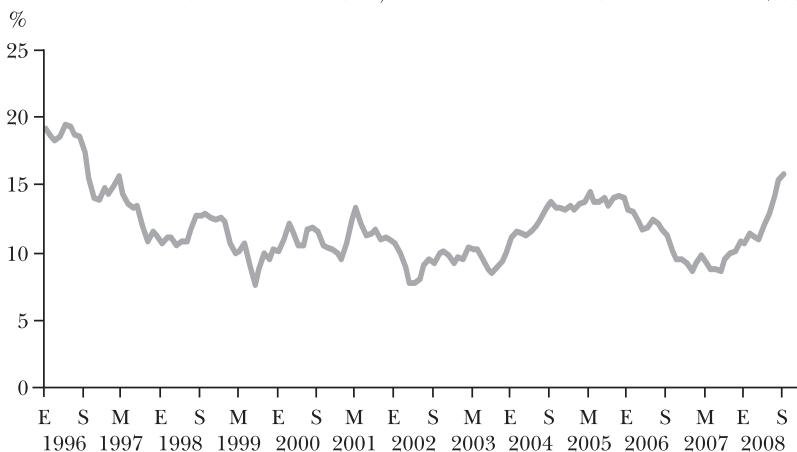
La evaluación de las metodologías de combinación aplicadas se realizó mediante la comparación de la raíz del error cuadrático medio (RECM) resultante de cada combinación para los diferentes plazos escogidos. En caso de presentarse disminuciones en la RECM con respecto al método de combinación implementado en la actualidad, se evaluó la significancia de esa disminución por medio de la prueba de Granger y Newbold señalada en la sección anterior.

⁷ Debido a que el modelo de títulos fiscales se estimó para un lapso que inicia en junio de 1996, se decidió utilizar esta fecha inicial para calcular los pronósticos de inflación de los modelos empleados.

IV. ANÁLISIS DE RESULTADOS

Dado que el interés de esta investigación es actualizar el método de combinación de pronósticos de inflación utilizado actualmente por el BCCR, y considerando que el comportamiento de la inflación en Costa Rica durante la última década no ha sido uniforme (ver gráfica I), es prudente hacer esfuerzos por considerar la posibilidad de cambios estructurales en la inflación durante el periodo en estudio. Por esta razón, en la sección IV.1 se presenta los resultados de pruebas de raíz unitaria para la serie de inflación, algunas de las cuales incorporan la posibilidad de cambio estructural.⁸ Además, se explican los resultados de las pruebas de insesgamiento e inclusión para los pronósticos individuales de inflación. Los principales resultados de las combinaciones efectuadas se presentan en la sección IV.2.

GRÁFICA I. INFLACIÓN INTERANUAL, DE ENERO DE 1996 A SEPTIEMBRE DE 2008



1. Pruebas de raíz unitaria y propiedades de los pronósticos

En el anexo 2 figuran las pruebas de raíz unitaria realizadas. El cuadro A.2 presenta los resultados de la prueba Dickey-

⁸ Todas las pruebas de raíz unitaria se realizaron para la serie mensual de inflación interanual para el periodo junio-1996-octubre del 2008. En todas se incluye un máximo de 37 rezagos, buscando consistencia con la recomendación para la prueba de Zivot-Andrews, de incluir al menos una cuarta parte de las observaciones muestrales.

Fuller aumentada y de la prueba Phillips-Perron para la serie de inflación. Tomando en cuenta la significancia de las variables exógenas incluidas en la regresión de prueba, la especificación escogida en ambos casos presenta constante pero no tendencia. A 5% de significancia es posible rechazar la hipótesis nula de raíz unitaria en ambas pruebas.

Debe recordarse que Dickey-Fuller y Phillips-Perron no consideran la posibilidad de cambio estructural en la serie, por lo que se decidió aplicar cuatro pruebas que sí toman en cuenta dicha posibilidad.

Las pruebas de Zivot y Andrews (1992) y Perron (1997) mantienen la hipótesis nula de raíz unitaria, pero en ellas la hipótesis alternativa es ahora estacionariedad *con un solo cambio estructural* en una fecha que se estima endógenamente. Los resultados en el cuadro A.3 muestran que para el caso de Zivot-Andrews es posible rechazar la hipótesis nula a 5% de significancia, tanto para el modelo que considera cambio en intercepto como para el que considera cambio en intercepto y tendencia. Sin embargo, en el caso de la prueba de Perron (cuadro A.4), la hipótesis nula de raíz unitaria puede rechazarse solo en el caso del modelo que considera cambio en intercepto.

Las pruebas de Lee y Strazicich (2003, 2004) presentan dos características de interés. En primer lugar, una de las pruebas considera *dos* cambios estructurales en vez de uno solo. En segundo lugar, a diferencia del estadístico de Zivot-Andrews, la magnitud del estadístico de las pruebas de Lee y Strazicich no se ve afectada al permitir cambios estructurales tanto para la hipótesis nula como para la alternativa. De esta forma, “...*el rechazo de la hipótesis nula implica sin ambigüedades un proceso estacionario con tendencia.*” (Lee y Strazicich, 2003; p.1082.)⁹ No obstante, para el caso de la serie de inflación de este estudio no fue posible rechazar la hipótesis nula de raíz unitaria en ninguno de los casos considerados. El cuadro A.5 presenta los resultados de las pruebas para 1 y para 2 cambios estructurales,

⁹ Lee y Strazicich (2003, 2004) encuentran que las pruebas de Zivot-Andrews y Perron con frecuencia rechazan la hipótesis nula aún cuando la serie tenga raíz unitaria, llevando a la conclusión de que la serie es estacionaria con cambio estructural cuando en realidad es no estacionaria con cambio estructural.

para los modelos que consideran cambio en intercepto, y cambio en intercepto y tendencia.

En resumen, si bien en las pruebas de Dickey-Fuller, Phillips-Perron y Zivot-Andrews es posible rechazar la hipótesis de existencia de raíz unitaria, mediante las pruebas de Perron (1997) y de Lee-Strazicich dicha hipótesis no puede ser rechazada. Nótese que, con excepción de Zivot-Andrews, en las pruebas que consideran cambio estructural no se rechaza la hipótesis nula de raíz unitaria. Adicionalmente, las pruebas de Zivot-Andrews y de Perron coinciden en estimar cambios en intercepto y tendencia en algunos meses de 2001.¹⁰

En vista de estos resultados, con el fin de tomar en cuenta la posibilidad tanto de raíz unitaria como de cambios estructurales en la serie de inflación, se decidió utilizar métodos de combinación para series no estacionarias que incorporasen cambio estructural.

Antes de implementar las metodologías de combinación, se analizaron varias características de los errores de pronóstico para cada uno de los modelos en los diferentes horizontes señalados. En las gráficas A.I a la A.IV del anexo 3 se muestran los errores de pronóstico de cada modelo, según el horizonte previsto. En términos generales, se observa que la magnitud del error de pronóstico, como sucede en este tipo de cálculos, se incrementa con el horizonte. Así, para el horizonte a tres meses el error absoluto medio (EAM) de pronóstico asciende a 1.5%, mientras que para los horizontes de 6, 12 y 24 meses, este error alcanza los valores de 2.0%, 2.9% y 3.6%, respectivamente.

En el anexo 4 se presentan las características de los errores de pronóstico: el insesgamiento con la prueba de Holden y Peel (cuadro A.6), la normalidad con la prueba de Jarque y Bera (cuadro A.7) y la autocorrelación con la prueba de Ljung-Box (cuadro A.8). Los modelos TF *e ingenuo* presentan pronósticos insesgados,¹¹ mientras que los pronósticos de los modelos ARMA, PT y Var_Me presentan evidencia de sesgo para todos los horizontes. Por su parte, en las pruebas de

¹⁰ Las pruebas de Lee y Strazicich, por su parte, estiman fechas de cambio en diciembre de 2003 y septiembre de 2005.

¹¹ Para los pronósticos del modelo Var_Pe a un horizonte de 3 meses no se rechaza la hipótesis de insesgamiento.

Jarque-Bera no se rechaza la hipótesis de normalidad en la mayoría de los casos.¹²

Al analizar las pruebas de inclusión (cuadros A.9 al A.20), que permiten determinar si los pronósticos de un modelo incorporan toda la información relevante con respecto a los pronósticos de otro modelo, se puede concluir con los resultados de la prueba de Chong y Hendry que no existe ningún modelo que incluya a todos los restantes en ningún horizonte considerado. No obstante, para el horizonte de 3 meses el resultado no es claro pues solo la prueba de Harvey, Leybourne y Newbold (HLN) muestra que el modelo *Var_Pe* incorpora a los demás pronósticos; mientras que para los horizontes de 6, 12 y 24 el contraste HLN evidencia la inclusión de la información de todos los pronósticos en el modelo TF. Este último resultado es confirmado por la prueba de Fair y Shiller para el horizonte de 12 meses.

Los resultados anteriores proveen evidencia de que a cada horizonte de pronóstico existe un modelo que incorpora la información contenida en todos los demás, por lo que se esperaría que no existieran beneficios sustanciales de realizar la combinación. Con esto en mente, y considerando que el modelo ingenuo no incluye información de variables económicas, para cada plazo se efectuaron las siguientes variaciones del ejercicio:

- una combinación que incluyese a todos los pronósticos,
- una que excluyese al modelo que incorporase a los demás,
- una que excluyese al modelo ingenuo,
- otra que excluyese tanto al modelo ingenuo como al que incorporase a los demás.

2. Resultados de las combinaciones de pronósticos

Las técnicas para series no estacionarias con cambio estructural implementadas fueron: mínimos cuadrados ponderados con la especificación de Coulson y Robins (MCP-CR), mínimos

¹² Los pronósticos del modelo PT a los horizontes de 6 y 12 meses y del modelo *Var_Pe* para todos los horizontes presentan evidencia de no normalidad.

cuadrados ponderados con la especificación de Hallman y Kamstra (MCP-HK), estado-espacio con la especificación de Hallman y Kamstra (EE-HK) y un modelo de transición suave con la metodología de Deutsch, Granger y Teräsvirta (TS-DGT).¹³ El código fuente utilizado para aplicar estas técnicas mediante el paquete econométrico Eviews versión 6.0 se documenta en Mora y Rodríguez (2009).

Con el fin de comparar los resultados obtenidos, se combinaron los pronósticos dinámicos mediante la técnica de combinación utilizada actualmente por el BCCR: ponderaciones óptimas sin términos de covariancia (Comb. original). Un resumen de las RECM para cada combinación calculada se presenta en el anexo 5, cuadros A.21 a A.24.

Con base en los resultados de las combinaciones se determinó que en general las técnicas que incorporan cambio estructural mostraron un error de pronóstico menor con respecto a los modelos individuales y a la combinación original. Para el horizonte de tres meses, MCP-HK fue la única combinación que incluyó solamente ponderaciones positivas, que se muestran en el cuadro 1.¹⁴ Debe señalarse que esta combinación no incluye al Var_Pe ni al modelo ingenuo y que además el valor del parámetro λ que minimiza la RECM es cero, lo cual indica que esta combinación no reconoce cambios estructurales, pues efectivamente se pondera con el mismo peso a todas las observaciones de la muestra. Adicionalmente, la prueba

CUADRO 1. PONDERACIONES ÓPTIMAS POR HORIZONTE

| | 3 meses (MCP-HK) | 6 meses (Comb. original) | 12 meses (Comb. original) | 24 meses (Comb. original) |
|-----------|---------------------|-----------------------------|------------------------------|------------------------------|
| Constante | 0.0003 | - | - | - |
| ARMA | 0.2304 | 0.1908 | 0.1594 | 0.1111 |
| PT | 0.1096 | 0.1224 | 0.1152 | 0.1111 |
| TF | 0.5653 | 0.0873 | 0.0655 | 0.0469 |
| Var_Me | 0.0947 | 0.2432 | 0.2399 | 0.2289 |
| Var_Pe | - | 0.0826 | 0.0884 | 0.0818 |
| Ingenuo | - | 0.2736 | 0.3316 | 0.4202 |

FUENTE: elaboración propia.

¹³ Debido a que TS-DGT realiza combinaciones dinámicas fue necesario separar el periodo de estudio en dos: uno para estimación inicial de los parámetros y otro para el cual se obtuvieron combinaciones actualizadas.

¹⁴ Las demás combinaciones incluyeron ponderaciones negativas, un resultado frecuente pero poco intuitivo (ver Hoffmaister *et al.*, 2001).

de Granger y Newbold (ver anexo 6, cuadro A.25) sugiere que el error de pronóstico de MCP-HK a tres meses es significativamente más bajo que el del mejor pronóstico individual, pero no da evidencia de que sea distinto del error de la combinación óptima utilizada actualmente.

Para el resto de horizontes algunas de las combinaciones realizadas con técnicas para series no estacionarias con cambio estructural redujeron el error de pronóstico, pero todas incluyeron ponderaciones negativas, por lo que la combinación utilizada actualmente (ponderaciones óptimas sin términos de covariancia) seguiría siendo la más adecuada. Los parámetros utilizados en las técnicas de combinación de nuevo sugieren que la aplicación de éstas no diferiría de la aplicación de técnicas que no consideran cambio estructural.¹⁵ Debe resaltarse que en los horizontes de 12 y 24 meses se encontró evidencia estadística de que la RECM de la combinación óptima original no supera la del modelo con el menor error de pronóstico (ver cuadro A.25).

V. CONSIDERACIONES FINALES

La intención del Banco Central de Costa Rica de aplicar un régimen monetario de meta explícita de inflación implica que los pronósticos de inflación son parte integral del ejercicio de programación macroeconómica pues permiten evaluar la viabilidad y realismo de la meta inflacionaria propuesta.

Los pronósticos pasivos de la inflación se generan a partir de un conjunto de modelos que posteriormente se combinan para obtener una proyección única. Es recomendable evaluar periódicamente las técnicas de combinación empleadas con el fin de mejorar la precisión de pronóstico. En concordancia con lo anterior, el objetivo de este trabajo fue evaluar técnicas de combinación de proyecciones de inflación que incorporasen la posible presencia de cambios estructurales.

¹⁵ En particular, el λ óptimo en los modelos de mínimos cuadrados ponderados con Hallman y Kamstra es consistentemente igual a cero, lo que equivale a aplicar mínimos cuadrados ordinarios sobre la ecuación (14). La aplicación del modelo de Deutsch, Granger y Teräsvirta resultó en valores altos para el parámetro γ , lo que implica un cambio muy lento en las ponderaciones.

Para este propósito se calcularon pronósticos dinámicos mensuales para el periodo de junio de 1996 a octubre del 2008 con horizontes de 3, 6, 12 y 24 meses, para los siguientes modelos:

- Univariable de inflación (ARMA).
- Vector autorregresivo lineal de mecanismos de transmisión de la política monetaria (Var_Me).
- Impacto de los precios del petróleo en Costa Rica (Var_Pe).
- Títulos fiscales (TF).
- Pass-through del tipo de cambio en Costa Rica (PT).
- Ingenuo.

Los modelos TF e ingenuo presentan pronósticos insesgados para todos los horizontes, mientras que Var_Pe solamente para el horizonte de tres meses. Adicionalmente, se encontró evidencia de que al horizonte de tres meses el modelo Var_Pe incorpora la información de todos los pronósticos, mientras que para los restantes horizontes las pruebas sugieren que es el modelo TF el que incorpora a los demás.

Tras aplicar las técnicas de combinación que toman en cuenta cambio estructural se encontró que en general éstas permitieron reducir el error de pronóstico con respecto a los modelos individuales y a la combinación original, no obstante, varias combinaciones incluyeron ponderaciones negativas para algunos modelos, por lo que su aplicación carece de sentido económico.

Una metodología que produjo resultados satisfactorios tanto en signo de las ponderaciones como en error de pronóstico, fue la de mínimos cuadrados ponderados con la técnica de Hallman y Kamstra aplicada para el horizonte de tres meses. Debe señalarse que la reducción en el error de pronóstico resultante no es significativa con respecto a la combinación actual y que la combinación obtenida no reconoce cambios estructurales en la serie.

Para los horizontes de 6, 12 y 24 meses las técnicas aplicadas no permitieron encontrar combinaciones que incluyeran solamente ponderaciones positivas y que al mismo tiempo

resultaran en una reducción significativa del error de pronóstico. Para los horizontes de 12 y 24 meses hay evidencia de que la combinación óptima original no supera la precisión del modelo con el menor error de pronóstico (títulos fiscales).¹⁶

Considerando las conclusiones anteriores se realizan las siguientes recomendaciones:

- En primer lugar, para horizontes de corto plazo, por ejemplo tres y seis meses, es razonable mantener la combinación de pronósticos aplicada actualmente por el Banco Central de Costa Rica. Esta combinación, desarrollada en Hoffmaister *et al.* (2001), incluye los modelos univariable de inflación, vector autorregresivo lineal de mecanismos de transmisión de la política monetaria, impacto de los precios del petróleo en Costa Rica, títulos fiscales, pass-through del tipo de cambio en Costa Rica e ingenuo.¹⁷
- Para horizontes de mediano plazo, 12 y 24 meses, los resultados sugieren que el modelo de títulos fiscales es una alternativa eficiente al uso de la combinación actual. Este modelo, desarrollado en Durán y Rojas (2008), pronostica la inflación con base en los tres primeros rezagos de la variación porcentual interanual del índice de precios al consumidor y en los rezagos segundo y tercero de la variación interanual del saldo medio mensual de títulos de propiedad del gobierno central.
- En esta línea, debe procurarse una revisión continua de los métodos de combinación de proyecciones y de las características de los pronósticos, especialmente cuando se incluyan nuevos modelos estructurales de proyección o cuando sean validados nuevamente los modelos actuales.

¹⁶ El código fuente para realizar estas combinaciones puede consultarse en Mora y Rodríguez (2009).

¹⁷ El anexo 1 detalla la especificación de cada uno de estos modelos.

Anexo I

Modelos de pronóstico de inflación

CUADRO A. 1. MODELOS DE PRONÓSTICO DE INFLACIÓN

| Modelo | Descripción |
|---------|---|
| ARMA | $(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3 - \phi_4 L^4 - \phi_5 L^5 - \phi_6 L^6) DLIPC_t = (1 - \theta_1 L^2 - \theta_2 L^3) \varepsilon_t$ |
| PT | $DLIPC_t = \beta_0 + \beta_1 DLTC_{t-4} + \beta_2 q_{t-4}^b + \beta_3 Y_{t-3}^b + \beta_4 DLIPC_{t-1} + \beta_5 aper_{t-3}$ |
| TF | $DLIPC_t = \beta_0 + \beta_1 DLIPC_{t-1} + \beta_2 DLIPC_{t-2} + \beta_3 DLIPC_{t-3} + \beta_4 TF_{t-2} + \beta_5 TF_{t-3}$ |
| Var_Me | $\begin{bmatrix} DLIPC_t \\ i_t \\ DLIMAE_t \\ DLTC_t \\ DLCPRI_t \end{bmatrix} = \begin{bmatrix} A(L)_{11,5} & A(L)_{12,5} & A(L)_{13,5} & A(L)_{14,5} & A(L)_{15,5} \\ A(L)_{21,5} & A(L)_{22,5} & A(L)_{23,5} & A(L)_{24,5} & A(L)_{25,5} \\ A(L)_{31,5} & A(L)_{32,5} & A(L)_{33,5} & A(L)_{34,5} & A(L)_{35,5} \\ A(L)_{41,5} & A(L)_{42,5} & A(L)_{43,5} & A(L)_{44,5} & A(L)_{45,5} \\ A(L)_{51,5} & A(L)_{52,5} & A(L)_{53,5} & A(L)_{54,5} & A(L)_{55,5} \end{bmatrix} \begin{bmatrix} DLIPC_{t-1} \\ i_{t-1} \\ DLIMAE_{t-1} \\ DLTC_{t-1} \\ DLCPRI_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ \varepsilon_{3t} \\ \varepsilon_{4t} \\ \varepsilon_{5t} \end{bmatrix}$ |
| Var_Pe | $\begin{bmatrix} DLPOIL_t \\ DLPCOMB_t \\ DLIPC_t \\ i_t \\ DLIMAE_t \\ DLTC_t \end{bmatrix} = \begin{bmatrix} A(L)_{11,5} & A(L)_{12,5} & A(L)_{13,5} & A(L)_{14,5} & A(L)_{15,5} \\ A(L)_{21,5} & A(L)_{22,5} & A(L)_{23,5} & A(L)_{24,5} & A(L)_{25,5} \\ A(L)_{31,5} & A(L)_{32,5} & A(L)_{33,5} & A(L)_{34,5} & A(L)_{35,5} \\ A(L)_{41,5} & A(L)_{42,5} & A(L)_{43,5} & A(L)_{44,5} & A(L)_{45,5} \\ A(L)_{51,5} & A(L)_{52,5} & A(L)_{53,5} & A(L)_{54,5} & A(L)_{55,5} \\ A(L)_{61,5} & A(L)_{62,5} & A(L)_{63,5} & A(L)_{64,5} & A(L)_{65,5} \end{bmatrix} \begin{bmatrix} DLPOIL_{t-1} \\ DLPCOMB_{t-1} \\ DLIPC_{t-1} \\ i_{t-1} \\ DLIMAE_{t-1} \\ DLTC_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ \varepsilon_{3t} \\ \varepsilon_{4t} \\ \varepsilon_{5t} \\ \varepsilon_{6t} \end{bmatrix}$ |
| Ingenuo | $DLIPC_t = DLIPC_{t-1}$ |

Variables

DLIPC: Variación interanual del índice de precios al consumidor, excepto para modelo *pass-through*, donde se usa tasa semestral.

DLTC: Variación interanual del tipo de cambio de referencia promedio compra-venta

q^b : Desalineamiento del tipo de cambio real respecto a su valor de largo plazo

Y^b : Brecha del producto interno bruto real respecto a su crecimiento potencial

aper: Grado de apertura comercial del país

TF: Variación interanual del saldo mensual de títulos de propiedad del gobierno Central, valor transado

i: tasa de interés de política monetaria (captación del BCCR a 30 días)

DLIMAE: Variación interanual del índice mensual de actividad económica

DLCPRI: Variación interanual del crédito al sector privado

DLPOIL: Variación interanual del precio de petróleo en dólares

DLCOMB: Variación interanual del precio interno de los combustibles

Anexo 2

Pruebas de raíz unitaria

CUADRO A. 2. PRUEBAS DE RAÍZ UNITARIA DICKEY-FULLER AUMENTADA Y PHILLIPS-PERRON, PERIODO 1996:06-2008:10

| Variable | <i>Dickey-Fuller aumentada^a</i> (con intercepto solamente) | | <i>Phillips-Perron^a</i> (con intercepto solamente) | |
|-----------|--|----------|--|----------|
| | Estadístico <i>t</i> | Decisión | Estadístico <i>t</i> | Decisión |
| Inflación | -3.38402 | I(0) | -3.252302 | I(0) |

^a Valores críticos: -3.475 a 1%, -2.881 a 5% y -2.577 a 10%.

CUADRO A. 3. PRUEBAS DE RAÍZ UNITARIA ZIVOT-ANDREWS, PERIODO 1996:06-2008:10

| Variable | <i>Cambio en intercepto^a</i> | | <i>Cambio en intercepto y tendencia^b</i> | | | |
|-----------|---|----------|---|----------|----------|------|
| | Estadístico <i>t</i> y fecha | Decisión | Estadístico <i>t</i> y fecha | Decisión | Decisión | |
| Inflación | -5.35868 | 2001:06 | I(0) | -5.12849 | 2001:10 | I(0) |

^a Valores críticos: -5.34 a 1% y -4.80 a 5%. ^b Valores críticos: -5.57 a 1% y -5.08 a 5%.

CUADRO A. 4. PRUEBAS DE RAÍZ UNITARIA PERRON97, PERIODO 1996:06-2008:10

| Variable | <i>Cambio en intercepto^a</i> | | <i>Cambio en intercepto y tendencia^b</i> | | <i>Cambio en pendiente temporal^c</i> | | | | |
|-----------|---|----------|---|----------|---|----------|----------|---------|------|
| | Estadístico <i>t</i> y fecha | Decisión | Estadístico <i>t</i> y fecha | Decisión | Estadístico <i>t</i> y fecha | Decisión | | | |
| Inflación | -5.30168 | 2001:04 | I(0) | -5.09431 | 2001:08 | I(1) | -1.72440 | 2008:08 | I(1) |

^a Valores críticos para 100 observaciones: -5.70 a 1%, -5.10 a 5% y -4.82 a 10%. ^b Valores críticos para 100 observaciones: -6.21 a 1%, -5.55 a 5% y -5.25 a 10%. ^c Valores críticos para 100 observaciones: -5.45 a 1%, -4.83 a 5% y -4.48 a 10%.

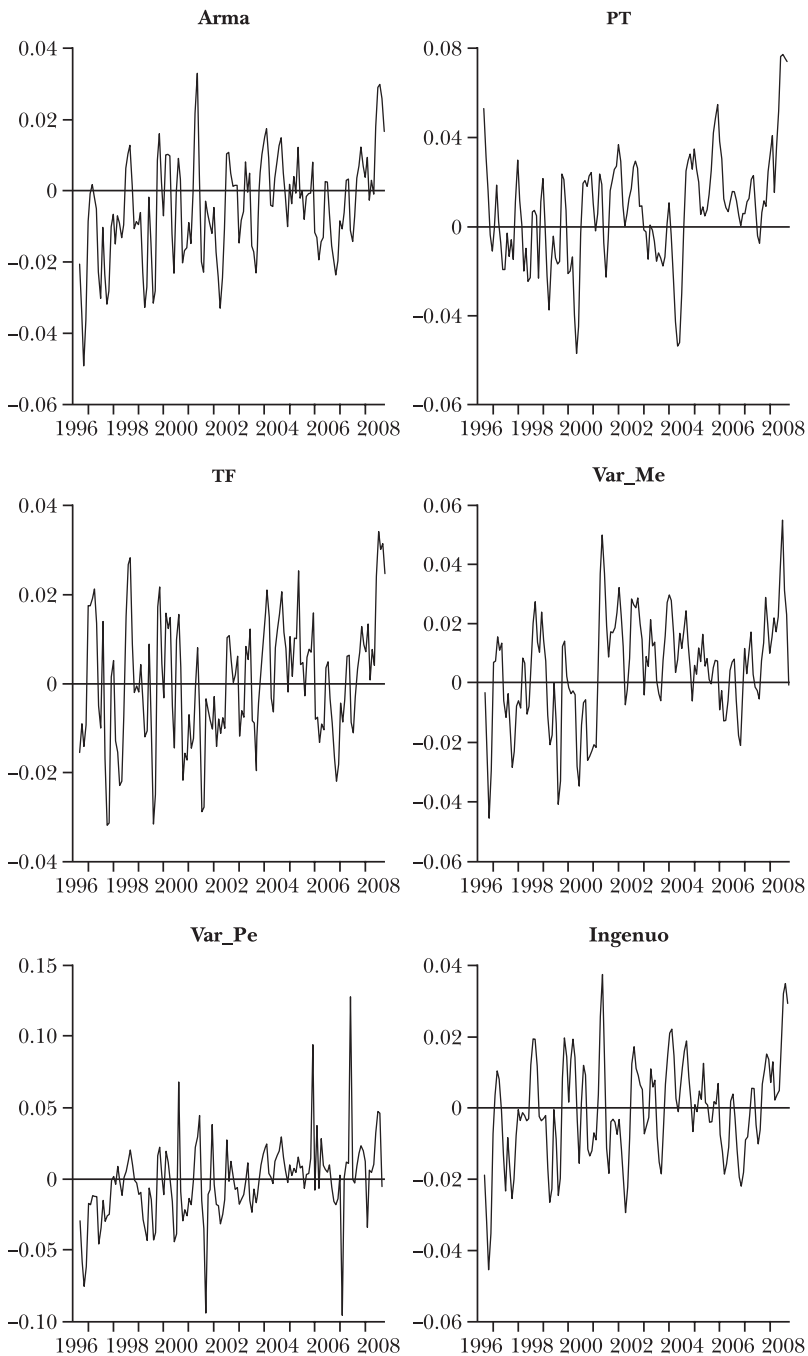
CUADRO A. 5. PRUEBAS DE RAÍZ UNITARIA LEE-STRAZICICH, PERIODO 1996:06-2008:10

| <i>Prueba para un cambio estructural</i> | | | | | | |
|--|---|-----------------|------|---|-----------------|------|
| <i>Variable</i> | <i>Cambio en intercepto^a</i> | | | <i>Cambio en intercepto y tendencia^b</i> | | |
| | <i>Estadístico t y fecha</i> | <i>Decisión</i> | | <i>Estadístico t y fecha</i> | <i>Decisión</i> | |
| Inflación | 0.4242 | 2003:12 | I(1) | -2.8847 | 2002:01 | I(1) |
| <i>Prueba para un cambio estructural</i> | | | | | | |
| <i>Variable</i> | <i>Cambio en intercepto^c</i> | | | <i>Cambio en intercepto y tendencia^d</i> | | |
| | <i>Estadístico t y fecha</i> | <i>Decisión</i> | | <i>Estadístico t y fecha</i> | <i>Decisión</i> | |
| Inflación | 0.0636 | 2003:12 | I(1) | -3.6187 | 2000:06 | I(1) |
| | | 2005:09 | | | 3005:09 | |

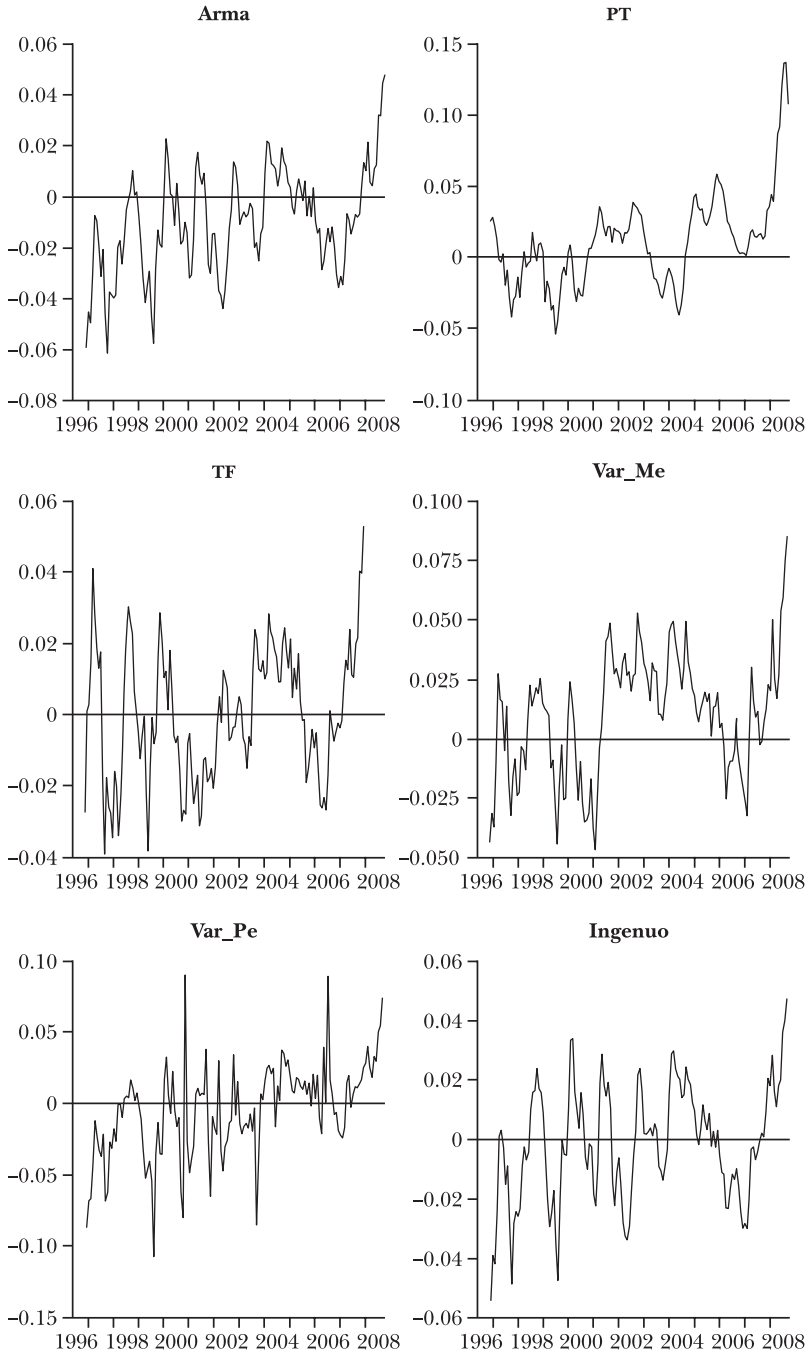
^a Valores críticos para 100 observaciones: -4.239 a 1%, -3.566 a 5% y -3.211 a 10%. ^b Valores críticos para 100 observaciones, $\lambda = 0.5$: -5.11 a 1%, -4.57 a 5% y -4.17 a 10%. ^c Valores críticos para 100 observaciones: -4.545 a 1%, -3.842 a 5% y -3.504 a 10%. ^d Valores críticos para 100 observaciones, $\lambda_1 = 0.6$, $\lambda_2 = 0.8$: -6.32 a 1%, -5.73 a 5% y -5.32 a 10%.

Anexo 3

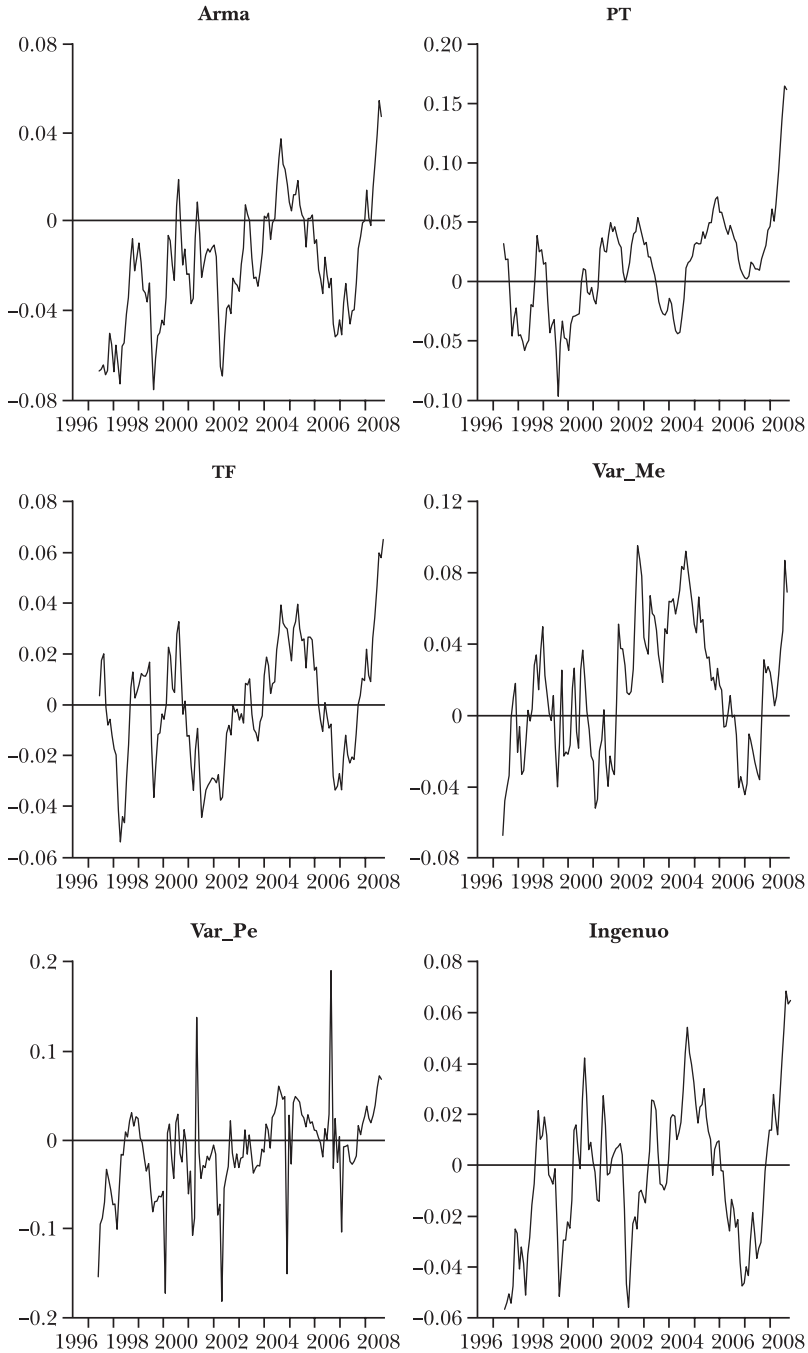
Errores de pronóstico

GRÁFICA A.I. ERRORES DE PRONÓSTICO, HORIZONTE A TRES MESES, 1996-2008

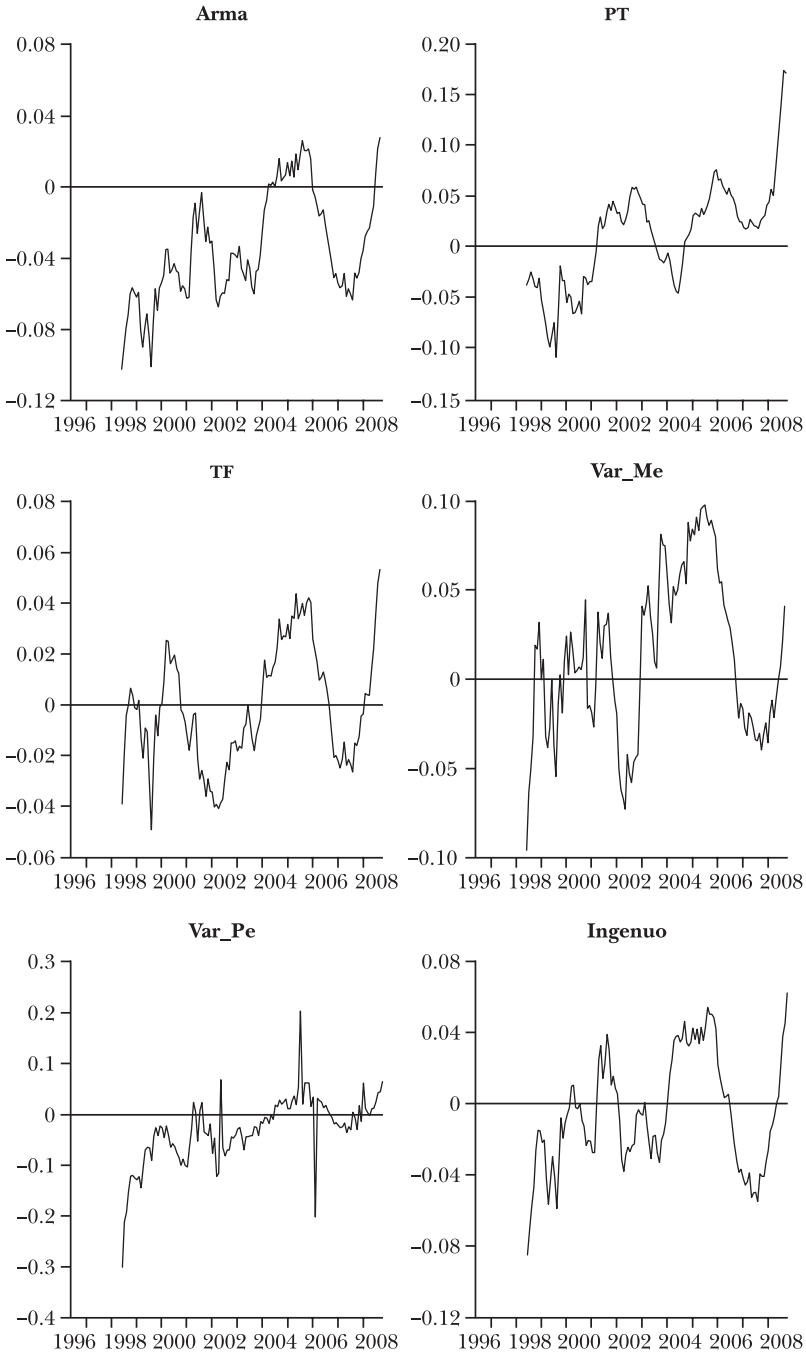
GRÁFICA A.II. ERRORES DE PRONÓSTICO, HORIZONTE A SEIS MESES, 1996-2008



GRÁFICA A.III. ERRORES DE PRONÓSTICO, HORIZONTE A 12 MESES, 1996-2008



GRÁFICA A.IV. ERRORES DE PRONÓSTICO, HORIZONTE A 24 MESES, 1996-2008



*Anexo 4***Pruebas de los pronósticos: de insesgamiento e inclusión****CUADRO A. 6. PRUEBA DE INSESGAMIENTO DE HOLDEN Y PEEL (estadístico F, valor p en paréntesis)**

| <i>Modelo\Horizonte</i> | <i>3 meses</i> | <i>6 meses</i> | <i>12 meses</i> | <i>24 meses</i> |
|-------------------------|----------------------|----------------------|----------------------|-----------------------|
| ARMA | 16.87243 (0.0001) | 34.09963 (0.0000) | 68.28066 (0.0000) | 151.9173 (0.0000) |
| PT | 13.73196 (0.0003) | 15.77696 (0.0001) | 11.03833 (0.0011) | 6.269140 (0.0136) |
| TF | 0.058383 (0.8094) | 0.031824 (0.8587) | 0.173378 (0.6778) | 0.084246 (80.7721) |
| Var_Me | 10.50901 (0.0015) | 23.68273 (0.0000) | 23.59533 (0.0000) | 9.771734 (0.0022) |
| Var_Pe | 2.031647 (0.1562) | 3.807731 (0.0530) | 6.405756 (0.0125) | 10.65880 (0.0014) |
| Ingenuo | 0.271729 (0.6030) | 0.506983 (0.4776) | 1.539792 (0.2168) | 3.851361 (0.0519) |

CUADRO A. 7. PRUEBA DE NORMALIDAD DE JARQUE-BERA (estadístico Jarque-Bera, valor p en paréntesis)

| <i>Modelo \ Horizonte</i> | <i>3 meses</i> | <i>6 meses</i> | <i>12 meses</i> | <i>24 meses</i> |
|---------------------------|------------------------|------------------------|------------------------|------------------------|
| ARMA | 0.495698 (0.78048) | 0.050428 (0.97510) | 1.089211 (0.58007) | 3.938086 (0.13959) |
| PT | 5.454404 (0.06540) | 85.67087 (0.00000) | 29.48443 (0.00000) | 5.564563 (0.06190) |
| TF | 0.689657 (0.70834) | 1.645823 (0.43915) | 1.105735 (0.57530) | 4.073060 (0.13048) |
| Var_Me | 1.693636 (0.42878) | 0.225477 (0.89338) | 3.700433 (0.15720) | 3.450155 (0.17816) |
| Var_Pe | 56,040.64 (0.00000) | 116,517.5 (0.00000) | 102,520.1 (0.00000) | 43,497.75 (0.00000) |
| Ingenuo | 0.500124 (0.77875) | 0.229505 (0.89159) | 0.911466 (0.63398) | 3.495816 (0.17414) |

CUADRO A. 8. PRUEBA DE AUTOCORRELACIÓN (estadístico Q, valor p en paréntesis)

| <i>Modelo \ Horizonte</i> | <i>3 meses</i> | <i>6 meses</i> | <i>12 meses</i> | <i>24 meses</i> |
|---------------------------|-------------------|-------------------|-------------------|-------------------|
| ARMA | 83.691 (0.000) | 204.54 (0.000) | 367.52 (0.000) | 550.78 (0.000) |
| PT | 155.57 (0.000) | 370.30 (0.000) | 410.10 (0.000) | 602.90 (0.000) |
| TF | 65.884 (0.000) | 207.10 (0.000) | 347.85 (0.000) | 530.91 (0.000) |
| Var_Me | 119.23 (0.000) | 247.33 (0.000) | 444.21 (0.000) | 531.69 (0.000) |
| Var_Pe | 11.266 (0.010) | 100.40 (0.000) | 74.995 (0.000) | 307.21 (0.000) |
| Ingenuo | 102.78 (0.000) | 196.65 (0.000) | 323.81 (0.000) | 522.60 (0.000) |

CUADRO A. 9 PRUEBAS DE INCLUSIÓN DE CHONG Y HENDRY: HORIZONTE A TRES MESES (estadístico F, valor p en paréntesis)

| <i>Incluye a →</i> | <i>ARMA</i> | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| ARMA | | 16.75783 (0.0000) | 21.84970 (0.0000) | 10.02817 (0.0001) | 10.32933 (0.0001) |
| PT | 174.7162 (0.0000) | | 200.3796 (0.0000) | 174.5221 (0.0000) | 180.4153 (0.0000) |
| TF | 5.954383 (0.0033) | 9.393788 (0.0001) | | 6.374434 (0.0022) | 6.613181 (0.0018) |
| Var_Me | 44.70253 (0.0000) | 54.17758 (0.0000) | 62.24064 (0.0000) | | 46.50595 (0.0000) |
| Var_Pe | 207.6608 (0.0000) | 236.4621 (0.0000) | 249.4880 (0.0000) | 210.9437 (0.0000) | |

CUADRO A. 10. PRUEBAS DE INCLUSIÓN DE CHONG Y HENDRY: HORIZONTE A SEIS MESES (estadístico F, valor p en paréntesis)

| <i>Incluye a →</i> | <i>ARMA</i> | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| ARMA | | 24.92966 (0.0000) | 39.54196 (0.0000) | 20.48899 (0.0000) | 21.77949 (0.0000) |
| PT | 149.8380 (0.0000) | | 187.3008 (0.0000) | 149.8169 (0.0000) | 161.9939 (0.0000) |
| TF | 6.258298 (0.0025) | 7.383476 (0.0009) | | 6.084130 (0.0029) | 8.091603 (0.0005) |
| Var_Me | 71.30965 (0.0000) | 78.21634 (0.0000) | 100.6152 (0.0000) | | 75.41675 (0.0000) |
| Var_Pe | 131.1196 (0.0000) | 149.5053 (0.0000) | 175.6709 (0.0000) | 134.0577 (0.0000) | |

CUADRO A. 11. PRUEBAS DE INCLUSIÓN DE CHONG Y HENDRY: HORIZONTE A 12 MESES (estadístico F, valor p en paréntesis)

| <i>Incluye a →</i> | <i>ARMA</i> | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| ARMA | | 37.95262 (0.0000) | 77.92273 (0.0000) | 35.92298 (0.0000) | 35.74447 (0.0000) |
| PT | 122.6964 (0.0000) | | 193.9017 (0.0000) | 124.5830 (0.0000) | 126.5303 (0.0000) |
| TF | 2.389654 (0.0955) | 2.153673 (0.1200) | | 1.964202 (0.1443) | 3.311645 (0.0394) |
| Var_Me | 75.56209 (0.0000) | 79.81654 (0.0000) | 132.4346 (0.0000) | | 77.47183 (0.0000) |
| Var_Pe | 183.7228 (0.0000) | 194.2682 (0.0000) | 291.0224 (0.0000) | 187.5165 (0.0000) | |

CUADRO A. 12. PRUEBAS DE INCLUSIÓN DE CHONG Y HENDRY: HORIZONTE A 24 MESES (estadístico F, valor p en paréntesis)

| <i>Incluye a →</i> | <i>ARMA</i> | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| ARMA | | 75.68087 (0.0000) | 172.0679 (0.0000) | 66.17676 (0.0000) | 71.95839 (0.0000) |
| PT | 124.6507 (0.0000) | | 263.5651 (0.0000) | 123.9568 (0.0000) | 137.2855 (0.0000) |
| TF | 0.227780 (0.7966) | 1.809173 (0.1681) | | 4.614479 (0.0117) | 1.546222 (0.2172) |
| Var_Me | 66.12716 (0.0000) | 75.11635 (0.0000) | 188.5693 (0.0000) | | 71.61710 (0.0000) |
| Var_Pe | 254.6535 (0.0000) | 285.5289 (0.0000) | 503.6239 (0.0000) | 253.9676 (0.0000) | |

CUADRO A. 13. PRUEBAS DE INCLUSIÓN DE FAIR Y SCHILLER: HORIZONTE A TRES MESES (estadístico t, valor p en paréntesis)

| <i>Modelos</i> | <i>Coefficiente β_1</i> | <i>Coefficiente β_2</i> | <i>Decisión</i> |
|-----------------|--|--|---------------------|
| ARMA – PT | 0.199331 (0.6559) | 13.12282 (0.0004) | PT incluye a ARMA |
| ARMA – TF | 1.039729 (0.3096) | 22.28717 (0.0000) | TF incluye a ARMA |
| ARMA – Var_Me | 0.402253 (0.5269) | 0.402253 (0.5269) | |
| ARMA – Var_Pe | 0.745810 (0.3893) | 0.009999 (0.9205) | |
| PT - TF | 7.213513 (0.0081) | 15.10313 (0.0002) | |
| PT – Var_Me | 12.29755 (0.0006) | 0.071300 (0.7898) | PT incluye a Var_Me |
| PT – Var_Pe | 13.70921 (0.0003) | 0.001422 (0.9700) | PT incluye a Var_Pe |
| TF – Var_Me | 21.81420 (0.0000) | 1.261708 (0.2632) | TF incluye a Var_Me |
| TF – Var_Pe | 21.94030 (0.0000) | 0.001679 (0.9674) | TF incluye a Var_Pe |
| Var_Me – Var_Pe | 1.378306 (0.2423) | 0.007841 (0.9296) | |

CUADRO A. 14. PRUEBAS DE INCLUSIÓN DE FAIR Y SCHILLER: HORIZONTE A SEIS MESES (estadístico t, valor p en paréntesis)

| <i>Modelos</i> | <i>Coefficiente β_1</i> | <i>Coefficiente β_2</i> | <i>Decisión</i> |
|-----------------|--|--|-------------------------|
| ARMA – PT | 1.818226 (0.1797) | 10.09711 (0.0018) | PT incluye a ARMA |
| ARMA – TF | 1.490756 (0.2242) | 32.03756 (0.0000) | TF incluye a ARMA |
| ARMA – Var_Me | 0.003727 (0.9514) | 1.167075 (0.2819) | |
| ARMA – Var_Pe | 1.698716 (0.1946) | 5.113440 (0.0253) | Var_Pe incluye a ARMA |
| PT - TF | 2.623031 (0.1076) | 23.84929 (0.0000) | TF incluye a PT |
| PT – Var_Me | 7.041129 (0.0089) | 0.085235 (0.7708) | PT incluye a Var_Me |
| PT – Var_Pe | 13.80508 (0.0003) | 8.823706 (0.0035) | |
| TF – Var_Me | 28.93242 (0.0000) | 0.091444 (0.7628) | TF incluye a Var_Me |
| TF – Var_Pe | 30.69320 (0.0000) | 3.768166 (0.0542) | |
| Var_Me – Var_Pe | 1.978138 (0.1618) | 4.201368 (0.0423) | Var_Pe incluye a Var_Me |

CUADRO A. 15. PRUEBAS DE INCLUSIÓN DE FAIR Y SCHILLER: HORIZONTE A 12 MESES (estadístico t, valor p en paréntesis)

| <i>Modelos</i> | <i>Coficiente β_1</i> | <i>Coficiente β_2</i> | <i>Decisión</i> |
|-----------------|--|--|---------------------|
| ARMA – PT | 0.000883 (0.9763) | 2.259940 (0.1351) | |
| ARMA – TF | 0.723933 (0.3964) | 54.30509 (0.0000) | TF incluye a ARMA |
| ARMA – Var_Me | 1.142881 (0.2870) | 0.939039 (0.3343) | |
| ARMA – Var_Pe | 2.810279 (0.0960) | 3.027030 (0.0842) | |
| PT – TF | 0.163743 (0.6864) | 50.41318 (0.0000) | TF incluye a PTh |
| PT – Var_Me | 3.850715 (0.0518) | 1.360805 (0.2455) | PT incluye a Var_Me |
| PT – Var_Pe | 4.756885 (0.0309) | 2.672621 (0.1044) | PT incluye a Var_Pe |
| TF – Var_Me | 53.86336 (0.0000) | 0.205160 (0.6513) | TF incluye a Var_Me |
| TF – Var_Pe | 53.86336 (0.0000) | 0.205160 (0.6513) | TF incluye a Var_Pe |
| Var_Me – Var_Pe | 1.211505 (0.2730) | 1.630300 (0.2039) | |

CUADRO A. 16. PRUEBAS DE INCLUSIÓN DE FAIR Y SCHILLER: HORIZONTE A 24 MESES (estadístico t, valor p en paréntesis)

| <i>Modelos</i> | <i>Coficiente β_1</i> | <i>Coficiente β_2</i> | <i>Decisión</i> |
|-----------------|--|--|-----------------------|
| ARMA – PT | 1.600383 (0.2083) | 0.748508 (0.3886) | |
| ARMA – TF | 0.567100 (0.4529) | 83.85677 (0.0000) | TF incluye a ARMA |
| ARMA – Var_Me | 8.495402 (0.0042) | 2.489638 (0.1172) | Var_Me incluye a ARMA |
| ARMA – Var_Pe | 17.07042 (0.0001) | 12.33427 (0.0006) | |
| PT – TF | 3.388128 (0.0681) | 90.05634 (0.0000) | |
| PT – Var_Me | 5.435396 (0.0214) | 0.414162 (0.5211) | PT incluye a Var_Me |
| PT – Var_Pe | 11.58368 (0.0009) | 7.929882 (0.0057) | |
| TF – Var_Me | 118.4908 (0.0000) | 14.59826 (0.0002) | |
| TF – Var_Pe | 95.32616 (0.0000) | 2.989291 (0.0863) | |
| Var_Me – Var_Pe | 1.142887 (0.2872) | 2.687632 (0.1037) | |

CUADRO A. 17. PRUEBAS DE INCLUSIÓN DE HARVEY, LEYBOURNE Y NEW-BOLD: HORIZONTE A TRES MESES (estadístico HLN, valor p en paréntesis)

| <i>Incluye a →</i> | ARMA | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|-----------------------|----------------------|-----------------------|------------------------|
| ARMA | | 2.003899 (0.04508) | 2.103102 (0.0355) | 2.012719 (0.04414) | -0.632355 (0.52716) |
| PT | 4.020044 (0.0001) | | 4.186897 (0.0000) | 3.788204 (0.00015) | 2.287256 (0.02218) |
| TF | 1.807895 (0.0706) | 1.478224 (0.13935) | | 1.823043 (0.06830) | 0.918195 (0.35852) |
| Var_Me | 3.954018 (0.0000) | 1.867202 (0.06187) | 3.716609 (0.0002) | | 1.689454 (0.09113) |
| Var_Pe | 1.182275 (0.2371) | 1.193050 (0.23285) | 1.200594 (0.2299) | 1.189369 (0.23429) | |

CUADRO A. 18. PRUEBAS DE INCLUSIÓN DE HARVEY, LEYBOURNE Y NEW-BOLD: HORIZONTE A SEIS MESES (estadístico HLN, valor p en paréntesis)

| <i>Incluye a →</i> | ARMA | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|------------------------|------------------------|-----------------------|------------------------|
| ARMA | | 1.677759 (0.093394) | 2.331074 (0.0198) | 1.693313 (0.09040) | -0.589854 (0.55529) |
| PT | 2.236045 (0.0254) | | 2.450490 (0.0143) | 2.546620 (0.01088) | 2.128928 (0.03326) |
| TF | 1.248398 (0.2119) | 0.603328 (0.546291) | | 0.632918 (0.52679) | 0.120037 (0.904454) |
| Var_Me | 3.161031 (0.0016) | 1.320760 (0.18658) | 3.418452 (0.000630) | | 2.418718 (0.015575) |
| Var_Pe | 4.082856 (0.0000) | 2.138242 (0.03250) | 3.834157 (0.0001) | 3.562230 (0.00037) | |

CUADRO A. 19. PRUEBAS INCLUSIÓN DE HARVEY, LEYBOURNE Y NEW-BOLD: HORIZONTE A 12 MESES (estadístico HLN, valor p en paréntesis)

| <i>Incluye a →</i> | ARMA | <i>PT</i> | <i>TF</i> | <i>Var_Me</i> | <i>Var_Pe</i> |
|--------------------|----------------------|------------------------|----------------------|------------------------|------------------------|
| ARMA | | 1.686533 (0.09169) | 2.229088 (0.0258) | 2.110842 (0.03479) | -0.157856 (0.87457) |
| PT | 2.318073 (0.0204) | | 2.895698 (0.0038) | 2.746666 (0.006020) | 2.263067 (0.023632) |
| TF | 0.606591 (0.5441) | 0.253590 (0.79981) | | 0.240455 (0.80998) | -1.097831 (0.27227) |
| Var_Me | 2.021704 (0.0432) | 1.448735 (0.147412) | 2.369736 (0.0178) | | 1.525416 (0.127155) |
| Var_Pe | 2.780384 (0.0054) | 0.040731 (0.967510) | 0.701146 (0.4832) | 6.003194 (0.0000) | |

CUADRO A. 20. PRUEBAS DE INCLUSIÓN DE HARVEY, LEYBOURNE Y NEWBOLD: HORIZONTE A 24 MESES (estadístico HLN, valor p en paréntesis)

| <i>Incluye a →</i> | ARMA | PT | TF | Var_Me | Var_Pe |
|--------------------|----------------------|------------------------|----------------------|-------------------------|-------------------------|
| ARMA | | 4.328616 (1.50E-05) | 2.170524 (0.0300) | 2.770388 (0.0056) | -0.570268 (0.568496) |
| PT | 1.982389 (0.0474) | | 3.700775 (0.0003) | 2.328071 (0.019908) | 1.501275 (0.133284) |
| TF | -0.22320 (0.8234) | 0.609360 0.542286 | | -0.810887 (0.417430) | -1.333924 (0.182229) |
| Var_Me | 1.510762 (0.1309) | 2.281105 (0.02254) | 2.321629 (0.0203) | | 1.12831 (0.259189) |
| Var_Pe | 2.503025 (0.0121) | 2.641162 (0.008262) | 1.909819 (0.0562) | 1.964738 (0.049445) | |

Anexo 5

Evaluación de pronósticos

CUADRO A. 21. ESTADÍSTICAS DE EVALUACIÓN DE PRONÓSTICOS POR MODELO: HORIZONTE A TRES MESES

| <i>Modelo</i> | <i>RECM</i> | <i>Observaciones</i> |
|-------------------------------|-------------|-------------------------|
| ARMA | 0.0152 | |
| PT | 0.0253 | |
| TF | 0.0138 | |
| Var_Me | 0.0181 | |
| Var_Pe | 0.0279 | |
| Ingenuo | 0.0143 | |
| Métodos de combinación | | |
| Comb. original | 0.0136 | |
| MCP- CR | 0.0150 | Coefficientes negativos |
| MCP- HK | 0.0131 | |
| EE- HK | 0.0096 | Coefficientes negativos |
| TS-DGT | 0.0331 | Coefficientes negativos |
| Promedio simple | 0.0145 | |

CUADRO A. 22. ESTADÍSTICAS DE EVALUACIÓN DE PRONÓSTICOS POR MODELO: HORIZONTE A SEIS MESES

| <i>Modelo</i> | <i>RECM</i> | <i>Observaciones</i> |
|-------------------------------|-------------|-------------------------|
| ARMA | 0.0225 | |
| PT | 0.0342 | |
| TF | 0.0188 | |
| Var_Me | 0.0281 | |
| Var_Pe | 0.0333 | |
| Ingenuo | 0.0200 | |
| Métodos de combinación | | |
| Comb. original | 0.0191 | |
| MCP- CR | 0.0202 | Coefficientes negativos |
| MCP- HK | 0.0173 | Coefficientes negativos |
| EE- HK | 0.0191 | Coefficientes negativos |
| TS-DGT | 0.0300 | Coefficientes negativos |
| Promedio simple | 0.0205 | |

CUADRO A. 23. ESTADÍSTICAS DE EVALUACIÓN DE PRONÓSTICOS POR MODELO: HORIZONTE A 12 MESES

| <i>Modelo</i> | <i>RECM</i> | <i>Observaciones</i> |
|-------------------------------|-------------|-------------------------|
| ARMA | 0.0338 | |
| PT | 0.0455 | |
| TF | 0.0235 | |
| Var_Me | 0.0398 | |
| Var_Pe | 0.0528 | |
| Ingenuo | 0.0276 | |
| Métodos de combinación | | |
| Comb. original | 0.0245 | |
| MCP- CR | 0.0220 | Coefficientes negativos |
| MCP- HK | 0.0266 | Coefficientes negativos |
| EE- HK | 0.0066 | Coefficientes negativos |
| TS-DGT | 0.0195 | Coefficientes negativos |
| Promedio simple | 0.0271 | |

CUADRO A. 24. ESTADÍSTICAS DE EVALUACIÓN DE PRONÓSTICOS POR MODELO: HORIZONTE A 24 MESES

| <i>Modelo</i> | <i>RECM</i> | <i>Observaciones</i> |
|-------------------------------|-------------|-------------------------|
| ARMA | 0.0461 | |
| PT | 0.0537 | |
| TF | 0.0237 | |
| Var_Me | 0.0461 | |
| Var_Pe | 0.0709 | |
| Ingenuo | 0.0321 | |
| Métodos de combinación | | |
| Comb. original | 0.0276 | |
| MCP- CR | 0.0347 | Coefficientes negativos |
| MCP- HK | 0.0218 | Coefficientes negativos |
| EE- HK | 0.0112 | Coefficientes negativos |
| TS-DGT | 0.0262 | Coefficientes negativos |
| Promedio simple | 0.0339 | |

Anexo 6

Pruebas de Granger y Newbold

CUADRO A. 25. PRUEBAS DE GRANGER Y NEWBOLD PARA DIFERENCIAS EN ECM

| <i>Horizonte</i> | <i>Combinaciones</i> | <i>P-value de la pendiente</i> |
|------------------|--------------------------------|--------------------------------|
| 3 meses | Modelo MCP-HK y Comb. original | 0.1165 |
| 6 meses | Comb. original y Modelo TF | 0.7134 |
| 12 meses | Comb. original y Modelo TF | 0.0002 |
| 24 meses | Comb. original y Modelo TF | 0.0011 |

REFERENCIAS BIBLIOGRÁFICAS

- Andersson, M., y S. Karlsson (2007), *Bayesian forecast combination for VAR models*, Banco Central de Suecia, Estocolmo (Sveriges Riksbank Research Paper, nº 216).
- Armstrong, J. S. (1989), "Combining Forecasts: The End of the Beginning or the Beginning of the End", *International Journal of Forecasting*, vol. 5, nº 4, pp. 585-88.
- Barnard, G. A. (1963), "New Methods of Quality Control", *Journal of the Royal Statistical Society (Serie A)*, vol. 126, pp. 255-59.

- Barrera, C. (2007), *Proyecciones desagregadas de inflación con modelos sparse var robustos*, Banco Central de Reserva del Perú, Departamento de Modelos Macroeconómicos, Lima, agosto (Documento de trabajo).
- Bates, J. M., y C. W. J. Granger (1969), "The Combination of Forecasts", *Operations Research Quarterly*, vol. 20, pp. 451-68.
- Bruneau, C., O. de Bandt, A. Flageollet y E. Michaux (2007), "Forecasting Inflation Using Economic Indicators: The Case of France", *Journal of Forecasting*, vol. 26, n° 1, pp. 1-22.
- Capistrán, C., y A. Timmermann (2006), *Forecast Combination with Entry and Exit of Experts*, Banco de México, México, D. F. (Documento de Investigación; n° 2006-08).
- Castaño, E., y L. F. Melo (1998), *Métodos de combinación de pronósticos: una aplicación a la inflación colombiana*, Banco de la República, Bogotá (Borradores de Economía, n° 109).
- Castrillo, D., y B. Laverde (2008), *Validación y actualización del modelo de pass-through del tipo de cambio en Costa Rica 1991-2007*, Banco Central de Costa Rica, Departamento de Investigación Económica, San José (Informe Técnico, DIE-16-2008-IT).
- Chong, Y., y D. F. Hendry (1986), "Econometric Evaluation of Linear Macro-Economic Models", *Review of Economic Studies*, vol. 53, pp. 671-90.
- Clemen, R. T. (1989), "Combining Forecasts: A Review and Annotated Bibliography", *International Journal of Forecasting*, vol. 5, n° 4, pp. 559-83.
- Coulson, N. E., y R. Robins (1993), "Forecast Combination in a Dynamic Setting", *Journal of Forecasting*, vol. 12, pp. 63-67.
- Deutsch, M., C. W. Granger y T. Teräsvirta (1994), "The Combination of Forecasts Using Changing Weights", *International Journal of Forecasting*, vol. 10, pp. 47-57.
- Diebold, F., y J. A. López (1996), *Forecast Evaluation and Combination*, National Bureau of Economic Research, Cambridge (Technical Working Paper, n° 192).
- Diebold, F., y P. Pauly (1987), "Structural Change and the Combination of Forecasts", *Journal of Forecasting*, vol. 6, pp. 21-40.
- Durán, R., y M. Rojas (2008), *Actualización de la validación del modelo de títulos fiscales para el pronóstico de la inflación*, Banco Central de Costa Rica, Departamento de Investigación Económica, San José (Informe Técnico DIE-15-2008-IT).

- Fair, R. C., y R. Shiller (1989), "The Informational Content of ex ante Forecasts", *Review of Economics and Statistics*, vol. 71, pp. 325-31.
- Fair, R. C., y R. Shiller (1990), "Comparing Information in Forecasts from Econometric Models", *American Economic Review*, vol. 80, n^o 3, pp. 375-89.
- González, E. (2008), *Pronósticos de agregados a partir de desagregados, caso empírico: inflación de alimentos en Colombia*, Banco de la República, Bogotá (Borradores de Economía, n^o 508).
- Granger, C. W. J., y P. Newbold (1977), *Forecasting Economic Time Series*, Academic Press, Nueva York.
- Granger, C. W. J., y R. Ramanathan (1984), "Improved Methods for Combining Forecasts", *Journal of Forecasting*, vol. 3, pp. 197-204.
- Hallman, J., y M. Kamstra (1989), "Combining Algorithms Based on Robust Estimation Techniques and Co-integrating Restrictions", *Journal of Forecasting*, vol. 8, pp. 189-98.
- Harvey, D., S. Leybourne y P. Newbold (1997), "Testing the Equality of Mean Squared Errors", *International Journal of Forecasting*, vol. 13, pp. 281-91.
- Hoffmaister, A., G. Saborío, I. Solano y A. Solera (2001), *Combinación de las proyecciones de inflación*, Banco Central de Costa Rica, División Económica, San José (Nota de Investigación, n^o 01-01).
- Holden, K., y D. A. Peel (1986), "An Empirical Investigation of Combinations of Economic Forecasts", *Journal of Forecasting*, vol. 5, pp. 229-42.
- Holden, K., y D. A. Peel (1989), "Unbiasedness, Efficiency and the Combination of Economic Forecasts", *Journal of Forecasting*, vol. 8, pp. 175-88.
- Hubrich, K. (2004), "Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy", *International Journal of Forecasting*, vol. 21, n^o 1, pp. 119-36.
- Kırsınbay, T. (2007), *The Use of Encompassing Tests for Forecast Combinations*, International Monetary Fund, noviembre (Working Paper, n^o 07/264).
- Lee, J., y M. Strazicich (2003), "Minimum LM Unit Root Test with Two Structural Breaks", *Review of Economics and Statistics*, vol. 85, n^o 4, pp 1082-89.

- Lee, J., y M. Strazicich (2004), *Minimum LM Unit Root Test with One Structural Break*, Appalachian State University (Working Paper); disponible en: <http://econ.appstate.edu/RePEc/pdf/wp0417.pdf>.
- Lin, C., y T. Teräsvirta (1994), "Testing the Constancy of Regression Parameters Against Continuous Structural Change", *Journal of Econometrics*, vol. 62, n^o 2, pp. 211-28.
- Melo, L., y H. Núñez (2004), *Combinación de pronósticos de la inflación en presencia de cambios estructurales*, Banco de la República, Bogotá (Borradores de Economía, n^o 286).
- Mora, C., y A. Rodríguez (2009), *Código fuente de los programas utilizados en las nuevas combinaciones de proyecciones de inflación*, Banco Central de Costa Rica, Departamento de Investigación Económica, San José (Informe Técnico DEC-DIE-003-2009).
- Mora, C., y C. Torres (2007), *Validación del modelo VAR lineal de mecanismos de transmisión de la política monetaria*, Banco Central de Costa Rica, Departamento de Investigación Económica, San José (Informe Técnico, DIE-37-2007-IT).
- Mora, C., y J. C. Quirós (2008), *Validación del modelo impacto de los precios de petróleo en Costa Rica*, Banco Central de Costa Rica, Departamento de Investigación Económica, San José (Informe Técnico DIE-IT-14-2008).
- Muñoz, E. (2008), *Validación del modelo univariable de inflación empleado en la combinación de pronósticos*, Banco Central de Costa Rica, Departamento de Investigación Económica, San José (Informe Técnico DIE-08-2008-IT).
- Perron, P. (1997), "Further Evidence on Breaking Trend Functions in Macroeconomic Variables", *Journal of Econometrics*, vol. 80, pp. 355-85.
- Saborío, G., y A. Solera (2003), *Incorporación de nuevas herramientas de pronóstico en la combinación de proyecciones de inflación*, Banco Central de Costa Rica, División Económica, San José (Nota Técnica DIE-DCS-03-2003-NT).
- Saborío, G., y A. Solera (2004), *Incorporación del modelo de saldos de títulos de propiedad del gobierno central en la combinación de proyecciones de inflación*, Banco Central de Costa Rica, División Económica, San José (Nota Técnica DIE-DCS-01-2004-NT).
- Smith, J., y K. F. Wallis (2007), *A Simple Explanation of the Forecast Combination Puzzle*, University of Warwick, Department of Economics, Warwick, Inglaterra (Staff Paper).

- Solera, A. (2005), *Pronóstico de inflación en Costa Rica: una estimación con redes neuronales artificiales*, Banco Central de Costa Rica, Departamento de Contabilidad Social, San José (Documento DCS-155-2005).
- Trenkler, G., y B. Gotu (1989), *Combination of Forecasts: A Bibliography*, University of Dortmund, Department of Statistics, Dortmund, Alemania.
- Utrera, G. (2004), *Una aproximación a la combinación de métodos econométricos para pronosticar la inflación en Argentina*, Instituto de Economía y Finanzas, Facultad de Ciencias Económicas, Universidad Nacional de Córdoba.
- Zivot, E., y D. W. K. Andrews (1992), "Further Evidence on the Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis Source", *Journal of Business and Economic Statistics*, vol. 10, nº 3, pp. 251-20.

Oknan Bello Dinartes

Combinación de pronósticos de inflación en Nicaragua

I. INTRODUCCIÓN

El objetivo principal de la política monetaria en Nicaragua es mantener la estabilidad de los precios. Para lograr este objetivo los encargados de la política monetaria toman decisiones basadas en la máxima información disponible, lo que incluye una evaluación de la trayectoria futura de la economía, para conducir a las principales variables macroeconómica en una senda favorable. Así, la naturaleza *forward-looking* de las decisiones de política económica subraya la importancia de realizar proyecciones.

Una práctica común en el trabajo de proyección ha sido desarrollar modelos empíricos para describir y pronosticar el comportamiento de la economía. Sin embargo, una serie de

Publica el CEMLA, con la debida autorización, el estudio de O. Bello Dinartes, funcionario del Banco Central de Nicaragua (BCN), presentado en la XIV Reunión de la Red de Investigadores de Bancos Centrales del Continente Americano, auspiciada por el Banco Central de Brasil, celebrada en Salvador, Bahía, del 11 al 13 de noviembre de 2009. Las opiniones expresadas en este trabajo son exclusivas del autor y no comprometen al BCN ni a su consejo directivo. El autor agradece los comentarios y sugerencias de Rigoberto Castillo, Óscar Gámez y Carlos Zambrana. E-mail: <obello@bcn.gob.ni>. Tel.: (505) 22557171, ext. 252.

decisiones relacionadas con la modelación: selección y transformación de datos, periodo muestral de estimación, técnicas de estimación utilizadas, especificación dinámica, marco teórico utilizado, etc.; inestabilidades desconocidas (quiebres estructurales) que favorecen a uno u otro modelo; y la incorrecta exclusión o inclusión de algunos regresores en el proceso de selección (Timmerman, 2006), tendrán impacto en el producto –por ejemplo, proyecciones– de los modelos. Éstos divergirán del verdadero proceso generador de datos de la economía, el cual será desconocido, y no tomarán en cuenta toda la información disponible.

El investigador, por tanto, contará con una batería de modelos de pronósticos, los cuales tendrán el potencial de aportar información para la proyección central de la variable a pronosticar. Ante esta situación, dos estrategias resultan naturales: escoger el mejor modelo o tratar de combinarlos para producir un solo pronóstico. Desde el trabajo seminal de Bates y Granger (1969), la literatura empírica y teórica ha mostrado que una combinación de diferentes pronósticos producirá una proyección más precisa, comparada con la mejor proyección individual.

En esta línea, en este trabajo se implementan diversas técnicas de combinación de pronósticos con el objetivo de producir un pronóstico mejorado de la inflación en Nicaragua. Para cumplir con este propósito se combinan proyecciones fuera de muestra, obtenidas mediante regresiones rolling y recursivas, de cinco modelos de inflación para horizontes de pronósticos de tres, seis, nueve y 12 meses. Para seleccionar los modelos a combinar en cada horizonte, se usa un algoritmo basado en pruebas de abarcamiento propuesto por Costantini y Pappalardo (2008). Las técnicas de combinación utilizadas van desde métodos sencillos como un promedio simple, y técnicas más elaboradas que toman en cuenta las características de los errores de pronóstico como sesgo, autocorrelación y estacionariedad.

Los resultados de las estimaciones muestran ganancias en precisión estadísticamente significativas, medida mediante la raíz del error cuadrático medio de los errores de pronóstico (RMSFE),¹ obtenidas a través de la combinación de los modelos

¹ Una discusión sobre algunas medidas de evaluación de pronóstico se

comparados al mejor modelo individual. Las máximas ganancias obtenidas fueron 19.4% para el horizonte de tres meses, 18.3% en el caso del horizonte de seis meses, y 14.2% y 12.4% para los horizontes de nueve y 12 meses, respectivamente.

El resto del trabajo se organiza de la siguiente manera: en la sección II se realiza una breve discusión, empírica y teórica, acerca de las bondades de combinar pronósticos; en la sección III describimos el algoritmo usado para seleccionar los modelos que se combinarían y los diferentes métodos de combinación de pronósticos; la sección IV se ocupa de los modelos a combinar; los resultados de la estimación se muestran en la sección V; por último, en la sección VI se presentan las conclusiones.

II. EVIDENCIA DE COMBINACIÓN DE PRONÓSTICOS

Según Timmerman (2006) hay al menos tres razones de por qué una combinación de pronósticos puede producir mejores proyecciones que las realizadas por el mejor modelo individual. Primero, la combinación de pronósticos puede ser motivada por un argumento de diversificación de cartera. Suponga que un formulador de política tiene ante sí varios modelos de pronósticos, pero no puede observar el conjunto de información subyacente de cada modelo individual. En esta situación, al no ser posible juntar todo el conjunto de información relevante en un modelo único que incorpore a los demás modelos, la mejor forma de explotar la información detrás de cada modelo individual será combinarlos. Relacionado a lo anterior, Diebold y López (1996) mencionan que aunque combinar conjuntos de información es mejor que combinar pronósticos, en la práctica combinar conjuntos de información puede resultar imposible o demasiado costoso, además, puede no ser susceptible a las técnicas habituales de análisis.

Otra razón para combinar pronósticos es que pueden existir quiebres estructurales desconocidos que favorezcan a un modelo en vez de otro. Algunos modelos se adaptan a estos quiebres rápidamente mientras otros modelos pueden tener

presenta en el anexo 1.

parámetros que se ajustan lentamente después del quiebre, así, una combinación de diferentes modelos puede producir pronósticos más robustos (Diebold y Pauly, 1987). Un tercer argumento a favor de combinar pronósticos es que los pronósticos individuales pueden estar sujetos a sesgos debido a variables omitidas que son desconocidas para el operador del modelo, por lo que una combinación de éstos puede compensar estos sesgos mejorando la precisión del pronóstico.

La evidencia empírica, aunque mixta, favorece la idea de que una combinación de pronósticos tiende a mejorar la precisión de las proyecciones. Makridakis *et al.* (1982), usando un esquema de competencia de pronósticos a gran escala (1,001 series de tiempo) conocido como *M-Competition*, compara el desempeño de una combinación de pronósticos usando un promedio simple versus una combinación usando promedios ponderados. Ellos encuentran que una combinación basada en un promedio simple produce los mejores pronósticos, y que ésta tiene un desempeño muy superior al mejor modelo individual. Una versión posterior de este trabajo fue realizada por Makridakis y Hibon (2000), donde evalúan el desempeño de diferentes técnicas de proyección. Ellos concluyen que: modelos estadísticos complejos algunas veces no son superiores en términos de su calidad de pronósticos comparados con modelos más sencillos; la precisión de los pronósticos depende del horizonte de proyección; y que en promedio una combinación de modelos es superior al mejor modelo individual.

Stock y Watson (2004) en un estudio para los países del G7, muestra que una combinación de pronóstico resulta en una proyección mejorada del crecimiento del producto, desempeñándose mejor que un modelo autorregresivo usado como marco de referencia. Igual que en otros estudios, modelos de combinación sencillos como una media simple o una media truncada muestran un buen desempeño. Clark y McCracken (2008), al considerar la propensión de los modelos VAR a inestabilidades, combinan distintas especificaciones de modelos VAR para tratar de mejorar la precisión de los pronósticos. Ellos encuentran que una combinación de los diferentes modelos mejora la precisión de las proyecciones, comparadas con el mejor modelo incluido en la combinación.

Castaño y Melo (1998), al aplicar diferentes métodos de

combinación de pronóstico para un conjunto de modelos de la inflación colombiana, informan ganancias en precisión de hasta 42% al combinar los modelos comparado con el mejor modelo de pronóstico. Melo y Núñez (2004), en un estudio para la misma serie donde aplican técnicas de combinación que toman en cuenta el cambio estructural en la inflación, señalan ganancias en precisión de las combinaciones comparadas con el mejor modelo individual, sin embargo, para el corto plazo no encuentran ganancias en precisión comparadas con los resultados obtenidos por Castaño y Melo (1998).

Kapetanios *et al.* (2008) en un estudio que describe los modelos de pronóstico del Banco de Inglaterra, entre los que se encuentran modelos univariados lineales y no lineales, modelos VAR, modelos con coeficientes variantes y modelos de factores, entre otros, muestra que al ser combinados en general exhiben un mejor desempeño que un modelo autorregresivo usado como referencia.

III. MARCO METODOLÓGICO

En esta sección se describe la metodología para seleccionar los modelos a combinar y las diferentes técnicas de combinación de pronósticos utilizados para producir una proyección combinada de la inflación en Nicaragua.

1. Prueba de abarcamiento de pronósticos

Un paso importante antes de proceder a combinar pronósticos es determinar cuáles pronósticos se van a combinar. En la práctica se dispone de varios pronósticos que proceden de diferentes fuentes y modelos, sin embargo, es posible que alguno de estos pronósticos no contenga información útil que puede ser aprovechada en la combinación. Las pruebas de abarcamiento de pronósticos son utilizadas para determinar si un pronóstico incorpora toda la información relevante para predicción contenida en un pronóstico rival. Si este no es el caso, ambos modelos contienen información marginal que puede ser usada en un pronóstico combinado de ellos.

Para seleccionar los modelos que se combinarán usamos un algoritmo de abarcamiento propuesto por Costantini y

Pappalardo (2008), el cual usa la prueba de abarcamiento propuesta por Harvey, Leybourne y Newbold (HLN, 1998).

La prueba de HLN está basada en la popular prueba de evaluación de pronósticos de Diebold y Mariano (DM, 1995). Esta última prueba es usada para examinar si dos modelos rivales tienen igual habilidad predictiva. En su construcción considera el diferencial de la función de pérdida muestral dado por $d_t = L(e_t^1) - L(e_t^2)$, donde $L(\cdot)$ es una función de pérdida arbitraria tal como RMSFE, e_t^j es el error de proyección h pasos adelante del modelo $j=1, 2$ y $t=1, 2, \dots, T$.² Si los pronósticos tienen en promedio igual valor predictivo entonces $E(d_t) = 0$.

La prueba se basa en el promedio muestral dado por

$$\bar{d} = \frac{\sum_{t=1}^T d_t}{T}. \text{ Si se asume estacionariedad en covarianza en la se-}$$

rie de diferencial de pérdidas, la prueba DM se distribuye asintóticamente normal estándar en la hipótesis nula de igual valor predictivo. La prueba estadística se puede expresar como en la ecuación (1):

$$(1) \quad DM = \bar{d} / \sqrt{\hat{V}(\bar{d})} \rightarrow N(0,1).$$

Donde $V(\bar{d})$ es un estimador consistente de la varianza asintótica de \bar{d} , y asumiendo que los pronósticos h pasos adelante muestran dependencia hasta el orden $h-1$, ésta se obtiene como:

$$(2) \quad V(\bar{d}) \approx (\gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k) / T.$$

Donde $\hat{\gamma}_k$ es la k -ésima autocovarianza de \bar{d} , estimada como

$$\hat{\gamma}_k = T^{-1} \sum_{t=k+1}^T (d_t - \bar{d})(d_{t-k} - \bar{d}), \quad k = 0, 1, 2, \dots, h-1.$$

Harvey, Leybourne, y Newbold (1997), recomendaron dos modificaciones al modelo DM que podrían mejorar el poder de la prueba en pequeñas muestras. Estos cambios consisten

² Se define a Y_t como el valor observado de la serie en el periodo t , a $f_{t/h}^j$ como el valor pronosticado de Y_t por el modelo j con información hasta $t-h$, e_t^j se expresa como $e_t^j = Y_t - f_{t/h}^j$.

en comparar la prueba estadística DM con valores críticos de la distribución *t-Student* con $T-1$ grados de libertad para reducir las distorsiones de tamaño, y modificar la prueba haciendo uso de un estimador insesgado de la varianza de \bar{d} . La prueba DM modificada (MDM) es:

$$(3) \quad MDM = \left[\frac{T+1-2h+T^{-1}h(h-1)}{T} \right]^{1/2} DM .$$

La prueba de abarcamiento HLN se obtiene modificando d_t a $d_t = (e_t^1 - e_t^2)e_t^1$. La hipótesis nula en esta prueba es que el pronóstico del modelo 1 incorpora al del modelo 2, es decir, toda la información relevante del modelo 2 ya está contenida en el modelo 1.

2. Algoritmo de abarcamiento y selección de modelos a combinar

El algoritmo de abarcamiento propuesto por Costantini y Pappalardo (2008) está basado en el hallazgo de Ericsson (1992), el cual establece que una condición suficiente para minimizar el RMSFE de un modelo dado es, verificar que éste abarca a los otros modelos competidores. Esto implica realizar la prueba de abarcamiento contrastando los modelos con más bajo RMSFE contra los modelos con más alto RMSFE. Este algoritmo de abarcamiento es el siguiente:

- *Paso 1.* Calcular el RMSFE de las proyecciones fuera de muestra de cada modelo. Ordenar los modelos de menor a mayor RMSFE.
- *Paso 2.* Escoger el mejor modelo (el modelo con el menor RMSFE) y examinar secuencialmente si éste abarca a los otros modelos usando la prueba HLN. Si el mejor modelo abarca al modelo alternativo a un nivel de significancia α , elimine al modelo alternativo como candidato para la combinación de pronósticos.
- *Paso 3.* Repetir el paso 2 con el segundo mejor modelo. La lista de modelos que se examinan incluirá sólo los modelos no eliminados en el paso anterior y el mejor modelo.
- *Paso 4.* Continuar con el tercer mejor modelo, y así hacia

adelante, hasta que no existan modelos para los cuales se rechaza la hipótesis nula de abarcamiento.

- *Paso 5.* Calcular el pronóstico combinado usando los diferentes métodos de combinación de pronósticos seleccionados.

Además del abarcamiento, para que un pronóstico se considere apropiado para formar parte de una combinación debería cumplir ciertas propiedades. De acuerdo con Diebold y López (1996), los pronósticos deben ser insesgados, es decir, la media de los errores de pronósticos debe ser igual a cero, y los errores de pronóstico un paso adelante no deben estar correlacionados con errores pasados.³ Si estas propiedades no son satisfechas, sería recomendable reexaminar el modelo subyacente que produjo los pronósticos.

Para verificar insesgamiento se utilizará la prueba de Holden y Peel (1989), la cual está basada en la siguiente ecuación:

$$(4) \quad Y_t - f_{t|t-h}^j = \alpha + \varepsilon_t.$$

Si la hipótesis $\alpha = 0$ no se rechaza, el pronóstico es insesgado.

Por otro lado, para verificar autocorrelación se utilizará la prueba de Ljung-Box (1979).

3. Técnicas de combinación de pronósticos

En esta parte se describen las metodologías de combinación utilizadas en este trabajo: promedio simple; combinación basada en el MSFE; combinación calculada usando mínimos cuadrados ordinarios; y método de combinación con mínimos cuadrados ponderados. Todos los métodos de combinación toman la forma de una combinación lineal de los pronósticos individuales:

$$(5) \quad \hat{Y}_{t+h/t} = w_{0,t} + \sum_{j=1}^n w_{j,t} f_{t+h/t}^j,$$

Donde $\hat{Y}_{t+h/t}$ es la proyección combinada (en nuestro caso la

³ Sin embargo, Diebold y López (1996) mencionan que para pronósticos $h > 1$ pasos adelante, es probable que los errores de pronósticos óptimos exhiban algún grado de correlación serial.

proyección central de la inflación) h pasos adelante, $f_{t+h/t}^j$ es el pronóstico de Y_{t+h} dado por el modelo j ($j=1, 2, \dots, n$) con información hasta t y $w_{j,t}$ es el peso del pronóstico j en la combinación. Para realizar y evaluar el desempeño de los pronósticos la muestra se divide en dos periodos: el primer periodo $t=1, 2, \dots, T_0-1$ es utilizado para estimar los parámetros de los diferentes modelos de pronóstico, mientras el periodo $t=T_0, T_0+1, \dots, T$ está compuesto por las proyecciones fuera de muestra de cada modelo individual.

a) Promedio simple

En este método se asigna igual peso a los pronósticos en la combinación, de tal manera que $w_{0,t} = 0$ mientras $w_{j,t} = \frac{1}{n}$. Este método tiene la virtud de ser imparcial, de fácil cálculo y en muchos casos parece superar en precisión a modelos más elaborados (ver por ejemplo Makridakis *et al.*, 1982; Makridakis *et al.*, 1993; Bessler y Brandt, 1981).

b) Combinación basada en el MSFE

En este método, el peso asignado a cada pronóstico individual depende inversamente de su desempeño histórico, de tal manera que los pronósticos más precisos tienen una ponderación mayor en la combinación. Los pesos son calculados como:

$$(6) \quad w_{i,t} = \frac{\lambda_{it}^{-1}}{\sum_{j=1}^n \lambda_{jt}^{-1}}.$$

Donde $\lambda_{i,t} = \sum_{s=T_0}^{T-h} \delta^{T-h-s} (Y_s^h - \hat{Y}_{i,s/s-h})^2$, $w_{0,t} = 0$ y δ es un factor de

descuento. Si $\delta < 1$, un mayor peso es asignado al desempeño más reciente de cada pronóstico individual. Cuando $\delta = 1$, no hay factor de descuento y las ponderaciones calculadas son equivalentes al esquema de ponderaciones óptimas según el supuesto de pronósticos no correlacionados de Bates y Granger (1969). En este trabajo se usa $\delta = 0.9, 0.95, 1$.

c) *Combinaciones basadas en regresiones*

En este tipo de métodos, los pronósticos son utilizados como variables independientes en un esquema de regresión. Tres procedimientos son aplicados en este trabajo: el procedimiento de Granger y Ramanathan (1984), el de Hallman y Kamstra (1989) y el de Coulson y Robins (1993).

Procedimiento de Granger y Ramanathan (1984): estos autores sugieren correr la siguiente regresión para estimar las ponderaciones a utilizar en la combinación:

$$(7) \quad Y_t = w_0 + w_1 f_{t/t-h}^1 + w_2 f_{t/t-h}^2 + \dots + w_n f_{t/t-h}^n + \varepsilon_t.$$

Con base en las ponderaciones estimadas, el pronóstico combinado se estima como en la ecuación (5). Granger y Ramanathan (1984) arguyen que con este método se pueden producir pronósticos combinados insesgados, a pesar que los pronósticos individuales presenten sesgos.

Procedimiento de Hallman y Kamstra (1989): en la práctica es común que los pronósticos a que se combinan no sean estacionarios, y por lo tanto, es necesario tomar en cuenta esta característica en el procedimiento de combinación.⁴ Hallman y Kamstra (1989) fueron los primeros en notar esto e incorporan el concepto de cointegración en la regresión combinante.

Ellos argumentan que cuando la variable Y_t es $I(1)$, cualquier pronóstico razonable $f_{t/t-h}$ debería estar cointegrado con ella a través del vector de cointegración (1,-1). Si esto no ocurre, el error de pronóstico $Y_t - f_{t/t-h}$ no será estacionario, en cambio si $Y_t - f_{t/t-h}$ y $Y_{t-h} - Y_t$ son $I(0)$, entonces $f_{t/t-h} - Y_{t-h}$ también lo será. Partiendo de esto, desarrollan un modelo en el que el cambio en Y_t es una combinación lineal del pronósticos de los cambios. Este modelo es equivalente a estimar la siguiente ecuación:

$$(8) \quad \begin{aligned} Y_t &= w_0 + w_1 f_{t/t-h}^1 + w_2 f_{t/t-h}^2 + \dots + w_n f_{t/t-h}^n + \varepsilon_t \\ \text{s.a.} \quad w_1 + w_2 + \dots + w_n &= 1 \end{aligned}$$

El pronóstico combinado se estimará como en la ecuación (5).

⁴ Como se verá más adelante, no se rechaza la hipótesis de raíz unitaria en la inflación en el periodo muestral utilizado para estimar los parámetros de la ecuación de combinación.

Procedimiento de Coulson y Robins (1993): al igual que la metodología de Hallman y Kamstra (1989), el procedimiento de Coulson y Robins (1989) es utilizado para combinar pronósticos con series $I(1)$. Esta metodología parte de la siguiente ecuación de regresión para cada uno de los h horizontes deseados:

$$(9) \quad \Delta Y_t = w_0 + w_1(f_{t/t-h}^1 - Y_{t-1}) + w_2(f_{t/t-h}^2 - Y_{t-1}) + \dots + w_n(f_{t/t-h}^n - Y_{t-1}) + \varepsilon_t$$

Una vez estimado el vector de parámetros $(w_0, w_1, w_2, \dots, w_k)$, la combinación de pronósticos se calcula como:

$$(10) \quad \hat{Y}_{t+h/t} = w_0 + w_1(f_{t+h/t}^1 - \hat{Y}_{t+h-1/t}) + w_2(f_{t+h/t}^2 - \hat{Y}_{t+h-1/t}) + \dots + w_n(f_{t+h/t}^n - \hat{Y}_{t+h-1/t}) + \hat{Y}_{t+h-1/t} + \varepsilon_t$$

Para horizontes de un periodo adelante, $\hat{Y}_{t+h-1/t}$ es el valor observado de la variable en t y para horizontes mayores a uno $\hat{Y}_{t+h-1/t}$ corresponde a un pronóstico de periodos anteriores.

d) Combinación de pronósticos basada en mínimos cuadrados ponderados

Este método, propuesto por Diebold y Pauly (1987), trata de modelar posibles quiebres estructurales en las series para combinar, dando un mayor peso a las últimas observaciones en la estimación de los parámetros de la ecuación de combinación (5).

Estos parámetros son estimados mediante mínimos cuadrados ponderados (MCP), usando la siguiente matriz de ponderaciones:⁵

$$(11) \quad \Psi = \text{diag}[\Psi_{tt}] = [kt^\gamma]$$

Donde $k, \gamma > 0$ y $t = 1, 2, \dots, T$. En este esquema se da una influencia decreciente de forma no lineal a las observaciones pasadas en la estimación de los parámetros de la ecuación

⁵ Diebold y Pauly (1987), muestran que esta matriz da mejores resultados que un conjunto alternativo de matrices de ponderaciones que ellos estudian.

combinante. La estimación del parámetro γ se lleva a cabo usando un método de búsqueda de malla, donde la función objetivo es RMSFE. Es decir, dado un conjunto de valores posibles de γ , para cada uno de estos valores se estiman los parámetros de la ecuación combinante, los pronósticos combinados y finalmente el RMSFE. El valor óptimo de γ es seleccionado como aquel que produce el mínimo RMSFE. Estas estimaciones son realizadas para los modelos de Coulson y Robins y de Hallman y Kamstra para cada horizonte de pronóstico.

IV. MODELOS DE PRONÓSTICOS

En esta parte se describen los modelos utilizados para pronosticar la inflación en Nicaragua: modelo autorregresivo integrado de media móvil (ARIMA), modelo de vectores autorregresivos (VAR), modelo de función de transferencia (FT), modelo no lineal autorregresivo de transición suave (STR), y modelo estructural (Estruc).⁶ Estos modelos forman parte de un conjunto de herramientas que utiliza el Banco Central de Nicaragua para realizar sus pronósticos de inflación.

1. Modelo autorregresivo integrado de media móvil (ARIMA)

El modelo ARIMA utilizado en este trabajo toma la forma:

$$(12) \quad (1 - \phi_1 B)(1 - \theta_1 B^{12}) \Delta ipc_t = (1 - \delta_1 B^{12}) \varepsilon_t.$$

Donde ipc es el logaritmo del índice de precios al consumidor; Δ es un operador de diferencia tal que $\Delta ipc_t = (1 - B)ipc_t$; B es un operador de rezagos tal que $B ipc_t = ipc_{t-1}$; $\phi_1, \theta_1, \delta_1$ son parámetros para estimar; y ε_t es un término de error ruido blanco. En el proceso de identificación del modelo se tomó en cuenta criterios usuales de información (Akaike, Schwartz) y la significancia individual de los parámetros.

Mientras este tipo de modelos tienen la desventaja de no ser robustos ante la presencia de cambios estructurales en la

⁶ Los modelos son de frecuencia mensual y fueron sometidos a pruebas estándar para asegurar errores bien comportados.

serie y de no poder describir relaciones económicas entre las variables, tiene la ventaja de ser robustos ante problemas de mala especificación debido a la selección incorrecta de las variables explicativas, son sencillos de estimar y han probado tener una alta capacidad de pronóstico en el corto plazo.

2. Modelo de vectores autorregresivos (VAR)

El modelo VAR tiene la siguiente especificación:

$$(13) \quad \Delta X_t = A + \sum_{i=1}^p \theta_i X_{t-i} + \Psi Dum_t + v_t.$$

Donde $X_t' = [\Delta cred, gap, \Delta ipc]$ es el vector de variables endógenas en el modelo; $cred$ es el logaritmo del crédito total del sector privado; gap es una medida de brecha de producto; Dum es un conjunto de variables dummies que captura estacionalidad y errores atípicos; y v_t es un vector de innovaciones ruido blanco. El orden de los rezagos p se determinó mediante pruebas de exclusión de rezagos.

3. Modelo de función de transferencia (FT)

El modelo FT es una generalización del modelo ARIMA descrito anteriormente en el que se incorpora el efecto de algunas variables que son importantes para explicar la inflación en Nicaragua. Este modelo tiene la forma:

$$(14) \quad (1 - \varphi_1 B - \varphi_2 B^6)(1 - \theta_1 B^{12}) \Delta ipc_t = \omega_0 + \omega_1 B^4 \Delta cred_t + \omega_2 B \Delta poil_t + \omega_3 B \Delta pfood_t + (1 - \delta_1 B^{12}) \varepsilon_t.$$

Donde $poil$ es el logaritmo del precio del petróleo; y $pfood$ es el logaritmo de un índice de precios internacionales de alimentos. Las demás variables son definidas como antes. Para identificar los modelos univariantes de las variables exógenas se utilizaron criterios usuales de información (Akaike, Schwartz).

4. Modelo no lineal autorregresivo de transición suave (STR)

El modelo STR es un modelo no lineal donde se supone

que el proceso generador de la serie oscila de forma suave entre dos regímenes extremos. Este tipo de modelos es especialmente útil para modelar asimetrías en la dinámica de algunas variables económicas y para modelar quiebres estructurales en las series (Teräsvirta y Anderson 1992).

En este trabajo el modelo STR toma la forma:

$$(15) \quad \Delta ipc_t = \alpha_0 + \alpha_1 \Delta ipc_{t-1} + \alpha_2 \Delta ipc_{t-2} + \alpha_3 \Delta poil_{t-1} + \alpha_4 \Delta pfood_{t-1} + (\beta_1 \Delta poil_{t-1} + \beta_2 \Delta ipc_{t-7})(1 + e^{-\delta(\Delta ipc_{t-d} - c_1)})^{-1} + \varepsilon_t$$

Donde α_i , β_i , δ , d , c_1 son parámetros para ser estimados. La no linealidad que introduce los cambios de régimen es capturada por la función de transición $(1 + e^{-\delta(\Delta ipc_{t-d} - c_1)})^{-1}$. En ésta $\delta > 0$ es un indicador de la velocidad de transición entre un régimen y otro, mientras el parámetro c_1 indica donde la transición toma lugar. Así, este modelo esencialmente implica que hay un proceso autorregresivo cuando el valor de la inflación es cercana a c_1 , mientras hay otro cuando la inflación se aleja de c_1 .

5. Modelo estructural (Estruc)

El modelo Estruc es un modelo de corrección de errores, el cual surge de integrar varias teorías acerca de los factores determinantes de la inflación: factores de oferta, que provienen de impulsos de costos o relaciones de markup (Brouwer y Ericsson, 1998) y choques climáticos adversos que afectan la producción agrícola; factores de demanda que incluyen choques en la curva IS; factores monetarios, los cuales se refieren a desequilibrios en el mercado de dinero; y factores externos que incluyen los efectos del tipo de cambio nominal (paridad de poder de compra). Después de eliminar las variables no significativas, la especificación final del modelo se presenta en la siguiente ecuación:

$$(16) \quad \Delta ipc_t = \alpha_0 + \alpha_1 \Delta tc_t + \alpha_2 \Delta rem_{t-2} + \alpha_4 \Delta cred_{t-4} + \alpha_5 \Delta pe_{t-2} + \alpha_6 ind_lluvia + \alpha_7 (ipc_t - \beta_0 - \beta_1 tc_t - \beta_2 wprod_t - \beta_3 pe - \beta_4 tend_{t-1}) + \alpha_7 Dum_t + \varepsilon_t$$

Donde tc es el logaritmo del tipo de cambio de córdobas por dólares; rem es la relación remesas PIB; pe es el logaritmo de un índice de precios externos, el cual incluye petróleo y alimentos; ind_lluvia es un índice excesos de precipitaciones

fluviales; y $wprod$ es el salario nominal ajustado por productividad. El resto de las variables se definen como antes.

V. RESULTADOS

En esta parte se describe la generación de los pronósticos de inflación y los resultados de aplicar las diferentes técnicas de combinación de pronósticos en los modelos de inflación descritos anteriormente.

1. Pronósticos rolling y recursivos

El periodo muestral utilizado para los análisis es 1994:1-2009:1. Esta muestra se divide en dos submuestras: la primera submuestra 1994:1-1998:12, es utilizada para estimar los parámetros de los diferentes modelos de pronóstico descritos en la sección IV; mientras la segunda submuestra 1999:1-2009:1, es utilizada para producir las proyecciones fuera de muestra de cada modelo individual, con las cuales se estimarán las ponderaciones de la ecuación de combinación (5). Los pronósticos producidos son de dos tipos: recursivos y rolling. Ambos esquemas son utilizados para dar mayor robustez a los resultados y aprovechar las ventajas que cada uno posee.⁷

Los pronósticos recursivos h pasos adelante para cada modelo se construyen de la siguiente manera: inicialmente se estima el modelo desde el primer dato disponible hasta 1998:12, con esta estimación se pronostica la inflación para 1998:12+ h . Posteriormente, se vuelve a estimar el modelo agregando una observación, es decir, con datos hasta 1999:1 y se pronostica la inflación para 1999:1+ h . Este proceso se repite sucesivamente hasta 2009:1- h , para producir el pronóstico de 2009:1. Los pronósticos rolling son construidos de forma similar a los pronósticos recursivos, sin embargo, cada vez que se agrega una observación al final de la muestra para producir los pronósticos h pasos adelante, se elimina una observación al principio, de tal forma que el número total de

⁷ Por ejemplo, mientras las estimaciones tipo rolling tienen la ventaja de corregir sesgos al eliminar la información más vieja en el cálculo de los parámetros de la ecuación de combinación, tienen la desventaja de producir un mayor error estándar en éstos.

observaciones (tamaño de la ventana rolling) en cada regresión se mantiene constante.

Los pronósticos rolling y recursivos de cada modelo son estimados para horizontes $h = 3, 6, 9, 12$ meses, de tal manera que coincidan con las revisiones trimestrales de los pronósticos de inflación a un año que realiza el Banco Central de Nicaragua.

Las gráficas I y II del anexo presentan los pronósticos rolling y recursivos para $h = 3$ y 12 y la inflación observada para cada periodo. Como se puede observar, todos los modelos muestran bastante precisión para proyectar la inflación en el corto plazo ($h = 3$), sin embargo, a medida que el horizonte de pronóstico es mayor su capacidad predictiva decrece.

Por otra parte, para las proyecciones con horizontes mayores a tres meses, el error de pronóstico es especialmente alto en los años 2007 y 2008. Este comportamiento podría ser indicativo de quiebre estructural en los errores, por lo que se hace necesario el uso de técnicas de combinación que incorporen quiebre estructural. Cabe destacar que en los años 2007 y 2008 la inflación fue cerca de 9 y 7 puntos porcentuales, respectivamente, mayor que el promedio de los últimos ocho años.

Es de notar, sin embargo, que el modelo estructural es el que presenta el menor error de proyección relativo para este periodo. Este resultado no es extraño debido a que en estos años la inflación estuvo mayormente afectada por el fuerte incremento de los precios internacionales de alimentos y del petróleo, y por los efectos adversos en la producción agrícola a raíz del huracán Félix, variables que son explicativas en el modelo estructural.

2. Evaluación de propiedades de los pronósticos

Como se mencionó arriba, un buen desempeño de la combinación de pronósticos requiere de buenos pronósticos individuales. En particular los pronósticos deben ser insesgados y los errores de pronóstico un paso adelante no deben estar correlacionados con errores pasados. Además, los pronósticos deben contener información relevante que pueda ser usada en la combinación, es decir, los pronósticos no deben ser abarcados por pronósticos rivales.

En el cuadro 1 del anexo 2 se presentan los resultados de la prueba de insesgamiento de Holden y Peel (1989) y la prueba de autocorrelación de Ljung-Box. Para $h = 3, 6, 9, 12$ meses no se rechaza la hipótesis de insesgamiento, mientras que para $h = 1$ los errores de pronósticos en general no presentan autocorrelación. Es de notar que para $h = 3, 6, 9, 12$ los errores están autocorrelacionados, sin embargo, como se mencionó antes, ésta es una característica común en los errores de pronóstico.

Una característica importante de los pronósticos, que muchas veces no se toma en consideración en este tipo de trabajo, es la posible no estacionariedad de éstos. Si los pronósticos presentan una raíz unitaria, es necesario tomar en cuenta esta característica en el procedimiento de combinación (Hallman y Kamstra, 1989). En los cuadros 2 y 3 del anexo 2 se presentan diferentes pruebas de raíz unitaria para la inflación en el periodo 1999:3 2009:1. En la mayoría de los casos, estas pruebas indican que la inflación presenta una raíz unitaria en este periodo, por lo que se justifica el uso de los procedimientos de combinación para series $I(1)$.

En el cuadro 4 del anexo 2 se presenta el RMSFE de la proyección fuera de muestra de cada modelo. En general, los pronósticos recursivos tienen un RMSFE menor que los pronósticos rolling, excepto para los modelos VAR y ARIMA, los cuales muestran un mejor desempeño dentro de este último esquema. Esto puede ser explicado por el hecho de que en el esquema rolling las observaciones más viejas son eliminadas en la estimación de los parámetros, lo cual es una ventaja en modelos con una larga estructura de rezagos y en la presencia quiebres estructurales en las series.

Sobre la base de los resultados del cuadro 4, los modelos son clasificados del mejor (el modelo con el más bajo RMSFE) al peor modelo (el modelo con el RMSFE más alto) para cada horizonte de pronóstico (cuadro 5 del anexo 2). En el cuadro 5, se observa que el modelo Estruc tiene el mejor desempeño de todos los modelos, independiente del esquema de estimación –rolling o recursivo– y del horizonte de pronóstico; además, su desempeño relativo al resto de modelos, mejora a medida que se alarga el horizonte de proyección.

Siguiendo el algoritmo de abarcamiento descrito en la sección III.2, la prueba HLN es aplicada en el cuadro de clasificación 5

para eliminar los modelos para los cuales no se rechaza la hipótesis de abarcamiento. Dado del esquema de estimación y el tamaño del horizonte de pronóstico, la selección de los modelos para combinación depende del nivel de significancia utilizado en la prueba HLN. Entre más bajo sea el nivel de significancia, más fuerte es la selección entre los modelos competidores, mientras que con un nivel de significancia mayor, un gran número de modelos será seleccionado para la combinación. Para balancear un poco entre estos dos escenarios, en este trabajo se utiliza un nivel de significancia de 10% para realizar la prueba de abarcamiento.

Los resultados están disponibles en los cuadros 6 y 7 del anexo 2. Para $h=3$, los cinco modelos propuestos en este trabajo son seleccionados para la combinación tanto en el esquema recursivo y rolling. Para $h=6$, los cinco modelos son seleccionados en el esquema recursivo; mientras en el esquema rolling son seleccionados solamente los modelos Estruc, ARIMA y VAR. Para $h=9$ se seleccionan los modelos Estruc y ARIMA dentro del esquema rolling y los modelos STR y Estruc en el esquema recursivo. Para $h=12$ los modelos para combinar en el esquema rolling son Estruc y ARIMA, sin embargo, en el esquema recursivo, el modelo Estruc parece abarcar a los demás modelos, por lo que no se obtendrían ganancias de la combinación de este modelo con el resto de modelos rivales. Es importante observar que los modelos seleccionados para la combinación en los distintos horizontes son un mixto del modelo estructural más algunos de los modelos de series de tiempo.

3. Resultado de la combinación de pronósticos

En esta sección se utilizan las diferentes metodologías de combinación de pronósticos descritas en la sección III.3, para combinar los modelos seleccionados mediante el algoritmo de abarcamiento.

Los resultados de los métodos de combinación se presentan en los cuadros 8 y 9 del anexo 2. Estos cuadros muestran el RMSFE de la proyección combinada relativo al del mejor modelo en cada horizonte de pronóstico, así, un valor menor a uno implica que el pronóstico combinado se desempeña mejor que el pronóstico del mejor modelo individual en ese

horizonte. En general se puede observar que en términos del RMSFE, los pronósticos combinados muestran un mejor desempeño que el mejor pronóstico individual. Las mejores combinaciones en los dos esquemas son obtenidas mediante los procedimientos de Granger y Ramanathan y de Hallman y Kamstra.

Las ganancias en precisión para la mejor combinación son diferentes según el horizonte de pronóstico. Para el caso de los pronósticos rolling (recursivos) la ganancia para $h=3$ es aproximadamente de 19.4% (19%), para $h=6$ es de 18.3% (12.5%) y para $h=9$ y $h=12$ es de 14.2% (13.4%) y 12.4%, respectivamente, observándose la mayor ganancia en el caso de $h=3$ y la menor ganancia para $h=12$.

Un resultado que es importante destacar es el bajo desempeño obtenido al utilizar la técnica de Diebold y Pauly (1987). En algunos estudios se ha encontrado que estos métodos producen buenos resultados en horizontes mayores a un año (Melo y Nuñez, 2004), lo que puede indicar que el cambio estructural tiene un mayor efecto en los métodos de combinación en horizontes largos. Por otra parte, las ponderaciones pueden presentar cambios no sistemáticos en el tiempo, los cuales no son capturados por este método (Holden y Pell, 1989).

Para verificar si las ganancias en precisión son estadísticamente significativas, se utiliza la prueba de Diebold y Mariano (DM, 1995) descrita en la sección III.1. En el cuadro 10 del anexo 2 se muestran los resultados de la prueba de DM al comparar el pronóstico combinado obtenido por el método de Granger y Ramanathan con respecto al pronóstico derivado del mejor modelo individual. A un nivel de significancia del 10%, el cuadro 10 confirma que el pronóstico combinado obtenido mediante el método de Granger y Ramanathan supera al pronóstico del mejor modelo.

VI. CONCLUSIONES

La naturaleza *forward-looking* de las decisiones de política económica implica que las proyecciones son un componente importante detrás de este proceso. De esta manera, mejorar la

calidad de los pronósticos es una tarea obligada en el quehacer del banco central.

Este trabajo aporta a esta labor al aplicar diversas técnicas de combinación de pronósticos a varios modelos de la inflación de Nicaragua. Los resultados de las estimaciones muestran ganancias significativas en precisión al combinar pronósticos en comparación con las ganancias del mejor modelo individual.

Las ganancias máximas en precisión para la mejor combinación comparadas con el mejor modelo fueron 19.4% para el horizonte de tres meses, 18.3% en el caso del horizonte de seis meses, y 14.2% y 12.4% para los horizontes de nueve y 12 meses, respectivamente.

Los resultados de este trabajo dejan abierta una agenda de investigación futura para estudiar nuevos modelos de inflación y nuevas técnicas de combinación de pronósticos que mejoren la calidad de los pronósticos del banco central.

Anexo I

Medidas de evaluación de pronósticos

Las medidas de evaluación de pronósticos miden la diferencia promedio entre los valores pronosticados de una serie y sus valores observados. Valores menores de estas medidas indican que, en promedio, los pronósticos de los modelos son más cercanos los valores observados.

Si se define a Y_t como el valor observado de la serie en el periodo t , a $f_{t/t-h}^i$ como el valor pronosticado Y_t con información hasta $t-h$ y a T como el número de pronósticos, algunas de las medidas más usadas para evaluar la precisión de los pronósticos son:

Raíz del error cuadrático medio de los errores de pronósticos (RMSFE):

$$RMSFE = \sqrt{\frac{1}{T} \sum_{t=1}^T (f_{t/t-h}^i - Y_t)^2} .$$

Raíz del error cuadrático medio porcentual de los errores de pronósticos (RMSPFE):

$$RMSPFE = \sqrt{\frac{1}{T} \sum_{t=1}^T ((f_{t/t-h} - Y_t) / Y_t)^2} .$$

Promedio de los valores absolutos de los errores de pronóstico:

$$MAFE = \frac{1}{T} \sum_{t=1}^T |(f_{t/t-h} - Y_t)| .$$

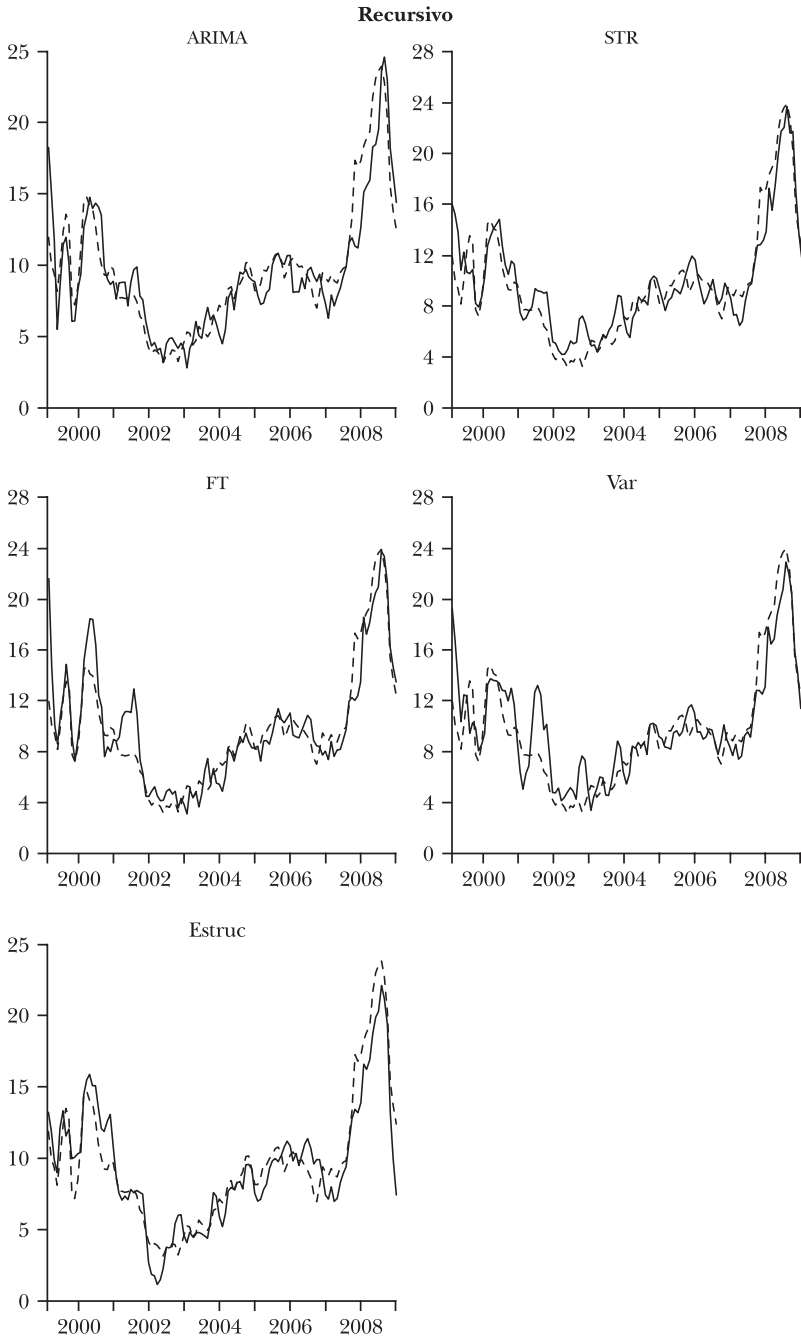
Promedio porcentual de los valores absolutos de los errores de pronóstico:

$$MAPFE = \frac{1}{T} \sum_{t=1}^T |(f_{t/t-h} - Y_t) / Y_t| .$$

U-Theil:

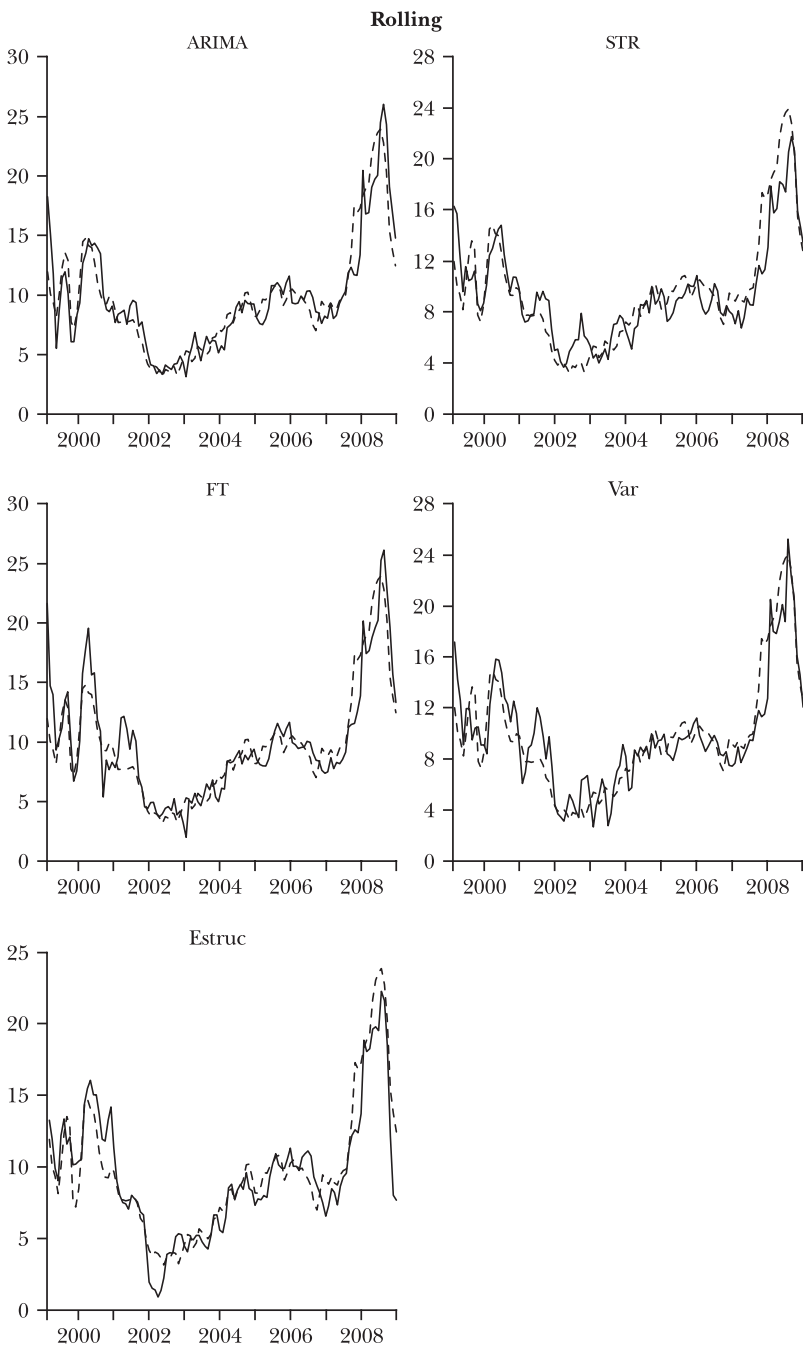
$$U - Theil = \sqrt{\frac{\sum_{t=1}^T (f_{t/t-h} - Y_t)^2}{\sum_{t=1}^T (Y_t - Y_{t-h})^2}} .$$

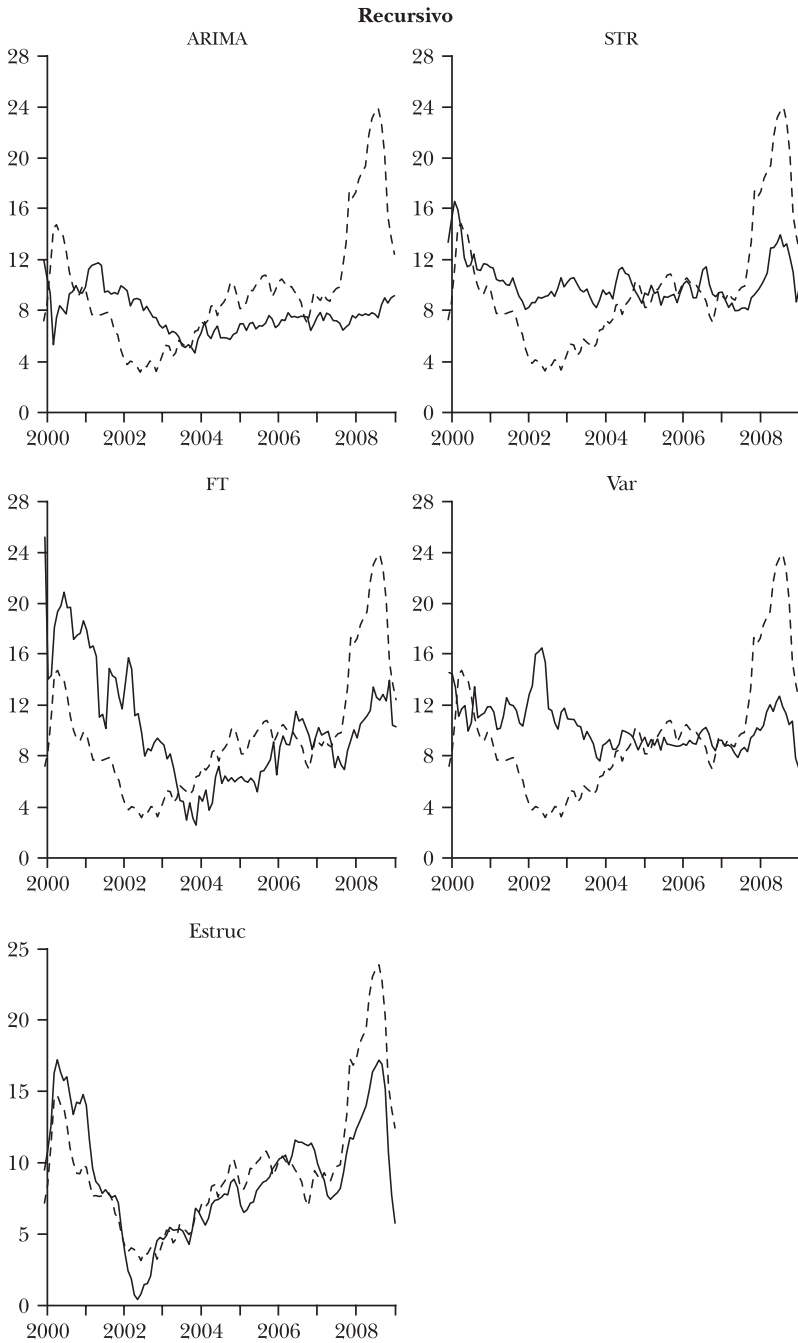
Anexo 2

GRÁFICA I. INFLACIÓN OBSERVADA Y PROYECTADA (1999:m3–2009:m1).

NOTA: Inflación interanual. Observada línea continua y proyectada discontinua.

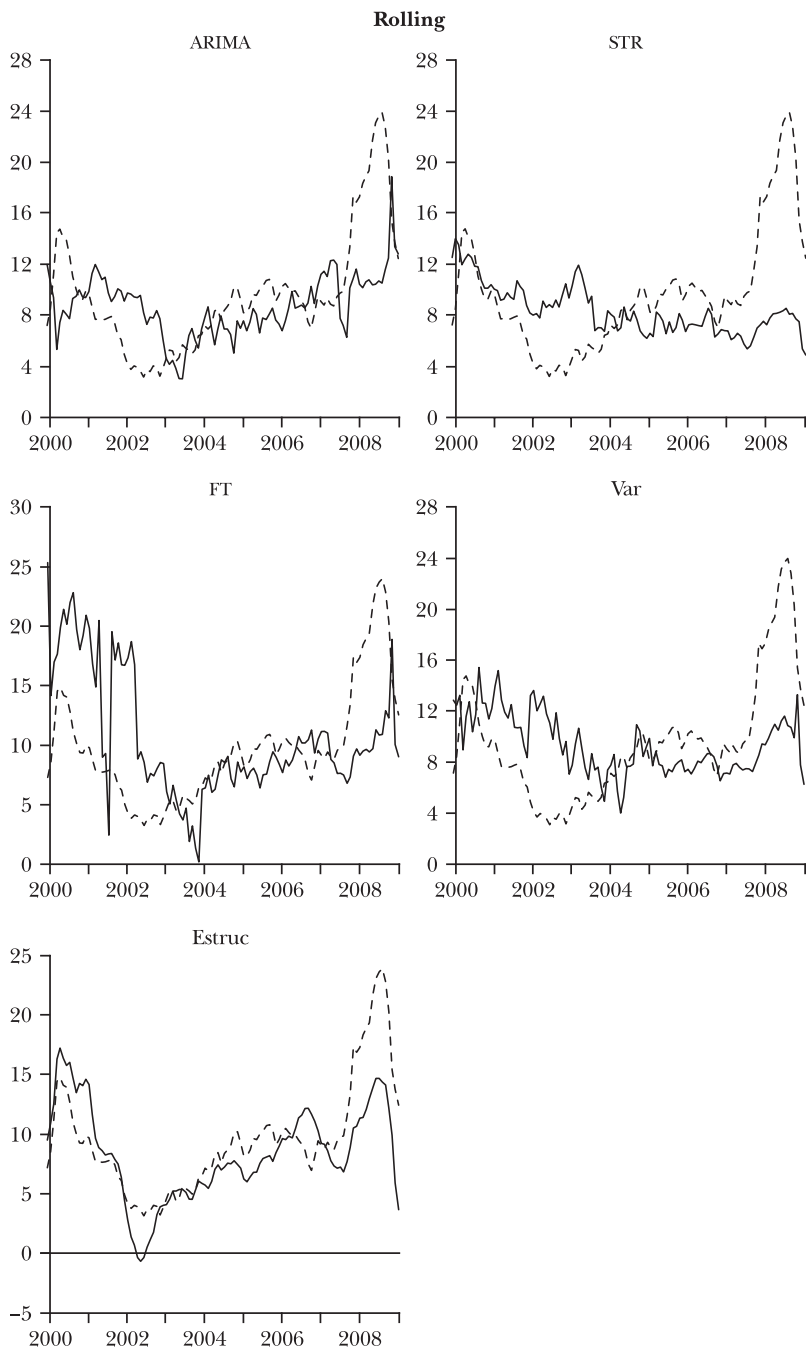
HORIZONTE TRES MESES



GRÁFICA II. INFLACIÓN OBSERVADA Y PROYECTADA (1999:m12-2009:m1).

NOTA: Inflación interanual. Observada línea continua y proyectada discontinua.

HORIZONTE 12 MESES



CUADRO 1. ESTADÍSTICAS DE LOS ERRORES DE PRONÓSTICO DE INFLACIÓN

| | | Prueba de Insesgamiento Holden Peel | | | | Prueba de Autocorrelación (Ljung-Box) ^a | | | | |
|-------------------------------|----------|-------------------------------------|--------|--------|--------|--|--------|--------|--------|--------|
| | | Horizonte de Pronóstico | | | | Horizonte de Pronóstico | | | | |
| | | h=3 | h=6 | h=9 | h=12 | h=1 | h=3 | h=6 | h=9 | h=12 |
| FT | Promedio | -0.75 | -0.69 | -0.53 | -0.749 | Q-stat | 93.38 | 188.27 | 399.16 | 546.58 |
| | P_Value | (0.46) | (0.49) | (0.6) | (0.46) | P_Value | (0.00) | (0.00) | (0.00) | (0.00) |
| ARIMA | Promedio | 0.02 | 0.53 | 0.95 | 1.050 | Q-stat | 81.97 | 138.23 | 233.58 | 312.9 |
| | P_Value | (0.99) | (0.6) | (0.34) | (0.3) | P_Value | (0.8) | (0.00) | (0.00) | (0.00) |
| Var | Promedio | -0.12 | 0.05 | 0.22 | 0.189 | Q-stat | 94.04 | 329.02 | 540.93 | 695.81 |
| | P_Value | (0.91) | (0.96) | (0.83) | (0.85) | P_Value | (0.87) | (0.00) | (0.00) | (0.00) |
| Estruc | Promedio | 0.92 | 1.24 | 1.57 | 1.760 | Q-stat | 188.51 | 393.46 | 525.42 | 577.83 |
| | P_Value | (0.36) | (0.22) | (0.12) | (0.08) | P_Value | (0.35) | (0.00) | (0.00) | (0.00) |
| STR | Promedio | 0.82 | 1.33 | 1.30 | 1.154 | Q-stat | 182.22 | 471.82 | 709.76 | 806 |
| | P_Value | (0.41) | (0.19) | (0.2) | (0.25) | P_Value | (0.14) | (0.00) | (0.00) | (0.00) |
| Pronósticos Recursivos | | | | | | | | | | |
| FT | Promedio | -0.8 | -0.62 | -0.5 | -0.58 | Q-stat | 148.68 | 290.77 | 559.8 | 725.66 |
| | P_Value | (0.42) | (0.54) | (0.62) | (0.56) | P_Value | (0.07) | (0.00) | (0.00) | (0.00) |
| ARIMA | Promedio | 0.95 | 1.47 | 1.83 | 1.89 | Q-stat | 102.81 | 207.65 | 403.52 | 548.51 |
| | P_Value | (0.34) | (0.15) | (0.07) | (0.06) | P_Value | (0.24) | (0.00) | (0.00) | (0.00) |
| Var | Promedio | -0.76 | -0.76 | -0.66 | -0.76 | Q-stat | 125.33 | 335.95 | 568.37 | 691 |
| | P_Value | (0.45) | (0.45) | (0.51) | (0.45) | P_Value | (0.42) | (0.00) | (0.00) | (0.00) |
| Estruc | Promedio | 0.79 | 0.9 | 1.08 | 1.17 | Q-stat | 223.45 | 405.61 | 515.05 | 559.39 |
| | P_Value | (0.43) | (0.37) | (0.28) | (0.24) | P_Value | (0.01) | (0.00) | (0.00) | (0.00) |
| STR | Promedio | -0.69 | -0.61 | -0.53 | -0.6 | Q-stat | 141.99 | 310.73 | 538.76 | 687.49 |
| | P_Value | (0.49) | (0.54) | (0.6) | (0.55) | P_Value | (0.24) | (0.00) | (0.00) | (0.00) |

^a El número de rezagos utilizados corresponde a la cuarta parte de las observaciones.

CUADRO 2. PRUEBAS DE RAÍZ UNITARIA DICKEY-FULLER AUMENTADA Y PHILLIPS-PERRON (periodo 1999m3-2009m1)

| | <i>Dickey-Fuller Aumentada</i> | | <i>Phillips-Perron</i> | |
|-------------------------------------|--------------------------------|-----------------|------------------------|-----------------|
| | <i>Estadístico t</i> | <i>Decisión</i> | <i>Estadístico t</i> | <i>Decisión</i> |
| Intercepto ^a | -2.64 | I(0) | -2.09 | I(1) |
| Tendencia e intercepto ^b | -3.10 | I(1) | -2.66 | I(1) |

^a Valores críticos: -3.44 al 5%, -3.14 al 10%. ^b Valores críticos: -2.88 al 5%, -2.57 al 10%.

CUADRO 3. PRUEBAS DE RAÍZ UNITARIA ZIVOT-ANDREWS Y LEE-STRAZICICH (periodo 1999m3-2009m1)

| | <i>Zivot-Andrews</i> ^a | | <i>Lee-Strazicich</i> ^b | |
|----------------------------------|--|-----------------|--|-----------------|
| | <i>Estadístico t</i> <i>y fecha</i> | <i>Decisión</i> | <i>Estadístico t</i> <i>y fecha</i> | <i>Decisión</i> |
| Cambio e intercepto | -4.28 2001m1 | I(1) | -2.46 2003m10 | I(1) |
| Cambio en intercepto y tendencia | -4.55 2001m9 | I(1) | -3.70 2007m12 | I(1) |

^a Valores críticos: cambio en intercepto -4.8 al 5%, -4.58 al 10%. Cambio en tendencia e intercepto -5.08 al 5%, -4.82 al 10%. ^b Valores críticos para 100 obs: cambio en intercepto -3.56 al 5%, -3.21 al 10%. Cambio en tendencia e intercepto, $\lambda=0.9$, -4.5 al 5%, -4.21 al 10%.

CUADRO 4. MEDIDA DE ERROR DE PROYECCIÓN. ESTIMACIÓN ROLLING Y RECURSIVA

| | <i>RMSFE(3)</i> | <i>RMSFE(6)</i> | <i>RMSFE(9)</i> | <i>RMSFE(12)</i> |
|-------------------------------|-----------------|-----------------|-----------------|------------------|
| Estimación (rolling) | | | | |
| FT | 2.10 | 3.63 | 4.80 | 6.38 |
| ARIMA | 1.82 | 2.79 | 3.50 | 4.35 |
| VAR | 1.98 | 2.91 | 4.00 | 4.97 |
| Estruc | 1.75 | 2.59 | 3.08 | 3.53 |
| STR | 1.98 | 3.21 | 4.35 | 5.33 |
| Estimación (recursiva) | | | | |
| FT | 1.93 | 3.29 | 4.32 | 5.63 |
| ARIMA | 1.95 | 3.21 | 4.22 | 5.26 |
| VAR | 2.14 | 3.21 | 4.16 | 5.18 |
| Estruc | 1.70 | 2.30 | 2.63 | 2.83 |
| STR | 1.71 | 2.51 | 3.26 | 4.13 |

CUADRO 5. CLASIFICACIÓN DE MODELOS SEGÚN RMSE

| | <i>Rolling</i> | | | <i>Recursivo</i> | | | | |
|---|----------------|-------|-------|------------------|-------|-------|-------|--------|
| | $h=3$ | $h=6$ | $h=9$ | $h=12$ | $h=3$ | $h=6$ | $h=9$ | $h=12$ |
| 1 | EST | EST | EST | EST | EST | EST | EST | EST |
| 2 | AR | AR | AR | AR | STR | STR | STR | STR |
| 3 | VAR | VAR | VAR | VAR | FT | VAR | VAR | VAR |
| 4 | STR | STR | STR | STR | AR | AR | AR | AR |
| 5 | FT | FT | FT | FT | VAR | FT | FT | FT |

CUADRO 6. RESULTADOS DE LAS PRUEBAS DE INCLUSIÓN (HLN). ESTIMACIÓN ROLLING

| | $h=3$ | $h=6$ | $h=9$ | $h=12$ |
|----------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|
| 1 ^{er} paso | Mejor Modelo Estruct | Mejor Modelo Estruct | Mejor Modelo Estruct | Mejor Modelo Estruct |
| | 0.079 (Estruct vs VAR) | 0.050 (Estruct vs VAR) | 0.102 (Estruct vs VAR) | 0.213 (Estruct vs VAR) |
| | 0.030 (Estruct vs ARIMA) | 0.060 (Estruct vs ARIMA) | 0.015 (Estruct vs ARIMA) | 0.020 (Estruct vs ARIMA) |
| | 0.074 (Estruct vs STR) | 0.168 (Estruct vs STR) | 0.403 (Estruct vs STR) | 0.476 (Estruct vs STR) |
| | 0.032 (Estruct vs FT) | 0.086 (Estruct vs FT) | 0.274 (Estruct vs FT) | 0.420 (Estruct vs FT) |
| 2 ^{do} paso | ARIMA | ARIMA | ARIMA | ARIMA |
| | 0.046 (ARIMA vs VAR) | 0.103 (ARIMA vs VAR) | 0.195 (ARIMA vs VAR) | |
| | 0.051 (ARIMA vs STR) | 0.153 (ARIMA vs STR) | | |
| | 0.094 (ARIMA vs FT) | 0.177 (ARIMA vs FT) | | |
| 3 ^{er} paso | VAR | | | |
| | 0.009 (VAR vs FT) | | | |
| | 0.012 (VAR vs STR) | | | |
| 4 ^{to} paso | STR | | | |
| | 0.003 (STR vs FT) | | | |

CUADRO 7. RESULTADOS DE LAS PRUEBAS DE INCLUSIÓN (HLN). ESTIMACIÓN RECURSIVA

| | $h=3$ | $h=6$ | $h=9$ | $h=12$ |
|----------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|
| 1 ^{er} paso | Mejor Modelo Estruct | Mejor Modelo Estruct | Mejor Modelo Estruct | Mejor Modelo Estruct |
| | 0.085 (Estruct vs VAR) | 0.085 (Estruct vs VAR) | 0.160 (Estruct vs VAR) | 0.309 (Estruct vs VAR) |
| | 0.036 (Estruct vs ARIMA) | 0.223 (Estruct vs ARIMA) | 0.421 (Estruct vs ARIMA) | 0.448 (Estruct vs ARIMA) |
| | 0.016 (Estruct vs STR) | 0.036 (Estruct vs STR) | 0.053 (Estruct vs STR) | 0.297 (Estruct vs STR) |
| | 0.009 (Estruct vs FT) | 0.108 (Estruct vs FT) | 0.473 (Estruct vs FT) | 0.225 (Estruct vs FT) |

| | | | |
|----------------------|-------------------------|------------------------|-----|
| 2 ^{do} paso | STR | STR | STR |
| | 0.102 (STR vs VAR) | 0.12 (STR vs VAR) | |
| | 0.081 (STR vs ARIMA) | 0.07 (STR vs FT) | |
| | 0.003 (STR vs FT) | | |
| 3 ^{er} paso | FT | VAR | |
| | 0.018 (FT vs VAR) | 0.016 (VAR vs FT) | |
| | 0.066 (FT vs ARIMA) | | |
| 4 ^{to} paso | ARIMA | ARIMA | |
| | 0.009 (ARIMA vs VAR) | 0.077 (ARIMA vs FT) | |

CUADRO 8. RMSFE RELATIVO AL MEJOR MODELO. ESTIMACIÓN ROLLING

| | <i>h=3</i> | <i>h=6</i> | <i>h=9</i> | <i>h=12</i> |
|------------------------|------------------|------------------|------------------|------------------|
| Mejor modelo [RMSE] | Estruc [1.75] | Estruc [2.59] | Estruc [3.08] | Estruc [3.53] |
| Comb. Gr_Ram | 0.81 | 0.82 | 0.86 | 0.88 |
| Colson Robin_sce | 1.21 | 1.19 | 1.33 | 1.21 |
| Promedio_1 | 0.91 | 0.89 | 0.91 | 0.97 |
| H_K_sce | 0.81 | 0.82 | 0.86 | 0.89 |
| Promedio_2 | 0.91 | 0.97 | 1.10 | 1.22 |
| Colson Robin_ce | 2.58 | 1.52 | 1.89 | 1.75 |
| H_K_ce | 1.18 | 1.33 | 1.28 | 1.38 |
| DMFE 0.9 | 0.93 | 0.92 | 0.92 | 0.96 |
| DMFE 0.95 | 0.92 | 0.91 | 0.91 | 0.95 |
| DMFE 1 | 0.89 | 0.88 | 0.90 | 0.96 |

CUADRO 9. RMSFE RELATIVO AL MEJOR MODELO. ESTIMACIÓN RECURSIVA

| | <i>h=3</i> | <i>h=6</i> | <i>h=9</i> |
|------------------------|------------------|------------------|------------------|
| Mejor modelo [RMSE] | Estruc [1.70] | Estruc [2.30] | Estruc [2.63] |
| Comb. Gr_Ram | 0.81 | 0.87 | 0.87 |
| Colson Robin_sce | 1.13 | 1.13 | 1.40 |
| Promedio_1 | 0.93 | 1.09 | 0.99 |
| H_K_sce | 0.81 | 0.88 | 0.87 |
| Promedio_2 | 0.93 | 1.09 | 1.23 |
| Colson Robin_ce | 1.53 | 1.59 | 1.89 |
| H_K_ce | 1.20 | 1.70 | 1.35 |

| | | | |
|-----------|------|------|------|
| DMFE 0.9 | 0.95 | 1.08 | 0.96 |
| DMFE 0.95 | 0.94 | 1.07 | 0.96 |
| DMFE 1 | 0.91 | 1.03 | 0.96 |

CUADRO 10. PRUEBA DE DIEBOLD Y MARIANO

| | $h=3$ | $h=6$ | $h=9$ | $h=12$ |
|------------------|-------|-------|-------|--------|
| Rolling | | | | |
| Estadístico | -1.59 | -1.35 | -1.72 | -1.42 |
| P_value | 0.06 | 0.09 | 0.04 | 0.08 |
| Recursiva | | | | |
| Estadístico | -1.89 | -1.24 | -3.49 | |
| P_value | 0.03 | 0.10 | 0.00 | |

CUADRO 11. ABREVIATURAS

| | |
|------------------|---|
| ARIMA | Modelo ARIMA |
| Estruc | Modelo estructural |
| STR | Modelo de transición suave |
| VAR | Modelo VAR |
| FT | Modelo de Función de Transferencia |
| Gr_Ram | Combinación de Granger y Ramanathan |
| Colson Robin_sce | Combinación de Coulson y Robins |
| Promedio_1 | Combinación basada en promedio simple |
| H_K_sce | Combinación Hallman y Kamstra |
| Promedio_2 | Combinación basada en promedio simple que incluye los 5 modelos |
| Colson Robin_ce | Combinación de Coulson y Robins con WLS |
| H_K_ce | Combinación Hallman y Kamstra con WLS |
| DMFE 0.9 | Combinación basada en MSFE con $\delta=0.90$ |
| DMFE 0.95 | Combinación basada en MSFE con $\delta=0.95$ |
| DMFE 1 | Combinación basada en MSFE con $\delta=1$ |

BIBLIOGRAFÍA

- Armstrong, J. S. (1989), "Combining Forecasts: The End of the Beginning or the Beginning of the End", *International Journal of Forecasting*, vol. 5, nº 4, pp. 585-88.
- Bates, J. M., y C. W. J. Granger (1969), "The Combination of Forecasts", *Operational Research Quarterly*, vol. 20, pp. 451-468.

- Bessler, D. A., y J. A. Brandt (1981), "Forecasting livestock prices with individual and composite methods", *Applied Economics*, vol. 13, pp. 513-22.
- Brouwer, G., y N. Ericsson (1998), "Modelling inflation in Australia", *Journal of Business and Economic Studies*, vol. 15, pp. 433-49.
- Capistrán, C., y A. Timmermann (2006), *Forecast Combination with Entry and Exit of Experts*, Banco de México (Documento de Investigación, n^o 2006-08).
- Castaño, E., y L. F. Melo (1998), *Métodos de combinación de pronósticos: una aplicación a la inflación colombiana*, Banco de la República (Borradores de Economía, n^o 109).
- Clark, T. E., y M. W. McCracken (2008), "Averaging forecasts from VARs with uncertain instabilities", *Journal of Applied Econometrics*.
- Clemen, R. T. (1989), "Combining Forecasts: A Review and Annotated Bibliography", *International Journal of Forecasting*, vol. 5, n^o 4, pp. 559-83.
- Coletti, D., y S. Murchison (2002), "Models in policy-making", *Bank of Canada Review*, verano, pp. 19-26.
- Costantini, M., y C. Pappalardo (2008), *Combination of Forecast Methods Using Encompassing tests: An Algorithm-Based Procedure*, Institute for Advanced Studies, Viena (Economics Series, n^o 228).
- Coulson, N. E., y R. Robins (1993), "Forecast Combination in a Dynamic Setting", *Journal of Forecasting*, vol. 12, pp. 63-67.
- Deutsch, M., C. W. Granger y T. Teräsvirta (1994), "The Combination of Forecasts Using Changing Weights", *International Journal of Forecasting*, vol. 10, pp. 47-57.
- Diebold, F. X., y R. Mariano (1995), "Comparing Predictive Accuracy", *Journal of Business and Economic Statistics*, vol. 13, pp. 253-63.
- Diebold, F., y J. López (1996), *Forecast Evaluation and Combination*, NBER (Technical working paper, n^o 192).
- Diebold, F., y P. Pauly (1987), "Structural Change and the Combination of Forecasts", *Journal of Forecasting*, vol. 6, pp. 21-40.
- Donaldson, R. G., y M. Kamstra (1996), "Forecast Combining with Neural Networks", *Journal of Forecasting*, vol. 15, pp. 49-61.
- Ericsson, N. R. (1992), "Parameter Constancy, Mean Square

- Forecast Errors, and Measuring Forecast Performance: An Exposition, Extensions, and Illustration”, *Journal of Policy Modelling*, vol. 4, pp. 465-95.
- Fair, R. C., y R. Shiller (1990), “Comparing Information in Forecasts from Econometric Models”, *American Economic Review*, vol. 80, n^o 3, pp. 375-89.
- Granger, C. W. J., y R. Ramanathan (1984), “Improved Methods for Combining Forecasts”, *Journal of Forecasting*, vol. 3, pp. 197-204.
- Hallman, J., y M. Kamstra (1989), “Combining Algorithms Based on Robust Estimation Techniques and Co-integrating Restrictions”, *Journal of Forecasting*, vol. 8, pp. 189-98.
- Harvey, D. I., S. Leybourne y P. Newbold (1998), “Tests for forecast encompassing”, *Journal of Business and Economic Statistics*, vol. 16, pp. 254-59.
- Harvey, D., S. Leybourne y P. Newbold (1997), “Testing the Equality of Mean Squared Errors”, *International Journal of Forecasting*, vol. 13, pp. 281-91.
- Holden, K., y D. A. Peel (1986), “An Empirical Investigation of Combinations of Economic Forecasts”, *Journal of Forecasting*, vol. 5, pp. 229-42.
- Holden, K., y D. A. Peel (1989), “Unbiasedness, Efficiency and the Combination of Economic Forecasts”, *Journal of Forecasting*, vol. 8, pp. 175-88.
- Hubrich, K. (2004), “Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy”, *International Journal of Forecasting*, vol. 21, n^o 1, pp. 119-36.
- Kapetanios, G., V. Labhard y S. Price (2008), “Forecast combination and the Bank of England's suite of statistical forecasting models”, *Economic Modelling*, vol. 25, pp. 772-92.
- Makridakis, S., A. Anderson, R. Carbone, R. Fildes, M. Hibon, R. Lewandowski, J. Newton, E. Parzen y R. Winkler (1982), “The accuracy of extrapolation (time series) methods: Results of a forecasting competition”, *Journal of Forecasting*, vol. 1, pp. 111-53.
- Makridakis, S., C. Chatfield, M. Hibon, M. Lawrence, T. Mills, K. Ord y L. Simmons (1993), “The M-2 competition: A real-time judgementally based forecasting study”, *International Journal of Forecasting*, vol. 9, pp. 5-22.

- Makridakis, S., y M. Hibon (2000), "The M3 competition: Results, conclusions, and implications", *International Journal of Forecasting*, vol. 16, pp. 451-76.
- Melo, L., y H. Núñez (2004), *Combinación de pronósticos de la inflación en presencia de cambios estructurales*, Banco de la República (Borradores de Economía, n° 286).
- Romer, C. D., y D. H. Romer (2008), "The FOMC versus the staff: Where can monetary policymakers add value?", *American Economic Review*, vol. 98, n° 2, pp. 230-35.
- Stock, J. H., y M. W. Watson (2004), "Combination forecasts of output growth in a seven country data set", *Journal of Forecasting*, vol. 23, pp. 405-30.
- Teräsvirta, T. (1994), "Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models", *Journal of the American Statistical Association*, vol. 89, n° 425, pp. 208-218.
- Teräsvirta, T., y H. M. Anderson (1992), "Characterizing Nonlinearities in Business Cycles using Smooth Transition Autoregressive Models", *Journal of Applied Econometrics*, vol. 7, pp. 119-36.
- Timmerman, A. (2006), "Forecast Combination", en G. Elliott, C. W. J. Granger y A. Timmerman (eds.), *Handbook of Economic Forecasting*, vol. 1, Elsevier, Amsterdam.
- West, K. D. (1996), "Asymptotic inference about predictive ability", *Econometrica*, vol. 64, pp. 1067-84.

Miguel E. Dorta
José A. Zambrano

Pronósticos factoriales en Venezuela: inflación y actividad económica

I. INTRODUCCIÓN

La literatura sobre pronósticos macroeconómicos se ha visto recientemente ampliada con un creciente número de trabajos donde se informa de manera consistente acerca de mejoras en la precisión de los pronósticos mediante la explotación de grandes cantidades de datos con técnicas como el modelo dinámico de factores (*dynamic factor model*) o el análisis de componentes principales. Con este tipo de estrategia se tratan simultáneamente varios problemas entre los cuales mencionamos los siguientes: se gana eficiencia estadística mediante la explotación de grandes volúmenes de series de tiempo sin perder grados de libertad, se atenúan los efectos

Publica el CEMLA, con la debida autorización, el estudio de M. E. Dorta y J. A. Zambrano, Coordinador de Estudios y Analista Económico II, respectivamente, del Departamento de Modelos Económicos, del Banco Central de Venezuela, presentado en la XIV Reunión de la Red de Investigadores de Bancos Centrales del Continente Americano, auspiciada por el Banco Central de Brasil, celebrada en Salvador, Bahía, del 11 al 13 de noviembre de 2009. Las opiniones expresadas en este trabajo son de responsabilidad exclusiva de los autores y no necesariamente coinciden con la institución para la cual trabajan.

nocivos que los cambios estructurales tienen sobre las estimaciones estadísticas, se elimina por completo cualquier sesgo de endogeneidad; y también, se elimina por completo cualquier problema de sesgo por errores de medición en las variables. En este tipo de investigación figuran trabajos importantes tales como Stock y Watson (2002), Forni *et al.* (2000, 2003), Bernanke *et al.* (2004), Aguirre y Céspedes (2004), Artis *et al.* (2005), Matheson (2005) y Marcelino y Schumacher (2007) entre muchos otros.

Este trabajo estudia el desempeño de los pronósticos de la inflación y la actividad económica en Venezuela comparando modelos de regresión dinámicos que utilizan los componentes principales (CP) de un conjunto de 45 variables de frecuencia mensual, durante el periodo 1991-2007.

A diferencia de la mayoría de los trabajos antecedentes, nosotros permitimos que previamente se descarten variables ya que el objetivo del método CP es independiente del objetivo de predicción. Este problema es tratado por Bair *et al.* (2005) quienes proponen una técnica llamada *supervised principal components* (SPC), la cual utiliza un subconjunto de variables que son seleccionadas con base en su asociación con la variable objetivo de pronóstico. En forma similar Bai y Ng (2008) proponen, como refinamiento al método de pronósticos factoriales, que los factores usados en las ecuaciones de pronósticos sean estimados de manera que tomen en cuenta que el objetivo es minimizar el error de pronóstico de una serie específica. Esto se logra con la aplicación del método de componentes principales con variables seleccionadas mediante reglas con umbrales duros y suaves (*hard and soft thresholding rules*).

Por su parte, tampoco los primeros factores estimados tienen que ser siempre los mejores predictores. Esto debe depender de la variable a pronosticar; por ejemplo, es posible que una variable específica sea explicada por el segundo o tercer factor más no por el primero, en cuyo caso resulta innecesariamente restrictivo obligar a que siempre tengan que estar determinados factores (por ejemplo, el primer factor) en la ecuación de pronóstico. Al momento de escribir este trabajo, no se encontraron antecedentes sobre técnicas para tratar este tipo de casos.

Nosotros sugerimos obtener los factores aplicando una estrategia semejante al SPC; y además, que al especificar y estimar

las ecuaciones dinámicas de pronóstico, el método de selección de los factores y sus rezagos sea tratado como un problema de selección estadística de modelo, frecuentemente referido en la literatura como el *subset selection problem*.¹ Para abordar este problema y controlar de manera eficiente el riesgo predictivo se utilizó el procedimiento sugerido por Dorta (2006) donde la selección estadística de predictores se lleva a cabo con un muestreo adaptativo basado en el *Risk Inflation Criterion* (RIC) propuesto por Foster y George (1994) y con fines comparativos, en dicho procedimiento también se usó el *Bayesian Information Criterion* (Schwarz, 1978).

Al mismo tiempo se analizó la posibilidad de que el procedimiento propuesto pueda mejorar su desempeño si en lugar de mínimos cuadrados ordinarios (MCO) se utiliza un método de regresión robusta local basado en mínimos cuadrados generalizados (MCG) iterado como una manera rápida y automática de tratar las observaciones atípicas (ver Cleveland, 1979).

Finalmente, el desempeño de los pronósticos fuera de la muestra se analizó mediante el cálculo de algunos indicadores de pronósticos, tales como: el error cuadrático medio de pronóstico (ECMP), el error medio absoluto de pronóstico (EMAP) y el U de Thail (UT), con el fin de evaluar ocho combinaciones de métodos y criterios para horizontes de pronóstico que van desde uno hasta 12 meses.

El resto del documento se organiza de la manera siguiente: En la segunda sección se describe el modelo de factores y dos maneras de estimarlo como son: el análisis de componentes principales en su formas convencional y supervisada. En la tercera sección se explica el método propuesto para el pronóstico con el modelo de factores y se describen los estimadores utilizados y el procedimiento empleado para obtener la especificación de las ecuaciones de pronóstico. En la cuarta sección se describen los datos en cuanto a las variables utilizadas y sus propiedades de series de tiempo. En la quinta sección se explica cómo se lleva a cabo la evaluación de los pronósticos fuera de la muestra y se presentan los resultados de dicha evaluación. Finalmente, se presentan las conclusiones del estudio.

¹ Ver George (2000).

II. MODELO DE FACTORES

El modelo de factores que se emplea en este trabajo comprende un procedimiento matemático que transforma un conjunto de variables correlacionadas, que explican *la actividad económica*² y *la inflación*³ de Venezuela, en un conjunto menor de variables no correlacionadas (ortogonales entre si) llamadas factores, los cuales retienen tanta información como sea posible mediante combinaciones lineales de un conjunto de variables representativo de la economía venezolana.

Stock y Watson (1998), describen el modelo de factores como una combinación lineal dinámica entre un conjunto de variables micro o macroeconómicas ($X_{i,t}$) medidas en el tiempo y r factores (f_t) dinámicos comunes, cuya representación se describe a continuación:

$$(1) \quad X_{it} = \lambda_i(L)f_t + \varepsilon_{it}.$$

Donde $i = 1, \dots, N$; $t = 1, \dots, T$; ε_{it} es el término de perturbación y $\lambda_i(L)$ es un polinomio no negativo donde el operador de rezagos es L , por lo tanto $L^m f_t = f_{t-m}$.

Si el número de rezagos del polinomio $\lambda_i(L)$ es finito de orden q la ecuación (1) puede ser escrita de la siguiente forma:

$$(2) \quad X_t = \Lambda F_t + \varepsilon_t.$$

$F_t = (f_t', \dots, f_{t-q}')'$ es un vector de dimensión $S \times 1$ que contiene los factores, donde $S \leq (q+1)r$, $\Lambda = (\lambda_1, \dots, \lambda_N)'$ y $\varepsilon_t = (\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{Nt})'$, son no observables. Stock y Watson (2002) muestran que el cumplimiento de algunos supuestos teóricos (restricciones y estacionaridad) dependen del vector de factores dinámicos

² Dado que los datos empleados en este estudio son mensuales y que en Venezuela la frecuencia más alta del PIB es trimestral se hizo necesario emplear otro indicador para medir la actividad económica. Se trata del índice general de actividad económica mensual (IGAEM) el cual es considerado como un indicador importante que incluso es utilizado por las autoridades del BCV como parte de la información que les permite tomar decisiones de política monetaria.

³ Para la inflación se evaluaron paralelamente la inflación general basada en el IPC del Área Metropolitana de Caracas y la inflación subyacente basada en el IPC núcleo, indicador que se obtiene como una agrupación especial del IPC después de la exclusión de bienes agrícolas y de los bienes y servicios con precios administrados.

los cuales pueden ser estimados consistentemente a través del análisis de componentes principales (ACP) del conjunto de variables de la matriz \mathbf{X}_t . La estimación por este método consiste en que el número de factores incluidos en el modelo estimado tiene que ser igual o mayor que el número verdadero. Por ejemplo, Bai y Ng (2002) ofrecen criterios de selección para determinar el número de factores que será incluido en el modelo. Estos criterios añaden condiciones a la función objetivo reducida. La condición depende de N , T y el número de factores incluidos en el modelo de tal modo que se asegure la consistencia.

1. Análisis de componentes principales (ACP)

Dado un conjunto de N variables cuantitativas, es posible calcular hasta N componentes principales (CP) o factores. Donde, cada factor es una combinación lineal de las variables originales, con coeficientes iguales a los vectores propios de la matriz de correlaciones o de covarianza de las variables originales.

$$X_{i,t} = \lambda_{i,1}f_{1,t} + \dots + \lambda_{i,r}f_{r,t} + \varepsilon_{i,t},$$

$$X_{i,t} = \Lambda_i' F_t + \varepsilon_{i,t}.$$

Donde, $X_{i,t}$ son variables observables, F_t es un vector de r factores comunes, Λ_i es el vector de coeficientes $r \times 1$ de los factores para la unidad i , y $\varepsilon_{i,t}$ es el error idiosincrásico de la estimación.

El objetivo de estimar estos factores ($f_{i,t}$) es obtener un conjunto reducido de indicadores muy relacionados con ese conjunto de variables que nos permita posteriormente establecer relaciones dinámicas lineales con la inflación y la actividad económica que hagan posible la obtención de pronósticos consistentes y oportunos.

Ahora bien, como los factores comunes no son directamente observables se deben estimar mediante ACP. Donde cada factor F_t estimado es una combinación lineal de las variables X_t . Dicha combinación se determina minimizando la suma de cuadrados de los residuos $(x_{i,t} - \lambda_i f_{i,t})^2$, es decir se debe minimizar la función objetivo:

$$Y_{N,T}(F, \Lambda) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T (x_{i,t} - \lambda_i f_{i,t})^2.$$

Con el supuesto de que existen r factores comunes, los estimadores óptimos de los factores resultan ser los r vectores propios asociados a los valores propios más grandes de la matriz $N^{-1} \sum_{i=1}^N x_i' x_i$ de dimensión $N \times N$, que corresponde a los CP de X_i .

2. Componentes principales supervisados

No siempre la aplicación del ACP a un número cada vez más grande de variables conduce a una mejoría en los pronósticos ya que el objetivo del ACP es independiente del objetivo de predicción. Este problema es tratado por Bair *et al.* (2005) proponiendo un método llamado *supervised principal components* especial para predicción. En forma similar Bai y Ng (2008) proponen, como refinamiento al método de pronósticos factoriales, que los factores usados en las ecuaciones de pronósticos sean estimados de manera que tomen en cuenta que el objetivo es minimizar el error de pronóstico de una serie específica. Esto se logra con la utilización del método de componentes principales con variables seleccionadas mediante reglas con umbrales duros y suaves (*hard and soft thresholding rules*).

En nuestro trabajo, además de los factores que se obtuvieron de las 45 variables inicialmente consideradas, también obtuvimos un segundo tipo de factores provenientes de un subconjunto de variables. Para ello se realizó el procedimiento siguiente, en el periodo muestral 1991:m1–2007:m12:

- Se empieza con todas las variables, se especifica y estima para cada una de ellas la ecuación (3) y se registran sus R^2 ajustados y los criterios RIC⁴ de las ecuaciones de pronóstico para la inflación general, la inflación núcleo y el IGAEM.

⁴ Los criterios AIC, BIC, RIC y otros para regresión lineal son casos especiales de la suma de cuadrados penalizada el cual constituye un marco unificado de comparación. Asumiendo que σ es conocido, este criterio general selecciona el subconjunto de variables que minimiza $(RSS_y/\sigma^2 + Fq_y)$, donde

- Se elimina la variable con el menor de los R^2 ajustados.
- Se repiten los pasos anteriores hasta que se agoten todas las variables menos las que son objetivo de pronóstico.
- Se identifican los mínimos valores de los criterios RIC para las tres variables objetivo de pronóstico. Se selecciona el conjunto de variables asociado a este mínimo.

De aquí resultaron seleccionadas 21 variables las cuales están identificadas en el cuadro 7 del Anexo. Los factores obtenidos de estas variables mediante ACP serán referidos más adelante como los componentes principales supervisadas (CPS).

III. MÉTODO DE PRONÓSTICOS CON MODELOS DE FACTORES

El pronóstico con el modelo de factores está basado en la especificación y estimación de ecuaciones dinámicas de regresión. Para la construcción de este modelo se supone que la actividad económica y la inflación pueden ser explicadas adecuadamente por sus propios rezagos y un número reducido de factores estimados mediante ACP de acuerdo con la siguiente expresión:

$$(3) \quad y_{t+1} = \alpha' Z_t + \sum_{i=1}^r \sum_{j=0}^p \beta_{ij} f_{i,t-j} + u_{t+1},$$

donde y_{t+1} representa la variable que nos interesa pronosticar

F es una dimensión de penalización preestablecida. Esta expresión penaliza RSS_i/σ^2 por F veces q_j , la dimensión del γ -ésimo modelo. Si hay p potenciales predictores y p es grande, una selección conservadora es $F=2\log p$. Este es el criterio RIC propuesto por Foster y George (1994) y también es el umbral universal para ondículas (*wavelets*) propuesto por Donoho y Johnstone (1994). Estos dos artículos motivaron, desde un enfoque minimax de la teoría de la decisión, a $F=2\log p$ como el que da la más pequeña posible inflación máxima en riesgo predictivo debida a selección (cuando $p \rightarrow \infty$). El criterio AIC corresponde a $F=2$, y el criterio BIC se obtiene fijando $F=\log T$, donde T es el tamaño de muestra. A menos que T sea muy pequeño, AIC impone una penalización más chica y por lo tanto seleccionará modelos más grandes que BIC. Note que BIC coincide con RIC si $2\log p = \log T$ y por lo tanto también será muy liberal si $p^2 > T$.

en su forma estacionaria, \mathbf{Z}_t es un vector que contiene una constante y rezagos de \mathbf{y}_{t+1} y f_1, f_2, \dots, f_r son los primeros r factores ortogonales entre sí estimados que potencialmente explican el comportamiento de \mathbf{y}_{t+1} .

El modelo propuesto en este trabajo utiliza en una primera etapa los r primeros factores, ya sean los CP o los CPS, obtenidos del ACP que acumulen no menos de un 80% de la variabilidad conjunta de la masa de datos. En una segunda etapa, la especificación y estimación de (3) se lleva a cabo mediante una técnica de selección estadística de predictores (*subset selection*), mediante la utilización de MCO simple o alternatively un método robusto basado en MCG iterado. Esto será ampliado más adelante.

Para obtener los pronósticos de hasta h pasos adelante se sigue el siguiente procedimiento:

- Todas las variables son pronosticadas el primer paso adelante mediante (3).
- Luego se toman estos pronósticos con los cuales se actualizan los f_1, f_2, \dots, f_r ; seguidamente, se actualiza la estimación de (3) y con esta ecuación se obtienen los pronósticos del paso siguiente.
- Se repite el paso anterior recursivamente hasta obtener los pronósticos de h pasos.

Es posible obtener pronósticos de h pasos en forma directa tal como lo realiza Stock y Watson (2002) o Artis *et al.* (2005). Es importante reconocer que es probable que de esta manera el desempeño de los pronósticos sea todavía mejor ya que se elimina el impacto potencial del error de especificación en el modelo de pronóstico de un paso para el resto de las variables utilizadas en la actualización de los factores. Aunque, en nuestro trabajo esta opción no se utilizó, los resultados aún permiten identificar claramente las combinaciones de técnicas que logran mejoras en los pronósticos.

1. Estimadores de regresión lineal utilizados

Para estimar (3) se usan alternativamente dos métodos: MCO simple con errores estándar corregidos según Newey-

West y MCG iterado con ponderaciones de robustez basada en Cleveland (1979) y Gross (1977).

El algoritmo para obtener la estimación robusta mediante MCG iterado se describe de la manera siguiente:

- *Paso 1.* Estimar la ecuación de regresión (3) mediante mínimos cuadrados ponderados usando como ponderaciones iniciales a $W_i=1$.
- *Paso 2.* Sea la función *tricube* expresada por $T(x) = (1-|x|^3)^3 I\{|x|<1\}(x)$ y sea m la mediana de $e_i = |y_i - \hat{y}_i|$ provenientes del ajuste de la regresión. Se calculan las ponderaciones de robustez mediante $W_i = T(e_i/6m)$.
- *Paso 3.* Calcular nuevos \hat{y}_i usando MCG con las ponderaciones calculadas según el paso anterior.⁵
- *Paso 4.* Repetir los pasos del 2 al 3 hasta que las estimaciones converjan.

El método robusto mediante MCG iterado presenta dos ventajas operativas: en primer lugar, es de aplicación automática, a diferencia de la búsqueda de variables ficticias usualmente utilizadas para lograr estimaciones más robustas. En segunda instancia, se evita la posible subjetividad del investigador en dicha búsqueda.

2. Selección estadística de predictores para regresión lineal

En los trabajos donde se aplica el modelo de factores con fines de pronóstico, se usan unos pocos factores siempre incluyendo en forma monótona desde el primer factor (el que más contribuye a la variabilidad conjunta de los datos), luego el segundo factor y así sucesivamente hasta el último que se ha prefijado con algún criterio estadístico usualmente también desligado del objetivo de pronóstico. Sin embargo, los

⁵ Existen otras funciones de ponderación usadas en la práctica. Las funciones de ponderación tienen al menos que cumplir cuatro propiedades: *i*) $W(x) > 0$ para $|x| < 1$; *ii*) $W(-x) = W(x)$; *iii*) $W(x)$ es no creciente para $x > 0$; y *iv*) $W(x) = 0$ para $|x| > 1$. Aquí se recomienda la función *tricube* porque permite mejores propiedades de los estimadores de los errores estándar en el caso de distribución Normal de los residuos sin perder propiedades de robustez en casos de distribuciones no Normales (ver Cleveland, 1979).

primeros factores estimados no siempre tienen que ser los mejores predictores. Por ejemplo, es posible que una variable específica sea explicada por el segundo o tercer factor más no por el primero, en cuyo caso resulta innecesariamente restrictivo obligar a que siempre tenga que estar el primer factor en la ecuación de pronóstico.

En este trabajo, la especificación y estimación de la ecuación (3) se realiza con una estrategia de selección estadística de los factores y sus rezagos conjuntamente con los rezagos de la variable dependiente según el enfoque de *subset selection* (George, 2000).⁶ Para lograr esto y controlar eficientemente el riesgo predictivo se utilizó el algoritmo sugerido por Dorta (2006) donde la selección de predictores es llevada a cabo con un muestreo adaptativo basado en el *Risk Inflation Criterion* (RIC) propuesto por Foster y George (1994) y el *Universal Threshold for Wavelets* por Donoho y Johnstone (1994).⁷ Este criterio está especialmente diseñado para minimizar la máxima inflación de riesgo predictivo cuando, de un número grande de potenciales predictores, se selecciona un subconjunto con incertidumbre. Con fines comparativos, dicho procedimiento también se realizó con el criterio BIC (Schwarz, 1978)

El algoritmo propuesto por Dorta (2006) reduce el espacio de regresiones posibles para ser analizadas, seleccionando un subconjunto de predictores de una regresión mediante una secuencia de muestreos Bernoulli con probabilidades adaptativas de selección en función de la frecuencia relativa de cumplimiento del criterio RIC (en dos variantes) y alternativamente con el BIC, las cuales se estabilizan luego de un número suficientemente grande de muestras. El cumplimiento del criterio RIC o BIC se basa en comparar los *p*-valores de los coeficientes estimados con niveles de significancia (NS) calculados que penalizan la pérdida de grados de libertad en forma equivalente a los criterios BIC y RIC.

Supongamos que hay *k* posibles predictores con una muestra de tamaño *T*.

⁶ Para aliviar la carga computacional del procedimiento, se preseleccionan los factores que acumulen no menos de 80% de la variabilidad de los datos.

⁷ Es el mismo criterio RIC descubierto en forma paralela e independiente en ambos trabajos.

A partir del trabajo de Foster y George (1994), es fácil derivar fórmulas de cálculo para NS compatibles con los criterios BIC y RIC.

$$NS(bic) = 1 - 2P\left(z > \log(T)^{1/2}\right),$$

$$NS(ric) = 1 - 2P\left(z > (2\log(k))^{1/2}\right).$$

Donde z sigue una distribución t de Student con $T-k^*$ grados de libertad, $k^*=k$ si $k \leq T/3$ y $k^* = \text{entero}(T/3)$ si $k > T/3$.

Es importante destacar que $NS(bic) = NS(ric)$ si $k^2 = T$; y por lo tanto, el $NS(bic)$ es un caso particular del $NS(ric)$. Además, si $k^2 > T$, $NS(ric) < NS(bic)$. En otras palabras, si $k^2 > T$ el $NS(bic)$ es más estricto que el $NS(ric)$. Así en la práctica parece más razonable preferir la aplicación del $NS(ric)$ ya que tiene sentido ser cada vez más estricto con el NS a medida que k es mayor, en lugar de ser más estricto cada vez que el tamaño de muestra es mayor independientemente de k .⁸

El trabajo de Foster y George (1994) también muestra que el criterio RIC exacto depende en forma compleja de la estructura de covarianzas de los predictores. Si en la práctica el $NS(ric)$ simple resultara ser demasiado conservador, se puede usar un límite inferior como ajuste. Ellos proponen calcular dicho límite inferior mediante la siguiente expresión:

$$NS(ricaj) = 1 - 2P\left(z > (2\log(k) - 2\log(\log(k)))^{1/2}\right), \quad T > 30, \quad k/T > 1/2.$$

También, z sigue una distribución t de Student con $T-k^*$ grados de libertad, $k^*=k$ si $k \leq T/3$ y $k^* = \text{entero}(T/3)$ si $k > T/3$.

IV. LOS DATOS

En este trabajo se empleó un conjunto de 45 variables representativas de la economía venezolana con frecuencia mensual, durante el periodo 1991-2007, obtenidas del Banco

⁸ Es importante aclarar que para valores de k muy pequeños (menos de 8) los $NS(ric)$ pueden ser mayores al tradicional 5%, en cuyo caso pudiera considerarse poco apropiado el uso del $NS(ric)$.

Central de Venezuela y otras instituciones públicas y privadas.⁹ Estas variables miden la disponibilidad de ingresos, la demanda, los choques de oferta y la mano de obra de la economía. De igual forma, se diferenciaron los logaritmos de las variables no estacionarias hasta hacerlas estacionarias,¹⁰ con el fin de evitar los problemas de inestabilidad de las estimaciones que genera la no estacionaridad de las series. Para ello, a cada una de las series se le practicó su estudio de estacionaridad respectivo, a través de las pruebas de Dickey Fuller y análisis de correlogramas.

V. EVALUACIÓN DE PRONÓSTICOS FUERA DE LA MUESTRA

La estrategia de pronóstico factorial que proponemos en este trabajo fue objeto de un análisis de desempeño fuera de la muestra para la inflación general, la inflación núcleo y el IGAEM. Como las pruebas de estacionaridad de los precios no permiten clasificar claramente su orden de integración, las CP y las CPS se obtuvieron de dos maneras dependiendo de si los precios estaban diferenciados una o dos veces. Así cada una de las tres variables objeto del análisis se pronosticó para las cuatro combinaciones que de allí se derivan. Los horizontes de pronósticos evaluados fueron de 1, 2, 3, 6, 9 y 12 meses. El periodo fuera de la muestra analizado corresponde a 2004:m1 – 2007:m12 (48 meses). En nuestro caso, se intentó simular lo que normalmente ocurre en la práctica; es decir, que cada vez que se hace un pronóstico se aprovecha toda la información que hubiera estado disponible para actualizar las estimaciones tanto de los factores como de los parámetros de las ecuaciones de pronóstico. En este sentido, las muestras recursivas para las estimaciones de los modelos dependen del correspondiente horizonte de pronóstico (h). Así, para $h = 1$ las muestras recursivas van desde 1991:m1 hasta T , con T que varía desde 2003:m12 hasta 2007:m11; para $h = 2$, T varía desde 2003:m11 hasta 2007:m10; y así sucesivamente hasta $h = 12$, donde T varía desde 2003:m1 hasta 2006:m12. De esta

⁹ Una lista de estas variables puede encontrarse en el cuadro 7 del anexo.

¹⁰ Promedio y varianza constante.

manera se garantiza tener siempre 48 pronósticos para cada horizonte.

Nosotros evaluamos ocho variantes de pronósticos factoriales. El algoritmo de selección de predictores referido en la sección III.2 se aplicó en forma alternada con MCO y MCG iterado cruzándolo con CP y CPS. Vale recordar que en cada caso, previamente se seleccionan los factores que acumulan hasta 80% de la variabilidad conjunta de los datos. A su vez, para cada uno de estos posibles cruces se emplearon las tres variantes de los criterios estadísticos mencionados en la sección III.2. Sin embargo, cuando se aplicó MCG iterado solamente se usó la variante simple del criterio RIC debido a que el algoritmo se trabó con frecuencia con los otros criterios. Esto ocurrió debido a que el MCG iterado puede producir ponderaciones de robustez que ocasionalmente generen problemas numéricos para invertir las matrices.

Como es práctica común en este tipo de análisis, primero se estiman modelos *benchmark* que en nuestro caso son modelos ARIMA para cada una de las tres variables en estudio: IPC general, IPC núcleo y el IGAEM. Para cada variable-horizonte se calculan los ECMP, EMAP y UT. Por su parte, estos indicadores también son calculados análogamente para cada uno de las ocho variantes de pronósticos factoriales.

Al final, se calculan las razones de los indicadores de los pronósticos con los modelos *benchmark* entre los correspondientes modelos factoriales. Así, mientras mayor es la razón, se dice que mejor es el desempeño del método correspondiente para predecir la variable objetivo. Estas razones se muestran en el Anexo donde los cuadros 1, 2 y 3 corresponden al IGAEM, IPC general y el IPC núcleo respectivamente, con los precios en primeras diferencias, dentro del conjunto de variables de partida, Por su parte, los cuadros 4, 5 y 6 son análogos a los tres anteriores pero en estos casos los precios se emplearon en segundas diferencias.

Para resumir los resultados concentramos el análisis en los casos donde la jerarquización en los cuadros mencionados fue el primer mejor desempeño según variable-horizonte. Los hechos más destacados son los siguientes:

- De manera contundente puede afirmarse que el uso de CPS es superior al uso de CP. Con base en el indicador ECMP se

observa que en 22 de 36 casos resultó superior el CPS sobre el CP. Estos se reparten en 8 de 12 para el IGAEM, 7 de 12 para el IPC general y 7 de 12 para el IPC núcleo. Si se usa el EAMP, en 24 de 36 casos el CPS resulta superior al CP. Según la variable, hay 6 de 12 para el IGAEM, 8 de 12 para el IPC general y 10 de 12 para el IPC núcleo.

- Se observa una abrumadora superioridad del empleo de MCG con ponderaciones de robustez sobre el uso de MCO. Con base en el ECMP, 31 de 36 casos son para MCG; donde, 12 de 12 son para el IGAEM, 9 de 12 para el IPC general y 10 de 12 para el IPC núcleo. Por su parte, en el caso del EAMP, 29 de 36 corresponden a MCG; donde, 12 de 12 son del IGAEM, 8 de 12 son del IPC general y 9 de 12 son para el IPC núcleo.
- El uso del criterio RIC simple prueba ser decisivamente superior al BIC y al límite inferior del RIC. Según el ECMP, de 36 casos 34 son para el RIC; donde, 12 son para el IGAEM, 11 para el IPC general y 11 para el IPC núcleo. Si el enfoque es en el EAMP, tenemos 32 de 36 casos: 12 para el IGAEM, 10 para el IPC general y 10 para el IPC núcleo.
- También, es interesante analizar los resultados según diferenciación de los precios en virtud de que, en el caso de Venezuela, las pruebas de hipótesis de raíces unitarias dejan dudas sobre si el orden de integración es uno o dos. Según el ECMP el uso de los precios en primera diferencia resulta en mejor desempeño de los pronósticos en 14 de 18 casos. Por su parte, según el EAMP los precios en primera diferencia conducen a un mejor desempeño de los pronósticos en 17 de 18 casos. Estos resultados están distribuidos muy uniformemente ya sea según la variable pronosticada o el horizonte de pronóstico. En consecuencia, este resultado constituye una evidencia de que es conveniente considerar a los precios como integrados de orden uno.
- Si enfocamos el análisis sobre la habilidad del modelo de factores (MF) para mejorar a los modelos ARIMA, se observa, según el ECMP que en todos los casos (12) el MF superó al ARIMA. Sin embargo, según el EAMP hay solo cinco casos donde el MF mejora al modelo ARIMA. En contraste, el pronóstico de la inflación, ya sea la general o el núcleo, resulta

en general con mejor desempeño si se usan modelos ARIMA. Solo si se usan las primeras diferencias de los precios para pronosticar el IPC general, se pueden encontrar casos donde el MF es mejor que el ARIMA (5 de 12 uniendo el ECMP y el EAMP). El deterioro del error de pronóstico del MF relativo al ARIMA es evidentemente creciente mientras más lejano es el horizonte de pronóstico lo que hace sospechar que el uso de pronósticos directos para horizontes múltiples puede ser clave para este caso.

VI. CONCLUSIONES

En este trabajo se estudió el desempeño de los pronósticos de la inflación y la actividad económica en Venezuela mediante la introducción de algunos refinamientos al procedimiento convencional, basado en el modelo de factores estimados mediante componentes principales, a partir de un conjunto de 45 variables de frecuencia mensual, durante el periodo 1991-2007. Con una estrategia similar a la de Bair *et al.* (2005) y Bai y Ng (2008), se descartan previamente variables que potencialmente distorsionan a los pronósticos. Además, tratamos la especificación y estimación de las ecuaciones dinámicas de pronóstico como un problema de selección estadística de modelo (*subset selection problem*), controlando eficientemente el riesgo predictivo mediante un muestreo adaptativo basado en el *risk inflation criterion* propuesto por Foster y George (1994). Al mismo tiempo se analizó la posibilidad de que el procedimiento propuesto pueda mejorar su desempeño si en lugar de MCO se utiliza un método de regresión basado en MCG iterado con ponderaciones de robustez (Cleveland, 1979). Los hechos más destacados que se desprenden del análisis de desempeño fuera de la muestra fueron los siguientes:

- Puede afirmarse contundentemente que el uso de componentes principales supervisados es superior al uso de componentes principales convencionales.
- Se observa una abrumadora superioridad del empleo de MCG con ponderaciones de robustez sobre el uso de MCO para la estimación de las ecuaciones de pronóstico.

- El *risk inflation criterion* (RIC) en su forma simple prueba ser decisivamente superior al *bayesian information criterion* y al límite inferior del RIC.
- Los precios en primeras diferencias condujeron definitivamente a mejores pronósticos para cualquiera de las variables en estudio. En consecuencia, este resultado constituye una evidencia a favor de que en Venezuela es conveniente considerar a los precios como integrados de primer orden.
- El desempeño de los modelos factoriales resultó superior al ARIMA para pronosticar la actividad económica (IGAEM).
- Pero el pronóstico de la inflación, ya sea la general o núcleo, resulta en general con mejor desempeño si se usan modelos ARIMA.
- En general, es muy posible que el desempeño de los modelos factoriales pueda mejorarse si se usan procedimientos de pronósticos directos para horizontes múltiples. Esto es particularmente importante para los casos de la inflación. En este sentido, sería recomendable como futura extensión de este trabajo estudiar este tipo de estrategia.

Anexos

Desempeño de los pronósticos fuera de la muestra, razones de modelos *benchmark* a modelos factoriales y precios en primeras diferencias

CUADRO 1. IGAEM

| | | <i>Horizonte de pronóstico (h)</i> | | | | | |
|-------------------|-----------------------|------------------------------------|----------|----------|----------|----------|-----------|
| | | <i>1</i> | <i>2</i> | <i>3</i> | <i>6</i> | <i>9</i> | <i>12</i> |
| 1. ECMP | <i>CP-OLS/RIC</i> | 0.929 | 0.978 | 0.958 | 0.926 | 0.930 | 0.838 |
| | <i>CP-OLS-RIC-LI</i> | 1.164 | 1.078 | 0.944 | 0.827 | 0.843 | 0.780 |
| | <i>CP-OLS/BIC</i> | 1.030 | 1.136 | 0.796 | 1.000 | 0.887 | 1.005 |
| | <i>CP-GLS/RIC</i> | 0.997 | 1.147 | 1.162 | 1.251 | 1.281 | 0.923 |
| | <i>CPS-OLS/RIC</i> | 1.006 | 1.033 | 1.016 | 1.049 | 1.140 | 0.964 |
| | <i>CPS-OLS/RIC-LI</i> | 0.913 | 1.077 | 1.075 | 1.031 | 0.963 | 0.973 |
| | <i>CPS-OLS/BIC</i> | 0.918 | 0.924 | 0.964 | 1.128 | 1.001 | 0.920 |
| | <i>CPS-GLS/RIC</i> | 1.267 | 1.209 | 1.200 | 1.193 | 1.325 | 1.155 |
| 1. Jerarquización | <i>CP-OLS/RIC</i> | 6.0 | 7.0 | 6.0 | 7.0 | 6.0 | 7.0 |
| | <i>CP-OLS-RIC-LI</i> | 2.0 | 4.0 | 7.0 | 8.0 | 8.0 | 8.0 |
| | <i>CP-OLS/BIC</i> | 3.0 | 3.0 | 8.0 | 6.0 | 7.0 | 2.0 |
| | <i>CP-GLS/RIC</i> | 5.0 | 2.0 | 2.0 | 1.0 | 2.0 | 5.0 |
| | <i>CPS-OLS/RIC</i> | 4.0 | 6.0 | 4.0 | 4.0 | 3.0 | 4.0 |
| | <i>CPS-OLS/RIC-LI</i> | 8.0 | 5.0 | 3.0 | 5.0 | 5.0 | 3.0 |
| | <i>CPS-OLS/BIC</i> | 7.0 | 8.0 | 5.0 | 3.0 | 4.0 | 6.0 |
| | <i>CPS-GLS/RIC</i> | 1.0 | 1.0 | 1.0 | 2.0 | 1.0 | 1.0 |
| 2. EMAP | <i>CP-OLS/RIC</i> | 0.754 | 0.829 | 0.811 | 0.786 | 0.799 | 0.726 |
| | <i>CP-OLS-RIC-LI</i> | 0.965 | 0.875 | 0.834 | 0.717 | 0.818 | 0.698 |
| | <i>CP-OLS/BIC</i> | 0.878 | 0.932 | 0.703 | 0.817 | 0.795 | 0.850 |
| | <i>CP-GLS/RIC</i> | 0.903 | 0.968 | 0.968 | 1.004 | 1.016 | 0.896 |
| | <i>CPS-OLS/RIC</i> | 0.813 | 0.859 | 0.814 | 0.827 | 0.948 | 0.834 |
| | <i>CPS-OLS/RIC-LI</i> | 0.730 | 0.859 | 0.833 | 0.820 | 0.801 | 0.788 |
| | <i>CPS-OLS/BIC</i> | 0.726 | 0.743 | 0.734 | 0.892 | 0.779 | 0.781 |
| | <i>CPS-GLS/RIC</i> | 1.043 | 0.956 | 0.927 | 0.913 | 1.095 | 0.922 |
| 2. Jerarquización | <i>CP-OLS/RIC</i> | 6.0 | 7.0 | 6.0 | 7.0 | 6.0 | 7.0 |
| | <i>CP-OLS-RIC-LI</i> | 2.0 | 4.0 | 3.0 | 8.0 | 4.0 | 8.0 |
| | <i>CP-OLS/BIC</i> | 4.0 | 3.0 | 8.0 | 6.0 | 7.0 | 3.0 |
| | <i>CP-GLS/RIC</i> | 3.0 | 1.0 | 1.0 | 1.0 | 2.0 | 2.0 |
| | <i>CPS-OLS/RIC</i> | 5.0 | 5.0 | 5.0 | 4.0 | 3.0 | 4.0 |
| | <i>CPS-OLS/RIC-LI</i> | 7.0 | 6.0 | 4.0 | 5.0 | 5.0 | 5.0 |
| | <i>CPS-OLS/BIC</i> | 8.0 | 8.0 | 7.0 | 3.0 | 8.0 | 6.0 |
| | <i>CPS-GLS/RIC</i> | 1.0 | 2.0 | 2.0 | 2.0 | 1.0 | 1.0 |
| 3. U-thail | <i>CP-OLS/RIC</i> | 0.779 | 0.710 | 0.612 | 0.616 | 0.659 | 0.321 |
| | <i>CP-OLS-RIC-LI</i> | 0.975 | 0.782 | 0.603 | 0.550 | 0.597 | 0.299 |
| | <i>CP-OLS/BIC</i> | 0.863 | 0.824 | 0.509 | 0.665 | 0.629 | 0.385 |
| | <i>CP-GLS/RIC</i> | 0.836 | 0.832 | 0.742 | 0.832 | 0.907 | 0.353 |
| | <i>CPS-OLS/RIC</i> | 0.843 | 0.749 | 0.649 | 0.698 | 0.808 | 0.369 |
| | <i>CPS-OLS/RIC-LI</i> | 0.765 | 0.781 | 0.687 | 0.686 | 0.682 | 0.372 |
| | <i>CPS-OLS/BIC</i> | 0.769 | 0.670 | 0.616 | 0.750 | 0.709 | 0.352 |
| | <i>CPS-GLS/RIC</i> | 1.062 | 0.877 | 0.767 | 0.794 | 0.939 | 0.442 |
| 3. Jerarquización | <i>CP-OLS/RIC</i> | 6.0 | 7.0 | 6.0 | 7.0 | 6.0 | 7.0 |
| | <i>CP-OLS-RIC-LI</i> | 2.0 | 4.0 | 7.0 | 8.0 | 8.0 | 8.0 |
| | <i>CP-OLS/BIC</i> | 3.0 | 3.0 | 8.0 | 6.0 | 7.0 | 2.0 |
| | <i>CP-GLS/RIC</i> | 5.0 | 2.0 | 2.0 | 1.0 | 2.0 | 5.0 |
| | <i>CPS-OLS/RIC</i> | 4.0 | 6.0 | 4.0 | 4.0 | 3.0 | 4.0 |
| | <i>CPS-OLS/RIC-LI</i> | 8.0 | 5.0 | 3.0 | 5.0 | 5.0 | 3.0 |
| | <i>CPS-OLS/BIC</i> | 7.0 | 8.0 | 5.0 | 3.0 | 4.0 | 6.0 |
| | <i>CPS-GLS/RIC</i> | 1.0 | 1.0 | 1.0 | 2.0 | 1.0 | 1.0 |

NOTAS: Error cuadrático medio de pronóstico (ECMP). Error absoluto medio de pronóstico (EAMP). Componentes principales (CP). Componentes principales supervisadas (CPS). *Risk inflation criterion* (RIC). Límite inferior para el *Risk inflation criterion* (RIC-LI). *Bayesian information criterion* (BIC). Mínimos cuadrados ordinarios con errores estándar de Newey-West (MCO). Mínimos cuadrados generalizados con ponderaciones de robustez (MCG).

CUADRO 2. IPC TITULAR

| | Método/criterio | Horizonte de pronóstico (h) | | | | | |
|-------------------|-----------------|-----------------------------|-------|-------|-------|-------|-------|
| | | 1 | 2 | 3 | 6 | 9 | 12 |
| 1. ECMP | CP-OLS/RIC | 0.931 | 0.809 | 0.780 | 0.786 | 0.796 | 0.702 |
| | CP-OLS/RIC-LI | 0.947 | 0.808 | 0.804 | 0.927 | 0.919 | 0.775 |
| | CP-OLS/BIC | 0.996 | 0.803 | 0.765 | 0.806 | 0.935 | 0.925 |
| | CP-GLS/RIC | 1.029 | 0.899 | 0.821 | 0.999 | 0.928 | 0.927 |
| | CPS-OLS/RIC | 0.950 | 0.814 | 0.721 | 0.657 | 0.586 | 0.568 |
| | CPS-OLS/RIC-LI | 0.940 | 0.794 | 0.744 | 0.737 | 0.701 | 0.680 |
| | CPS-OLS/BIC | 0.941 | 0.819 | 0.744 | 0.785 | 0.775 | 0.814 |
| | CPS-GLS/RIC | 1.084 | 0.875 | 0.849 | 0.954 | 0.886 | 1.049 |
| 1. Jerarquización | CP-OLS/RIC | 8 | 5 | 4 | 5 | 5 | 6 |
| | CP-OLS/RIC-LI | 5 | 6 | 3 | 3 | 3 | 5 |
| | CP-OLS/BIC | 3 | 7 | 5 | 4 | 1 | 3 |
| | CP-GLS/RIC | 2 | 1 | 2 | 1 | 2 | 2 |
| | CPS-OLS/RIC | 4 | 4 | 8 | 8 | 8 | 8 |
| | CPS-OLS/RIC-LI | 7 | 8 | 7 | 7 | 7 | 7 |
| | CPS-OLS/BIC | 6 | 3 | 6 | 6 | 6 | 4 |
| | CPS-GLS/RIC | 1 | 2 | 1 | 2 | 4 | 1 |
| 2. EMAP | CP-OLS/RIC | 0.940 | 0.770 | 0.730 | 0.743 | 0.754 | 0.645 |
| | CP-OLS/RIC-LI | 0.906 | 0.773 | 0.773 | 0.929 | 0.929 | 0.774 |
| | CP-OLS/BIC | 0.946 | 0.793 | 0.751 | 0.779 | 0.922 | 0.911 |
| | CP-GLS/RIC | 1.101 | 0.944 | 0.855 | 1.012 | 0.928 | 0.978 |
| | CPS-OLS/RIC | 0.994 | 0.806 | 0.681 | 0.615 | 0.536 | 0.507 |
| | CPS-OLS/RIC-LI | 0.952 | 0.837 | 0.744 | 0.704 | 0.711 | 0.665 |
| | CPS-OLS/BIC | 0.951 | 0.875 | 0.754 | 0.793 | 0.791 | 0.807 |
| | CPS-GLS/RIC | 1.107 | 0.927 | 0.879 | 1.023 | 0.868 | 1.059 |
| 2. Jerarquización | CP-OLS/RIC | 7 | 8 | 7 | 6 | 6 | 7 |
| | CP-OLS/RIC-LI | 8 | 7 | 3 | 3 | 1 | 5 |
| | CP-OLS/BIC | 6 | 6 | 5 | 5 | 3 | 3 |
| | CP-GLS/RIC | 2 | 1 | 2 | 2 | 2 | 2 |
| | CPS-OLS/RIC | 3 | 5 | 8 | 8 | 8 | 8 |
| | CPS-OLS/RIC-LI | 4 | 4 | 6 | 7 | 7 | 6 |
| | CPS-OLS/BIC | 5 | 3 | 4 | 4 | 5 | 4 |
| | CPS-GLS/RIC | 1 | 2 | 1 | 1 | 4 | 1 |
| 3. U-thail | CP-OLS/RIC | 0.940 | 0.811 | 0.783 | 0.788 | 0.798 | 0.704 |
| | CP-OLS/RIC-LI | 0.956 | 0.810 | 0.807 | 0.930 | 0.920 | 0.777 |
| | CP-OLS/BIC | 1.005 | 0.805 | 0.768 | 0.809 | 0.937 | 0.928 |
| | CP-GLS/RIC | 1.038 | 0.901 | 0.824 | 1.002 | 0.929 | 0.930 |
| | CPS-OLS/RIC | 0.959 | 0.816 | 0.724 | 0.659 | 0.587 | 0.569 |
| | CPS-OLS/RIC-LI | 0.948 | 0.796 | 0.747 | 0.740 | 0.702 | 0.682 |
| | CPS-OLS/BIC | 0.949 | 0.821 | 0.747 | 0.788 | 0.777 | 0.817 |
| | CPS-GLS/RIC | 1.094 | 0.877 | 0.852 | 0.958 | 0.887 | 1.052 |
| 3. Jerarquización | CP-OLS/RIC | 8 | 5 | 4 | 5 | 5 | 6 |
| | CP-OLS/RIC-LI | 5 | 6 | 3 | 3 | 3 | 5 |
| | CP-OLS/BIC | 3 | 7 | 5 | 4 | 1 | 3 |
| | CP-GLS/RIC | 2 | 1 | 2 | 1 | 2 | 2 |
| | CPS-OLS/RIC | 4 | 4 | 8 | 8 | 8 | 8 |
| | CPS-OLS/RIC-LI | 7 | 8 | 7 | 7 | 7 | 7 |
| | CPS-OLS/BIC | 6 | 3 | 6 | 6 | 6 | 4 |
| | CPS-GLS/RIC | 1 | 2 | 1 | 2 | 4 | 1 |

NOTAS: Error cuadrático medio de pronóstico (ECMP). Error absoluto medio de pronóstico (EMAP). Componentes principales (CP). Componentes principales supervisadas (CPS). *Risk inflation criterion* (RIC). Límite inferior para el *Risk inflation criterion* (RIC-LI). *Bayesian information criterion* (BIC). Mínimos cuadrados ordinarios con errores estándar de Newey-West (MCO). Mínimos cuadrados generalizados con ponderaciones de robustez (MCG).

CUADRO 3. IPC NÚCLEO

| | Método/criterio | Horizonte de pronóstico (h) | | | | | |
|-------------------|-----------------|-----------------------------|-------|-------|-------|-------|-------|
| | | 1 | 2 | 3 | 6 | 9 | 12 |
| 1. ECMP | CP-OLS/RIC | 0.981 | 0.823 | 0.704 | 0.734 | 0.716 | 0.658 |
| | CP-OLS-RIC-LI | 0.950 | 0.762 | 0.767 | 0.771 | 0.703 | 0.664 |
| | CP-OLS/BIC | 0.968 | 0.764 | 0.700 | 0.734 | 0.627 | 0.657 |
| | CP-GLS/RIC | 0.844 | 0.863 | 0.817 | 0.834 | 0.812 | 0.655 |
| | CPS-OLS/RIC | 0.987 | 0.770 | 0.693 | 0.603 | 0.572 | 0.541 |
| | CPS-OLS/RIC-LI | 0.991 | 0.843 | 0.786 | 0.720 | 0.677 | 0.634 |
| | CPS-OLS/BIC | 0.815 | 0.670 | 0.666 | 0.633 | 0.700 | 0.677 |
| | CPS-GLS/RIC | 0.924 | 0.751 | 0.693 | 0.744 | 0.799 | 0.690 |
| 1. Jerarquización | CP-OLS/RIC | 3 | 3 | 4 | 4 | 3 | 4 |
| | CP-OLS-RIC-LI | 5 | 6 | 3 | 2 | 4 | 3 |
| | CP-OLS/BIC | 4 | 5 | 5 | 5 | 7 | 5 |
| | CP-GLS/RIC | 7 | 1 | 1 | 1 | 1 | 6 |
| | CPS-OLS/RIC | 2 | 4 | 6 | 8 | 8 | 8 |
| | CPS-OLS/RIC-LI | 1 | 2 | 2 | 6 | 6 | 7 |
| | CPS-OLS/BIC | 8 | 8 | 8 | 7 | 5 | 2 |
| | CPS-GLS/RIC | 6 | 7 | 7 | 3 | 2 | 1 |
| 2. EMAP | CP-OLS/RIC | 0.997 | 0.748 | 0.673 | 0.654 | 0.625 | 0.586 |
| | CP-OLS-RIC-LI | 0.942 | 0.697 | 0.743 | 0.707 | 0.628 | 0.604 |
| | CP-OLS/BIC | 0.941 | 0.731 | 0.707 | 0.682 | 0.622 | 0.644 |
| | CP-GLS/RIC | 0.924 | 0.924 | 0.887 | 0.862 | 0.843 | 0.696 |
| | CPS-OLS/RIC | 0.935 | 0.694 | 0.607 | 0.506 | 0.462 | 0.435 |
| | CPS-OLS/RIC-LI | 0.786 | 0.688 | 0.610 | 0.574 | 0.579 | 0.541 |
| | CPS-OLS/BIC | 0.796 | 0.705 | 0.719 | 0.617 | 0.641 | 0.645 |
| | CPS-GLS/RIC | 0.924 | 0.751 | 0.693 | 0.744 | 0.799 | 0.690 |
| 2. Jerarquización | CP-OLS/RIC | 1 | 3 | 6 | 5 | 5 | 6 |
| | CP-OLS-RIC-LI | 2 | 6 | 2 | 3 | 4 | 5 |
| | CP-OLS/BIC | 3 | 4 | 4 | 4 | 6 | 4 |
| | CP-GLS/RIC | 6 | 1 | 1 | 1 | 1 | 1 |
| | CPS-OLS/RIC | 4 | 7 | 8 | 8 | 8 | 8 |
| | CPS-OLS/RIC-LI | 8 | 8 | 7 | 7 | 7 | 7 |
| | CPS-OLS/BIC | 7 | 5 | 3 | 6 | 3 | 3 |
| | CPS-GLS/RIC | 5 | 2 | 5 | 2 | 2 | 2 |
| 3. U-thail | CP-OLS/RIC | 0.981 | 0.823 | 0.704 | 0.734 | 0.716 | 0.658 |
| | CP-OLS-RIC-LI | 0.950 | 0.762 | 0.767 | 0.771 | 0.703 | 0.664 |
| | CP-OLS/BIC | 1.228 | 0.764 | 0.635 | 0.621 | 0.623 | 0.477 |
| | CP-GLS/RIC | 0.844 | 0.863 | 0.817 | 0.834 | 0.812 | 0.655 |
| | CPS-OLS/RIC | 0.987 | 0.770 | 0.693 | 0.603 | 0.572 | 0.541 |
| | CPS-OLS/RIC-LI | 0.485 | 0.463 | 0.523 | 0.498 | 0.447 | 0.432 |
| | CPS-OLS/BIC | 0.815 | 0.670 | 0.666 | 0.633 | 0.700 | 0.677 |
| | CPS-GLS/RIC | 0.924 | 0.751 | 0.693 | 0.744 | 0.799 | 0.690 |
| 3. Jerarquización | CP-OLS/RIC | 3 | 2 | 3 | 4 | 3 | 4 |
| | CP-OLS-RIC-LI | 4 | 5 | 2 | 2 | 4 | 3 |
| | CP-OLS/BIC | 1 | 4 | 7 | 6 | 6 | 7 |
| | CP-GLS/RIC | 6 | 1 | 1 | 1 | 1 | 5 |
| | CPS-OLS/RIC | 2 | 3 | 4 | 7 | 7 | 6 |
| | CPS-OLS/RIC-LI | 8 | 8 | 8 | 8 | 8 | 8 |
| | CPS-OLS/BIC | 7 | 7 | 6 | 5 | 5 | 2 |
| | CPS-GLS/RIC | 5 | 6 | 5 | 3 | 2 | 1 |

NOTAS: Error cuadrático medio de pronóstico (ECMP). Error absoluto medio de pronóstico (EMAP). Componentes principales (CP). Componentes principales supervisadas (CPS). *Risk inflation criterion* (RIC). Límite inferior para el *Risk inflation criterion* (RIC-LI). *Bayesian information criterion* (BIC). Mínimos cuadrados ordinarios con errores estándar de Newey-West (MCO). Mínimos cuadrados generalizados con ponderaciones de robustez (MCG).

CUADRO 4. IGAEM

| | Método/criterio | Horizonte de pronóstico (h) | | | | | |
|-------------------|-----------------|-----------------------------|-------|-------|-------|-------|-------|
| | | 1 | 2 | 3 | 6 | 9 | 12 |
| 1. ECMP | CP-OLS/RIC | 1.007 | 1.000 | 0.981 | 0.948 | 0.931 | 0.843 |
| | CP-OLS/RIC-LI | 1.007 | 1.000 | 0.981 | 0.948 | 0.931 | 0.843 |
| | CP-OLS/BIC | 1.039 | 1.028 | 0.897 | 0.949 | 0.860 | 0.933 |
| | CP-GLS/RIC | 1.042 | 1.093 | 1.131 | 1.029 | 1.193 | 1.303 |
| | CPS-OLS/RIC | 1.100 | 1.012 | 1.001 | 0.996 | 1.045 | 1.028 |
| | CPS-OLS/RIC-LI | 1.065 | 1.037 | 0.981 | 0.985 | 1.033 | 0.909 |
| | CPS-OLS/BIC | 1.110 | 1.058 | 1.066 | 1.009 | 1.125 | 0.820 |
| | CPS-GLS/RIC | 1.272 | 1.090 | 1.204 | 1.055 | 1.163 | 1.148 |
| 1. Jerarquización | CP-OLS/RIC | 7 | 7 | 6 | 7 | 6 | 6 |
| | CP-OLS/RIC-LI | 7 | 7 | 6 | 7 | 6 | 6 |
| | CP-OLS/BIC | 6 | 5 | 8 | 6 | 8 | 4 |
| | CP-GLS/RIC | 5 | 1 | 2 | 2 | 1 | 1 |
| | CPS-OLS/RIC | 3 | 6 | 4 | 4 | 4 | 3 |
| | CPS-OLS/RIC-LI | 4 | 4 | 5 | 5 | 5 | 5 |
| | CPS-OLS/BIC | 2 | 3 | 3 | 3 | 3 | 8 |
| | CPS-GLS/RIC | 1 | 2 | 1 | 1 | 2 | 2 |
| 2. EMAP | CP-OLS/RIC | 0.810 | 0.832 | 0.812 | 0.818 | 0.826 | 0.797 |
| | CP-OLS/RIC-LI | 0.810 | 0.832 | 0.812 | 0.818 | 0.826 | 0.797 |
| | CP-OLS/BIC | 0.856 | 0.856 | 0.783 | 0.783 | 0.784 | 0.850 |
| | CP-GLS/RIC | 0.851 | 0.872 | 0.946 | 0.931 | 0.969 | 1.061 |
| | CPS-OLS/RIC | 0.931 | 0.833 | 0.817 | 0.771 | 0.863 | 0.880 |
| | CPS-OLS/RIC-LI | 0.815 | 0.846 | 0.768 | 0.791 | 0.867 | 0.779 |
| | CPS-OLS/BIC | 0.842 | 0.841 | 0.832 | 0.801 | 0.921 | 0.706 |
| | CPS-GLS/RIC | 1.012 | 0.916 | 0.953 | 0.897 | 0.967 | 0.940 |
| 2. Jerarquización | CP-OLS/RIC | 7 | 7 | 5 | 3 | 6 | 5 |
| | CP-OLS/RIC-LI | 7 | 7 | 5 | 3 | 6 | 5 |
| | CP-OLS/BIC | 3 | 3 | 7 | 7 | 8 | 4 |
| | CP-GLS/RIC | 4 | 2 | 2 | 1 | 1 | 1 |
| | CPS-OLS/RIC | 2 | 6 | 4 | 8 | 5 | 3 |
| | CPS-OLS/RIC-LI | 6 | 4 | 8 | 6 | 4 | 7 |
| | CPS-OLS/BIC | 5 | 5 | 3 | 5 | 3 | 8 |
| | CPS-GLS/RIC | 1 | 1 | 1 | 2 | 2 | 2 |
| 3. U-thail | CP-OLS/RIC | 0.844 | 0.725 | 0.627 | 0.631 | 0.659 | 0.323 |
| | CP-OLS/RIC-LI | 0.844 | 0.725 | 0.627 | 0.631 | 0.659 | 0.323 |
| | CP-OLS/BIC | 0.871 | 0.746 | 0.573 | 0.631 | 0.609 | 0.357 |
| | CP-GLS/RIC | 0.874 | 0.793 | 0.722 | 0.684 | 0.845 | 0.499 |
| | CPS-OLS/RIC | 0.922 | 0.734 | 0.639 | 0.662 | 0.740 | 0.394 |
| | CPS-OLS/RIC-LI | 0.892 | 0.753 | 0.627 | 0.656 | 0.732 | 0.348 |
| | CPS-OLS/BIC | 0.931 | 0.767 | 0.681 | 0.671 | 0.797 | 0.314 |
| | CPS-GLS/RIC | 1.042 | 1.093 | 1.131 | 1.029 | 1.193 | 1.303 |
| 3. Jerarquización | CP-OLS/RIC | 7 | 7 | 6 | 7 | 6 | 6 |
| | CP-OLS/RIC-LI | 7 | 7 | 6 | 7 | 6 | 6 |
| | CP-OLS/BIC | 6 | 5 | 8 | 6 | 8 | 4 |
| | CP-GLS/RIC | 5 | 2 | 2 | 2 | 2 | 2 |
| | CPS-OLS/RIC | 3 | 6 | 4 | 4 | 4 | 3 |
| | CPS-OLS/RIC-LI | 4 | 4 | 5 | 5 | 5 | 5 |
| | CPS-OLS/BIC | 2 | 3 | 3 | 3 | 3 | 8 |
| | CPS-GLS/RIC | 1 | 1 | 1 | 1 | 1 | 1 |

NOTAS: Error cuadrático medio de pronóstico (ECMP). Error absoluto medio de pronóstico (EMAP). Componentes principales (CP). Componentes principales supervisadas (CPS). *Risk inflation criterion* (RIC). Límite inferior para el *Risk inflation criterion* (RIC-LI). *Bayesian information criterion* (BIC). Mínimos cuadrados ordinarios con errores estándar de Newey-West (MCO). Mínimos cuadrados generalizados con ponderaciones de robustez (MCG).

CUADRO 5. IPC TITULAR

| | Método/criterio | Horizonte de pronóstico (h) | | | | | |
|-------------------|-----------------|-----------------------------|-------|-------|-------|-------|-------|
| | | 1 | 2 | 3 | 6 | 9 | 12 |
| 1. ECMP | CP-OLS/RIC | 0.892 | 0.687 | 0.648 | 0.625 | 0.611 | 0.561 |
| | CP-OLS-RIC-LI | 0.892 | 0.687 | 0.648 | 0.625 | 0.611 | 0.561 |
| | CP-OLS/BIC | 0.833 | 0.618 | 0.609 | 0.734 | 0.599 | 0.415 |
| | CP-GLS/RIC | 0.839 | 0.738 | 0.653 | 0.683 | 0.573 | 0.470 |
| | CPS-OLS/RIC | 0.907 | 0.785 | 0.679 | 0.742 | 0.562 | 0.478 |
| | CPS-OLS/RIC-LI | 0.837 | 0.768 | 0.690 | 0.575 | 0.469 | 0.400 |
| | CPS-OLS/BIC | 0.850 | 0.707 | 0.648 | 0.620 | 0.491 | 0.524 |
| | CPS-GLS/RIC | 0.935 | 0.787 | 0.750 | 0.698 | 0.548 | 0.496 |
| 1. Jerarquización | CP-OLS/RIC | 3 | 6 | 5 | 5 | 1 | 1 |
| | CP-OLS-RIC-LI | 3 | 6 | 5 | 5 | 1 | 1 |
| | CP-OLS/BIC | 8 | 8 | 8 | 2 | 3 | 7 |
| | CP-GLS/RIC | 6 | 4 | 4 | 4 | 4 | 6 |
| | CPS-OLS/RIC | 2 | 2 | 3 | 1 | 5 | 5 |
| | CPS-OLS/RIC-LI | 7 | 3 | 2 | 8 | 8 | 8 |
| | CPS-OLS/BIC | 5 | 5 | 7 | 7 | 7 | 3 |
| | CPS-GLS/RIC | 1 | 1 | 1 | 3 | 6 | 4 |
| 2. EMAP | CP-OLS/RIC | 0.860 | 0.694 | 0.644 | 0.594 | 0.579 | 0.523 |
| | CP-OLS-RIC-LI | 0.860 | 0.694 | 0.644 | 0.594 | 0.579 | 0.523 |
| | CP-OLS/BIC | 0.838 | 0.635 | 0.584 | 0.678 | 0.612 | 0.481 |
| | CP-GLS/RIC | 0.821 | 0.750 | 0.677 | 0.661 | 0.535 | 0.474 |
| | CPS-OLS/RIC | 0.915 | 0.768 | 0.680 | 0.725 | 0.574 | 0.461 |
| | CPS-OLS/RIC-LI | 0.837 | 0.779 | 0.650 | 0.552 | 0.457 | 0.372 |
| | CPS-OLS/BIC | 0.843 | 0.726 | 0.596 | 0.604 | 0.464 | 0.512 |
| | CPS-GLS/RIC | 0.976 | 0.838 | 0.720 | 0.707 | 0.529 | 0.472 |
| 2. Jerarquización | CP-OLS/RIC | 3 | 6 | 5 | 6 | 2 | 1 |
| | CP-OLS-RIC-LI | 3 | 6 | 5 | 6 | 2 | 1 |
| | CP-OLS/BIC | 6 | 8 | 8 | 3 | 1 | 4 |
| | CP-GLS/RIC | 8 | 4 | 3 | 4 | 5 | 5 |
| | CPS-OLS/RIC | 2 | 3 | 2 | 1 | 4 | 7 |
| | CPS-OLS/RIC-LI | 7 | 2 | 4 | 8 | 8 | 8 |
| | CPS-OLS/BIC | 5 | 5 | 7 | 5 | 7 | 3 |
| | CPS-GLS/RIC | 1 | 1 | 1 | 2 | 6 | 6 |
| 3. U-thail | CP-OLS/RIC | 0.900 | 0.689 | 0.651 | 0.628 | 0.612 | 0.562 |
| | CP-OLS-RIC-LI | 0.900 | 0.689 | 0.651 | 0.628 | 0.612 | 0.562 |
| | CP-OLS/BIC | 0.840 | 0.620 | 0.611 | 0.736 | 0.600 | 0.416 |
| | CP-GLS/RIC | 0.847 | 0.740 | 0.655 | 0.686 | 0.574 | 0.472 |
| | CPS-OLS/RIC | 0.915 | 0.787 | 0.682 | 0.745 | 0.563 | 0.479 |
| | CPS-OLS/RIC-LI | 0.845 | 0.770 | 0.693 | 0.577 | 0.470 | 0.402 |
| | CPS-OLS/BIC | 0.857 | 0.709 | 0.650 | 0.622 | 0.492 | 0.526 |
| | CPS-GLS/RIC | 0.944 | 0.788 | 0.753 | 0.701 | 0.549 | 0.498 |
| 3. Jerarquización | CP-OLS/RIC | 3 | 6 | 5 | 5 | 1 | 1 |
| | CP-OLS-RIC-LI | 3 | 6 | 5 | 5 | 1 | 1 |
| | CP-OLS/BIC | 8 | 8 | 8 | 2 | 3 | 7 |
| | CP-GLS/RIC | 6 | 4 | 4 | 4 | 4 | 6 |
| | CPS-OLS/RIC | 2 | 2 | 3 | 1 | 5 | 5 |
| | CPS-OLS/RIC-LI | 7 | 3 | 2 | 8 | 8 | 8 |
| | CPS-OLS/BIC | 5 | 5 | 7 | 7 | 7 | 3 |
| | CPS-GLS/RIC | 1 | 1 | 1 | 3 | 6 | 4 |

NOTAS: Error cuadrático medio de pronóstico (ECMP). Error absoluto medio de pronóstico (EMAP). Componentes principales (CP). Componentes principales supervisadas (CPS). *Risk inflation criterion* (RIC). Límite inferior para el *Risk inflation criterion* (RIC-LI). *Bayesian information criterion* (BIC). Mínimos cuadrados ordinarios con errores estándar de Newey-West (MCO). Mínimos cuadrados generalizados con ponderaciones de robustez (MCG).

CUADRO 6. IPC NÚCLEO

| | Método/criterio | Horizonte de pronóstico (h) | | | | | |
|-------------------|-----------------|-----------------------------|-------|-------|-------|-------|-------|
| | | 1 | 2 | 3 | 6 | 9 | 12 |
| 1. ECMP | CP-OLS/RIC | 0.776 | 0.614 | 0.596 | 0.485 | 0.500 | 0.461 |
| | CP-OLS-RIC-LI | 0.776 | 0.614 | 0.596 | 0.485 | 0.500 | 0.461 |
| | CP-OLS/BIC | 0.897 | 0.649 | 0.592 | 0.561 | 0.501 | 0.451 |
| | CP-GLS/RIC | 0.980 | 0.690 | 0.471 | 0.497 | 0.480 | 0.376 |
| | CPS-OLS/RIC | 0.912 | 0.727 | 0.645 | 0.515 | 0.476 | 0.411 |
| | CPS-OLS/RIC-LI | 0.726 | 0.666 | 0.598 | 0.498 | 0.406 | 0.346 |
| | CPS-OLS/BIC | 0.830 | 0.650 | 0.579 | 0.419 | 0.420 | 0.412 |
| | CPS-GLS/RIC | 0.911 | 0.704 | 0.681 | 0.580 | 0.592 | 0.693 |
| 1. Jerarquización | CP-OLS/RIC | 6 | 7 | 4 | 6 | 3 | 2 |
| | CP-OLS-RIC-LI | 6 | 7 | 4 | 6 | 3 | 2 |
| | CP-OLS/BIC | 4 | 6 | 6 | 2 | 2 | 4 |
| | CP-GLS/RIC | 1 | 3 | 8 | 5 | 5 | 7 |
| | CPS-OLS/RIC | 2 | 1 | 2 | 3 | 6 | 6 |
| | CPS-OLS/RIC-LI | 8 | 4 | 3 | 4 | 8 | 8 |
| | CPS-OLS/BIC | 5 | 5 | 7 | 8 | 7 | 5 |
| | CPS-GLS/RIC | 3 | 2 | 1 | 1 | 1 | 1 |
| 2. EMAP | CP-OLS/RIC | 0.728 | 0.569 | 0.558 | 0.444 | 0.460 | 0.414 |
| | CP-OLS-RIC-LI | 0.728 | 0.569 | 0.558 | 0.444 | 0.460 | 0.414 |
| | CP-OLS/BIC | 0.933 | 0.637 | 0.555 | 0.495 | 0.452 | 0.387 |
| | CP-GLS/RIC | 0.891 | 0.657 | 0.492 | 0.464 | 0.445 | 0.386 |
| | CPS-OLS/RIC | 0.835 | 0.699 | 0.610 | 0.456 | 0.406 | 0.340 |
| | CPS-OLS/RIC-LI | 0.812 | 0.716 | 0.625 | 0.538 | 0.465 | 0.449 |
| | CPS-OLS/BIC | 0.750 | 0.637 | 0.534 | 0.432 | 0.376 | 0.392 |
| | CPS-GLS/RIC | 0.894 | 0.696 | 0.664 | 0.569 | 0.537 | 0.661 |
| 2. Jerarquización | CP-OLS/RIC | 7 | 7 | 4 | 6 | 3 | 3 |
| | CP-OLS-RIC-LI | 7 | 7 | 4 | 6 | 3 | 3 |
| | CP-OLS/BIC | 1 | 5 | 6 | 3 | 5 | 6 |
| | CP-GLS/RIC | 3 | 4 | 8 | 4 | 6 | 7 |
| | CPS-OLS/RIC | 4 | 3 | 3 | 5 | 7 | 8 |
| | CPS-OLS/RIC-LI | 5 | 1 | 2 | 2 | 2 | 2 |
| | CPS-OLS/BIC | 6 | 6 | 7 | 8 | 8 | 5 |
| | CPS-GLS/RIC | 2 | 2 | 1 | 1 | 1 | 1 |
| 3. U-thail | CP-OLS/RIC | 0.776 | 0.614 | 0.596 | 0.485 | 0.500 | 0.461 |
| | CP-OLS-RIC-LI | 0.776 | 0.614 | 0.596 | 0.485 | 0.500 | 0.461 |
| | CP-OLS/BIC | 0.897 | 0.649 | 0.592 | 0.561 | 0.501 | 0.451 |
| | CP-GLS/RIC | 0.980 | 0.690 | 0.471 | 0.497 | 0.480 | 0.376 |
| | CPS-OLS/RIC | 0.912 | 0.727 | 0.645 | 0.515 | 0.476 | 0.411 |
| | CPS-OLS/RIC-LI | 0.830 | 0.650 | 0.579 | 0.419 | 0.420 | 0.412 |
| | CPS-OLS/BIC | 0.860 | 0.724 | 0.635 | 0.512 | 0.483 | 0.440 |
| | CPS-GLS/RIC | 0.911 | 0.704 | 0.681 | 0.580 | 0.592 | 0.693 |
| 3. Jerarquización | CP-OLS/RIC | 7 | 7 | 4 | 6 | 3 | 2 |
| | CP-OLS-RIC-LI | 7 | 7 | 4 | 6 | 3 | 2 |
| | CP-OLS/BIC | 4 | 6 | 6 | 2 | 2 | 4 |
| | CP-GLS/RIC | 1 | 4 | 8 | 5 | 6 | 8 |
| | CPS-OLS/RIC | 2 | 1 | 2 | 3 | 7 | 7 |
| | CPS-OLS/RIC-LI | 6 | 5 | 7 | 8 | 8 | 6 |
| | CPS-OLS/BIC | 5 | 2 | 3 | 4 | 5 | 5 |
| | CPS-GLS/RIC | 3 | 3 | 1 | 1 | 1 | 1 |

NOTAS: Error cuadrático medio de pronóstico (ECMP). Error absoluto medio de pronóstico (EMAP). Componentes principales (CP). Componentes principales supervisadas (CPS). *Risk inflation criterion* (RIC). Límite inferior para el *Risk inflation criterion* (RIC-LI). *Bayesian information criterion* (BIC). Mínimos cuadrados ordinarios con errores estándar de Newey-West (MCO). Mínimos cuadrados generalizados con ponderaciones de robustez (MCG).

CUADRO 7. LISTA DE VARIABLES

| <i>N^o</i> | <i>Etiqueta</i> | <i>Variable</i> | <i>Origen de integración</i> | <i>Uso</i> |
|----------------------|-----------------|--|------------------------------|------------|
| 1 | IGAEM | Índice general de actividad económica mensual | 1 | CP/CPS |
| 2 | IGAEMNP | Índice general de actividad económica mensual no petrolero mensual | 1 | CP |
| 3 | IGAEMP | Índice general de actividad económica mensual petrolero | 1 | CP |
| 4 | IPC | Índice de precio al consumidor base 1997 | 1 y 2 | CP/CPS |
| 5 | IPCX | Índice de precio al consumidor de Estados Unidos | 1 | CP/CPS |
| 6 | IPM | Índice de precio al mayor base 1997 | 1 | CP/CPS |
| 7 | IPMNAC | Índice de precio al mayor de bienes nacionales base 1997 | 1 | CP/CPS |
| 8 | IPMIMP | Índice de precio al mayor de bienes importados base 1997 | 1 | CP |
| 9 | IPMAGRO | Índice de precio al mayor de productos agrícolas base 1997 | 1 | CP |
| 10 | IPMMACF | Índice de precio al mayor de productos manufactureros base 1997 | 1 | CP |
| 11 | M1 | Dinero | 1 | CPS |
| 12 | M2N | Liquidez | 1 | CPS |
| 13 | RIND | Reservas internacionales netas en dólares | 1 | CP |
| 14 | proxBs | Sustituta del TC USD/B | 1 | CP |
| 15 | prox\$ | Sustituta del TC B/USD | 1 | CP |
| 16 | MYBN | Moneda y billetes | 1 | CP/CPS |
| 17 | tcudm | Tipo de cambio ponderado | 1 | CP |
| 18 | TCPMNC | Tipo de cambio del mercado no controlado | 1 | CP |
| 19 | TCN | Tipo de cambio nominal | 1 | CP |
| 20 | BMN | Base monetaria | 1 | CP |
| 21 | CDN | Cuasidinero | 1 | CP |
| 22 | IMH | Índice de mineral de hierro | 1 | CP/CPS |
| 23 | IEG | Índice general de electricidad generada | 1 | CP/CPS |
| 24 | IVC | Índice de ventas comerciales | 1 | CP/CPS |
| 25 | IVP | Índice de valor de la producción | 1 | CP |
| 26 | MDP | Importaciones privadas en dólares | 1 | CP/CPS |
| 27 | INPRE | Índice de precios relativo interno y externo | 1 | CP |
| 28 | PPCSF | Producción de petróleo crudo sin faja | 1 | CP |
| 29 | PPREFGLP | Producción de petróleo refinado | 1 | CP |
| 30 | VOXPCSFD | Exportaciones de petróleo crudo sin faja | 1 | CP |
| 31 | VOXPREFD | Exportaciones de petróleo refinado | 1 | CP |
| 32 | VOXPSFD | Total de exportación de petróleo | 1 | CP |
| 33 | PP | Precio del petróleo (cesta venezolana) | 1 | CP |
| 34 | NUCLEO | Núcleo inflacionario | 1 y 2 | CP/CPS |
| 35 | IPCG 1_2 | Índice de precio de alimentos, bebidas y tabaco | 1 | CP/CPS |

| | | | | |
|----|---------|--|---|--------|
| 36 | IPCG 3 | Índice de precio de vestido y calzados | 1 | CP/CPS |
| 37 | IPCG 4 | Índice de precio de alquiler de vivienda | 1 | CP/CPS |
| 38 | IPCG 5 | Índice de precio de servicios de vivienda excepto teléfono | 1 | CP |
| 39 | IPCGR 6 | Índice de precio de equipamiento de hogar | 1 | CP/CPS |
| 40 | IPCGR 7 | Índice de precio de salud | 1 | CP/CPS |
| 41 | IPCGR 8 | Índice de precio de transporte | 1 | CP |
| 42 | IPCGR 9 | Índice de precio de comunicaciones | 1 | CP |
| 43 | IPCG 10 | Índice de precio de esparcimiento y cul- tura | 1 | CP/CPS |
| 44 | IPCG 11 | Índice de precio de servicio de educa- ción | 1 | CP/CPS |
| 45 | IPCG 14 | Índice de precio de restaurantes y hote- les, bienes y servicios diversos | 1 | CP/CPS |

NOTAS: A todas las variables se les aplicó logaritmo. Componentes Principales (CP). Componentes Principales Supervisadas (CPS).

REFERENCIAS

- Aguirre, A., y L. F. Céspedes (2004), *Uso de análisis factorial dinámico para proyecciones macroeconómicas*, Banco Central de Chile (Documentos de Trabajo, n° 274).
- Artis, M. J., A. Banerjee y M. Marcellino (2005), "Factor Forecasts for the UK", *Journal of Forecasting*, vol. 24, pp. 279-98.
- Bai, J., y S. Ng (2002), "Determining the number of factors in approximate factor models", *Econometrica*, vol. 70, pp. 191-221.
- Bai, J., y S. Ng (2008), "Forecasting economic time series using targeted predictors", *Journal of Econometrics*, vol. 146, pp. 304-17.
- Bair, E., T. Hastie, P. Debnath y R. Tibshirani (2005), "Prediction by supervised principal components", *Journal of the American Statistical Association*, vol. 101, n° 473, pp. 119-37.
- Bernanke, B. S., J. Boivin y E. Piotr (2004), *Measuring the effects of monetary policy: a factor augmented vector autoregressive (FAVAR) approach*, National Bureau of Economic Research, Inc., (Working Papers, n° 10220)
- Cleveland, W. (1979), "Robust Locally Weighted Regression and Smoothing Scatterplots", *Journal of the American Statistical Association*, vol. 74, n° 368.
- Donoho, D. L., e I. M. Johnstone (1994), "Ideal Spatial Adaptation by Wavelet Shrinkage", *Biometrika*, vol. 81, pp. 425-55.

- Dorta, M. (2006), *Selección de variables por muestreo para regresión múltiple basado en el Risk Inflation Criterion*, texto mimeografiado, Banco Central de Venezuela.
- Forni, M., M. Hallin, M. Lippi y L. Reichlin (2000), "The generalized factor model: identification and estimation", *The Review of Economics and Statistics*, vol. 82, pp. 540-54.
- Forni, M., M. Hallin, M. Lippi y L. Reichlin (2003), *The generalized dynamic factor model: one sided estimation and forecasting*, CEPR (Discussion Paper Series, n° 3432).
- Foster, D. P., y E. I. George (1994), "The Risk Inflation Criterion for Multiple Regression", *The Annals of Statistics*, vol. 22, n° 4, pp. 1947-75.
- George, E. I. (2000), "The variable selection problem", *Journal of the American Statistical Association*, vol. 95, n° 452, pp. 1304-308.
- Gross, Alan M. (1977), "Confidence Intervals for Bisquare Regression Estimates", *Journal of America Statistical Association*, vol. 72, pp. 341-54.
- Marcelino, M., y C. Schumacher (2007) *Factor-MIDAS for now and forecasting with ragged-edge data: a model comparison for German GDP*, Deutsche Bundesbank (Discussion Paper, Series 1: Economic Studies, n° 34/2007).
- Matheson, T. (2005), *Factor model forecasts for New Zealand*, Reserve Bank of New Zealand (DP2005/01).
- Schwarz, G. (1978), "Estimating the Dimension of a Model", *The Annals of Statistics*, vol. 6, pp. 461-64.
- Stock, J. H., y M. W. Watson (2002), "Macroeconomic forecasting using diffusion indexes", *Journal of Business & Economic Statistics*, vol. 20, n° 2.

Eliana González M.
Alejandro Reyes G.

Una comparación empírica de diferentes enfoques de combinación de pronósticos: el caso de la inflación en Colombia

I. INTRODUCCIÓN

Para un banco central es importante contar con información fidedigna y actualizada para así poder tomar decisiones políticas. Sin embargo, debido a la diversidad de datos, fuentes de datos y metodologías de procesamiento, el proceso analítico surge como una tarea difícil. Para un banco central es particularmente importante contar con información fiable sobre la inflación futura esperada. Para tener un buen desempeño de pronóstico, el análisis tiene que ocuparse de un amplio

Traduce y publica el CEMLA, con la debida autorización, el artículo “An Empirical Comparison of Different Approaches of Forecast Combination: The Colombian Inflation Case”, de E. González M. y A. Reyes G., presentado en la XIV Reunión de la Red de Investigadores de Bancos Centrales del Continente Americano, auspiciada por el Banco Central de Brasil, celebrada en Salvador, Bahía, del 11 al 13 de noviembre de 2009. Los autores son profesionales del Departamento de Estudios Económicos del Banco de la República, de Colombia. Cualquier error restante, así como las conclusiones y comentarios incluidos en este estudio son responsabilidad exclusiva de los autores y no comprometen ni al Banco de la República ni a su Junta de Gobernadores. Sírvase referir comentarios a: (egonzamo@banrep.gov.co o areyesgo@banrep.gov.co).

espectro de fuentes de datos, algunas de las cuales son encuestas, modelos econométricos y juicios de expertos o del personal. La junta de gobierno hace uso de este amplio rango de información disponible para decidir cual es la inflación futura esperada y a la vez (mediante el resumen o abstracción de otros criterios valiosos) ayudar con la determinación de la posición de la política monetaria. A la luz de esta tarea, una opción que los bancos centrales deberían buscar es concentrar de forma coherente toda la información disponible para así simplificar el proceso de análisis.

En este artículo buscamos una manera de resumir toda la información proporcionada por el conjunto de modelos de pronóstico (que incluye modelos econométricos y conocimiento de expertos) en un solo resultado. Esto se puede lograr con diferentes metodologías; una de ellas es seleccionar el pronóstico que produzca el menor error de pronóstico en términos de la raíz del error cuadrático medio (RECM) u otra medida de errores de pronóstico pero, al hacerlo así, alguna información importante de otros pronósticos podría quedar por fuera. Otro criterio podría considerar la opinión del personal técnico mediante la creación de un pronóstico de consenso, solo que este procedimiento involucra un factor (que a menudo es deseable) de discreción que podría producir un error de pronóstico mayor. De los criterios anteriores sobresalen dos características importantes para lograr el pronóstico más exacto: el poder predictivo y la facilidad de cálculo. Nosotros intentamos primero hacer un promedio simple de todos los pronósticos como un benchmark de la combinación de pronósticos; posteriormente procedimos a analizar dos metodologías, ambas estadísticas: análisis de componentes principales y promedio de modelos basado en criterios de información.

La literatura existente ha mostrado que a menudo los pronósticos combinados superan los pronósticos individuales en términos de errores de pronóstico¹ menores (Clements, 1989; Hendry y Clements, 2004; y Elliott y Timmermann, 2004). Las combinaciones de pronóstico son una manera útil de extraer

¹ De acuerdo con algunos criterios de evaluación como por ejemplo error cuadrático medio (ECM) de pronóstico, error medio absoluto (EMA), etcétera.

información de un grupo de pronósticos individuales si se considera que los pronósticos individuales se pueden obtener a partir de diferentes formas funcionales, métodos de estimación e incluso diferentes variables explicativas. Sin embargo, no existe un pronóstico particular en el cual se puede confiar con certeza y descartar los otros; porque un pronóstico puede particularmente ser el mejor de todos si se hacen pronósticos a corto plazo pero puede que no sea suficientemente bueno a largo plazo, por ejemplo, el pronóstico puede ser bueno para algunos horizontes pero no para todos los horizontes considerados. Por otra parte, un pronóstico individual puede funcionar bien en algunas situaciones, por ejemplo, cuando se explica un choque en particular. Por ello, la combinación de pronósticos resume en un solo número toda la información relevante, sobre la capacidad predictiva, de cada pronóstico individual.

Este documento está organizado en cinco secciones incluyendo ésta. La segunda sección incluye una breve explicación de algunas metodologías de combinación de pronósticos: las utilizadas en este documento y alguna combinación de pronósticos basada en un modelo de regresión, que utilizamos para fines comparativos. En la tercera sección incluimos una descripción de los datos y la estructura de los modelos de pronóstico para combinar, así como una pequeña descripción contextual del proceso inflacionario en Colombia. En la cuarta sección analizamos los resultados y los comparamos con el benchmark y con todos los pronósticos individuales basados en la raíz del error cuadrático medio. Finalmente, presentamos las conclusiones en la quinta sección.

II. METODOLOGÍAS Y MARCO TEÓRICO

Nos enfocamos en métodos de combinación que explican series de tiempo no estacionarias. Analizamos y comparamos cuatro métodos de combinación diferentes: promedio simple, combinación de pronósticos de regresión lineal, componentes principales y promedio de modelos basado en criterios de información.

1. Combinación de pronósticos de regresión (Regr_Comb)

Seguimos las metodologías de combinación de Hallman y Kamstra (1989) y de Coulson y Robins (1993). Los dos enfoques asumen que las series de pronóstico son no estacionarias, Esta metodología usa estimaciones de MCO, de tal forma que se escoge la mejor combinación² de todas las posibles, en términos de error cuadrático medio de pronóstico menor, como el pronóstico combinado (CME de aquí en adelante).

En consecuencia, establecemos Y_t como la serie para ser predecida, $f_{t|t-h}^i$ como el modelo de pronóstico i ($i=1, \dots, K$), y $(\gamma_0, \gamma_1, \gamma_2, \dots, \gamma_k)'$ un vector de parámetros de estimación. La metodología de Hallman y Kamstra para el horizonte de pronóstico h se basa en la siguiente regresión:

$$(1) \quad Y_t = \gamma_{0h} + \gamma_{1h} f_{t|t-h}^1 + \gamma_{2h} f_{t|t-h}^2 + \dots + \gamma_{kh} f_{t|t-h}^k + \varepsilon_t,$$

sujeto a $\gamma_1 + \gamma_2 + \dots + \gamma_k = 1$, donde $\varepsilon_t \sim \text{iid}(0, \sigma^2)$ y $t = 1, 2, \dots, T$. Entonces, la combinación de pronósticos h periodos adelante está dada por:

$$(2) \quad \hat{Y}_{t+h|t} = \hat{\gamma}_{0h} + \hat{\gamma}_{1h} f_{t+h|t}^1 + \hat{\gamma}_{2h} f_{t+h|t}^2 + \dots + \hat{\gamma}_{kh} f_{t+h|t}^k.$$

Por otro lado, la metodología de combinación de Coulson y Robins se basa en el siguiente modelo lineal:³

$$(3) \quad Y_t - Y_{t-h} = \gamma_{0h} + \gamma_{1h} (f_{t|t-h}^1 - Y_{t-h}) + \gamma_{2h} (f_{t|t-h}^2 - Y_{t-h}) + \dots + \gamma_{kh} (f_{t|t-h}^k - Y_{t-h}) + \varepsilon_t,$$

donde la combinación de pronósticos h pasos adelante se obtiene como:

$$(4) \quad \hat{Y}_{t+h|t} = Y_t + \hat{\gamma}_{0h} + \hat{\gamma}_{1h} (f_{t+h|t}^1 - Y_t) + \hat{\gamma}_{2h} (f_{t+h|t}^2 - Y_t) + \dots + \hat{\gamma}_{kh} (f_{t+h|t}^k - Y_t).$$

Por lo tanto, el pronóstico combinado es un promedio

$$^2 \left(\binom{k}{2} + \binom{k}{3} + \dots + \binom{k}{k} \right) \text{modelos.}$$

³ En el artículo original la primera diferencia se toma de las series observadas y de las series de pronósticos. Gómez *et al.* (2006) propusieron tomar la diferencia h - th de manera que la combinación de pronósticos h periodos adelante no dependa del Y_{t+h-1} no observado sino del Y_t .

ponderado de los pronósticos individuales que se obtuvieron de los modelos. Se incluye un intercepto en la ecuación de combinación para corregir un posible sesgo contenido en alguno de los pronósticos individuales incluidos en la combinación. Adicionalmente, el método de Coulson y Robins es igual al método de Hallman y Kamstra cuando la suma de todas las ponderaciones se restringe a uno. Por otra parte, para evitar multicolinealidad en la ecuación de combinación sólo se incluyen en la combinación aquellos pronósticos individuales que no están incluidos⁴ por otros. Por ello previamente se realizaron pruebas de inclusión (Leybourne y Newbold, 1998) para verificar inclusión en pares y multivariada, y así determinar cuáles pronósticos individuales se incluirán en la combinación de pronósticos. Melo y Núñez (2004) adoptaron esta metodología para el banco central de Colombia.

2. Análisis de componentes principales (CP)

El análisis de componentes principales intenta explicar la estructura de varianza y covarianza de un grupo de variables con combinaciones lineales ortogonales de las variables originales. Aún y cuando el método requiere del mismo número de combinaciones lineales que las variables originales para explicar la variabilidad total del sistema original, la mayor parte de su variabilidad generalmente se concentra en los primeros componentes. Esta propiedad permite la reducción de datos lo que a su vez simplifica muchos problemas que se podrían encontrar. Bernanke y Boivin (2003) muestran que los factores estimados de CP representan un eficiente resumen de la información incluida en un grupo de datos más amplio.

La posibilidad de reducir el número de variables independientes que se usa en una regresión es una clara ganancia para las ciencias económicas sin perder información que pudiera ser relevante para el problema, tal y como mencionan Stock y Watson (2004). Por otra parte, la utilidad generada

⁴ Un modelo de pronóstico incluye o abarca un segundo modelo de pronóstico si toda la información predictiva relevante contenida en el modelo de pronóstico más reciente no está incluida en el modelo de pronóstico anterior.

por este método para este estudio es la forma simple utilizada para resumir información en unos cuantos componentes que explican la mayor parte de la varianza con los primeros k componentes. Particularmente para este trabajo, la capacidad de combinar una cantidad importante de pronósticos por medio de una medida única (sólo el primer componente) que explica la mayoría de su variabilidad.

El procedimiento consiste en una transformación lineal simple del sistema original en un sistema alternativo que contenga el mismo número de miembros, es decir, el número de componentes es el mismo que de las variables originales. Este sistema alternativo tiene la propiedad de que todos los componentes son ortogonales entre sí (independiente). Esto es una gran ventaja cuando surge la multicolinealidad. El método se basa en el cálculo de k eigenvalores del sistema de k variables de la matriz de varianza-covarianza o de la matriz de correlación. El componente i -ésimo puede ser expresado como sigue:

$$(7) \quad PC_i = e_i f = e_{i1} f^1 + e_{i2} f^2 + \dots + e_{ik} f^k,$$

donde el vector f corresponde al sistema de k variables observado para los periodos $t = 1, \dots, T$ y el vector e_i corresponde al valor propio de la matriz de varianza-covarianza de f asociado al valor propio i . El conjunto de variables en f se ha estandarizado previamente y si algunas de las variables no son estacionarias, éstas se transforman con el uso de diferencias.

El pronóstico combinado es una combinación lineal de un subconjunto de componentes principales del conjunto de pronósticos individuales, donde las ponderaciones se obtienen de una regresión de la variable que queremos pronosticar como una función de los primeros componentes l obtenidos con los datos disponibles hasta el momento T . El número de componentes principales $l < K$, se determina por unos criterios de información o por la selección de aquellos que explican una proporción determinada de la varianza.

$$Y_t - Y_{t-h} = a + b_1 PC_{1t} + b_2 PC_{2t} + \dots + b_l PC_{lt} + \varepsilon_t.$$

Por ende, el pronóstico combinado se da por:

$$\hat{Y}_{t+h|t} = Y_t + \hat{a} + \hat{b}_1 PC_{1t} + \hat{b}_2 PC_{2t} + \dots + \hat{b}_l PC_{lt}.$$

3. Promedio de modelos basado en criterios de información (ITMA)

Consiste en un promedio ponderado de pronósticos que se remonta al trabajo de Akaike en los años 1978, 1979, 1981 y 1983, donde las ponderaciones óptimas se basan en el AIC o criterio de Akaike. El AIC es un estimador asintótico insesgado del logaritmo de verosimilitud de un modelo, el cual contiene un término para penalizar por el número de parámetros para evitar la sobreparametrización. Es posible interpretar el criterio AIC como un intercambio entre sesgo y varianza y está dado por:

$$AIC = 2k - 2l = 2k + T \ln(\hat{\sigma}_\varepsilon^2 / T),$$

donde l es el logaritmo de verosimilitud, k es el número de parámetros en el modelo y $\hat{\sigma}_\varepsilon^2 = \frac{1}{T} \sum_{t=1}^T \varepsilon_t^2$ es la estimación de la varianza del término de error en el modelo.

En términos formales, dejemos que M sea el conjunto de modelos de pronóstico, entonces la diferencia entre el criterio AIC de un par de modelos es un estimador insesgado de la diferencia de la distancia AIC para los dos modelos. La distancia AIC, llamada así debido a Kullback y Leibler (1951), se define como:

$$I(f, g) = \int f(x) \log \left(\frac{f(x)}{g(x/\hat{\theta})} \right) dx,$$

donde $f(x)$ es el proceso de generación de datos desconocido, $g(x/\hat{\theta})$ es el modelo dado y $\hat{\theta}$ es la estimación de los parámetros en $g(x/\hat{\theta})$.

Los K modelos en el conjunto M están jerarquizados de acuerdo con la distancia AIC. Por lo tanto, $\exp(-1/2\psi_i)$, con $\psi_i = AIC_i - \min_j AIC_j$, puede interpretarse como la ponderación del modelo i que será el mejor modelo AIC dado el hecho de que existe cierto modelo en el conjunto M que es el mejor modelo AIC que representa los datos disponibles. De ese modo, la ponderación final óptima del modelo i en el conjunto M está dada por:

$$\omega_i = \frac{\exp(-1/2\psi_i)}{\sum_{j=1}^N \exp(-1/2\psi_j)}, \text{ tal que } \sum_{i=1}^K \omega_i = 1.$$

Kapetanios *et al.* (2007) sugirieron una ampliación de este enfoque utilizando la suma de errores cuadráticos de pronóstico fuera de muestra en lugar de la suma de residuos cuadráticos dentro de la muestra, para construir el criterio AIC con el objeto de obtener las ponderaciones para combinar o promediar los modelos. Esto implica diferentes ponderaciones para cada horizonte de pronóstico. Los autores utilizaron algunos ejercicios de Monte Carlo y encontraron que los pronósticos combinados obtenidos utilizando errores fuera de muestra funcionaron tan bien o mejor que el AIC basado en errores dentro de la muestra. La idea es reemplazar $\hat{\sigma}_\varepsilon^2 = \frac{1}{T_0} \sum_{t=1}^{T_0} \varepsilon_t^2$ por

$$\sigma_\varepsilon^2 = \frac{1}{T} \sum_{t=T_0+1}^T (y_t - \hat{y}_t)^2, \text{ donde } T = T_0 + T_1 \text{ es el tamaño completo}$$

de la muestra, T_0 es el tamaño dentro de la muestra y T_1 es el tamaño fuera de muestra y \hat{y}_t es el pronóstico para el periodo t , para construir el criterio AIC para cada modelo. De esta manera cuando se asigna la ponderación correspondiente a cada modelo, se le atribuye mayor importancia a la capacidad de pronóstico del modelo que al ajuste dentro de la muestra de ese modelo particular.

El pronóstico combinado está dado por:

$$\hat{Y}_{T+h|T} = \omega_1 f_{T+h|T}^1 + \omega_2 f_{T+h|T}^2 + \dots + \omega_K f_{T+h|T}^K.$$

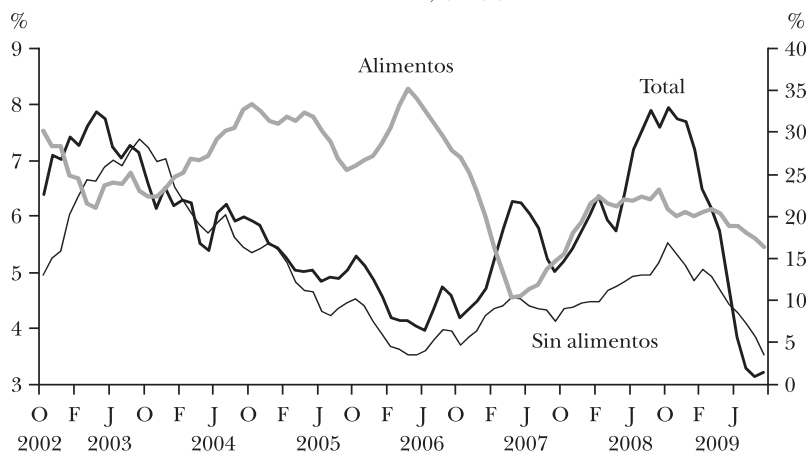
III. DATOS

El ejercicio se realizó para tres conjuntos agregados de la inflación del índice de precios al consumidor (IPC): inflación del IPC *total*, *sin alimentos* y *de alimentos*. Para el periodo analizado los tres agregados de inflación son altamente volátiles.

El conjunto de pronósticos individuales para combinar incluye pronósticos obtenidos de diferentes modelos y metodologías de estimación, que van desde los ARIMA hasta

especificaciones no lineales tales como el modelo de regresión con transición suavizada (RTS) y redes neurales incluyendo agregaciones de pronósticos de algunos componentes de la canasta del IPC. Para el ejercicio de combinación utilizamos una muestra de 81 pronósticos⁵ fuera de muestra de octubre del 2002 a septiembre del 2009 para cada uno de los pronósticos individuales.

GRÁFICA I. INFLACIÓN ANUAL DEL IPC, 2002-2009



Para la inflación total del IPC, se consideraron nueve modelos de pronóstico individual. Los modelos son:

- i) ARIMA.
- ii) Agregado de pronósticos de ARIMA para cuatro componentes de inflación: alimentos, vivienda, vestido y otros bienes y servicios (ARIMAG).
- iii) Agregado de pronósticos con MCO de seis componentes de inflación de alimentos, vivienda, vestido y otros (G6).
- iv) Agregado de pronósticos con MCO de diez componentes de inflación de alimentos, vivienda, vestido y otros (G10).
- v) Regresión con transición suavizada (RTS).

⁵ Los pronósticos fuera de muestra son pronósticos para los siguientes nueve meses obtenidos en cada periodo de tiempo con información disponible en ese momento.

- vi*) No paramétrico (NOPAR).
- vii*) Criterios del personal (ARTESANAL).
- viii*) Red neural (NN).
- ix*) Agregado de pronósticos de red neural para tres componentes de inflación: bienes transables, bienes no transables y bienes y servicios administrados (NNC).

Para la combinación de inflación de alimentos se consideraron seis pronósticos individuales. Los cuales son:

- i*) ARIMAX.
- ii*) Agregado de pronósticos MCO de seis componentes de inflación de alimentos: carne de res, leche, papas, frutas, vegetales y otros (G6).
- iii*) Agregado de pronósticos MCO de seis componentes de inflación de alimentos: y huevos, productos lácteos, aceites comestibles, papas, alimentos fuera de casa, cereales, tubérculos, vegetales, fruta y alimentos procesados (G10).
- iv*) Agregado de pronósticos MCO de tres componentes de inflación de alimentos: alimentos perecederos, alimentos procesados y alimentos fuera de casa (G3).
- v*) Red neural.
- vi*) Diferencia ponderada del pronóstico promedio para la inflación total y la inflación sin alimentos (*naïve*).⁶

Para la combinación de inflación sin alimentos se consideraron cinco pronósticos individuales. Los cuales son:

- i*) ARIMA.
- ii*) Agregado de pronósticos ARIMA para tres componentes de inflación: vivienda, vestido y otros bienes y servicios (ARIMAG).
- iii*) Agregado de pronósticos para tres componentes de inflación: bienes transables, bienes no transables, bienes y servicios administrados; con la metodología de estimación de mínimos cuadrados flexibles (G3),

⁶ Ver Gómez *et al.* (2006) para una descripción detallada de los modelos.

iv) Red neural.

v) Criterios del personal (*staff*).

IV. RESULTADOS EMPÍRICOS

El cuadro 1 muestra la variabilidad explicada por los dos componentes principales para cada uno de los agregados de inflación del IPC en Colombia. Para el caso de la inflación total del IPC, la variabilidad explicada por el primer componente principal es al menos 68%, mientras que el segundo CP sólo explica 13%. Para la información del IPC sin alimentos, la

CUADRO 1. VARIACIÓN EXPLICADA PARA CADA COMPONENTE PRINCIPAL

| <i>Horizonte</i> | <i>PC1</i> | <i>PC2</i> |
|--|------------|------------|
| Inflación total de IPC | | |
| 1 | 0.93 | 0.05 |
| 2 | 0.89 | 0.04 |
| 3 | 0.85 | 0.05 |
| 4 | 0.82 | 0.06 |
| 5 | 0.79 | 0.08 |
| 6 | 0.76 | 0.10 |
| 7 | 0.71 | 0.13 |
| 8 | 0.69 | 0.12 |
| 9 | 0.68 | 0.09 |
| Inflación sin alimentos del IPC | | |
| 1 | 0.96 | 0.02 |
| 2 | 0.90 | 0.06 |
| 3 | 0.80 | 0.12 |
| 4 | 0.72 | 0.15 |
| 5 | 0.63 | 0.21 |
| 6 | 0.58 | 0.22 |
| 7 | 0.57 | 0.23 |
| 8 | 0.62 | 0.19 |
| 9 | 0.66 | 0.17 |
| Inflación de alimentos del IPC | | |
| 1 | 0.97 | 0.02 |
| 2 | 0.93 | 0.04 |
| 3 | 0.88 | 0.07 |
| 4 | 0.85 | 0.10 |
| 5 | 0.84 | 0.10 |
| 6 | 0.84 | 0.10 |
| 7 | 0.85 | 0.09 |
| 8 | 0.83 | 0.09 |
| 9 | 0.79 | 0.08 |

variación explicada por el primer CP es al menos 57% menos que en el caso de inflación total y el segundo CP explica a lo sumo 23%. Para la inflación del IPC de alimentos, el primer componente principal explica más de 80% para todos los horizontes mientras que el segundo CP explica a lo sumo 10% de la variabilidad asociada a los pronósticos individuales de la inflación de alimentos. De estos resultados decidimos trabajar únicamente con el primer componente principal. De manera que el pronóstico combinado tiene la forma: $\hat{Y}_t = a + b * CP_{it}$.

Con el objeto de obtener el componente principal de cada periodo de tiempo, utilizamos una muestra móvil que constaba de los últimos tres años de información, de manera que se tomara en cuenta alguna dinámica.

Por otra parte, para producir los pronósticos ITMA, se construyeron las ponderaciones utilizando los errores de pronóstico de los 30 periodos previos para cada uno de los horizontes. Por ejemplo, el promedio de pronósticos para enero del 2006 utiliza ponderaciones basadas en los errores de pronóstico de enero del 2003 a diciembre del 2005 y así sucesivamente.

El cuadro 2 muestra las ponderaciones de cada modelo de pronóstico para algunos horizontes y para diferentes periodos de tiempo de manera que se pueda notar cómo han cambiado con el tiempo de acuerdo con la precisión histórica de pronóstico de cada modelo.

Para comparar la capacidad predictiva del pronóstico individual y el desempeño de los pronósticos combinados (promedio simple como benchmark, combinación basada en regresión -CME-, componentes principales -CP- y el promedio de modelos basado en criterios de información -ITMA-) nosotros evaluamos los pronósticos para horizontes de uno a nueve meses, de los últimos 41 periodos (de enero del 2006 a mayo del 2009) con la raíz del error cuadrático medio (RECM) de pronóstico como una medida de desempeño del pronóstico.

El cuadro 3 muestra la RECM para cada pronóstico individual y los cuatro pronósticos combinados para todos los horizontes considerados. El panel superior muestra los resultados de inflación total del IPC. Cuando se comparan los pronósticos individuales parece que el pronóstico por consenso del personal funcionó mejor que los otros pronósticos en términos

de un RECM menor, sin embargo para horizontes más largos (cinco meses de adelanto y más) el modelo de red neural genera pronósticos más precisos. Con respecto a los pronósticos combinados parece ser que, para el corto plazo, el pronóstico combinado con base en la regresión funciona mejor mientras que para horizontes de más de dos meses la combinación con la RECM más pequeña es la que se obtuvo por componentes principales. Por otra parte, aunque para algunos horizontes ningún pronóstico combinado produce una RECM menor que el mejor pronóstico individual (uno y dos periodos adelante), parece que existe una ganancia significativa en la precisión del pronóstico si se usa la combinación de pronósticos. Existen reducciones en la RECM de entre 4 y 49 puntos básicos cuando se compara el mejor pronóstico individual y el mejor pronóstico combinado. Cuando se compara sólo el pronóstico combinado resulta que la combinación basada en la regresión funciona mejor que las otras combinaciones para un mes pero, para horizontes de más de dos meses el enfoque de componentes principales produce pronósticos más precisos. En lo que respecta a la combinación ITMA, ésta no reduce la RECM relativa al promedio simple, sin embargo, aún produce pronósticos más precisos que algunos de los pronósticos individuales.

A la mitad del panel del cuadro 3, mostramos los resultados de inflación sin alimentos. En este caso el consenso del personal (*staff*) supera todos los otros pronósticos individuales para todos los horizontes (excepto para nueve meses). Con respecto a los pronósticos combinados, los CP producen una RECM menor para la mayoría de los horizontes (excepto para un mes). No obstante, en este caso no se observa una reducción de la RECM relativa al mejor pronóstico individual, excepto para ocho y nueve meses adelante. La combinación ITMA se desempeña mejor que el promedio simple sólo para horizontes de más de seis meses. Sólo produce una reducción en la RECM cuando se compara con los modelos ARIMA.

En el panel inferior del cuadro 3, los resultados para la inflación de alimentos muestran que el error de pronóstico es alto incluso para pronósticos de un periodo adelante (88 puntos básicos en promedio para todos los pronósticos individuales para el horizonte uno) y para más horizontes la RECM

CUADRO 3. EVALUACIÓN DEL PRONÓSTICO: RAÍZ DEL ERROR CUADRÁTICO MEDIO (RECM), PERIODO DE PRONÓSTICOS FUERA DE MUESTRA: DE ENERO DEL 2006 A MAYO DEL 2009

| <i>Modelo</i> | <i>1</i> | <i>2</i> | <i>3</i> | <i>4</i> | <i>5</i> | <i>6</i> | <i>7</i> | <i>8</i> | <i>9</i> | |
|---------------|--------------|--------------|--------------|--|--------------|--------------|--------------|--------------|--------------------|--|
| | | | | Inflación total del IPC | | | | | | |
| ARIMA | 0.318 | 0.613 | 0.937 | 1.247 | 1.534 | 1.794 | 2.348 | 2.713 | 3.136 | |
| ARIMA_Gr | 0.391 | 0.675 | 0.967 | 1.239 | 1.510 | 1.750 | 2.433 | 2.762 | 3.089 | |
| Staff | <i>0.225</i> | <i>0.459</i> | <i>0.716</i> | <i>0.909</i> | 1.100 | 1.288 | 1.860 | 2.083 | 2.290 | |
| G6 | 0.527 | 0.772 | 1.161 | 1.539 | 1.881 | 2.196 | 2.723 | 3.067 | 3.365 | |
| G10 | 0.394 | 0.694 | 1.061 | 1.425 | 1.764 | 2.102 | 2.495 | 2.882 | 3.253 | |
| STR | 0.368 | 0.671 | 0.956 | 1.228 | 1.454 | 1.673 | 2.193 | 2.469 | 2.787 | |
| Non Param | 0.378 | 0.668 | 0.902 | 1.119 | 1.284 | 1.411 | 1.757 | 1.891 | 2.079 | |
| NN | 0.315 | 0.597 | 0.778 | 0.932 | <i>1.078</i> | <i>1.177</i> | <i>1.425</i> | <i>1.624</i> | <i>1.811</i> | |
| NN_comp. | 0.287 | 0.528 | 0.787 | 0.993 | 1.169 | 1.261 | 1.661 | 1.829 | 2.042 | |
| Simple_Ave | 0.273 | 0.531 | 0.796 | 1.044 | 1.273 | 1.481 | 1.961 | 2.229 | 2.504 | |
| PC | 0.335 | <i>0.500</i> | 0.672 | 0.807 | 0.921 | 0.957 | 1.210 | 1.299 | 1.326 ^a | |
| Regr_comb | <i>0.227</i> | 0.515 | 0.825 | 1.035 | 1.145 | 1.295 | 1.657 | 2.218 | 2.304 | |
| ITMA | 0.512 | 0.759 | 1.005 | 1.245 | 1.469 | 1.670 | 2.017 | 2.256 | 2.460 | |
| | | | | Inflación sin alimentos del IPC | | | | | | |
| ARIMA | 0.176 | 0.313 | 0.446 | 0.589 | 0.759 | 0.949 | 1.165 | 1.376 | 1.606 | |
| ARIMA_Gr | 0.193 | 0.343 | 0.497 | 0.642 | 0.806 | 0.984 | 1.232 | 1.447 | 1.665 | |

| | | | | | | | | | |
|---------------------------------------|-------|-------|--------------------|-------|--------------------|-------|-------|--------------------|--------------------|
| Staff | 0.130 | 0.208 | 0.260 | 0.278 | 0.309 | 0.342 | 0.451 | 0.522 | 1.384 |
| NN | 0.158 | 0.268 | 0.326 | 0.365 | 0.416 | 0.462 | 0.573 | 0.622 | 0.695 |
| G3 | 0.145 | 0.227 | 0.303 | 0.301 | 0.343 | 0.432 | 0.541 | 0.557 | 0.644 |
| Simple_Ave | 0.141 | 0.239 | 0.317 | 0.373 | 0.457 | 0.559 | 0.748 | 0.858 | 1.056 |
| PC | 0.144 | 0.239 | 0.297 | 0.309 | 0.349 | 0.382 | 0.507 | 0.458 ^a | 0.494 |
| Regr_comb | 0.140 | 0.251 | 0.327 | 0.383 | 0.465 | 0.478 | 0.578 | 0.655 | 0.757 |
| ITMA | 0.210 | 0.287 | 0.340 | 0.399 | 0.474 | 0.560 | 0.696 | 0.808 | 0.928 |
| Inflación de alimentos del IPC | | | | | | | | | |
| ARIMAX | 0.941 | 1.776 | 2.557 | 3.099 | 3.486 | 3.690 | 5.313 | 6.012 | 6.633 |
| NN | 0.832 | 1.591 | 2.284 | 2.750 | 2.997 | 3.168 | 4.204 | 4.814 | 5.386 |
| Naïve | 0.867 | 1.576 | 2.257 | 2.815 | 3.244 | 3.566 | 4.753 | 5.436 | 6.119 |
| G6 | 0.666 | 1.566 | 2.508 | 3.281 | 3.895 | 4.436 | 5.463 | 6.161 | 6.765 |
| G10 | 0.645 | 1.471 | 2.351 | 3.121 | 3.723 | 4.257 | 5.077 | 5.863 | 6.560 |
| G3 | 1.017 | 1.823 | 2.485 | 2.925 | 3.035 | 3.137 | 3.710 | 4.365 | 4.951 |
| Simple_Ave | 0.730 | 1.459 | 2.165 | 2.704 | 3.076 | 3.382 | 4.423 | 5.190 | 5.795 |
| PC | 1.137 | 1.561 | 2.051 | 2.335 | 2.497 ^a | 2.485 | 3.035 | 3.032 ^a | 3.064 ^a |
| Regr_comb | 0.609 | 1.294 | 1.928 ^a | 2.544 | 3.004 | 3.211 | 4.373 | 4.304 | 4.746 |
| ITMA | 1.338 | 1.964 | 2.651 | 2.893 | 3.257 | 3.556 | 4.749 | 5.443 | 5.897 |

NOTAS: En negrita: el mejor pronóstico para el horizonte de la columna (Panel superior: pronóstico individual, Panel inferior: pronósticos combinados). En cursiva: min(RMSE) de los pronósticos combinados < min(RMSE) de los pronósticos individuales.

^a Reducción significativa en el RMSE relativo al min(RMSE) de los pronósticos individuales ts, según la prueba MDM.

es en promedio mucho mayor a 100 puntos básicos; esto sugiere que el IPC de alimentos es más difícil de pronosticar debido a su alta volatilidad. En el caso de la inflación de alimentos parece que el G10, para corto plazo, y el G3, para mediano plazo, funcionan mejor que los otros pronósticos individuales para la mayoría de los horizontes. La combinación basada en regresión produce la RECM más pequeña para horizontes de corto plazo y los componentes principales funcionan bien para el mediano plazo (más de tres meses). Vale la pena mencionar que la ganancia de la combinación de pronósticos es significativa para todos los horizontes. Existen reducciones en la RECM de entre cuatro y 189 puntos básicos con una reducción promedio de 67 puntos.

Se utilizó la prueba modificada de Diebold y Mariano (MDM) para igual precisión de pronóstico⁷ para verificar si existe una combinación particular que reduzca significativamente la RECM en comparación con el mejor pronóstico individual para cada horizonte. Es necesario tomar tales resultados con cautela dado que esta prueba se aplica a modelos no anidados o de inclusión y los resultados de la prueba de Harvey, Leybourne y Newbold de inclusión sugieren que el pronóstico de CP abarca toda la información predictiva relevante de todos los otros pronósticos⁸ para horizontes mayores que un mes. Este último resultado no es sorprendente debido al método de construcción del pronóstico de CP, puesto que consiste en el componente común de todos los pronósticos individuales. Los resultados de esta prueba están disponibles mediante solicitud. Los casos en los que se rechaza la hipótesis nula de ECM igual y en que el ECM es menor al ECM del pronóstico del *benchmark* se señalan con la letra a en el cuadro 3. Sólo en algunos casos, la mejor combinación genera una reducción significativa de la RECM relativa al mejor pronóstico individual. La mayoría de estos casos se observa para pronósticos de inflación de alimentos.

Debido al pequeño tamaño fuera de muestra disponible

⁷ Harvey, Leybourne y Newbold (1997).

⁸ La prueba de hipótesis nula de Harvey, Leybourne y Newbold para inclusión de grupos de dos modelos de pronóstico no es rechazado para todos los pares de pronósticos que consideran el pronóstico de CP a 5% de significancia.

para la evaluación de los pronósticos, se realizó un ejercicio *bootstrap* con el objeto de obtener resultados más robustos para probar la precisión de los pronósticos combinados. El ejercicio consistió en obtener 500 muestras de los errores de pronóstico (de los pronósticos individuales y los pronósticos combinados). Dado que para la mayoría de horizontes los errores de pronóstico están autocorrelacionados, se estimó un modelo AR para la serie de errores de pronóstico $e_{t+h/t} = \varphi_0 + \varphi_1 e_{t+h-1/t} + v_{t+h}$; $v_{t+h} \sim N(0, \sigma_v^2)$.⁹ De esa manera se realizó el bootstrapping sobre los residuos, v_{t+h} . Con la muestra de los residuos y las estimaciones de los parámetros se construyó la serie de muestra de los errores de pronóstico $e_{t+h/t}^i = \hat{\varphi}_0 + \hat{\varphi}_1 e_{t+h-1/t}^i + v_{t+h}^i$; $i = 1, \dots, 500$. El tamaño de muestra iguala al número de pronóstico fuera de muestra disponible para cada horizonte.

Para cada muestra, se calculó la RECM relativa a la RECM del pronóstico individual con el menor RECM. Por tanto, si la proporción de muestras para las que la RECM relativa es menor que, digamos 0.95, es grande, entonces el pronóstico combinado reduce de forma significativa la RECM relativa al mejor pronóstico individual, lo que significa que la combinación ayuda a reducir el error de pronóstico.

Los resultados del ejercicio de bootstrapping se presentan en el cuadro 4. Las celdas sombreadas indican para cuáles casos la RECM relativa es menor a 0.95. Por otro lado, las casillas en cursiva son aquellas para las cuales al menos 90% de las muestras de bootstrapping tienen una RECM relativa menor a 0.95. Vale la pena mencionar que, en el caso de inflación total, las combinaciones de pronóstico no reducen de forma significativa la RECM relativa del mejor pronóstico individual para la mayoría de horizontes, excepto los de ocho y nueve meses. La misma situación ocurre en el caso de la inflación de alimentos. Por otro lado, para el caso de inflación de alimentos los resultados son más prometedores. La combinación de CP en efecto produce una reducción de al menos 5% en la RECM en comparación con el mejor pronóstico

⁹ Debido a la pequeña muestra disponible de los errores de pronóstico para horizontes de 7, 8 y 9 meses, se estimó un AR(1) para todos los horizontes. El prueba de no correlación de los residuales no es rechazado a 1% y están disponibles por pedido.

CUADRO 4. RMSE RELATIVO DE ERRORES DE PRONÓSTICO DE BOOSTRAPPING, PERIODO DE PRONÓSTICOS FUERA DE MUESTRA, DE ENERO DE 2006 A MAYO DE 2009

| Modelo | Horizonte de pronóstico | | | | | | | | | | | | | | | | | |
|------------|-------------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|------|------|------|------|------|------|------|------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | | | | | | | | | |
| | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | Rel_RMSEE % | | | | | | | | |
| ARIMA | 1.42 | 0.00 | 1.34 | 0.01 | 1.31 | 0.02 | 1.37 | 0.00 | 1.42 | 0.00 | 1.52 | 0.00 | 1.65 | 0.00 | 1.67 | 0.00 | 1.73 | 0.00 |
| ARIMA_Gr | 1.74 | 0.00 | 1.47 | 0.01 | 1.35 | 0.02 | 1.36 | 0.01 | 1.40 | 0.00 | 1.49 | 0.00 | 1.71 | 0.00 | 1.70 | 0.00 | 1.71 | 0.00 |
| Staff | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.02 | 0.33 | 1.09 | 0.14 | 1.31 | 0.01 | 1.28 | 0.02 | 1.27 | 0.03 |
| G6 | 2.34 | 0.00 | 1.68 | 0.00 | 1.62 | 0.00 | 1.69 | 0.00 | 1.75 | 0.00 | 1.87 | 0.00 | 1.91 | 0.00 | 1.89 | 0.00 | 1.86 | 0.00 |
| G10 | 1.75 | 0.00 | 1.51 | 0.00 | 1.48 | 0.00 | 1.57 | 0.00 | 1.64 | 0.00 | 1.79 | 0.00 | 1.75 | 0.00 | 1.77 | 0.00 | 1.80 | 0.00 |
| Nonlinear | 1.64 | 0.00 | 1.46 | 0.00 | 1.33 | 0.01 | 1.35 | 0.01 | 1.35 | 0.00 | 1.42 | 0.00 | 1.54 | 0.00 | 1.52 | 0.00 | 1.54 | 0.00 |
| Non Param | 1.68 | 0.00 | 1.46 | 0.00 | 1.26 | 0.05 | 1.23 | 0.03 | 1.19 | 0.04 | 1.20 | 0.03 | 1.23 | 0.02 | 1.16 | 0.08 | 1.15 | 0.09 |
| NN | 1.40 | 0.01 | 1.30 | 0.02 | 1.09 | 0.24 | 1.03 | 0.30 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 |
| NN_comp. | 1.28 | 0.03 | 1.15 | 0.14 | 1.10 | 0.20 | 1.09 | 0.19 | 1.09 | 0.17 | 1.07 | 0.19 | 1.17 | 0.08 | 1.13 | 0.12 | 1.13 | 0.12 |
| Simple_Ave | 1.22 | 0.05 | 1.16 | 0.10 | 1.11 | 0.17 | 1.15 | 0.09 | 1.18 | 0.02 | 1.26 | 0.02 | 1.38 | 0.01 | 1.37 | 0.01 | 1.38 | 0.00 |
| PC | 1.49 | 0.03 | 1.09 | 0.14 | 0.94 | 0.54 | 0.89 | 0.67 | 0.85 | 0.78 | 0.81 | 0.87 | 0.85 | 0.79 | 0.80 | 0.88 | 0.73 | 0.93 |
| Regr_comb | 1.01 | 0.33 | 1.12 | 0.07 | 1.15 | 0.11 | 1.14 | 0.10 | 1.06 | 0.15 | 1.10 | 0.17 | 1.16 | 0.13 | 1.37 | 0.01 | 1.27 | 0.01 |
| ITMA | 2.28 | 0.00 | 1.66 | 0.00 | 1.40 | 0.00 | 1.37 | 0.00 | 1.36 | 0.00 | 1.42 | 0.00 | 1.42 | 0.01 | 1.39 | 0.01 | 1.36 | 0.01 |

Inflación total del IPC

| Inflación sin alimentos del IPC | | | | | | | | | | | | | | | | | | |
|---------------------------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|
| ARIMA | 1.36 | 0.01 | 1.50 | 0.00 | 1.71 | 0.00 | 2.12 | 0.00 | 2.46 | 0.00 | 2.77 | 0.00 | 2.58 | 0.00 | 2.64 | 0.00 | 2.49 | 0.00 |
| ARIMA_Gr | 1.49 | 0.00 | 1.65 | 0.00 | 1.91 | 0.00 | 2.31 | 0.00 | 2.61 | 0.00 | 2.87 | 0.00 | 2.73 | 0.00 | 2.77 | 0.00 | 2.59 | 0.00 |
| Staff | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 1.00 | 0.00 | 2.15 | 0.17 |
| NN | 1.22 | 0.07 | 1.29 | 0.01 | 1.25 | 0.00 | 1.31 | 0.01 | 1.35 | 0.01 | 1.35 | 0.00 | 1.27 | 0.03 | 1.19 | 0.07 | 1.08 | 0.21 |
| G3 | 1.12 | 0.21 | 1.09 | 0.13 | 1.16 | 0.12 | 1.08 | 0.14 | 1.11 | 0.15 | 1.26 | 0.03 | 1.20 | 0.08 | 1.07 | 0.30 | 1.00 | 0.00 |
| Simple_Ave | 1.09 | 0.21 | 1.15 | 0.05 | 1.22 | 0.03 | 1.34 | 0.00 | 1.48 | 0.00 | 1.63 | 0.00 | 1.66 | 0.00 | 1.65 | 0.00 | 1.64 | 0.00 |
| PC | 1.11 | 0.19 | 1.15 | 0.11 | 1.14 | 0.11 | 1.11 | 0.15 | 1.13 | 0.11 | 1.12 | 0.14 | 1.12 | 0.22 | 0.88 | 0.71 | 0.77 | 0.92 |
| Regr_comb | 1.08 | 0.24 | 1.20 | 0.02 | 1.25 | 0.07 | 1.38 | 0.00 | 1.51 | 0.00 | 1.40 | 0.00 | 1.28 | 0.04 | 1.26 | 0.03 | 1.18 | 0.06 |
| ITMA | 1.62 | 0.00 | 1.38 | 0.00 | 1.31 | 0.00 | 1.44 | 0.00 | 1.54 | 0.00 | 1.64 | 0.00 | 1.54 | 0.00 | 1.55 | 0.00 | 1.44 | 0.00 |
| Inflación de alimentos del IPC | | | | | | | | | | | | | | | | | | |
| ARIMAX | 1.46 | 0.01 | 1.21 | 0.08 | 1.13 | 0.17 | 1.13 | 0.20 | 1.16 | 0.12 | 1.18 | 0.07 | 1.43 | 0.01 | 1.38 | 0.01 | 1.34 | 0.02 |
| NN | 1.29 | 0.05 | 1.08 | 0.24 | 1.01 | 0.37 | 1.00 | n.a. | 1.00 | n.a. | 1.01 | 0.34 | 1.13 | 0.07 | 1.10 | 0.15 | 1.09 | 0.13 |
| Naïve | 1.34 | 0.01 | 1.07 | 0.23 | 1.00 | 0.00 | 1.02 | 0.29 | 1.08 | 0.21 | 1.14 | 0.07 | 1.28 | 0.01 | 1.25 | 0.04 | 1.24 | 0.05 |
| G6 | 1.03 | 0.27 | 1.06 | 0.24 | 1.11 | 0.15 | 1.19 | 0.05 | 1.30 | 0.01 | 1.41 | 0.00 | 1.47 | 0.00 | 1.41 | 0.00 | 1.37 | 0.00 |
| G10 | 1.00 | n.a. | 1.00 | n.a. | 1.04 | 0.27 | 1.14 | 0.12 | 1.24 | 0.01 | 1.36 | 0.00 | 1.37 | 0.00 | 1.34 | 0.00 | 1.33 | 0.00 |
| G3 | 1.58 | 0.01 | 1.24 | 0.05 | 1.10 | 0.17 | 1.06 | 0.26 | 1.01 | 0.34 | 1.00 | n.a. | 1.00 | n.a. | 1.00 | n.a. | 1.00 | n.a. |
| Simple_Ave | 1.13 | 0.11 | 0.99 | 0.41 | 0.96 | 0.47 | 0.98 | 0.38 | 1.03 | 0.32 | 1.08 | 0.14 | 1.19 | 0.07 | 1.19 | 0.07 | 1.17 | 0.07 |
| PC | 1.76 | 0.00 | 1.06 | 0.26 | 0.91 | 0.63 | 0.85 | 0.78 | 0.83 | 0.80 | 0.79 | 0.92 | 0.82 | 0.83 | 0.70 | 0.98 | 0.62 | 0.98 |
| Regr_comb | 0.94 | 0.48 | 0.88 | 0.66 | 0.85 | 0.76 | 0.93 | 0.57 | 1.00 | 0.36 | 1.02 | 0.29 | 1.18 | 0.07 | 0.99 | 0.44 | 0.96 | 0.44 |
| ITMA | 2.07 | 0.00 | 1.34 | 0.01 | 1.18 | 0.09 | 1.05 | 0.24 | 1.09 | 0.16 | 1.13 | 0.06 | 1.28 | 0.06 | 1.25 | 0.05 | 1.19 | 0.10 |

NOTA: La columna de % contiene la proporción de muestras de bootstrapping para las cuales el RMSE es 0.95 a lo sumo.

individual para algunos horizontes (seis, ocho y nueve meses).

V. COMENTARIOS FINALES

El desempeño de los pronósticos combinados tanto económicos como estadísticos fue mejor que la mayoría de pronósticos individuales, especialmente para horizontes de mediano plazo. Parece ser que la combinación basada en regresión funcionó mejor que las otras metodologías estadísticas de combinación de pronósticos especialmente para el muy corto plazo. La combinación de pronósticos de componentes principales superó la combinación basada en regresión de todos los agregados de inflación de IPC considerados en el presente estudio para horizontes de mediano plazo. En el caso de inflación total e inflación de alimentos, existe en la RECM una reducción significativa de los pronósticos combinados comparada con los pronósticos individuales; en el caso de inflación sin alimentos los resultados son menos prometedores. La mejor combinación casi nunca superó los pronósticos de consenso del personal.

Por otro lado, aunque el método de promedio de modelos basado en criterios de información genera en promedio errores de pronóstico menores que algunos de los pronósticos individuales, este método no funcionó mejor que los otros pronósticos de combinación y difícilmente iguala las ponderaciones o el método de ponderación simple. El ITMA tiene la ventaja de facilidad de implementación y flexibilidad puesto que permite construir las ponderaciones con criterios de información diferente y aún así brinda una alternativa para reducir el error de pronóstico relativo a algunos pronósticos individuales.

En general se produce una reducción en el error de pronóstico por el pronóstico combinado especialmente para mediano a largo plazo. Es bueno utilizar metodologías económicas y estadísticas de combinación de pronósticos porque ellas significativamente generan mejores resultados que promediar los modelos individuales utilizando ponderaciones iguales. Este resultado es alentador y abre una interesante ventana de investigación para mayores mejoras en las metodologías de pronóstico.

En futuras investigaciones se considerará una combinación de pronósticos con más factores comunes o componentes principales teniendo en cuenta que, aunque el primer componente principal explica la mayoría de la variabilidad de los pronósticos individuales, el siguiente componente puede aportar alguna información crucial. Para continuar en la línea de la combinación de pronósticos otra idea es la implementación del promedio del modelo bayesiano y el uso de otros criterios de información para promedio de modelos tales como criterios de Schwartz y Mallows (BIC) para construir las ponderaciones de los modelos de pronóstico a ponderar.

REFERENCIAS

- Bernanke, B., y J. Boivin (2003), "Monetary Policy in a Data-Rich Environment", *Journal of Monetary Economics*, vol. 50, n° 3.
- Clement, R. T. (1989), "Combining Forecasts: A Review and an Annotated Bibliography", *International Journal of Forecasting*, vol. 5, pp. 559-83.
- Coulson, N., y R. Robins.1993. "Forecast Combination in a Dynamic Setting." *Journal of Forecasting*, 12: 63-67.
- Elliott, G., y A. Timmermann (2004), "Optimal Forecast Combinations under General Loss Functions and Forecast Error Distributions", *Journal of Econometrics*, vol. 122, pp. 47-79.
- Fisher, J. D. M. (2000), *Forecasting inflation with a lot of data*, Banco de Reserva Federal de Chicago, marzo (Chicago Fed Letter, n° 151).
- Gómez, M., E. González, L. F. Melo y J. L. Torres (2006), *Forecasting Food Price Inflation in Developing Countries with Inflation Targeting Regimes: the Colombian Case*, Banco de la República (Borradores de Economía, n° 409).
- Hallman, J., y M. Kamstra (1989), "Combining Algorithms Based on Robust Estimation Techniques and Co-integrating Restrictions", *Journal of Forecasting*, vol. 8, pp. 189-98.
- Harvey, D., S. Leybourne y P. Newbold (1998), "Tests for Forecast Encompassing", *Journal of Business and Economic Statistics*, vol. 16, pp. 254-59.

- Kapetanios, G., V. Labhard y S. Price (2007), *Forecast combination and the Bank of England's suite of statistical forecasting models*, Bank of England (Working paper, n° 323).
- Kapetanios, G., V. Labhard y S. Price (2008), "Forecasting using Bayesian and Information theoretic model averaging: an application to UK inflation", *Journal of Business Economics and Statistics*, vol. 26, pp. 33-41.
- Kullback, S., y R. Leibler (1951), "On information and sufficiency", *Annals of Mathematical Statistics*, vol. 22, pp 79-86.
- Melo, L. F., y H. Núñez (2004), *Combinación de pronósticos para la inflación en presencia de cambios estructurales*, Banco de la República (Borradores de Economía, n° 286).
- Melo, L. F., y M. Misas (2004), *Modelos estructurales de inflación en Colombia: estimación a través de mínimos cuadrados flexibles*, Banco de la República (Borradores de Economía, n° 283).
- Stock, J., y M. Watson (2004), *Macroeconomic Forecasting Using Many Predictors*, texto mimeografiado, Universidad de Princeton.

MIEMBROS DEL CEMLA

ASOCIADOS

| | |
|---|--|
| Banco Central de la República Argentina | Banco de Guatemala |
| Centrale Bank van Aruba | Bank of Guyana |
| Central Bank of the Bahamas | Banque de la République d'Haïti |
| Central Bank of Barbados | Banco Central de Honduras |
| Central Bank of Belize | Bank of Jamaica |
| Banco Central de Bolivia | Banco de México |
| Banco Central do Brasil | Bank van de Nederlandse Antillen |
| Eastern Caribbean Central Bank | Banco Central de Nicaragua |
| Cayman Islands Monetary Authority | Banco Central del Paraguay |
| Banco Central de Chile | Banco Central de Reserva del Perú |
| Banco de la República (Colombia) | Banco Central de la República Dominicana |
| Banco Central de Costa Rica | Centrale Bank van Suriname |
| Banco Central de Cuba | Central Bank of Trinidad and Tobago |
| Banco Central del Ecuador | Banco Central del Uruguay |
| Banco Central de Reserva de El Salvador | Banco Central de Venezuela |

COLABORADORES

Bancos centrales

| | |
|---|--------------------------------------|
| Deutsche Bundesbank (Alemania) | Banca d'Italia |
| Bank of Canada | De Nederlandsche Bank (Países Bajos) |
| Banco de España | Bangko Sentral ng Pilipinas |
| Federal Reserve System (Estados Unidos) | Banco de Portugal |
| Banque de France | European Central Bank |

Otras instituciones

| | |
|--|--|
| Superintendencia de Bancos y Seguros (Ecuador) | Superintendencia de Bancos (República Dominicana) |
| Superintendencia del Sistema Financiero (El Salvador) | Banco Centroamericano de Integración Económica |
| Superintendencia de Bancos (Guatemala) | Banco Latinoamericano de Comercio Exterior, S. A. |
| Comisión Nacional de Bancos y Seguros (Honduras) | Deutscher Genossenschafts- und Raiffei- senverband e. V. (Confederación Ale- mana de Cooperativas) |
| Superintendencia de Bancos (Panamá) | Fondo Latinoamericano de Reservas |

CENTRO DE ESTUDIOS MONETARIOS LATINOAMERICANOS

Asociación Regional de Bancos Centrales

www.cemla.org