BANCO CENTRAL DE COSTA RICA

DOCUMENTO DE TRABAJO
N.º 004 | 2016

Pronósticos univariados de inflación para Costa Rica con volatilidad estocástica y efectos GARCH

Mariany Fuentes Fuentes
Adolfo Rodríguez Vargas

Fotografía de portada: “Presentes”, conjunto escultórico en bronce, año 1983, del artista costarricense Fernando Calvo Sánchez. Colección del Banco Central de Costa Rica.

Pronósticos univariados de inflación para Costa Rica con volatilidad estocástica y efectos GARCH

Mariany Fuentes Fuentes*, Adolfo Rodríguez Vargas†

Las ideas expresadas en este documento son de los autores y no necesariamente representan las del Banco Central de Costa Rica.

Resumen

En este trabajo se estiman modelos de pronóstico univariados para la inflación de Costa Rica con el fin de que sean insumo en la formulación de la política monetaria del Banco Central de Costa Rica (BCCR). Se estiman 14 especificaciones que consideran diferentes supuestos sobre la forma funcional y las propiedades estadísticas del proceso generador de datos. Éstas incluyen modelos de componentes no observables y ARMA, con diferentes especificaciones para la ecuación de media y varios supuestos para el comportamiento de la variancia: homocedasticidad, efectos GARCH y volatilidad estocástica. Las propiedades de los pronósticos estimados se evalúan rigurosamente siguiendo las recomendaciones de la literatura sobre pronósticos óptimos, y aquellos con el mejor desempeño se incluyen en una combinación.

Se encuentra que los pronósticos obtenidos a partir de modelos de componentes no observables mostraron el mejor desempeño, y que la inclusión de volatilidad estocástica mejora la capacidad de pronóstico a los horizontes más largos. Para horizontes más cortos, los pronósticos con mejor desempeño son más precisos que los bayesianos actualmente en uso en el BCCR. La combinación calculada supera el desempeño de los pronósticos individuales a todos los horizontes.

Se recomienda que para los horizontes de 6 y 12 meses se utilice la combinación propuesta en conjunto con los pronósticos bayesianos. Para horizontes de 1 y 3 meses, es posible utilizar la combinación o bien los pronósticos UC, que son los que tienden a dominar a estos plazos.

Palabras clave:: Resource allocation, productivity.
Clasificación JEL: E31, E37, C52, C53.

* Departamento de Investigación Económica. fuentesfm@bccr.fi.cr
† Departamento de Investigación Económica. rodriguezva@bccr.fi.cr

Univariate Forecasts for Costa Rican Inflation With Stochastic Volatility and GARCH Effects

Mariany Fuentes Fuentes[‡], Adolfo Rodríguez Vargas[§]

The ideas expressed in this paper are those of the authors and not necessarily represent the view of the Central Bank of Costa Rica.

Abstract

This paper estimates univariate models for forecasting inflation in Costa Rica to be used as an input in the monetary policy formulation of the Central Bank of Costa Rica (BCCR). We estimate 14 specifications that consider several assumptions about the functional form and the statistical properties of the data generating process. We estimate unobserved components models and ARMA models, with different specifications for the conditional mean and several assumptions about the behaviour of the variance: homocedasticity, GARCH effects and stochastic volatility. The forecasting properties of these models were rigorously evaluated following the recommendations in the literature about optimal forecasts, and then the best-performing forecasts were included in a combination.

We found that the forecasts from unobserved components models showed the best performance, and that inclusion of stochastic volatility improved forecasting performance at longer horizons. At shorter horizons, the forecasts with better performance were more precise than the Bayesian forecasts currently used at the BCCR. The combination improves on the performance of individual forecasts at all horizons.

We recommend using the proposed combination along with the Bayesian forecasts, especially at longer horizons: 6 and 12 months. Then, at 1 and 3-month horizon, it is better to use either the combination or the UC forecasts, because these encompass the others at these horizons.

Key words: inflation, forecasting, stochastic volatility, GARCH, combination, evaluation.
JEL codes: E31, E37, C52, C53.

[‡] Department of Economic Research. Email address. fuentesfm@bccr.fi.cr
[§] Department of Economic Research. Email address. rodriguezva@bccr.fi.cr

Contenido

1. Introducción 1
2. Datos y metodología 3
   2.1. Datos utilizados 3
   2.2. Pronósticos ARIMA 4
   2.3. Pronósticos GARCH 4
   2.4. Modelo estructural de series de tiempo 6
   2.5. Modelos con volatilidad estocástica 7
   2.6. Combinación de pronósticos 10
   2.7. Evaluación de los pronósticos 11
3. Resultados 14
   3.1. Especificaciones de los modelos y pronósticos calculados 14
   3.2. Insesgamiento 22
   3.3. Correlación de errores 23
   3.4. Precisión 24
   3.5. Pruebas de inclusión de información 26
   3.6. Variancia de los errores de pronóstico 26
   3.7. Desempeño de combinación de pronósticos 27
   3.8. Robustez de resultados de la evaluación 29
4. Conclusiones 30
5. Referencias 31
6. Anexos 35

Pronósticos univariados de inflación para Costa Rica con volatilidad estocástica y efectos GARCH

1. Introducción

La Ley Orgánica del Banco Central de Costa Rica (BCCR) establece a la autoridad monetaria la responsabilidad de velar por la estabilidad interna de la moneda, entendida como la consecución de una inflación baja y estable. Para un banco central que tiene como objetivo el mantenimiento de un nivel de inflación bajo y estable, la capacidad para tomar oportunamente decisiones de política depende en buena medida de su capacidad técnica para anticipar mediante modelos de pronóstico la evolución de la inflación en el corto y mediano plazo, dado que la política monetaria actúa con rezago sobre la inflación.

La práctica usual en bancos centrales es utilizar un conjunto de modelos de proyección con el fin de reducir el riesgo de introducir sesgos por depender en exceso de un único modelo. Los pronósticos individuales pueden estar articulados en una plataforma de proyección más compleja, como en el caso del Banco de Inglaterra (ver Burguess et al, 2013) o utilizarse en una combinación de proyecciones de inflación (ver Jore, 2012, para Noruega como un caso típico). Por lo general el conjunto de modelos utilizado incluye modelos de carácter estructural, que incorporan teoría económica en su formulación, así como modelos estadísticos más simples.

En el caso del BCCR, en el año 2000 se empezó a utilizar una combinación de pronósticos de inflación que incluía un VAR para modelar el mecanismo de transmisión de la política monetaria, y modelos uniecuacionales para estimar el impacto de precios del petróleo, el efecto traspaso de tipo de cambio a precios, y la presión fiscal sobre precios, así como un modelo ARMA. Una diferencia notoria con los ejercicios de combinación usuales es que se incluía un solo modelo univariable de inflación. La metodología de combinación fue revisada en 2009, pero no se incluyó modelos adicionales[1].

Actualmente los pronósticos de inflación utilizados por el BCCR provienen de un modelo semiestructural neokeynesiano y de modelos bayesianos (*Bayesian Model Averaging y Weighted Average Least Squares*) que permiten sintetizar el contenido informativo de gran cantidad de variables económicas[2]. Sin embargo, el BCCR continúa careciendo de un conjunto de modelos univariados de inflación con distintos supuestos sobre la forma funcional y las propiedades estadísticas del proceso generador de datos. La presente investigación trata de subsanar esta carencia mediante la estimación de diversas especificaciones de modelos univariables de inflación, y la evaluación rigurosa de las propiedades de los pronósticos asociados siguiendo las recomendaciones de la literatura sobre pronósticos óptimos. Además, los pronósticos se combinan para obtener una medición agregada cuyas propiedades superen a las de los pronósticos individuales.

[1] Ver Hoffmaister, Saborío y Solano (2001) y Mora y Rodríguez (2009).

[2] Ver Chavarría y Chaverri (2015) para detalles.

Al modelar la inflación es importante tomar en cuenta que se ha documentado extensivamente cómo la variancia de la inflación no es homocedástica, sino que más bien muestra persistencia y es variable en el tiempo[3]. Por esto, utilizar modelos que tomen en cuenta varianzas no constantes con distribuciones asimétricas o colas pesadas podría mejorar los pronósticos. Una vertiente de la literatura empírica ha optado por modelar la variancia no constante de la inflación mediante modelos GARCH[4]. Tres ejemplos de una amplia literatura son Broto (2008), donde se utiliza modelos Q-STARCH (Quadratic Structural ARCH) para estudiar la dinámica de la inflación en varios países de Latinoamérica y evaluar el impacto de la adopción de metas de inflación; Russell (2014), que aplica un modelo GARCH para modelar la inflación de Estados Unidos y encuentra que si se considera la volatilidad, la participación de la inflación esperada no es tan significativa en la dinámica inflacionaria; y Ramón (2008), que obtiene una mejora en el pronóstico para Filipinas al utilizar este tipo de modelos. Así pues, se considera valioso introducir mediante este trabajo el uso de modelos con efectos GARCH para el pronóstico de la inflación en Costa Rica.

De particular interés para el pronóstico es la relación entre el nivel de la inflación y su volatilidad. Esta asociación fue sugerida inicialmente por Okun (1971) y más notoriamente por Friedman (1977), y fue modelada formalmente por Ball (1990). Desde el punto de vista empírico, Ball y Cechetti (1990) encuentran que el nivel de la inflación tiene un efecto mayor sobre la variancia de choques permanentes en la inflación que sobre la variancia de choques transitorios, lo que es corroborado por Evans (1991). Una contribución empírica importante es Karanasos, Karanassou y Fountas (2004), quienes, en contraste con gran parte de la literatura aplicada, encuentran una relación bidireccional positiva entre la inflación de EE.UU. y su variancia. En el caso de Costa Rica, Solera (2002) encuentra una relación directa entre el nivel y la volatilidad de la inflación, así como una respuesta asimétrica de la medida de incertidumbre a diferencias entre la inflación pronosticada y su nivel vigente. Esto sugiere la utilidad de pronosticar la inflación de Costa Rica mediante modelos GARCH con retroalimentación entre las estimaciones del nivel de la inflación y de su variancia.

Un aporte sustantivo de este estudio para el pronóstico de la inflación en Costa Rica es introducir modelos que consideran la otra vertiente teórica en la modelación de variancia no constante: los modelos con volatilidad estocástica. Esta variante puede adaptarse a distintas especificaciones para la media condicional del proceso, por lo que constituyen una herramienta muy flexible para el pronóstico. Por ejemplo, Chan (2013) muestra que introducir volatilidad estocástica junto con un componente de medias móviles mejora el desempeño del pronóstico de la inflación de EE.UU. en varias formas funcionales para la ecuación de media, particularmente en horizontes de corto plazo. Así mismo, Chan (2015) aplica un modelo de volatilidad estocástica con parámetros cambiantes y encuentra que este modelo puede producir pronósticos más precisos que el modelo estándar de volatilidad estocástica.

---

[3] Contribuciones tempranas incluyen Engle (1982), para el Reino Unido, y Engle (1983) para los EE.UU. Estudios más recientes incluyen Kontonikas (2004) y Conrad y Karanassos (2008).

[4] *Generalized Autoregressive Conditional Heteroskedasticity.*

El resto de este documento se estructura como sigue: la sección 2 expone los detalles de los datos, las metodologías de pronóstico utilizadas y los criterios de evaluación de los pronósticos, en la sección 3 se presentan los resultados de los ejercicios de pronóstico, evaluación y combinación de los pronósticos univariados, y en la sección 4 se resumen los resultados del estudio.

2. Datos y metodología

2.1. Datos utilizados

La serie de inflación utilizada es la variación interanual del Índice de Precios al Consumidor, calculado por el Instituto Nacional de Estadística y Censos, con base junio de 2015, para el periodo enero 2000 a marzo 2016 (195 observaciones). Torres (2012) detecta 4 cambios estructurales en el nivel de la inflación el período 1997 – 2011, el más reciente de los cuales se ubicó alrededor de mayo de 2009. Por esta razón se aplicó las pruebas de raíz unitaria con un cambio estructural de Zivot y Andrews (1992) y con dos y cuatro cambios estructurales de Lee y Strazicich (2003), y en todos los casos se puede rechazar la nula de raíz unitaria, por lo que se prosigue bajo el supuesto de que la serie de inflación es estacionaria (ver cuadro 10 del anexo)

Gráfico 1. Costa Rica: Tasa de inflación interanual. Enero 2000 - marzo 2016

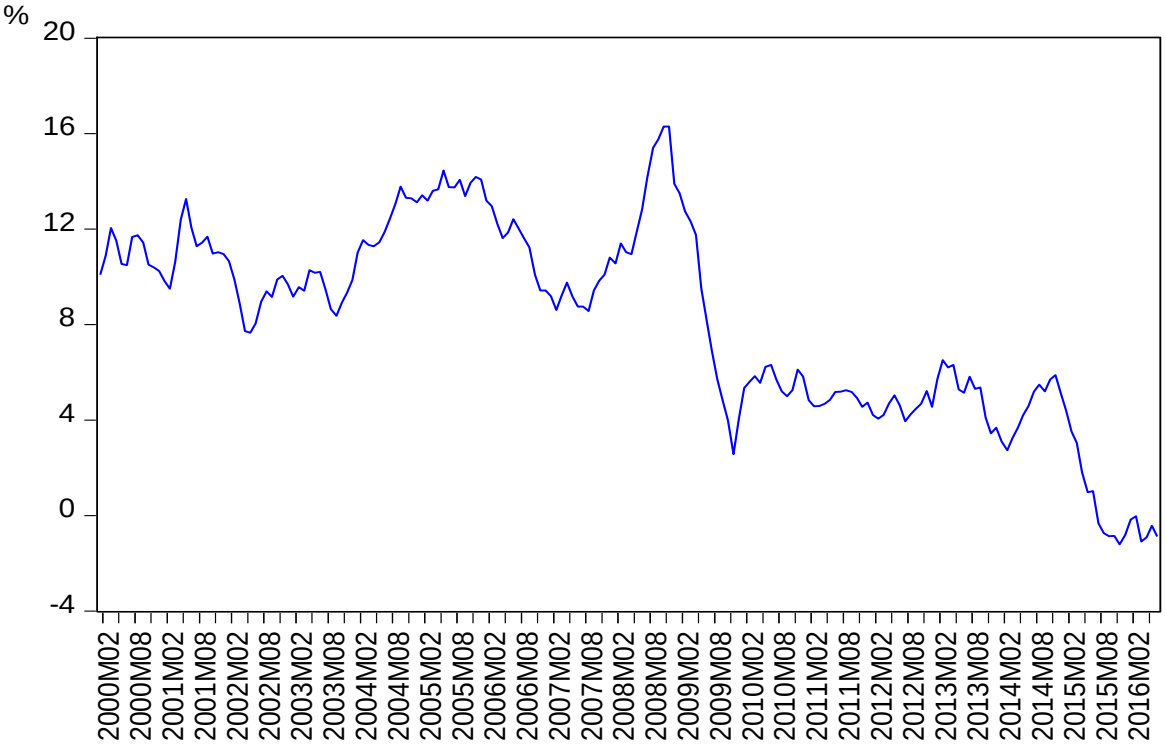

Fuente: Instituto Nacional de Estadística y Censos.

La media de la serie de inflación para el periodo de estudio completo es 8,3%, sin embargo, existe una notable diferencia en el nivel previo al cambio estructural más reciente: el nivel para el período enero 2000-abril 2009 casi triplica la media para el periodo de mayo 2009-

marzo 2016. Durante este segundo período también se ha registrado un descenso marcado en el nivel de la inflación desde inicios de 2015, lo que ha influido en un nivel de volatilidad relativamente mayor que antes del cambio estructural[5].

Cuadro 1. Costa Rica: Estadísticas descriptivas para la serie de inflación interanual. Enero 2000 - marzo 2016

Periodo	Media	Mediana	Desviación estándar	Mínimo	Máximo	Coeficiente de variación
Enero 00-Abril 09	11,3%	11,1%	1,9%	7,7%	16,3%	17,0%
Mayo 09-Marzo 16	4,2%	4,7%	2,1%	-1,2%	9,5%	50,5%
Enero 00-Marzo 16	8,3%	9,2%	4,0%	-1,2%	16,3%	48,6%

Fuente: Elaboración propia.

El período de estimación de los modelos es enero-2000 - marzo-2014, y el de evaluación de los pronósticos es abril-2014 – marzo-2016. La escogencia del período de estimación considera la recomendación de Pesaran y Timmermann (2007) de que la muestra óptima de estimación debe incluir todas las observaciones posteriores al quiebre estructural así como observaciones previas. Esto da una ganancia en reducción de variancia a cambio de algún sesgo.

En los apartados siguientes se detallan las metodologías utilizadas para obtener los pronósticos que serán evaluados en este estudio.

2.2. Pronósticos ARIMA

La determinación de la especificación óptima del modelo ARIMA por utilizar para los pronósticos se obtuvo mediante dos algoritmos:

- El algoritmo de Gómez y Maravall (1994), implementado de manera automática en su programa TRAMO/SEATS.

- El algoritmo implementado de manera automática en la versión 9.5 del programa econométrico Eviews.

Los detalles de ambos algoritmos pueden consultarse en el anexo 2.

2.3. Pronósticos GARCH

2.3.1. GARCH

En los modelos ARIMA, un supuesto fundamental es que la variancia es constante. Por el contrario, en el modelo ARCH básico la volatilidad es una función únicamente de las perturbaciones pasadas, y en el proceso GARCH se generaliza la volatilidad como un

[5] No hay aún suficientes datos para determinar si esta fase de inflaciones más bajas a partir de 2015 es el resultado de un nuevo cambio estructural.

proceso de memoria larga y una estructura de rezagos más flexible. Un proceso GARCH(1,1), el modelo más ampliamente utilizado, puede expresarse de la siguiente manera:

$$y_t = z_t'\beta + \varepsilon_t$$

$$\varepsilon_t|\psi_{t-1} \sim N(0, \sigma_t^2) \qquad (1)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1\varepsilon_{t-1}^2 + \beta_1\sigma_{t-1}^2$$

donde ε_t un proceso estocástico, ψ_t es el conjunto de información al momento t, con $\alpha_0 > 0$, $\alpha_1 \geq 0$, $\beta_1 \geq 0$ y $(\alpha_1 + \beta_1) < 1$ para que se cumpla la condición de estacionariedad. Puede verse en que un GARCH la variancia condicional se especifica como un proceso ARMA, con rezagos de la variancia misma y de las innovaciones ε_t^2.

2.3.2. EGARCH con retroalimentación simultánea

Los modelos GARCH estándar suponen que errores positivos y negativos tienen un efecto simétrico sobre la volatilidad, lo que usualmente se interpreta como simetría en el efecto de "buenas" y "malas" noticias. Esta limitación para capturar los llamados efectos de "apalancamiento" llevó al desarrollo de una clase de modelos asimétricos, los GARCH exponenciales o EGARCH, en los cuales no se impone las restricciones de no negatividad en los parámetros presente en los modelos GARCH estándar.

Por otra parte, el modelo con retroalimentación simultánea que utiliza Karanasos (2004) para analizar la inflación de Estados Unidos permite examinar la relación entre inflación e incertidumbre en la inflación, medida mediante su volatilidad, ya que se permite una retroalimentación simultánea entre la ecuación de media condicional y la varianza de la inflación. Este modelo se sustenta en el argumento de Friedman (1977) de que altas inflaciones conducen a alta incertidumbre en los niveles de inflación. Por otro lado, el modelo permite modelar el efecto de cambios en los niveles de incertidumbre en la inflación sobre los niveles de inflación, lo que se justifica mediante el argumento de que alta incertidumbre en la inflación crea un incentivo a los hacedores de política a crear inflaciones sorpresivas con el fin de estimular el crecimiento. Con el fin de modelar esta causalidad bidireccional se propone el siguiente modelo:

$$y_t = \psi_0 + \psi_1 y_{t-1} + \phi_1\varepsilon_{t-1} + \varepsilon_t + \sqrt{h_t} \qquad (2)$$

$$\ln h_t = \omega_t + \alpha_1\theta z_t + \alpha_1\gamma[|z_t| - E|z_t|] + y_{t-1}$$

donde z_t son las perturbaciones estandarizadas $z_t = \frac{\varepsilon_t}{\sqrt{h_t}}$.

2.4. Modelo estructural de series de tiempo

Harvey (1989) desarrolla el modelo estructural de series de tiempo, o de componentes no observables (UC, por sus siglas en inglés) en el cual la serie de tiempo se puede descomponer en una serie de términos, cada uno con una interpretación directa concreta. En la descomposición clásica, la serie se expresa como la suma de componentes de tendencia, ciclo, estacionalidad y componente irregular:

$$y_t = \mu_t + \psi_t + \gamma_t + \varepsilon_t \qquad (3)$$

donde μ_t es la tendencia, ψ_t es el ciclo y γ_t es el componente estacional. Estos componentes son estocásticos y sus perturbaciones no están correlacionadas. El componente de tendencia μ_t está determinado por:

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t \qquad (4)$$

$$\beta_t = \beta_{t-1} + \zeta_t$$

con η_t y ζ_t perturbaciones de ruido blanco no correlacionadas, con media cero y variancia σ_η^2 y σ_ζ^2. En este proceso el término η_t introduce cambios de nivel en la tendencia, mientras que ζ_t permite cambios en la tendencia.

El componente ψ_t se modela como una función cíclica de tiempo con frecuencia λ_c. El ciclo se expresa como una combinación trigonométrica de seno y coseno que se puede representar de manera recursiva como:

$$\begin{pmatrix} \psi_t \\ \psi_t^* \end{pmatrix} = \rho \begin{pmatrix} \cos\lambda_c & \operatorname{sen}\lambda_c \\ -\operatorname{sen}\lambda_c & \cos\lambda_c \end{pmatrix} \begin{pmatrix} \psi_{t-1} \\ \psi_{t-1}^* \end{pmatrix} + \begin{pmatrix} k_t \\ k_t^* \end{pmatrix} \qquad (5)$$

donde k_t y k_t^* están no correlacionados y tienen variancia común σ_k^2. El modelo es estacionario si $|\rho| < 1$ y si λ_c es igual a cero.

Los efectos de estacionalidad γ_t se pueden introducir de dos formas. En primer lugar, mediante un conjunto de variables indicadoras (*dummies*) estacionales, cuyo efecto sume cero para el año completo, esto es, cuya suma sea igual a una perturbación aleatoria ω_t con media cero y variancia σ_ω^2. Así, si *s* es el número de estaciones en el año:

$$\sum_{j=0}^{s-1} \gamma_{t-j} = \omega_t \qquad (6)$$

En segundo lugar, el patrón estacional puede modelarse de manera similar al componente cíclico mediante un conjunto de términos trigonométricos en las frecuencias estacionales $\lambda_j = 2\pi j/s$:

$$\gamma_t = \sum_{j=1}^{s/2} \gamma_{j,t}$$

con

$$\begin{pmatrix} \gamma_{j,t} \\ \gamma_{j,t}^* \end{pmatrix} = \rho \begin{pmatrix} \cos\lambda_j & \operatorname{sen}\lambda_j \\ -\operatorname{sen}\lambda_j & \cos\lambda_j \end{pmatrix} \begin{pmatrix} \gamma_{j,t-1} \\ \gamma_{j,t-1}^* \end{pmatrix} + \begin{pmatrix} \omega_{j,t} \\ \omega_{j,t}^* \end{pmatrix} \qquad (7)$$

donde $j = 1, \dots, [s/2]$, y $\omega_{j,t}$ y $\omega_{j,t}^*$ son procesos de ruido blanco con media cero los cuales están no correlacionados y ambos tienen variancia σ_ω^2.

La estimación de modelos estructurales de series de tiempo se suele realizar expresándolos en forma estado-espacio, donde los componentes no observables constituyen los estados del sistema, que se pueden actualizar mediante algún procedimiento de filtrado, usualmente el de Kalman.

2.5. Modelos con volatilidad estocástica

2.5.1. Modelo estándar de volatilidad estocástica

En general, los modelos de volatilidad estocástica, al igual que los modelos GARCH, son utilizados para modelar series de volatilidad no constante, pero se diferencian de ellos porque consideran que la varianza condicionada es en sí misma un proceso aleatorio.

El modelo básico especifica un proceso estocástico para la volatilidad en el que supone que la volatilidad en el día *t*, denotada como σ_t, es parcialmente determinada por eventos impredecibles en el mismo día (ver Taylor, 1982; Taylor, 2005). Los modelos de volatilidad estocástica se caracterizan por incluir choques aleatorios por unidad de tiempo: u_t y η_t el último de los cuales determina parcialmente a σ_t. Dado que hay dos choques, no es posible distinguir los valores efectivos de σ_t y u_t a partir de la variable y_t. Es decir, la volatilidad es latente y no observable: σ_t no depende de las observaciones pasadas de la serie, sino de una variable no observable, que habitualmente es un proceso estocástico autorregresivo. Se dice que el modelo de volatilidad estocástica es independiente si estos dos procesos son independientes.

El modelo estándar de Taylor está dado por cuatro supuestos básicos:

a. La inflación es igual a una media constante más la multiplicación de la volatilidad y un término de error u_t :

$$y_t = \mu + \sigma_t u_t \qquad (8)$$

b. El término de error iid se distribuye como $N(0,1)$

c. La volatilidad está determinada por un proceso AR(1) para su logaritmo:

$$\ln(\sigma_t) = \phi \ln \sigma_{t-1} + \alpha(1-\phi) + \eta_t \qquad (9)$$

donde σ_t es positivo, η_t se distribuye como $N\left(0, \sigma_\eta^2\right)$ con $\sigma_\eta^2 = \beta^2(1-\phi^2)$ y ϕ representa la persistencia en la volatilidad con $|\phi| < 1$, lo que garantiza la estacionariedad del proceso.

d. Los procesos σ_t y u_t son estocásticamente independientes.

En esta formulación, la volatilidad tiene un componente impredecible, pues la variancia condicional viene dada por $var(\sigma_t | y_{t-1}, y_{t-2}, \dots) > 0$, y las autocorrelaciones de la volatilidad decrecen lentamente.

Este modelo básico puede aplicarse en variados casos especificando la forma funcional de la media condicional μ_t, como es el caso del modelo de regresión lineal, especificaciones ARMA o el modelo estructural de series de tiempo, como se verá en las secciones siguientes.

2.5.2. Modelo de componentes no observables con volatilidad estocástica y errores MA(1)

Chan (2013) introduce una clase de modelos con volatilidad estocástica y errores MA(1) en la que la media condicional está dada por un modelo de componentes no observables en representación de estado- espacio. Así, los errores en la ecuación de media no son independientes, y la ecuación de media y de transición tienen volatilidad estocástica (SV, por sus siglas en inglés). El objetivo principal de Chan es mostrar que la inclusión del componente MA mejora el ajuste y el pronóstico, lo que ilustra mediante una aplicación para el pronóstico de la inflación en Estados Unidos.

La especificación del modelo de componentes no observables con volatilidad estocástica es la siguiente:

$$y_t = \tau_t + \varepsilon_t^y$$

$$\varepsilon_t^y = u_t + \psi\, u_{t-1}$$

$$u_t \sim N(0, e^{h_t})$$

$$h_t = \mu_h + \phi_h(h_{t-1} - \mu_h) + \varepsilon_t^h$$

$$\varepsilon_t^h \sim N(0, \sigma_h^2) \qquad (10)$$

$$\tau_t = \tau_{t-1} + \varepsilon_t^\tau$$

$$\varepsilon_t^{\tau} \sim N(0, e^{g_t})$$

$$g_t = \mu_g + \phi_g(g_{t-1} - \mu_g) + \varepsilon_t^g$$

$$\varepsilon_t^g \sim N(0, \sigma_g^2)$$

donde y_t representa la inflación, el componente τ_t es la tendencia subyacente, se supone que $|\phi_h| < 1$ y $|\phi_g| < 1$, y que los errores u_t y ε_t^h son independientes para todos los rezagos. Nótese que los errores ε_t^y siguen el proceso MA(1) ya mencionado y que las variancias para u_t y ε_t^{τ} son variantes en el tiempo, con las volatilidades logarítmicas h_t y g_t siguiendo procesos AR(1). La variancia condicional de y_t está dada por:

$$Var(y_t|\mu, \psi, h) = e^{h_t} + \psi_1^2 e^{h_{t-1}} + \cdots + \psi_q^2 e^{h_{t-q}} \quad (11)$$

Esto implica que la variancia condicional de y_t es variante en el tiempo a través de dos canales: las medias móviles de las q+1 variancias recientes $e^{h_t}, \ldots, e^{h_{t-q}}$, y la volatilidad logarítmica h_t, que evoluciona de acuerdo al proceso estacionario AR(1) de (10). A diferencia del modelo estándar SV, y_t está serialmente correlacionado aún después de condicionar en los estados.

Como se mencionó en la sección anterior, la estimación de este tipo de modelos suele realizarse a partir de su forma estado-espacio, lo que en el caso de un modelo con errores MA(q) requiere algún tipo de transformación de los datos para hacer independientes los errores de la ecuación de medida. Por ello, Chan (2013) desarrolla un método de muestreo de Monte Carlo basado en cadenas de Markov para estimar directamente este tipo de modelos aprovechando la estructura dispersa de la matriz de covariancias de las observaciones.

2.5.3. Modelo ARMA-SV

Chan (2013) también considera una especificación AR(1) para la media condicional, errores MA(1):

$$y_t = \phi_0 + \phi_1 y_{t-1} + \varepsilon_t^y$$

$$\varepsilon_t^y = u_t + \psi\, u_{t-1}$$

$$h_t = \mu_h + \phi_h(h_{t-1} - \mu_h) + \varepsilon_t^h \quad (12)$$

$$\varepsilon_t^h \sim N(0, \sigma_h^2)$$

donde se impone la condición de estacionariedad para el modelo AR(1) y u_t tiene volatilidad estocástica como en el modelo anterior.

2.6. Combinación de pronósticos

Cuando se tiene varios pronósticos de una misma variable y no es claro que uno de ellos domine a los demás (*encompassing*), puede resultar deseable realizar una combinación de todos. En primer lugar, la combinación podría resultar en menores errores de pronóstico. Además, es improbable que un mismo pronóstico domine para todos los horizontes de pronóstico, por lo que combinar pronósticos con variada precisión a diferentes horizontes podría mejorar la precisión general. Finalmente, si existieran quiebres estructurales desconocidos que favorezcan a un modelo en vez de otro, la combinación podría resultar en pronósticos más robustos.

En la abundante literatura sobre combinación de pronósticos pueden distinguirse varias clases de métodos:

- **Promedios simples y truncados, medianas y otras medidas.** Esta clase usualmente implica eliminar valores extremos, dar peso nulo a algunos pronósticos o ponderar equitativamente todos los pronósticos.

- **Combinaciones con pesos basados en desempeño pasado**. En este grupo de métodos el principio es dar mayor ponderación a pronósticos con una historia de buen poder predictivo. Ejemplos incluyen una de las primeras contribuciones en esta literatura, Bates y Granger (1969), así como la más reciente de Stock y Watson (2004).

- **Combinación óptima mediante mínimos cuadrados.** Los pesos se derivan de una regresión para los valores efectivos con base en los pronósticos. El método fue propuesto por Granger y Ramanathan (1984). Otras contribuciones incluyen Diebold y Pauly (1987), para considerar posibles cambios estructurales, y Hallman y Kamstra (1989) y Coulson y Robins (1993) para series de pronósticos no estacionarias. Aiolfi y Timmermann (2006) proponen reemplazar pronósticos individuales por *clusters* basados en capacidad de pronóstico.

- **Combinaciones bayesianas.** Este tipo de métodos incluye Diebold y Pauly (1990) y Stock y Watson (2004).

- **Componentes principales**. Generalmente utilizado cuando se cuenta con un número relativamente grande de pronósticos. Ver Stock y Watson (2004).

- **Métodos con parámetros cambiantes.** Incluyen modelos de transición entre regímenes y modelos de transición suave, entre otros Deutsch, Granger y Teräsvirta (1994) proveen una reseña de este tipo de modelos.

- **Proyección lineal sobre la media.** Capistrán y Timmermann (2009) proponen obtener la combinación como los valores proyectados de una regresión de los valores efectivos sobre el promedio simple de los pronósticos:

$$y_t = \beta_0 + \beta_1 \bar{y}_t + \varepsilon_t$$

$$y_t^c = \widehat{\beta_0} + \widehat{\beta_1}\bar{y}_t \qquad (13)$$

$$\bar{y} = \sum_{i=1}^{n} \frac{y_t^i}{n}$$

donde y_t^i es cada pronóstico individual.

Ahora bien, en la literatura aplicada sobre combinación de pronósticos un resultado recurrente es el mejor desempeño relativo de métodos de combinación más sencillos, como promedios simples, sobre metodologías más elaboradas, como combinaciones con parámetros con cambio de régimen o con transición suave. Smith y Wallis (2009) ilustran este "acertijo de la combinación de pronósticos" mediante simulaciones y un ejemplo aplicado, y muestran que el error al estimar los pesos puede llegar a ser importante. Una explicación teórica formal de este hecho estilizado ha sido propuesta recientemente por Claeskens, Magnus, Vasnev y Wang (2016), quienes encuentran que la estimación de los pesos óptimos de una combinación siempre afecta sustancialmente la variancia de la combinación. Por esta razón, en el presente trabajo se ha decidido utilizar el esquema de combinación relativamente simple de Capistrán y Timmermann (2009) (CT), y comparar su desempeño con el del promedio simple.

2.7. Evaluación de los pronósticos

Los pronósticos se evalúan considerando pruebas formales en cinco dimensiones: insesgamiento, autocorrelación de errores, ajuste, inclusión de información, y patrones de variancia. Estos criterios se derivan de una amplia literatura sobre evaluación que incluye las contribuciones tempranas de Mincer y Zarnowitz (1969) y Granger y Newbold (1973), la lista de preguntas que deberían guiar una evaluación de pronósticos sugerida por Stekler (1991), y las cuatro propiedades de pronósticos óptimos bajo pérdida cuadrática expuestas en Diebold y López (1996). Ver también West (2006) para una reseña de literatura relevante. A continuación se presenta una síntesis de las pruebas utilizadas para evaluar cada dimensión.

2.7.1 Insesgamiento

Un pronóstico no debería sobreestimar ni subestimar sistemáticamente el verdadero valor de la variable pronosticada, lo que implica que los errores de pronóstico deberían tener media cero. Para verificar insesgamiento se utiliza la prueba convencional de Mincer y Zarnowitz (1969) basada en la regresión en niveles dada por:

$$y_{t+s} = \alpha + \beta \hat{y}_{t+s} + \varepsilon_{t+s} \qquad (14)$$

donde $\hat{y}_{t+s}$ es el pronóstico con horizonte *s* para la variable de interés, y y_{t+s} su valor efectivo. Se asume insesgamiento si no puede rechazarse la hipótesis nula conjunta de α =0 y β=1. En este estudio se utiliza pruebas de Wald.

2.7.2. Correlación de errores

Diebold y López (1996) muestran que los errores de pronóstico e_{t+h} para el pronóstico óptimo $\hat{y}_{t+h}$ son ruido blanco para el horizonte h=1 y a lo sumo siguen un proceso MA(h-1) para h>1. El procedimiento que recomiendan utilizar para el primer caso es la prueba modificada de rangos con signo de Wilcoxon propuesta por Dufour (1981) para autocorrelación. En este caso se calcula el estadístico:

$$W_D = \sum_{s=1}^{T} I_+\left(z_t\right) Rank(\left|z_t\right|) \quad (15)$$

donde $z_t = (e_{t+1,t} e_{t+2,t+1})$. Bajo la hipótesis nula de que los errores e_{t+h} son independientes, simétricamente distribuidos con mediana igual a 0, el producto cruzado z_t también lo será y su mediana será también 0. Bajo la alternativa de autocorrelación positiva (negativa) la mediana sería positiva (negativa).

Para el caso de horizontes h > 1 Diebold y López recomiendan utilizar la prueba de Cumby y Huizinga (1992), cuya hipótesis nula es que los errores siguen un proceso MA(q), con 0 ≤ q ≤ h-1, y cuya hipótesis alternativa es que q > h. Bajo la nula, las autocorrelaciones muestrales de e_{t+h}, dadas por $\hat{\rho} = \left[\hat{\rho}_{q+1} \quad ... \quad \hat{\rho}_{q+h}\right]$, están asintóticamente distribuidas como $\sqrt{T}\hat{\rho} \sim N(0,V)$, por lo que $C = T\hat{\rho}'\hat{V}^{-1}\hat{\rho} \sim \chi_s^2$, donde $\hat{v}$ es un estimador consistente de *V*.

2.7.3. Precisión

En primera instancia se presenta medidas usuales de precisión como el error cuadrático medio (ECM) y su raíz (RECM), y el coeficiente de desigualdad de Theil:

$$ECM = \frac{\sum_{s=1}^{T}(y_{t+s} - \hat{y}_{t+s})^2}{T} \qquad Theil = \frac{RECM}{\sqrt{\sum_{s=1}^{T}\hat{y}_{t+s}^2 / T} + \sqrt{\sum_{s=1}^{T} y_{t+s}^2 / T}} \quad (16)$$

Así mismo, la significancia de diferencias en la capacidad de pronóstico medida mediante el ECM se determina mediante las pruebas de Diebold y Mariano (1995) y de Harvey, Leybourne y Newbold (1997)[6] (HLN).

Como una medida adicional de capacidad predictiva se calcula el porcentaje de acierto en la dirección de los cambios en la inflación:

$$A = \frac{\sum_{s=1}^{T} 1\left\{\operatorname{sgn}(\Delta y_{t+s}) = \operatorname{sgn}(\Delta \hat{y}_{t+s})\right\}}{T} \quad (17)$$

con la función 1{.} igual a 1 si el signo del cambio en el pronóstico es igual al del cambio en el valor efectivo de la inflación. Dado que la función 1{.} solo puede tomar dos valores, es deseable un porcentaje de acierto superior al 50%.

2.7.4. Evaluación de variancias de los errores

Pronósticos óptimos bajo pérdida cuadrática también deberían tener errores cuya variancia no sea creciente conforme aumenta el horizonte de pronóstico (Diebold y López, 1996). Esencialmente esto refleja que la incertidumbre de los pronósticos debería disminuir, o al menos no aumentar, cuando se dispone de más información para su elaboración. Para verificar esta propiedad, se sigue a Timmermann (2006a) y se realiza pruebas F de diferencia en variancias.

2.7.5. Inclusión de pronósticos

El objetivo de las pruebas de inclusión (*encompassing*) de pronósticos es determinar si un pronóstico ya contiene toda la información utilizada para producir uno o varios pronósticos alternativos, lo cual resulta de utilidad para decidir si es ventajoso realizar una combinación de ellos. Chong y Hendry (1986) desarrollaron una prueba de inclusión para pronósticos puntuales partiendo de una función de pérdida cuadrática, que se basa en la regresión:

$$y_{t+s} = \beta_0 + \beta_1 \hat{y}_{t+s,1} + \beta_2 \hat{y}_{t+s,2} + \varepsilon_{t+s} \quad (18)$$

---

[6] Los estadísticos son $DM = \frac{\bar{d}}{s_d}$ y $HLN = \left(\frac{T+1-2k+k(k-1)/T}{T}\right)^{1/2} DM$, donde $\bar{d}$ es la media de la diferencia cuadrática de los errores de pronóstico, s_d es una estimación consistente de su desviación estándar, k es el horizonte de pronóstico y T el número de observaciones.

El pronóstico 1 incluye al 2 si no se rechaza la hipótesis nula de $\begin{pmatrix}\beta_0 & \beta_1 & \beta_2\end{pmatrix}=\begin{pmatrix}0 & 1 & 0\end{pmatrix}$ mientras que el pronóstico 2 incluye al 1 si no se rechaza que $\begin{pmatrix}\beta_0 & \beta_1 & \beta_2\end{pmatrix}=\begin{pmatrix}0 & 0 & 1\end{pmatrix}$. En cualquier otro caso se considera que ambos pronósticos contienen información útil.

Aunque en los modelos univariados utilizados en este estudio se basan en el mismo conjunto de información (la serie de inflación), la prueba de Chong y Hendry se implementa con el fin de verificar si existen diferencias significativas en la forma en que cada modelo utiliza la historia de la inflación.

3. Resultados

3.1. Especificaciones de los modelos y pronósticos calculados

Los modelos utilizados para pronóstico en este estudio son 14 y se pueden agrupar en modelos de componentes no observables (UC, por sus siglas en inglés) y modelos ARMA. Se incluye además los tres modelos bayesianos actualmente en uso en el BCCR, propuestos por Chavarría y Chaverri (2015). Las especificaciones detalladas anteriormente se utilizaron para realizar pronósticos en cuatro horizontes: h = 1 mes, h = 3 meses, h = 6 meses y h = 12 meses. Se utiliza estos horizontes pues los modelos univariables suelen utilizarse mayoritariamente para pronóstico a plazos relativamente cortos, dada su mayor precisión de predicción.

3.1.1. Modelos UC

Se estimó cuatro modelos de componentes no observables (Harvey, 1989):

- UC-TC: modelo estructural de series de tiempo de tendencia y ciclo.
- UC-TCS1: modelo estructural de series de tiempo de tendencia, ciclo y estacionalidad con variables dicotómicas.
- UC-TCS2: modelo estructural de series de tiempo de tendencia, ciclo y estacionalidad trigonométrica.
- UC-MA SV: modelo de componentes no observables de tendencia con perturbaciones MA(1) y volatilidad estocástica.

3.1.2. Modelos ARMA

Se estimó 10 modelos ARMA con diferentes supuestos sobre el proceso generador de datos. En primer lugar, se estimó tres especificaciones básicas:

- ARMA(1,1), seleccionado mediante el algoritmo de Gómez y Maravall.

- ARMA(3,2) SMA(1).
- AR(2) SAR(2).

Estos dos últimos modelos incluyen un componente estacional y fueron estimados mediante el algoritmo implementado por Eviews (ver anexo 1).

A su vez, cada una de estas tres especificaciones básicas se estimó considerando variancia no constante. En primer lugar, se estimó los ARMA en conjunto con el modelo GARCH más simple, GARCH(1,1), lo cual resulta en las especificaciones

- GARCH(1,1) ARMA(1,1)
- GARCH(1,1) ARMA(3,2)
- GARCH(1,1) AR(2) SAR(2)

Por otra parte se estimó un modelo de volatilidad estocástica en el que el componente de media está dado por una especificación ARMA (1,1):

- ARMA-SV

Asimismo para capturar retroalimentación simultánea entre la ecuación de media (ARMA) y la ecuación de volatilidad condicional, se estimó los tres ARMA considerando un proceso GARCH exponencial EGARCH(1,1), donde la ecuación de media contiene como variable explicativa la raíz de la volatilidad condicional (denotado como *in mean (0)*) y la ecuación para la variancia incluye como variable explicativa al primer rezago del nivel de la inflación (y_{t-1}, denotado como L(1)):

- EGARCH(1,1) in mean (0)-L(1) ARMA(1,1)
- EGARCH(1,1) in mean (0)-L(1) AR(2) SAR(2)
- EGARCH(1,1) in mean (0)-L(1) ARMA(3,2) SMA(1)

3.1.3. Modelos bayesianos

Finalmente las últimas cuatro especificaciones utilizadas son las que consideran las técnicas bayesianas utilizadas por Chavarría y Chaverri (2014) y son estimadas para efectos de comparación:

- *BMA*: *Bayesian Model Averaging*
- *WALS: Weighted-Average Least Squares*
- Factores dinámicos.

El gráfico 2 muestra los pronósticos organizados por horizonte y por grupo de método, y el cuadro 2 contiene las estadísticas descriptivas para todos los pronósticos. Se puede observar que, como es de esperar, la desviación estándar en general disminuye conforme aumenta el horizonte de pronóstico para la mayoría de los modelos. Por otro lado, las medias de los pronósticos que se mantienen relativamente más estables conforme aumenta el horizonte de pronóstico son las de los modelos de componentes no observables y los modelos bayesianos.

Gráfico 2
Pronósticos de inflación
h=1

UC

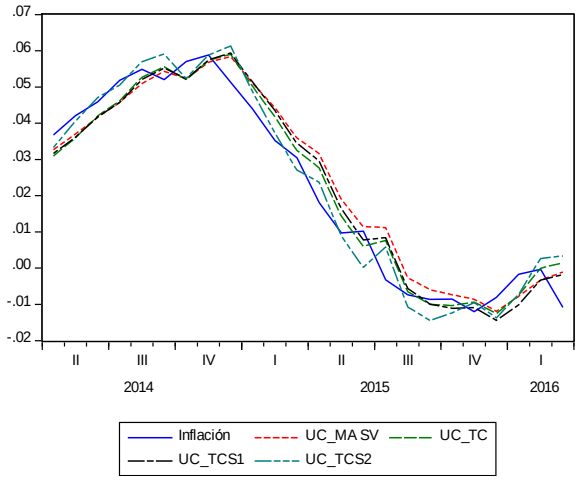

ARMA

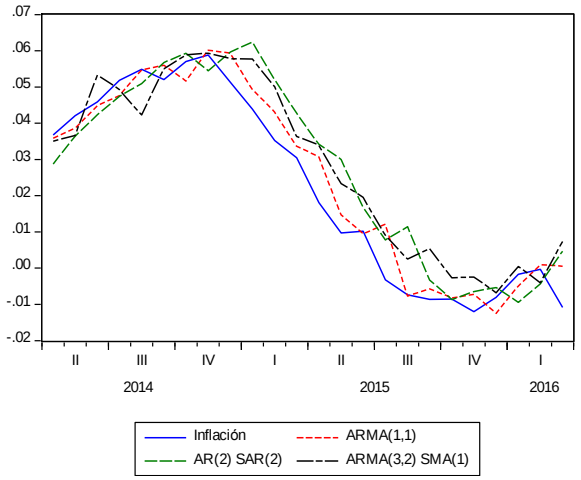

ARMA, GARCH, SV

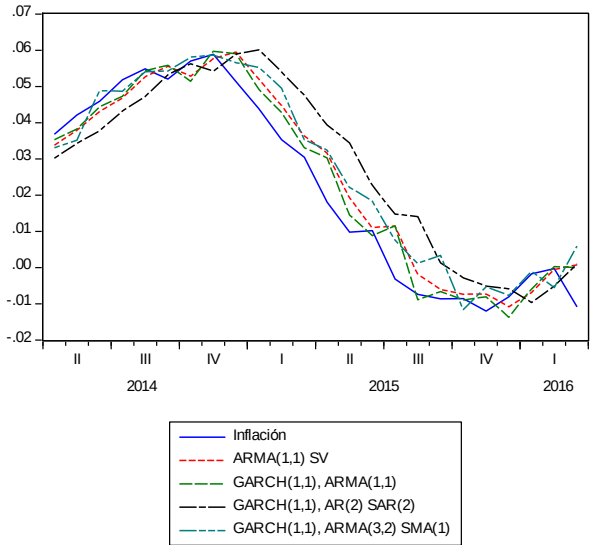

ARMA, EGARCH

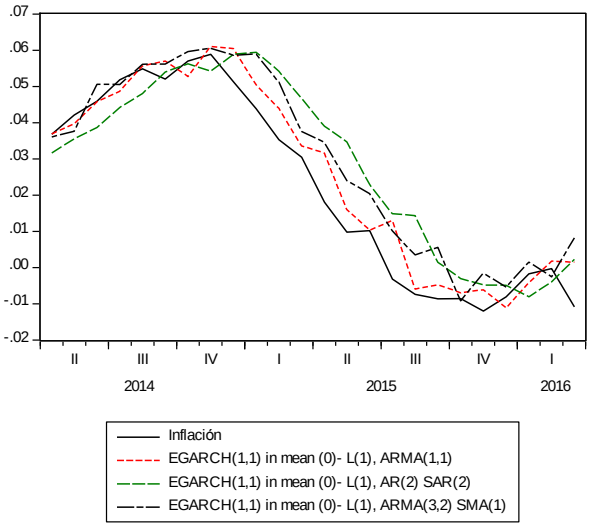

h=3

UC

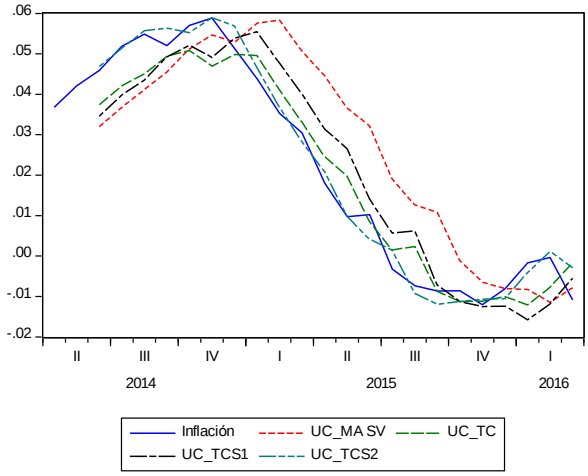

ARMA

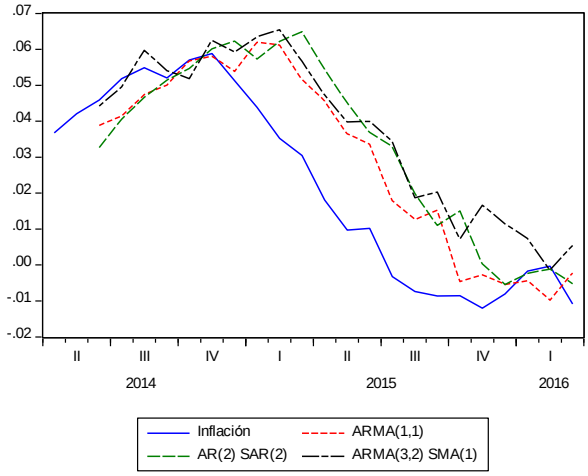

ARMA, GARCH, SV

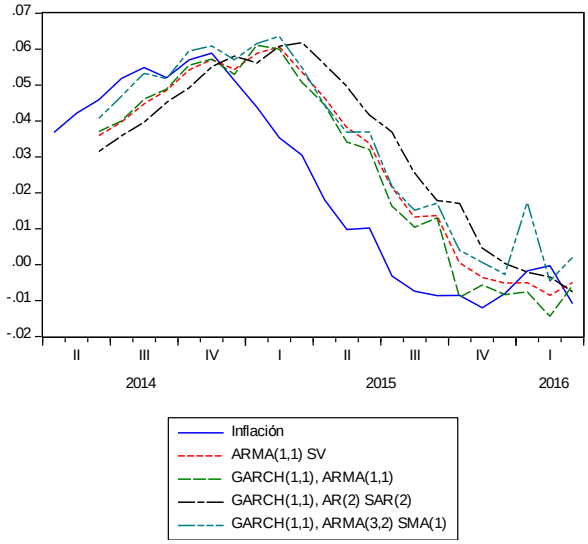

ARMA, EGARCH

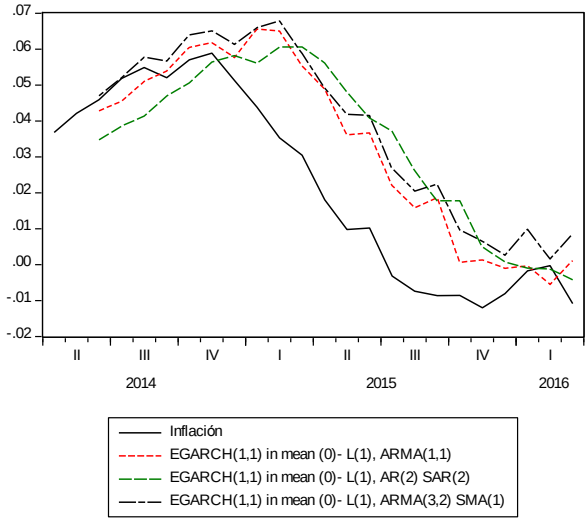

h=6

UC

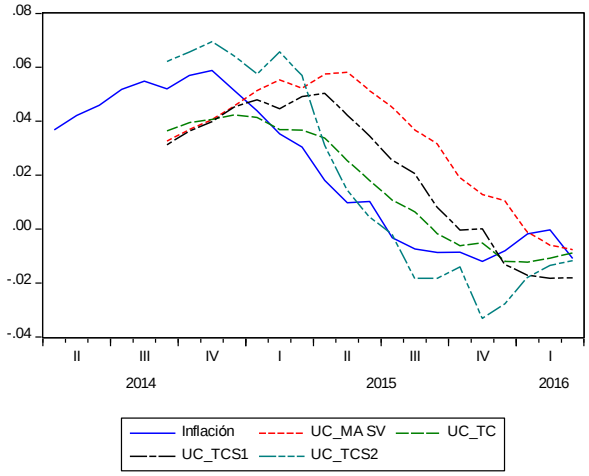

ARMA

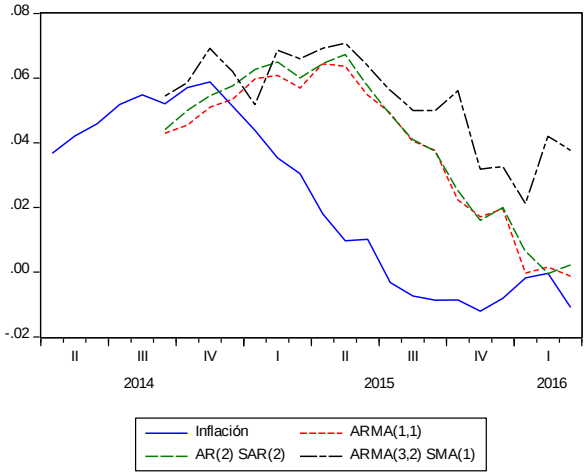

ARMA, GARCH, SV

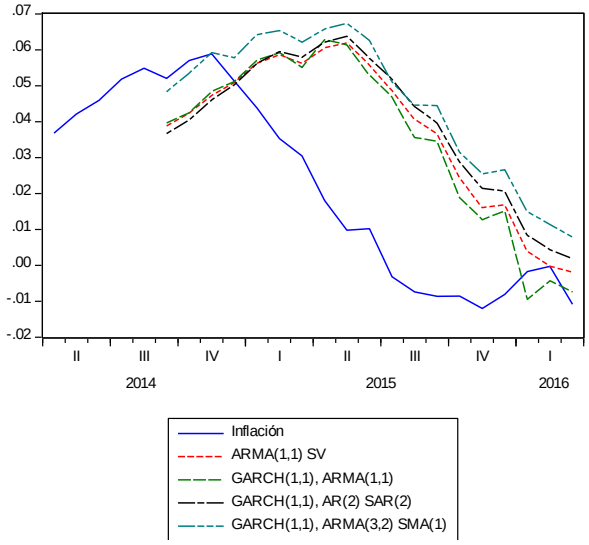

ARMA, EGARCH

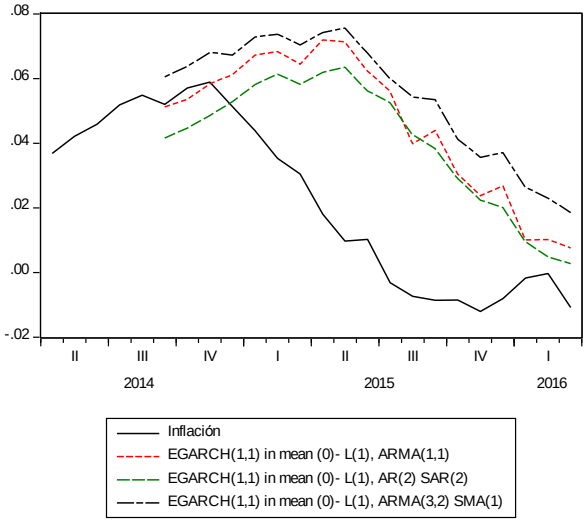

h=12

UC

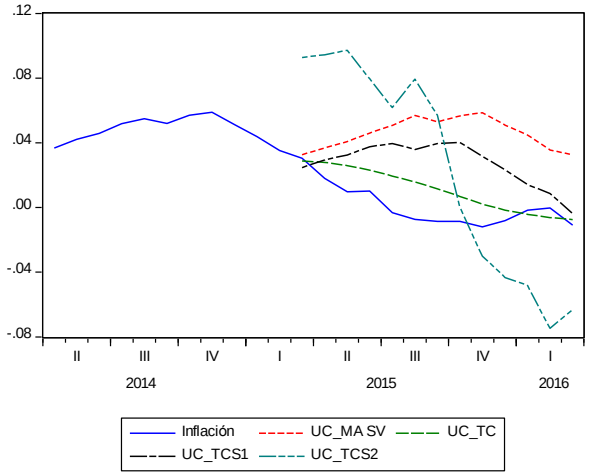

ARMA

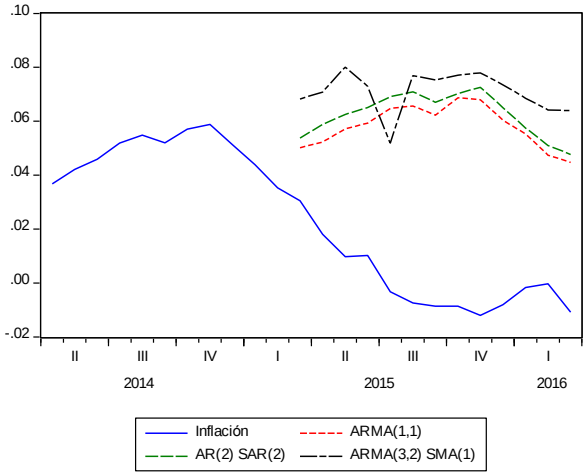

ARMA, GARCH, SV

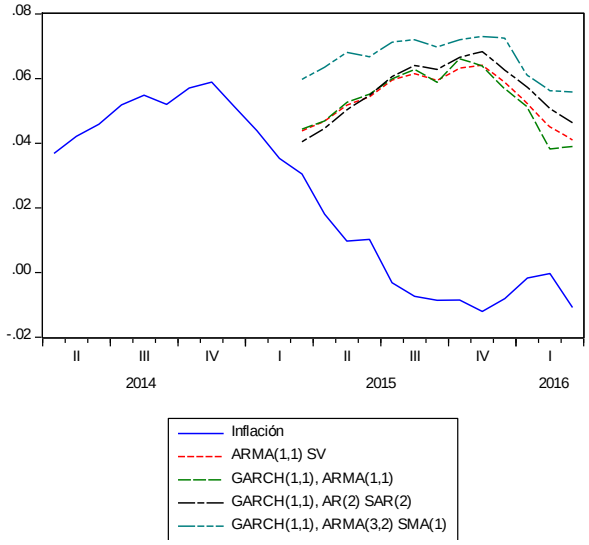

ARMA, EGARCH

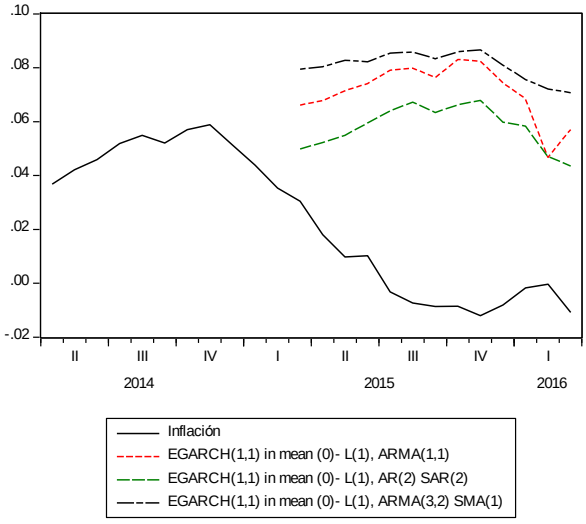

Pronósticos bayesianos

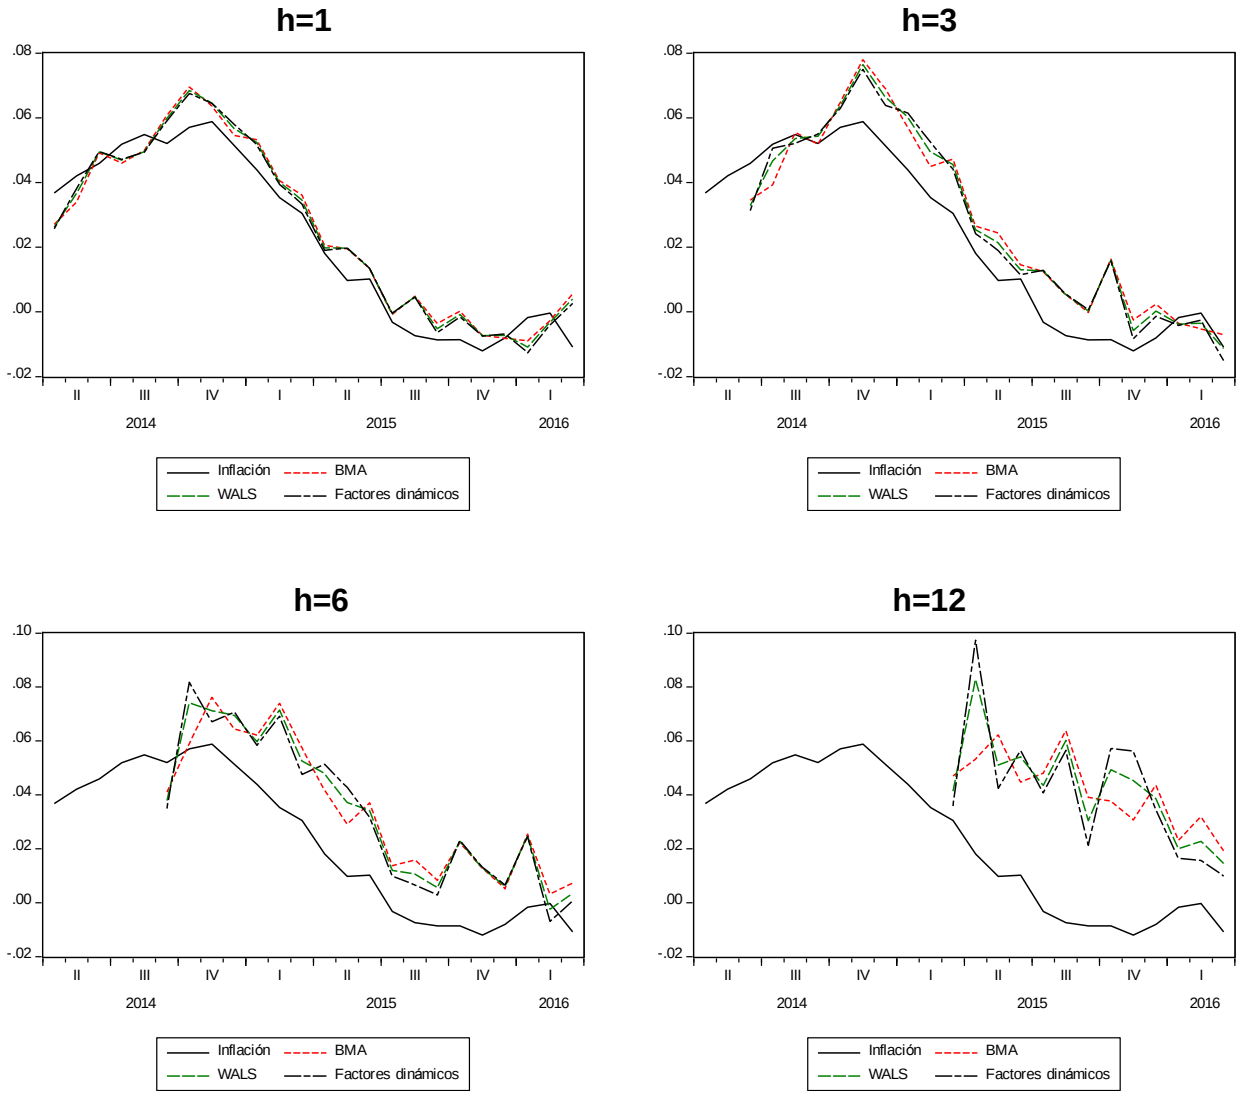

Fuente: Elaboración propia

Cuadro 2. Estadísticas descriptivas para los pronósticos calculados

	Media				Desviación estándar			
	h =1	h =3	h =6	h =12	h=1	h =3	h =6	h =12
UC_MA SV	0,02440	0,02695	0,03274	0,04579	0,02534	0,02508	0,02189	0,00947
ARMA(1,1) SV	0,02523	0,02940	0,03753	0,05395	0,02538	0,02495	0,02137	0,00785
ARMA(1,1)	0,02486	0,02969	0,03891	0,05813	0,02583	0,02558	0,02230	0,00781
AR(2) SAR(2)	0,02753	0,03338	0,04104	0,06238	0,02566	0,02500	0,02270	0,00804
ARMA(3,2) SMA(1)	0,02822	0,03698	0,05327	0,07084	0,02410	0,02218	0,01444	0,00767
GARCH(1,1), ARMA(1,1)	0,02430	0,02765	0,03538	0,05349	0,02610	0,02663	0,02404	0,00919
GARCH(1,1), AR(2) SAR(2)	0,02815	0,03312	0,03953	0,05608	0,02435	0,02312	0,02003	0,00899
GARCH(1,1), ARMA(3,2) SMA(1)	0,02694	0,03356	0,04545	0,06626	0,02511	0,02385	0,01990	0,00630
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,02584	0,03331	0,04621	0,07127	0,02578	0,02537	0,02191	0,01038
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,02859	0,03394	0,04043	0,05797	0,02409	0,02260	0,02003	0,00796
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,02926	0,03804	0,05491	0,08084	0,02489	0,02385	0,01884	0,00520
UC_TC	0,02321	0,01994	0,01636	0,01087	0,02596	0,02498	0,02171	0,01351
UC_TCS1	0,02316	0,02148	0,02150	0,02710	0,02659	0,02654	0,02543	0,01362
UC_TCS2	0,02290	0,02134	0,01762	0,02328	0,02769	0,02789	0,03849	0,06726
BMA	0,02569	0,02840	0,03453	0,04186	0,02605	0,02701	0,02466	0,01359
WALS	0,02545	0,02812	0,03426	0,04260	0,02637	0,02760	0,02626	0,01837
Factores dinámicos	0,02512	0,02757	0,03346	0,04156	0,02657	0,02805	0,02750	0,02385

Fuente: Elaboración propia

3.2. Insesgamiento

Ninguno de los pronósticos resulta insesgado a todos los horizontes considerados, y en particular, ninguno es insesgado al horizonte más largo de 12 meses (cuadro 3). Si bien esta propiedad se verifica para la mayoría de pronósticos en el horizonte de 1 mes, solamente los pronósticos de componentes no observables son insesgados para horizontes mayores, incluida la versión con volatilidad estocástica. Exceptuando el correspondiente al ARMA(1,1) para 1 mes, ningún otro pronóstico con efectos GARCH o EGARCH resulta insesgado.

Cuadro 3. Prueba de insesgamiento de Mincer y Zarnowitz (1969)
-Valor p para prueba Wald conjunta-

	h = 1	h = 3	h = 6	h = 12
UC_MA SV	**0,3114**	**0,1238**	0,0021	0,0000
ARMA(1,1) SV	**0,0856**	0,0167	0,0001	0,0000
ARMA(1,1)	**0,1053**	0,0068	0,0000	0,0000
AR(2) SAR(2)	0,0262	0,0011	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0010	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	**0,2630**	0,0378	0,0001	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0488	0,0081	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0063	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0112	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0232	0,0034	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000
UC_TC	**0,7913**	**0,5917**	**0,7645**	0,0001
UC_TCS1	**0,6806**	**0,8182**	**0,1479**	0,0000
UC_TCS2	**0,2824**	**0,3222**	0,0000	0,0000
BMA	**0,0676**	0,0010	0,0000	0,0000
WALS	**0,0741**	0,0005	0,0000	0,0000
Factores dinámicos	**0,1080**	0,0012	0,0000	0,0000

Fuente: Elaboración propia

3.3. Correlación de errores

El cuadro 4 muestra los valores p para las pruebas de Cumby y Huizinga (CH) y de Wilcoxon/Dufour (WD) para los errores de pronóstico. De CH puede concluirse que todos los pronósticos para h > 1 cumplen con la propiedad de seguir como máximo un proceso MA(h-1). Sin embargo, no todos los errores de pronóstico para el horizonte de 1 mes pueden considerarse no autocorrelacionados: de acuerdo con WD solamente los pronósticos ARMA(1,1) simple y con efectos GARCH, y dos de los pronósticos de componentes no observables cumplen con esa propiedad. Si se considera además los resultados de CH para este horizonte, los pronósticos bayesianos y dos de los EGARCH también pueden considerarse no autocorrelacionados.

Cuadro 4. Pruebas de autocorrelación de errores de pronóstico
-Valores p [1/] -

	h = 1		h = 3	h = 6	h = 12
	Wilcoxon/ Dufour	Cumby & Huizinga (1992)			
UC_MA SV	0,0037	0,0058	**0,1940**	**0,1644**	**0,8359**
ARMA(1,1) SV	0,0065	0,0118	**0,2010**	**0,1646**	**0,8471**
ARMA(1,1)	**0,1858**	**0,4805**	**0,2078**	**0,1560**	**0,8243**
AR(2) SAR(2)	0,0078	0,0037	**0,1817**	**0,1538**	**0,7795**
ARMA(3,2) SMA(1)	0,0059	**0,0637**	**0,2310**	**0,3975**	**0,6877**
GARCH(1,1), ARMA(1,1)	**0,2669**	**0,5040**	**0,2079**	**0,1397**	**0,7870**
GARCH(1,1), AR(2) SAR(2)	0,0007	0,0004	**0,1736**	**0,1934**	**0,8425**
GARCH(1,1), ARMA(3,2) SMA(1)	**0,0658**	**0,1367**	**0,2259**	**0,1880**	**0,8634**
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0156	**0,5013**	**0,2167**	**0,1805**	**0,7860**
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0008	0,0004	**0,1767**	**0,1826**	**0,7867**
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0111	**0,1216**	**0,2310**	**0,2004**	**0,8319**
UC_TC	**0,0974**	**0,1255**	**0,1999**	**0,2001**	**0,5456**
UC_TCS1	0,0372	0,0226	**0,1968**	**0,1425**	**0,5387**
UC_TCS2	**0,9636**	**0,8199**	**0,3246**	**0,7042**	**0,3173**
BMA	0,0071	**0,1567**	**0,7875**	**0,2209**	**0,5766**
WALS	0,0102	**0,1664**	**0,6971**	**0,9282**	**0,5552**
Factores dinámicos	0,0170	**0,1831**	**0,7104**	**0,2284**	**0,5465**

[1/] Se presenta los valores p para el estadístico de Cumby y Huizinga (1992) para la hipótesis de que los errores siguen un MA(h-1) versus la alternativa de MA(h). Para h =1 se utiliza además la prueba de Wilcoxon propuesta por Dufour (1981).

Fuente: Elaboración propia

3.4. Precisión

De acuerdo con la RECM (cuadro 5), los modelos de UC son los que muestran mejor ajuste. Para el horizonte h=1, los modelos que resultan en las menores RECM son dos pronósticos UC y el GARCH (1,1), ARMA(1,1). Para el horizonte h=3 y horizonte h=6, los pronósticos más precisos son los UC sin volatilidad estocástica, mientras que para el horizonte más largo h=12 se tiene dos especificaciones UC junto con el pronóstico BMA. En general, este mismo patrón se repite en el caso del coeficiente de desigualdad de Theil: los pronósticos UC son los que muestran mejor ajuste, sobre todo en el corto plazo, con los pronósticos bayesianos mostrando mejor capacidad de pronóstico para los horizontes mayores.

Cuadro 5. RECM y coeficiente de desigualdad de Theil para pronósticos

	RECM				Theil [1/]			
	h = 1	h = 3	h = 6	h = 12	h = 1	h = 3	h = 6	h = 12
UC_MA SV	0,0066	0,0155	0,0284	0,0492	0,0953	0,2207	0,4104	0,8327
ARMA(1,1) SV	0,0067	0,0162	0,0309	0,0562	0,0960	0,2249	0,4229	0,8408
ARMA(1,1)	0,0060	0,0156	0,0314	0,0600	0,0858	0,2156	0,4209	0,8453
AR(2) SAR(2)	0,0104	0,0203	0,0325	0,0641	0,1459	0,2704	0,4241	0,8512
ARMA(3,2) SMA(1)	0,0096	0,0208	0,0427	0,0718	0,1350	0,2712	0,5007	0,8586
GARCH(1,1), ARMA(1,1)	0,0058	0,0149	0,0295	0,0559	0,0839	0,2072	0,4066	0,8393
GARCH(1,1), AR(2) SAR(2)	0,0124	0,0224	0,0332	0,0589	0,1746	0,3035	0,4470	0,8523
GARCH(1,1), ARMA(3,2) SMA(1)	0,0081	0,0174	0,0357	0,0675	0,1151	0,2329	0,4484	0,8555
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0064	0,0176	0,0366	0,0729	0,0911	0,2345	0,4514	0,8640
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0123	0,0221	0,0328	0,0599	0,1720	0,2972	0,4375	0,8453
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0096	0,0208	0,0434	0,0814	0,1332	0,2650	0,4932	0,8720
UC_TC	0,0057	0,0069	0,0110	0,0139	0,0830	0,1056	0,1930	0,4736
UC_TCS1	0,0061	0,0096	0,0194	0,0317	0,0885	0,1429	0,3081	0,7463
UC_TCS2	0,0057	0,0033	0,0145	0,0622	0,0821	0,0479	0,2032	0,7673
BMA	0,0075	0,0121	0,0215	0,0435	0,1067	0,1667	0,2974	0,7737
WALS	0,0072	0,0115	0,0214	0,0453	0,1019	0,1576	0,2937	0,7743
Factores dinámicos	0,0070	0,0113	0,0216	0,0466	0,0995	0,1550	0,2963	0,7787

[1/] Valores más cercanos a cero indican un mejor ajuste.

Fuente: Elaboración propia

Ahora bien, la prueba HLN de una cola permite identificar los casos en que un pronóstico resulta en errores *significativamente* menores que otro. Los resultados de aplicar la prueba a cada posible par de pronósticos se muestran en el cuadro 11 del anexo. Se encontró que para todos los horizontes considerados, a un 5% de significancia, los pronósticos que resultan en más diferencias significativas con respecto a los demás son los derivados de los modelos UC, ARMA(1,1) (homocedástico y GARCH) y de los modelos con volatilidad estocástica. En particular, a juzgar por el número de diferencias significativas reportadas, los pronósticos de modelos con volatilidad estocástica aumentan su capacidad de predicción a horizontes más largos. Esto mismo ocurre para los pronósticos bayesianos, que resultan más precisos con más frecuencia al horizonte más largo de 12 meses.

El porcentaje de aciertos en la dirección del movimiento de la inflación (cuadro 6) ocurrido durante el periodo se obtiene comprobando si el signo de la predicción es igual al ocurrido realmente. Es deseable un porcentaje de acierto mayor a 50%. Para horizontes de 1 y 3 meses todos los modelos superan el umbral de 50% de acierto, pero en general, los modelos que tienen mayor porcentaje de aciertos para todos los horizontes son pronósticos bayesianos, en particular a 3 meses, y especialmente el modelo WALS. Los modelos UC simples también se desempeñan mejor para los horizontes más largos, especialmente el modelo UC_TC.

Cuadro 6. Porcentaje de acierto en la predicción de dirección del cambio en nivel de la inflación

-En negrita si mayor a 50%-

	h = 1	h = 3	h = 6	h = 12
UC_MA SV	**0,6957**	**0,5714**	0,4444	0,3333
ARMA(1,1) SV	**0,6087**	**0,5714**	0,5000	0,3333
ARMA(1,1)	**0,6522**	**0,5714**	**0,6111**	0,4167
AR(2) SAR(2)	**0,5652**	**0,7143**	0,4444	0,3333
ARMA(3,2) SMA(1)	**0,5652**	**0,5238**	**0,7222**	0,3333
GARCH(1,1), ARMA(1,1)	**0,6522**	**0,5714**	**0,6111**	0,3333
GARCH(1,1), AR(2) SAR(2)	**0,6087**	**0,5714**	0,4444	0,3333
GARCH(1,1), ARMA(3,2) SMA(1)	**0,6087**	**0,6667**	**0,5556**	0,2500
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	**0,6522**	**0,6190**	**0,5556**	0,3333
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0,6087**	**0,6667**	0,4444	0,3333
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	**0,5652**	**0,6190**	**0,5556**	0,2500
UC_TC	**0,6087**	**0,5714**	**0,6111**	**0,5833**
UC_TCS1	**0,6087**	**0,5714**	0,3889	0,4167
UC_TCS2	**0,6522**	**0,8095**	**0,7778**	0,2500
BMA	**0,6522**	**0,8095**	**0,7222**	0,4167
WALS	**0,6957**	**0,8571**	**0,6667**	**0,6667**
Factores dinámicos	**0,6522**	**0,8095**	**0,5556**	**0,5833**

Fuente: Elaboración propia.

3.5. Pruebas de inclusión de información

Los resultados de aplicar la prueba de inclusión de pronósticos de Chong y Hendry para cada par de pronósticos a cada horizonte se presentan en los cuadros 12 y 13 del anexo. Es claro que a los horizontes más cortos de 1 y 3 meses, los modelos de UC incluyen a la mayoría de los demás pronósticos, con la parcial excepción de los modelos con volatilidad estocástica, lo que sugiere que considerar dicha especificación en general aporta información valiosa para el pronóstico. Los pronósticos de modelos ARMA(1,1) (homocedástico y GARCH) también incluyen a la mayoría de los demás pronósticos a estos horizontes. Al horizonte de 6 meses solamente el modelo simple de UC incluye a los pronósticos bayesianos, mientras que al horizonte de 12 meses ningún pronóstico incluye a algún otro. Estos resultados sugieren que realizar una combinación de pronósticos podría resultar más provechoso para los horizontes más largos, pues los pronósticos a horizontes más cortos tienden a estar dominados por los modelos UC.

3.6. Variancia de los errores de pronóstico

En general las variancias de los errores de pronóstico cumplen con la propiedad de ser crecientes conforme aumenta el pronóstico hasta el horizonte de 6 meses (cuadro 7). Sin embargo, en la mayoría de los casos se da una disminución en la variancia del error para pronósticos a 12 meses. Solamente en el caso de los pronósticos bayesianos y de uno de

los pronósticos de componentes no observables se mantiene el patrón de variancia creciente hasta el horizonte de los 12 meses. Sin embargo, como puede apreciarse en el cuadro 14 del anexo, en general las variancias de los errores de pronóstico a 12 meses no pueden considerarse significativamente distintas de las de errores a 3 y 6 meses, con la parcial excepción de los pronósticos de componentes no observables que consideran estacionalidad.

Cuadro 7. Variancias de los errores de pronóstico

	h = 1	h = 3	h = 6	h = 12
UC_MA SV	0,00004	0,00021	0,00056	0,00041
ARMA(1,1) SV	0,00004	0,00020	0,00052	0,00034
ARMA(1,1)	0,00003	0,00017	0,00049	0,00032
AR(2) SAR(2)	0,00009	0,00027	0,00046	0,00031
ARMA(3,2) SMA(1)	0,00006	0,00018	0,00046	0,00024
GARCH(1,1), ARMA(1,1)	0,00003	0,00018	0,00053	0,00035
GARCH(1,1), AR(2) SAR(2)	0,00013	0,00037	0,00058	0,00043
GARCH(1,1), ARMA(3,2) SMA(1)	0,00005	0,00015	0,00043	0,00027
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,00003	0,00016	0,00045	0,00034
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,00012	0,00033	0,00051	0,00032
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,00005	0,00014	0,00040	0,00021
UC_TC	0,00003	0,00005	0,00013	0,00009
UC_TCS1	0,00004	0,00010	0,00037	0,00033
UC_TCS2	0,00003	0,00001	0,00022	0,00363
BMA	**0,00005**	**0,00009**	**0,00013**	**0,00021**
WALS	**0,00004**	**0,00008**	**0,00014**	**0,00031**
Factores dinámicos	**0,00004**	**0,00009**	**0,00018**	**0,00053**

Fuente: Elaboración propia.

3.7. Desempeño de combinación de pronósticos

A partir de los resultados de la evaluación realizada en las secciones 3.2 – 3.6 se encontró que los pronósticos que consistentemente mostraron mejor desempeño son los correspondientes a modelos UC simples y con volatilidad estocástica (UC_TC, UC_TCS1, UC_MA SV), y los pronósticos ARMA(1,1) homocedástico, GARCH y con volatilidad estocástica. Estos seis pronósticos se combinaron a cada horizonte según el procedimiento de Capistrán y Timmermann (CT) y se repitió la evaluación realizada en secciones anteriores. Los resultados se muestran en el gráfico 3 y los cuadros 8 y 9. Los resultados de la evaluación del promedio simple de los pronósticos son cualitativamente muy similares y se pueden solicitar a los autores.

Como puede verse, las combinaciones de pronósticos son insesgadas a todos los horizontes, sus errores siguen los patrones propios de errores óptimos y en general tienen un desempeño aceptable en la predicción de la dirección de cambios en la inflación. Además, para el horizonte más largo de 12 meses, los errores de pronóstico de la combinación resultan significativamente menores que los de todos los modelos (excepto UC_TC y UC_TC1). A horizontes más cortos, la combinación es más precisa que algunos

modelos no incluidos pero en general no es significativamente más precisa que los pronósticos que la integran. Las únicas diferencias entre la evaluación del promedio simple y de esta combinación son que el promedio simple no es insesgado para h = 6 y h = 12, y que su capacidad de pronóstico es menor a h = 12, según la prueba HLN y el porcentaje de acierto de cambios de dirección. Para horizontes h = 1 y h = 3, la prueba HLN no muestra diferencias significativas entre ambos, pero el promedio simple es más preciso que varios de los pronósticos que integran la combinación.

Gráfico 3. Combinación de pronósticos

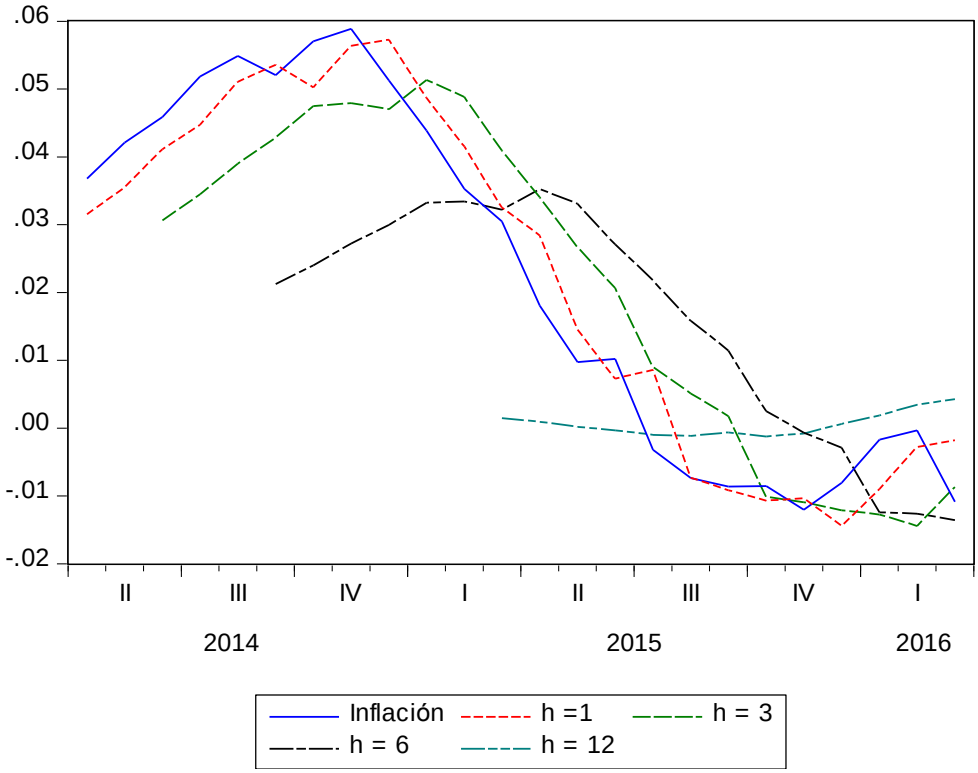

Fuente: Elaboración propia

Cuadro 8. Evaluación combinación de pronósticos
-Varias pruebas-

	Valor p para hipótesis nula de insesgamiento	% de acierto dirección de cambios en inflación	Valores p para pruebas de autocorrelación [1/]	Variancia de errores de pronóstico
h=1	1.00	0.6087	0.0614	0.00003
h=3	1.00	0.6190	0.2075	0.00014
h=6	1.00	0.5000	0.2396	0.00038
h=12	1.00	0.5833	0.3173	0.00016

[1/] h=1: Wilcoxon, resto: Cumby y Huizinga

Fuente: Elaboración propia

Cuadro 9. Valores p de prueba de capacidad de pronóstico de Harvey, Leybourne y Newbold (1997)

-En negrita si error de pronóstico es significativamente menor en columna que en fila-

	Combinación			
	h = 1	**h = 3**	**h = 6**	**h = 12**
UC_MA SV	0.0971	0.0790	0.1205	**0.0196**
ARMA(1,1) SV	0.1101	0.0985	0.1046	**0.0075**
ARMA(1,1)	0.3337	0.1154	0.1014	**0.0047**
AR(2) SAR(2)	**0.0118**	0.0581	0.0907	**0.0028**
ARMA(3,2) SMA(1)	**0.0032**	**0.0325**	**0.0225**	**0.0004**
GARCH(1,1), ARMA(1,1)	0.4105	0.1259	0.1221	**0.0091**
GARCH(1,1), AR(2) SAR(2)	**0.0106**	**0.0378**	0.0780	**0.0085**
GARCH(1,1), ARMA(3,2) SMA(1)	**0.0318**	0.0649	0.0609	**0.0011**
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0.1862	0.0769	0.0584	**0.0017**
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0.0133**	**0.0438**	0.0831	**0.0050**
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	**0.0121**	**0.0331**	**0.0224**	**0.0001**
UC_TC	0.5237	0.9981	0.9802	0.4023
UC_TCS1	0.1262	0.9718	0.4650	0.0832
UC_TCS2	0.4959	0.9997	0.7627	**0.0045**
BMA	**0.0285**	0.3855	0.3349	**0.0062**
WALS	**0.0418**	0.4921	0.3284	**0.0036**
Factores dinámicos	0.0526	0.5232	0.3039	**0.0072**

Fuente: Elaboración propia

3.8. Robustez de resultados de la evaluación

La muestra de evaluación de los pronósticos incluye un período de inflación históricamente baja iniciado en los primeros meses de 2015 y que incluye 9 meses de inflación negativa. Con el fin de verificar si los resultados de la evaluación presentada son sensibles a la escogencia de una muestra con esa particularidad, se repitió el ejercicio excluyendo los años 2015-2016. La muestra alternativa de evaluación comprende de enero-2013 a diciembre-2014.

Los cuadros 15 y 16, anexo 6.4, presentan un resumen de los resultados de la evaluación con esta muestra alternativa. Al considerar todos los criterios, los resultados de las evaluaciones son muy similares en términos generales, y no alteran las conclusiones derivadas del análisis con la muestra original. No obstante, hay dos diferencias. La primera es que los pronósticos para esta muestra muestran un mejor ajuste (RECM, Theil), especialmente para horizontes mayores a 1 mes, y esta mejora se incrementa con el largo del horizonte. El mejor ajuste general se refleja en que los pronósticos más precisos son menos dominantes en esta muestra, según la prueba HLN. La segunda diferencia es que la variancia de los errores de pronóstico es creciente con el horizonte en casi todos los casos, lo que concuerda con propiedades de pronósticos óptimos.

Sin embargo, estas diferencias no cambian el ordenamiento de los pronósticos, pues los que consistentemente mostraron el mejor desempeño son los mismos seis que con la

muestra original: UC_TC, UC_TCS1, UC_MA_SV, ARMA(1,1), ARMA(1,1)_SV y GARCH(1,1)_ARMA(1,1). Así pues, la evaluación con muestra alternativa resulta en la misma combinación de pronósticos ya descrita.

4. Conclusiones

El objetivo de este trabajo fue dotar al BCCR de un conjunto de pronósticos de inflación obtenidos a partir de modelos univariados con distintos supuestos sobre la forma funcional y las propiedades estadísticas del proceso generador de datos de la inflación. Las propiedades de estos pronósticos fueron evaluadas rigurosamente siguiendo las recomendaciones de la literatura sobre pronósticos óptimos, y los pronósticos con el mejor desempeño se usaron en una combinación.

En general, los pronósticos obtenidos a partir de modelos UC mostraron el mejor desempeño, incluyendo la variante con volatilidad estocástica. Le siguen todas las variantes del modelo ARMA(1,1), para el que la inclusión de volatilidad estocástica también resulta en una mejora en la capacidad de pronóstico, en este caso a horizontes más largos. Por el contrario, la inclusión de efectos de retroalimentación entre la media y la variancia de la inflación en los modelos no incrementó perceptiblemente la calidad de sus pronósticos. Los mejores pronósticos se comparan favorablemente con los pronósticos bayesianos actualmente en uso, en particular a los horizontes más cortos de 1 y 3 meses.

Combinar los pronósticos resulta una mejoría en las propiedades de los pronósticos a todos los horizontes: las combinaciones son insesgadas, sus errores muestran los patrones propios de errores de pronóstico óptimos, y la capacidad de pronóstico mejora especialmente al horizonte de 12 meses. Consideramos que para pronóstico a horizontes de 1 a 3 meses puede evaluarse si utilizar el promedio simple o los pronósticos UC, que tienden a dominar a estos plazos. Si bien los modelos univariados como los estimados en este estudio esencialmente se utilizan para pronóstico de corto plazo, nuestra recomendación en caso de realizar con ellos pronósticos a horizontes mayores a 3 meses es aplicar la combinación CT propuesta, en conjunto con los pronósticos bayesianos evaluados.

5. Referencias

Aiolfi, M., & Timmermann, A. (2006). Persistence in forecasting performance and conditional combination strategies. *Journal of Econometrics, 135*(1-2), 31-53.

Ball, L. (1990). *Why does high inflation raise inflation uncertainty? (NBER Working Paper No. 3224).* National Bureau of Economic Research.

Ball, L., & Cecchetti, S. (1990). Inflation and uncertainty at short and long horizons. *Brookings Papers on Economic Activity, 1*, 215-245.

Bates, J. M., & Granger, C. W. (1969). The combination of forecasts. *Operational Research Quarterly, 20*(4), 451-468.

Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedastic. *Journal of Econometrics*, 307-327.

Broto, C. (2008). *Inflation Targeting in Latin America: Empirical Analysis Using GARCH Models (Documentos de Trabajo No. 0826).* Banco de España.

Burguess, S., Fernandez-Corugedo, E., Groth, C., Harrison, R., Monti, F., Theodoridis, K., & Waldron, M. (2013). *The Bank of England's forecasting platoform: COMPASS, MAPS, EASE and the suite of models (Working Paper No. 471).* Bank of England.

Capistrán, C., & Timmermann, A. (2009). Forecast Combination with Entry and Exit of Experts. *Journal of Business and Economic Statistics*, 428-440.

Chan , J. (2015). The Stochastic Volatility in Mean Model with Time Varying Parameters. *Australian National University*, 1-26.

Chan, J. (2013). Moving Average Stochastic Volatility Modeles with Application to Inflation Forecast. *Australian National University*, 1-25.

Chan, J., & Hsiao, C. (2013). Estimation of Stochastic Volatility Models with Heavy Tails and Serial Dependence. *Australian National University*, 1-21.

Chavarría , J., & Chaverri, C. (2015). *Pronósticos de inflación mediante técnicas bayesianas.* Documento de Investigación 05-2015: San José. Banco Central de Costa Rica.

Chong, Y. Y., & Hendry, D. (1986). Econometric Evaluation of LinearMacro-Economic Models. *Review of Economic Studies, 53*, 671-690.

Claeskens, G., Magnus, J. R., Vasnev, A., & Wang, W. (2016). *The forecast combination puzzle: a simple theoretical explanation (KBI 1604) .* Lovaina, Bélgica.: KU Leuven.

Conrad, C., & Karanassos, M. (2008). *Modeling Volatility Spillovers between the Variabilities of US Inflation and Output: theUECCC GARCH Model (Discussion Paper Series No. 475).* Universidad de Heildelberg.

Cumby, R. E., & Huizinga, J. (1992). Testing the autocorrelation structure of disturbances in ordinary least squares and instrumental variables regression. *Econometrica, 60*, 185-195.

Deutsch, M., Granger, C. W., & Teräsvirta, T. (1994). The Combination of Forecasts Using Changing Weights. *International Journal of Forecasting, 10*, 47-57.

Diebold, F. X., & López, J. A. (1996). Forecast Evaluation and Combination. In G. S. Maddala, & C. R. Rao, *Handbook of Statistics* (pp. 241-268). Amsterdam: North-Holland.

Diebold, F. X., & Pauly, P. (1987). Structural change and the combination of forecasts. *Journal of Forecasting, 6*(1), 21-40.

Diebold, F. X., & Pauly, P. (1990). The use of prior information in forecasts. *International Journal of Forecasting, 6*(4), 503-508.

Diebold, F., & Mariano, R. (1995). Comparing Predictive Accuracy. *Journal of Business and Economic Statistics, 13*, 253-265.

Dufour, J.-M. (1981). Rank Tests for Serial Dependence. *Journal of Time Series Analysis, 2*(3), 117-128.

Engle, R. (1982). Autoregressive Conditional Heteroskedasticity with estimates of the variance of United Kingdom Inflation. *Econometrica, 50*(1), 987-1007.

Engle, R. (1983). Estimates of the variance of US inflation based upon the ARCH model. *Journal of Money, Credit and Banking, 15*, 286-301.

Evans, M. (1991). Discovering the link between the inflation rate and inflation uncertainty. *Journal of Money, Credit and Banking*, 169-184.

Gómez, V., & Maravall, A. (1994). Prediction and Interpolation for Nonstationary Series with the Kalman Filter. *Journal of the American Statistical Association*, 611-624.

Gómez, V., & Maravall, A. (1996). Programs TRAMO and SEATS, Instruction for User (Beta Version: september 1996). *Banco de España Working Papers 9628*.

Granger, C. W., & Newbold, P. (1973). Some Comments on the Evaluation of Economic Forecasts. *Applied Economics, 5*, 35-47.

Granger, C. W., & Newbold, P. (1977). *Forecasting Economic Time Series.* Nueva York: Academic Press.

Granger, C. W., & Ramanathan, R. (1984). Improved methods of combining forecasts. *Journal of Forecasting, 3*(2), 197-204.

Harvey, A., & Shephard, N. (1993). Structural Time Series Models. *Handbook of Statistics*, 261-302.

Harvey, D., Leybourne, S., & Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of Forecasting, 13*, 281-291.

Hoffmaister, A., Saborío, G., & Solano, I. (2001). *Combinación de las proyecciones de inflación (Nota de Investigación No 01-01, División Económica) .* San José: Banco Central de Costa Rica.

IHS Global Inc. (2016). *Eviews 9. User's Manual I*. Irvine, CA.

Jones, R. (1980). Maximum Likelihood Fitting of ARMA Models to Time Series With Missing Observations. *Technometrics, 22*, 389-395.

Jore, A. S. (2012). *Evaluating real-time forecasts from Norges Bank's System of Averaging Models (Staff Memo No 12/2012).* Norges Bank.

Karanasos, M., Karanassou, M., & Fountas, S. (2004). Analyzing US Inflation by a GARCH Model with Simultaneous Feedback. *WSEAS Transactions on information science and applications*, 767-72.

Kontonikas, A. (2004). Inflation and inflation uncertainty in the United Kingdom: Evidence from GARCH modelling. *Journal of Economic Modelling, 21*, 525-543.

Lee, J., & Strazicich, M. (2003). Minimum Lagrange Multiplier Unit Root Tests with Two Structural Breaks. *Review of Economics and Statistics, 85*(4), 1082-1089.

Mincer, J., & Zarnowitz, V. (1969). The Evaluation of Economic Forecasts. In J. Mincer, *Economic Forecasts and Expectations: Analyses of Forecasting Behavior (NBER Studies in Business Cycles, Vol. 19).* Cambridge, MA: National Bureau of Economic Research.

Mora, C., & Rodríguez, A. (2009). *Combinación de proyecciones de inflación: Nuevas metodologías.* Documento de Investigación 010-2009: San José. Banco Central de Costa Rica.

Okun, A. (1971). The Mirage of Steady Inflation. *Brooking Papers on Economic Activity*, 485-498.

Patton, A., & Timmermann, A. (2004). *Properties of Optimal Forecasts under Asymmetric Loss and Nonlinearity.* Londres: London School of Economics y Universidad de California en San Diego.

Pesaran, H., & Timmermann, A. (2007). Selection of Estimation Window in the Presence of Breaks. *Journal of Econometrics, 137*, 134-161.

Ramon, H. (2008). Forecasting the Volatility of Philippine Inflation using GARCH Models. *Bangko Sentral ng Pilipinas*, 1-26.

Russell, B. (2014). Arch and Structural Breaks in United States Inflation. *Applied Economic Letters, 21*(14), 1-17.

Smith, J., & Wallis, K. F. (2007). *A Simple Explanation of the Forecast Combination Puzzle (Department of Economics Staff Paper).* Warwick: Universidad de Warwick.

Smith, J., & Wallis, K. F. (2009). A Simple Explanation of the Forecast Combination Puzzle. *Oxford Bulletin of Economics and Statistics, 7*(3), 331-355.

Solera, Á. (2002). *Inflación e incertidumbre inflacionaria: evidencia para Costa Rica (Documento de Investigación DIE-14-2001-DI).* Banco Central de Costa Rica.

Stekler, H. O. (1991). Macroeconomic Forecast Evaluation Techniques. *International Journal of Forecasting, 7*, 375-384.

Stock, J., & Watson, M. (2004). Combination of forecasts of output growth in a seven-country data set. *Journal of Forecasting, 23*(6), 405-430.

Taylor, S. (1982). Financial returns modelled by the product of two stochastic processes -a study of daily sugar prices 1961-79. In O. D. Anderson (Ed.), *Time Series Analysis: Theory and Practice* (Vol. 1, pp. 203-226). Amsterdam: North-Holland.

Taylor, S. (2005). *Asset Price Dynamics, Volatility, and Prediction.* Princeton University Press.

Timmermann, A. (2006). Forecast combinations. In C. W. Granger, & A. Timmermann (Eds.), *Handbook of Economic Forecasting* (Vol. 1). North-Holland.

Timmermann, A. (2006a). An Evaluation of the World Economic Outlook Forecasts (IMF Working Paper WP/06/59). Washington, D.C.: IMF.

Timmermann, A. (2006b). Forecast Combinations. In G. Elliot, C. W. Granger, & A. Timmermann, *Forecasting, Handbook of Economic Forecasting.* Elsevier.

West, K. D. (2006). Forecast Evaluation. In G. Elliot, C. W. Granger, & A. Timmermann, *Handbook of Economic Forecasting.* Elsevier.

Zivot, E., & Andrews, K. (1992). Further Evidence on the Great Crash, the Oil Price Shock and the Unit Root Hypothesis. *Journal of Business and Economic Statistics, 10*(10), 251-270.

6. Anexos

6.1. Raíz unitaria

Cuadro 10.Pruebas de raíz unitaria para la serie de inflación interanual

	Cambio en nivel	
	Valor p	**Estadístico**
Zivot-Andrews (1 cambio)	0,022787	-3,9302
Lee-Strazicich (2 cambios)		-3,7432
Lee-Strazicich (4 cambios)		-4,3056

Pruebas realizadas con 9 rezagos para 2000m1 – 2016m5.
Valores críticos para Lee y Strazicich, para 2 cambios estructurales y T=100:
1%: -4.54 / 5%: -3.84 / 10%: -3.50
Fuente: Elaboración propia.

6.2. Algoritmos de selección de especificaciones ARIMA para inflación

En el caso de Gómez y Maravall (1994) el algoritmo estima, pronostica e interpola modelos de regresión con errores ARIMA en presencia de varias clases de valores atípicos. Para el vector de observaciones de inflación $y = (y_{t1}, y_{t2}, \dots, y_{tN})$ se estima el modelo

$$y_t = z_t'\beta + v_t \quad (19)$$

donde β es un vector de coeficientes de regresión, z_t' es un conjunto de variables de regresión y v_t sigue el proceso ARIMA dado en forma general por

$$\phi(B)\delta(B)z_t = \theta(B)a_t \quad (20)$$

donde B el operador de rezagos, $\phi(B)$ es el polinomio con raíces estacionales autorregresivas, $\delta(B)$ contiene las raíces unitarias asociadas con las diferencias (regular y estacional), $\theta(B)$ es el polinomio de medias móviles y a_t es un ruido blanco i.i.d $(0, \sigma_a)$. Nótese que se supone homocedasticidad. Para la implementación del algoritmo se consideran las siguientes formas multiplicativas:

$$\begin{aligned}
&\delta(B) = (1-B)^d(1-B^s)^D \\
&\phi(B) = \left(1 + \phi_1 B + \cdots + \phi_p B^p\right)(1 + \Phi_1 B^s + \cdots + \Phi_P B^{sxP}) \quad (21) \\
&\theta(B) = \left(1 + \theta_1 B + \cdots + \theta_q B^q\right)(1 + \Theta_1 B^s + \cdots + \Theta_q B^{sxq})
\end{aligned}$$

donde s denota el número de observaciones por año.

La implementación automática del algoritmo estima los parámetros en (1) y (2) mediante máxima verosimilitud exacta (default) o mediante mínimos cuadrados condicionales o incondicionales (opciones). Para ello se utiliza la especificación estado-espacio propuesta por Jones (1980) para estimación ARMA con valores perdidos. Esto permite detectar y corregir varios tipos de valores atípicos, además de interpolar de manera óptima dichos valores perdidos.

El algoritmo de selección y estimación implementado por Eviews 9.5 comprende tres bloques principales (IHS, 2016):

a. *Seleccionar cuáles transformaciones realizar a la variable dependiente*: se determina si se toma las variables en logaritmos, mediante una regla de decisión basada en regresiones que usan las variables en niveles y en logaritmos.

b. *Seleccionar el nivel de diferenciación a aplicar a la variable dependiente*: se determina cuál debería ser el orden de diferenciación, mediante la prueba de raíz unitaria de Kwiatkowski, Phillips, Schmidt, and Shin (1992).

c. *Seleccionar el orden de los términos ARMA:* la selección del orden de los términos se realiza a partir de los criterios de información de Akaike, de Schwarz y de Hannan-Quinn, o bien, mediante el error cuadrático medio de pronósticos dentro de muestra.

6.3. Pruebas varias

Cuadro 11. Valores p de prueba de capacidad de pronóstico de Harvey, Leybourne y Newbold (1997)

-En negrita si error de pronóstico es significativamente menor en columna que en fila-

h = 1

	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1) , AR(2) SAR(2)	GARCH(1,1) , ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS 1	UC_TC S2	BMA	WALS	Factores dinámicos
UC_MA SV		0,7114	**0,0452**	0,9936	0,9988	**0,0245**	0,9931	0,9680	0,3248	0,9910	0,9929	0,0988	0,1658	0,1866	0,7846	0,7013	0,6460
ARMA(1,1) SV	0,2886		**0,0236**	0,9952	0,9994	**0,0216**	0,9935	0,9784	0,1546	0,9914	0,9960	0,0910	0,1591	0,1563	0,7555	0,6652	0,6071
ARMA(1,1)	0,9548	0,9764		0,9943	0,9994	0,1043	0,9933	0,9880	0,9828	0,9915	0,9963	0,3113	0,6064	0,3642	0,9217	0,8794	0,8426
AR(2) SAR(2)	**0,0064**	**0,0048**	**0,0057**		0,1898	**0,0060**	0,9622	**0,0152**	**0,0060**	0,9447	0,1342	**0,0094**	**0,0094**	**0,0132**	0,0782	0,0598	0,0527
ARMA(3,2) SMA(1)	**0,0012**	**0,0006**	**0,0006**	0,8102		**0,0007**	0,9476	**0,0003**	**0,0006**	0,9360	0,5388	**0,0016**	**0,0026**	**0,0025**	0,0650	**0,0447**	**0,0387**
GARCH(1,1), ARMA(1,1)	0,9755	0,9784	0,8957	0,9940	0,9993		0,9931	0,9874	0,9686	0,9913	0,9958	0,3943	0,7453	0,4385	0,9428	0,9125	0,8848
GARCH(1,1), AR(2) SAR(2)	**0,0069**	**0,0065**	**0,0067**	**0,0378**	0,0524	**0,0069**		**0,0145**	**0,0071**	0,1131	**0,0376**	**0,0105**	**0,0101**	**0,0131**	**0,0443**	**0,0366**	**0,0334**
GARCH(1,1), ARMA(3,2) SMA(1)	**0,0320**	**0,0216**	**0,0120**	0,9848	0,9997	**0,0126**	0,9855		**0,0177**	0,9815	0,9975	**0,0187**	**0,0319**	**0,0280**	0,3187	0,2394	0,2064
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,6752	0,8454	**0,0172**	0,9940	0,9994	**0,0314**	0,9929	0,9823		0,9910	0,9965	0,1561	0,3169	0,1988	0,8328	0,7580	0,7038
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0,0090**	**0,0086**	**0,0085**	0,0553	0,0640	**0,0087**	0,8869	**0,0185**	**0,0090**		**0,0466**	**0,0130**	**0,0129**	**0,0156**	0,0512	**0,0426**	**0,0390**
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	**0,0071**	**0,0040**	**0,0037**	0,8658	0,4612	**0,0042**	0,9624	**0,0025**	**0,0035**	0,9534		**0,0078**	**0,0102**	**0,0092**	0,1023	0,0759	0,0666
UC_TC	0,9012	0,9090	0,6887	0,9906	0,9984	0,6057	0,9895	0,9813	0,8439	0,9870	0,9922		0,8658	0,5208	0,9860	0,9774	0,9668
UC_TCS1	0,8342	0,8409	0,3936	0,9906	0,9974	0,2547	0,9899	0,9681	0,6831	0,9871	0,9898	0,1342		0,3044	0,9130	0,8721	0,8406
UC_TCS2	0,8134	0,8437	0,6358	0,9868	0,9975	0,5615	0,9869	0,9720	0,8012	0,9844	0,9908	0,4792	0,6956		0,9926	0,9896	0,9824
BMA	0,2154	0,2445	0,0783	0,9218	0,9350	0,0572	0,9557	0,6813	0,1672	0,9488	0,8977	**0,0140**	0,0870	**0,0074**		0,0502	0,0792
WALS	0,2987	0,3348	0,1206	0,9402	0,9553	0,0875	0,9634	0,7606	0,2420	0,9574	0,9241	**0,0226**	0,1279	**0,0104**	0,9498		0,1415
Factores dinámicos	0,3540	0,3929	0,1574	0,9473	0,9613	0,1152	0,9666	0,7936	0,2962	0,9610	0,9334	**0,0332**	0,1594	**0,0176**	0,9208	0,8585	
Casos en que error de columna es menor al de fila:	6	6	9	1	0	9	0	5	6	0	2	9	6	9	1	3	3

h = 3

	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1) , AR(2) SAR(2)	GARCH(1,1) , ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS 1	UC_TC S2	BMA	WALS	Factores dinámicos
UC_MA SV		0,7991	0,5718	0,9524	0,9710	0,1773	0,9728	0,8992	0,8949	0,9650	0,9799	**0,0227**	**0,0338**	**0,0082**	0,1596	0,1230	0,1130
ARMA(1,1) SV	0,2009		0,1281	0,9698	0,9808	0,0756	0,9803	0,9002	0,9282	0,9738	0,9928	**0,0345**	**0,0496**	**0,0152**	0,1483	0,1168	0,1086
ARMA(1,1)	0,4282	0,8719		0,9670	0,9853	0,0956	0,9773	0,9790	0,9773	0,9715	0,9949	**0,0359**	0,0535	**0,0145**	0,1660	0,1275	0,1172
AR(2) SAR(2)	**0,0476**	**0,0302**	**0,0330**		0,5982	**0,0371**	0,9503	0,0933	0,0768	0,9086	0,6298	**0,0311**	**0,0385**	**0,0190**	0,0731	0,0618	0,0592
ARMA(3,2) SMA(1)	**0,0290**	**0,0192**	**0,0147**	0,4018		**0,0176**	0,7828	**0,0217**	**0,0367**	0,7455	0,4947	**0,0130**	**0,0174**	**0,0062**	**0,0337**	**0,0260**	**0,0243**
GARCH(1,1), ARMA(1,1)	0,8227	0,9244	0,9044	0,9629	0,9824		0,9742	0,9764	0,9648	0,9683	0,9906	**0,0322**	**0,0495**	**0,0112**	0,2022	0,1535	0,1397
GARCH(1,1), AR(2) SAR(2)	**0,0272**	**0,0197**	**0,0227**	**0,0497**	0,2172	**0,0258**		**0,0458**	**0,0428**	0,1052	0,2012	**0,0220**	**0,0270**	**0,0141**	**0,0475**	**0,0411**	**0,0398**
GARCH(1,1), ARMA(3,2) SMA(1)	0,1008	0,0998	**0,0210**	0,9067	0,9783	**0,0236**	0,9542		0,6426	0,9453	0,9920	**0,0205**	**0,0285**	**0,0083**	0,0868	0,0640	0,0582
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,1051	0,0718	**0,0227**	0,9232	0,9633	**0,0352**	0,9572	0,3574		0,9473	0,9970	**0,0291**	**0,0398**	**0,0137**	0,0952	0,0721	0,0660
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0,0350**	**0,0262**	**0,0285**	0,0914	0,2545	**0,0317**	0,8948	0,0547	0,0527		0,2423	**0,0249**	**0,0310**	**0,0159**	0,0529	**0,0457**	**0,0443**
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	**0,0201**	**0,0072**	**0,0051**	0,3702	0,5053	**0,0094**	0,7988	**0,0080**	**0,0030**	0,7577		**0,0142**	**0,0180**	**0,0072**	**0,0367**	**0,0279**	**0,0258**
UC_TC	0,9773	0,9655	0,9641	0,9689	0,9870	0,9678	0,9780	0,9795	0,9709	0,9751	0,9858		0,9898	**0,0004**	0,9863	0,9646	0,9540
UC_TCS1	0,9662	0,9504	0,9465	0,9615	0,9826	0,9505	0,9730	0,9715	0,9602	0,9690	0,9820	**0,0102**		**0,0002**	0,8697	0,7877	0,7596
UC_TCS2	0,9918	0,9848	0,9855	0,9810	0,9938	0,9888	0,9859	0,9917	0,9863	0,9841	0,9928	0,9996	0,9998		0,9993	0,9976	0,9963
BMA	0,8404	0,8517	0,8340	0,9269	0,9663	0,7978	0,9525	0,9132	0,9048	0,9471	0,9633	**0,0137**	0,1303	**0,0007**		0,0904	0,1452
WALS	0,8770	0,8832	0,8725	0,9382	0,9740	0,8465	0,9589	0,9360	0,9279	0,9543	0,9721	**0,0354**	0,2123	**0,0024**	0,9096		0,2869
Factores dinámicos	0,8870	0,8914	0,8828	0,9408	0,9757	0,8603	0,9602	0,9418	0,9340	0,9557	0,9742	**0,0460**	0,2404	**0,0037**	0,8548	0,7131	
Casos en que error de columna es menor al de fila:	5	5	7	1	0	7	0	3	3	0	0	15	10	16	3	4	4

Cuadro 11 (cont.) Valores p de prueba de capacidad de pronóstico de Harvey, Leybourne y Newbold (1997)

-En negrita si error de pronóstico es significativamente menor en columna que en fila-

h = 6

	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1) , AR(2) SAR(2)	GARCH(1,1) , ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS 1	UC_TC S2	BMA	WALS	Factores dinámicos
UC_MA SV		0,9380	0,9371	0,9512	0,9912	0,8149	0,9749	0,9813	0,9814	0,9662	0,9963	**0,0341**	0,0546	0,0788	0,1697	0,1648	0,1711
ARMA(1,1) SV	0,0620		0,8259	0,9200	0,9921	0,0877	0,9924	0,9924	0,9884	0,9855	0,9987	**0,0356**	0,0524	0,0674	0,1260	0,1240	0,1299
ARMA(1,1)	0,0629	0,1741		0,9517	0,9903	**0,0301**	0,9507	0,9934	0,9937	0,9387	0,9989	**0,0347**	**0,0490**	0,0628	0,1151	0,1130	0,1185
AR(2) SAR(2)	**0,0488**	0,0800	**0,0483**		0,9843	**0,0168**	0,6780	0,9794	0,9952	0,5917	0,9987	**0,0316**	**0,0420**	0,0549	0,0970	0,0950	0,0997
ARMA(3,2) SMA(1)	**0,0088**	**0,0079**	**0,0097**	**0,0157**		**0,0086**	**0,0122**	**0,0221**	0,0649	**0,0095**	0,6089	**0,0075**	**0,0097**	**0,0123**	**0,0172**	**0,0179**	**0,0196**
GARCH(1,1), ARMA(1,1)	0,1851	0,9123	0,9699	0,9832	0,9914		0,9736	0,9895	0,9924	0,9690	0,9980	**0,0381**	0,0565	0,0744	0,1484	0,1441	0,1500
GARCH(1,1), AR(2) SAR(2)	**0,0251**	**0,0076**	**0,0493**	0,3220	0,9878	**0,0264**		0,9723	0,9498	0,1796	0,9988	**0,0280**	**0,0387**	0,0517	0,0904	0,0895	0,0941
GARCH(1,1), ARMA(3,2) SMA(1)	**0,0187**	**0,0076**	**0,0066**	**0,0206**	0,9779	**0,0105**	**0,0277**		0,7762	**0,0087**	0,9996	**0,0216**	**0,0278**	**0,0363**	0,0586	0,0585	0,0622
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	**0,0186**	**0,0116**	**0,0063**	**0,0048**	0,9351	**0,0076**	0,0502	0,2238		**0,0291**	0,9979	**0,0218**	**0,0259**	**0,0350**	0,0552	0,0540	0,0566
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0,0338**	**0,0145**	0,0613	0,4083	0,9905	**0,0310**	0,8204	0,9913	0,9709		0,9991	**0,0289**	**0,0407**	0,0523	0,0922	0,0916	0,0969
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	**0,0037**	**0,0013**	**0,0011**	**0,0013**	0,3911	**0,0020**	**0,0012**	**0,0004**	**0,0021**	**0,0009**		**0,0085**	**0,0093**	**0,0130**	**0,0175**	**0,0178**	**0,0193**
UC_TC	0,9659	0,9644	0,9653	0,9684	0,9925	0,9619	0,9720	0,9784	0,9782	0,9711	0,9915		0,9783	0,7861	0,9888	0,9934	0,9955
UC_TCS1	0,9454	0,9476	0,9510	0,9580	0,9903	0,9435	0,9613	0,9722	0,9741	0,9593	0,9907	**0,0217**		0,1944	0,6884	0,7030	0,7361
UC_TCS2	0,9212	0,9326	0,9372	0,9451	0,9877	0,9256	0,9483	0,9637	0,9650	0,9477	0,9870	0,2139	0,8056		0,9975	0,9962	0,9888
BMA	0,8303	0,8740	0,8849	0,9030	0,9828	0,8516	0,9096	0,9414	0,9448	0,9078	0,9825	**0,0112**	0,3116	**0,0025**		0,4784	0,5298
WALS	0,8352	0,8760	0,8870	0,9050	0,9821	0,8559	0,9105	0,9415	0,9460	0,9084	0,9822	**0,0066**	0,2970	**0,0038**	0,5216		0,5879
Factores dinámicos	0,8289	0,8701	0,8815	0,9003	0,9804	0,8500	0,9059	0,9378	0,9434	0,9031	0,9807	**0,0045**	0,2639	**0,0112**	0,4702	0,4121	
Casos en que error de columna es menor al de fila:	7	6	6	4	0	8	3	2	1	4	0	15	8	7	2	2	2

h = 12

	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1) , AR(2) SAR(2)	GARCH(1,1) , ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS 1	UC_TC S2	BMA	WALS	Factores dinámicos
UC_MA SV		1,0000	1,0000	1,0000	1,0000	0,9999	0,9992	1,0000	1,0000	1,0000	1,0000	**0,0124**	**0,0092**	0,7656	0,2354	0,3259	0,3962
ARMA(1,1) SV	**0,0000**		0,9999	1,0000	1,0000	0,3752	0,9469	1,0000	0,9999	0,9998	1,0000	**0,0043**	**0,0018**	0,6351	0,0641	0,1144	0,1713
ARMA(1,1)	**0,0000**	**0,0001**		1,0000	0,9997	**0,0000**	0,2563	1,0000	0,9998	0,3967	1,0000	**0,0025**	**0,0007**	0,5511	**0,0268**	0,0544	0,0929
AR(2) SAR(2)	**0,0000**	**0,0000**	**0,0000**		0,9902	**0,0000**	**0,0104**	0,9990	0,9995	**0,0001**	1,0000	**0,0014**	**0,0003**	0,4560	**0,0099**	**0,0228**	**0,0447**
ARMA(3,2) SMA(1)	**0,0000**	**0,0000**	**0,0003**	**0,0098**		**0,0000**	**0,0000**	**0,0431**	0,6079	**0,0004**	0,9988	**0,0002**	**0,0001**	0,2773	**0,0021**	**0,0040**	**0,0079**
GARCH(1,1), ARMA(1,1)	**0,0001**	0,6248	1,0000	1,0000	1,0000		0,9063	1,0000	1,0000	0,9998	1,0000	**0,0053**	**0,0018**	0,6417	0,0664	0,1145	0,1718
GARCH(1,1), AR(2) SAR(2)	**0,0008**	0,0531	0,7437	0,9896	1,0000	0,0937		1,0000	0,9996	0,7332	1,0000	**0,0055**	**0,0038**	0,5716	0,0599	0,0997	0,1426
GARCH(1,1), ARMA(3,2) SMA(1)	**0,0000**	**0,0000**	**0,0000**	**0,0010**	0,9569	**0,0000**	**0,0000**		0,9708	**0,0000**	1,0000	**0,0005**	**0,0001**	0,3722	**0,0039**	**0,0103**	**0,0226**
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	**0,0000**	**0,0001**	**0,0002**	**0,0005**	0,3921	**0,0000**	**0,0004**	**0,0292**		**0,0002**	0,9997	**0,0010**	**0,0002**	0,2691	**0,0033**	**0,0061**	**0,0112**
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0,0000**	**0,0002**	0,6033	0,9999	0,9996	**0,0002**	0,2668	1,0000	0,9998		1,0000	**0,0027**	**0,0008**	0,5539	**0,0283**	0,0587	0,0993
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	**0,0000**	**0,0000**	**0,0000**	**0,0000**	**0,0012**	**0,0000**	**0,0000**	**0,0000**	**0,0003**	**0,0000**		**0,0001**	**0,0000**	0,1112	**0,0001**	**0,0004**	**0,0012**
UC_TC	0,9876	0,9957	0,9975	0,9986	0,9998	0,9947	0,9945	0,9995	0,9990	0,9973	0,9999		0,9534	0,9954	0,9989	0,9987	0,9944
UC_TCS1	0,9908	0,9982	0,9993	0,9997	0,9999	0,9982	0,9962	0,9999	0,9998	0,9992	1,0000	**0,0466**		0,9636	0,9958	0,9934	0,9697
UC_TCS2	0,2344	0,3649	0,4489	0,5440	0,7227	0,3583	0,4284	0,6278	0,7309	0,4461	0,8888	**0,0046**	**0,0364**		0,0708	0,0968	0,1333
BMA	0,7646	0,9359	0,9732	0,9901	0,9979	0,9336	0,9401	0,9961	0,9967	0,9717	0,9999	**0,0011**	**0,0042**	0,9292		0,6709	0,6691
WALS	0,6741	0,8856	0,9456	0,9772	0,9960	0,8855	0,9003	0,9897	0,9939	0,9413	0,9996	**0,0013**	**0,0066**	0,9032	0,3291		0,6655
Factores dinámicos	0,6038	0,8287	0,9071	0,9553	0,9921	0,8282	0,8574	0,9774	0,9888	0,9007	0,9988	**0,0056**	**0,0303**	0,8667	0,3309	0,3345	
Casos en que error de columna es menor al de fila:	10	7	5	4	1	7	5	3	1	5	0	16	15	0	7	5	5

Fuente: Elaboración propia.

Cuadro 12. Resultado de la prueba de inclusión de pronósticos de Chong y Hendry (1986)

-Para cada par se indica el pronóstico que incluye al otro-

h=1	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV			Columna	Fila	Fila	Columna		Fila			Fila			Columna	Fila		
ARMA(1,1) SV			Columna		Fila	Columna		Fila			Fila	Columna		Columna			
ARMA(1,1)	Fila	Fila		Fila	Fila	Columna	Fila	Fila	Fila	Fila	Fila						
AR(2) SAR(2)	Columna		Columna			Columna						Columna	Columna	Columna	Columna	Columna	Columna
ARMA(3,2) SMA(1)	Columna	Columna	Columna			Columna						Columna	Columna	Columna	Columna	Columna	Columna
GARCH(1,1), ARMA(1,1)	Fila	Fila	Fila	Fila	Fila		Fila	Fila	Fila	Fila	Fila				Fila		
GARCH(1,1), AR(2) SAR(2)			Columna			Columna						Columna		Columna	Columna	Columna	Columna
GARCH(1,1), ARMA(3,2) SMA(1)	Columna	Columna	Columna			Columna						Columna	Columna	Columna			
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)			Columna			Columna						Columna	Columna	Columna			
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)			Columna			Columna						Columna	Columna	Columna	Columna	Columna	Columna
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	Columna	Columna	Columna			Columna						Columna	Columna	Columna			
UC_TC		Fila		Fila	Fila		Fila	Fila	Fila	Fila	Fila				Fila	Fila	Fila
UC_TCS1				Fila	Fila			Fila	Fila	Fila	Fila				Fila	Fila	Fila
UC_TCS2	Fila	Fila		Fila	Fila		Fila	Fila	Fila	Fila	Fila						
BMA	Columna			Fila	Fila	Columna	Fila			Fila		Columna	Columna			Columna	Columna
WALS				Fila	Fila		Fila			Fila		Columna	Columna		Fila		
Factores dinámicos				Fila	Fila		Fila			Fila		Columna	Columna		Fila		
Casos en que pronóstico de columna incluye al de fila:	5	3	9	0	0	11	0	0	0	0	0	11	9	9	4	5	5

h=3	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV				Fila								Columna		Columna			
ARMA(1,1) SV												Columna	Columna	Columna			
ARMA(1,1)												Columna	Columna	Columna			
AR(2) SAR(2)	Columna											Columna		Columna			
ARMA(3,2) SMA(1)						Columna						Columna	Columna	Columna			
GARCH(1,1), ARMA(1,1)					Fila							Columna	Columna	Columna			
GARCH(1,1), AR(2) SAR(2)												Columna		Columna			
GARCH(1,1), ARMA(3,2) SMA(1)												Columna	Columna	Columna			
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)												Columna	Columna	Columna			
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)												Columna		Columna			
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)												Columna	Columna	Columna			
UC_TC	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila			Columna	Fila	Fila	Fila
UC_TCS1		Fila	Fila		Fila	Fila		Fila	Fila		Fila			Columna	Fila		
UC_TCS2	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila	Fila		Fila	Fila	Fila
BMA												Columna	Columna	Columna			
WALS												Columna		Columna			
Factores dinámicos												Columna		Columna			
Casos en que pronóstico de columna incluye al de fila:	1	0	0	0	0	1	0	0	0	0	0	14	8	16	0	0	0

Cuadro 12 (cont.) Resultado de la prueba de inclusión de pronósticos de Chong y Hendry (1986)

-Para cada par se indica el pronóstico que incluye al otro-

h=6	**UC_MA SV**	**ARMA(1,1) SV**	**ARMA(1,1)**	**AR(2) SAR(2)**	**ARMA(3,2) SMA(1)**	**GARCH(1,1), ARMA(1,1)**	**GARCH(1,1), AR(2) SAR(2)**	**GARCH(1,1), ARMA(3,2) SMA(1)**	**EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)**	**EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)**	**EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)**	**UC_TC**	**UC_TCS1**	**UC_TCS2**	**BMA**	**WALS**	**Factores dinámicos**
UC_MA SV																	
ARMA(1,1) SV																	
ARMA(1,1)																	
AR(2) SAR(2)																	
ARMA(3,2) SMA(1)												Columna	Columna				
GARCH(1,1), ARMA(1,1)																	
GARCH(1,1), AR(2) SAR(2)																	
GARCH(1,1), ARMA(3,2) SMA(1)																	
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)																	
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)																	
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)													Columna				
UC_TC					Fila										Fila	Fila	Fila
UC_TCS1					Fila						Fila						
UC_TCS2																	
BMA												Columna					
WALS												Columna					
Factores dinámicos												Columna					
Casos en que pronóstico de columna incluye al de fila:	0	0	0	0	0	0	0	0	0	0	0	4	2	0	0	0	0

h=12

Ningún pronóstico incluyó a otro.

Fuente: Elaboración propia.

Cuadro 13.Valores p de pruebas de inclusión de pronósticos de Chong y Hendry (1986)

h=1

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 1 \quad 0)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,1344	0,0163	0,1460	0,5157	0,0242	0,0021	0,4148	0,0111	0,0039	0,4161	0,0504	0,1656	0,0057	0,0705	0,0459	0,0398
ARMA(1,1) SV	0,0916		0,0110	0,0370	0,1923	0,0166	0,0018	0,1645	0,0072	0,0029	0,1670	0,0313	0,1591	0,0042	0,0263	0,0172	0,0149
ARMA(1,1)	0,1847	0,1962		0,2191	0,2218	0,0493	0,1280	0,2029	0,1675	0,1422	0,2074	0,2272	0,1931	0,0712	0,0200	0,0130	0,0109
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0002	0,0000	0,0017	0,0000	0,0000	0,0054	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0043		0,0000	0,0022	0,0001	0,0000	0,0029	0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,4047	0,4270	0,0912	0,4476	0,4473		0,2812	0,4080	0,1376	0,3086	0,4164	0,4439	0,4235	0,1442	0,0502	0,0334	0,0282
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0014	0,0005	0,0000	0,0086	0,0214	0,0000	0,0020		0,0000	0,0029	0,0200	0,0000	0,0004	0,0000	0,0008	0,0003	0,0002
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0231	0,0246	0,0296	0,0317	0,0344	0,0115	0,0153	0,0313		0,0175	0,0321	0,0355	0,0238	0,0099	0,0022	0,0014	0,0012
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0001	0,0000	0,0000	0,0001	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
UC_TC	0,8940	0,8763	0,5673	0,6402	0,9112	0,6594	0,4583	0,8698	0,5009	0,5099	0,8801		0,8041	0,3699	0,3777	0,2916	0,2594
UC_TCS1	0,6747	0,8279	0,1161	0,2979	0,8554	0,1612	0,0472	0,7863	0,0822	0,0654	0,7943	0,2297		0,0625	0,2272	0,1633	0,1447
UC_TCS2	0,2193	0,2527	0,1945	0,3364	0,1497	0,2171	0,3362	0,1068	0,1862	0,3216	0,1172	0,3373	0,2801		0,0378	0,0293	0,0273
BMA	0,0013	0,0006	0,0000	0,1592	0,0622	0,0000	0,1580	0,0108	0,0000	0,1617	0,0092	0,0001	0,0006	0,0000		0,0357	0,0410
WALS	0,0035	0,0018	0,0000	0,1738	0,0863	0,0000	0,1617	0,0180	0,0000	0,1711	0,0153	0,0004	0,0018	0,0000	0,1120		0,1310
Factores dinámicos	0,0066	0,0036	0,0000	0,2347	0,1172	0,0001	0,2167	0,0260	0,0000	0,2300	0,0221	0,0008	0,0034	0,0000	0,2231	0,2301	

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 0 \quad 1)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0916	0,1847	0,0000	0,0000	0,4047	0,0000	0,0014	0,0231	0,0000	0,0000	0,8940	0,6747	0,2193	0,0013	0,0035	0,0066
ARMA(1,1) SV	0,1344		0,1962	0,0000	0,0000	0,4270	0,0000	0,0005	0,0246	0,0000	0,0000	0,8763	0,8279	0,2527	0,0006	0,0018	0,0036
ARMA(1,1)	0,0163	0,0110		0,0000	0,0000	0,0912	0,0000	0,0000	0,0296	0,0000	0,0000	0,5673	0,1161	0,1945	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,1460	0,0370	0,2191		0,0043	0,4476	0,0000	0,0086	0,0317	0,0000	0,0000	0,6402	0,2979	0,3364	0,1592	0,1738	0,2347
ARMA(3,2) SMA(1)	0,5157	0,1923	0,2218	0,0002		0,4473	0,0000	0,0214	0,0344	0,0000	0,0001	0,9112	0,8554	0,1497	0,0622	0,0863	0,1172
GARCH(1,1), ARMA(1,1)	0,0242	0,0166	0,0493	0,0000	0,0000		0,0000	0,0000	0,0115	0,0000	0,0000	0,6594	0,1612	0,2171	0,0000	0,0000	0,0001
GARCH(1,1), AR(2) SAR(2)	0,0021	0,0018	0,1280	0,0017	0,0022	0,2812		0,0020	0,0153	0,0000	0,0000	0,4583	0,0472	0,3362	0,1580	0,1617	0,2167
GARCH(1,1), ARMA(3,2) SMA(1)	0,4148	0,1645	0,2029	0,0000	0,0001	0,4080	0,0000		0,0313	0,0000	0,0001	0,8698	0,7863	0,1068	0,0108	0,0180	0,0260
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0111	0,0072	0,1675	0,0000	0,0000	0,1376	0,0000	0,0000		0,0000	0,0000	0,5009	0,0822	0,1862	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0039	0,0029	0,1422	0,0054	0,0029	0,3086	0,0000	0,0029	0,0175		0,0000	0,5099	0,0654	0,3216	0,1617	0,1711	0,2300
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,4161	0,1670	0,2074	0,0000	0,0001	0,4164	0,0000	0,0200	0,0321	0,0000		0,8801	0,7943	0,1172	0,0092	0,0153	0,0221
UC_TC	0,0504	0,0313	0,2272	0,0000	0,0000	0,4439	0,0000	0,0000	0,0355	0,0000	0,0000		0,2297	0,3373	0,0001	0,0004	0,0008
UC_TCS1	0,1656	0,1591	0,1931	0,0000	0,0000	0,4235	0,0000	0,0004	0,0238	0,0000	0,0000	0,8041		0,2801	0,0006	0,0018	0,0034
UC_TCS2	0,0057	0,0042	0,0712	0,0000	0,0000	0,1442	0,0000	0,0000	0,0099	0,0000	0,0000	0,3699	0,0625		0,0000	0,0000	0,0000
BMA	0,0705	0,0263	0,0200	0,0000	0,0000	0,0502	0,0000	0,0008	0,0022	0,0000	0,0000	0,3777	0,2272	0,0378		0,1120	0,2231
WALS	0,0459	0,0172	0,0130	0,0000	0,0000	0,0334	0,0000	0,0003	0,0014	0,0000	0,0000	0,2916	0,1633	0,0293	0,0357		0,2301
Factores dinámicos	0,0398	0,0149	0,0109	0,0000	0,0000	0,0282	0,0000	0,0002	0,0012	0,0000	0,0000	0,2594	0,1447	0,0273	0,0410	0,1310	

Cuadro 13 (cont.) Valores p de pruebas de inclusión de pronósticos de Chong y Hendry (1986)

h=3

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 1 \quad 0)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0002	0,0003	0,1128	0,0444	0,0019	0,0000	0,0006	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1) SV	0,0000		0,0007	0,0079	0,0149	0,0027	0,0000	0,0003	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1)	0,0002	0,0020		0,0065	0,0194	0,0087	0,0000	0,0023	0,0011	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,0067	0,0294	0,0344	0,0409	0,0811		0,0001	0,0098	0,0010	0,0006	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0001	0,0000	0,0001	0,0001	0,0000		0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0002	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
UC_TC	0,0653	0,1010	0,1123	0,1205	0,3804	0,1168	0,0523	0,6723	0,1781	0,0569	0,3771		0,0001	0,0000	0,4165	0,3107	0,2922
UC_TCS1	0,0194	0,0638	0,1976	0,0391	0,6938	0,1990	0,0020	0,9373	0,3712	0,0037	0,7842	0,0000		0,0000	0,1031	0,0423	0,0424
UC_TCS2	0,3484	0,3357	0,3298	0,4176	0,3938	0,3321	0,3788	0,1804	0,3173	0,3967	0,2493	0,5309	0,5150		0,2384	0,1676	0,1329
BMA	0,0044	0,0041	0,0025	0,0028	0,0030	0,0026	0,0011	0,0012	0,0023	0,0017	0,0014	0,0000	0,0001	0,0000		0,0003	0,0005
WALS	0,0022	0,0024	0,0020	0,0008	0,0022	0,0020	0,0002	0,0013	0,0019	0,0004	0,0014	0,0000	0,0002	0,0000	0,0018		0,0023
Factores dinámicos	0,0050	0,0053	0,0041	0,0022	0,0045	0,0041	0,0007	0,0027	0,0041	0,0012	0,0030	0,0000	0,0004	0,0000	0,0048	0,0040	

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 0 \quad 1)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0002	0,0003	0,1128	0,0444	0,0019	0,0000	0,0006	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1) SV	0,0000		0,0007	0,0079	0,0149	0,0027	0,0000	0,0003	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1)	0,0002	0,0020		0,0065	0,0194	0,0087	0,0000	0,0023	0,0011	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,0067	0,0294	0,0344	0,0409	0,0811		0,0001	0,0098	0,0010	0,0006	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0001	0,0000	0,0001	0,0001	0,0000		0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0002	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
UC_TC	0,0653	0,1010	0,1123	0,1205	0,3804	0,1168	0,0523	0,6723	0,1781	0,0569	0,3771		0,0001	0,0000	0,4165	0,3107	0,2922
UC_TCS1	0,0194	0,0638	0,1976	0,0391	0,6938	0,1990	0,0020	0,9373	0,3712	0,0037	0,7842	0,0000		0,0000	0,1031	0,0423	0,0424
UC_TCS2	0,3484	0,3357	0,3298	0,4176	0,3938	0,3321	0,3788	0,1804	0,3173	0,3967	0,2493	0,5309	0,5150		0,2384	0,1676	0,1329
BMA	0,0044	0,0041	0,0025	0,0028	0,0030	0,0026	0,0011	0,0012	0,0023	0,0017	0,0014	0,0000	0,0001	0,0000		0,0003	0,0005
WALS	0,0022	0,0024	0,0020	0,0008	0,0022	0,0020	0,0002	0,0013	0,0019	0,0004	0,0014	0,0000	0,0002	0,0000	0,0018		0,0023
Factores dinámicos	0,0050	0,0053	0,0041	0,0022	0,0045	0,0041	0,0007	0,0027	0,0041	0,0012	0,0030	0,0000	0,0004	0,0000	0,0048	0,0040	

Cuadro 13 (cont.) Valores p de pruebas de inclusión de pronósticos de Chong y Hendry (1986)

h=6

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 1 \quad 0)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0000	0,0000	0,0000	0,0034	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1) SV	0,0000		0,0000	0,0000	0,0002	0,0000	0,0000	0,0000	0,0000	0,0003	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1)	0,0000	0,0000		0,0000	0,0001	0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,0000	0,0001	0,0006	0,0000	0,0006		0,0000	0,0000	0,0000	0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
UC_TC	0,0000	0,0000	0,0000	0,0000	0,0605	0,0000	0,0000	0,0001	0,0000	0,0000	0,0001		0,0000	0,0000	0,1552	0,1858	0,3323
UC_TCS1	0,0000	0,0000	0,0007	0,0104	0,2450	0,0011	0,0000	0,0221	0,0175	0,0000	0,0773	0,0000		0,0000	0,0000	0,0000	0,0000
UC_TCS2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000
BMA	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000
WALS	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000
Factores dinámicos	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 0 \quad 1)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1) SV	0,0000		0,0000	0,0000	0,0000	0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1)	0,0000	0,0000		0,0000	0,0000	0,0006	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0007	0,0000	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0104	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0034	0,0002	0,0001	0,0000		0,0006	0,0000	0,0000	0,0000	0,0000	0,0000	0,0605	0,2450	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,0000	0,0000	0,0001	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0011	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0001	0,0221	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0175	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0003	0,0000	0,0000	0,0000	0,0001	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0001	0,0773	0,0000	0,0000	0,0000	0,0000
UC_TC	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000
UC_TCS1	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000
UC_TCS2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000
BMA	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,1552	0,0000	0,0000		0,0000	0,0000
WALS	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,1858	0,0000	0,0000	0,0000		0,0000
Factores dinámicos	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,3323	0,0000	0,0000	0,0000	0,0000	

Cuadro 13 (cont.) Valores p de pruebas de inclusión de pronósticos de Chong y Hendry (1986)

h=12

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 1 \quad 0)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1) SV	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1)	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
UC_TC	0,0000	0,0000	0,0000	0,0000	0,0004	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0001	0,0002	0,0004
UC_TCS1	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000
UC_TCS2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000
BMA	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000
WALS	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000
Factores dinámicos	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	

Ho: $(\beta_0 \quad \beta_1 \quad \beta_2) = (0 \quad 0 \quad 1)$	UC_MA SV	ARMA(1,1) SV	ARMA(1,1)	AR(2) SAR(2)	ARMA(3,2) SMA(1)	GARCH(1,1), ARMA(1,1)	GARCH(1,1), AR(2) SAR(2)	GARCH(1,1), ARMA(3,2) SMA(1)	EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	UC_TC	UC_TCS1	UC_TCS2	BMA	WALS	Factores dinámicos
UC_MA SV		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1) SV	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(1,1)	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
AR(2) SAR(2)	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0004	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GARCH(1,1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
UC_TC	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000	0,0000
UC_TCS1	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000	0,0000
UC_TCS2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000		0,0000	0,0000	0,0000
BMA	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0001	0,0000	0,0000		0,0000	0,0000
WALS	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0002	0,0000	0,0000	0,0000		0,0000
Factores dinámicos	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0004	0,0000	0,0000	0,0000	0,0000	

Fuente: Elaboración propia

Cuadro 14. Pruebas de igualdad de variancia

-Valores p de pruebas para pronósticos a horizontes indicados en fila/columna-

UC_MA SV

	1	3	6	12
1		**0,0003**	**0,0000**	**0,0002**
3	**0,0003**		**0,0425**	0,2437
6	**0,0000**	**0,0425**		0,5314
12	**0,0002**	0,2437	0,5314	

ARMA(1,1) SV

	1	3	6	12
1		**0,0004**	**0,0000**	**0,0004**
3	**0,0004**		**0,0415**	0,3341
6	**0,0000**	**0,0415**		0,3974
12	**0,0004**	0,3341	0,3974	

ARMA(1,1)

	1	3	6	12
1		**0,0002**	**0,0000**	**0,0002**
3	**0,0002**		**0,0296**	0,2895
6	**0,0000**	**0,0296**		0,3798
12	**0,0002**	0,2895	0,3798	

AR(2) SAR(2)

	1	3	6	12
1		**0,0114**	**0,0006**	**0,0259**
3	**0,0114**		0,2472	0,8238
6	**0,0006**	0,2472		0,4260
12	**0,0259**	0,8238	0,4260	

ARMA(3,2) SMA(1)

	1	3	6	12
1		**0,0152**	**0,0001**	**0,0178**
3	**0,0152**		**0,0461**	0,6305
6	**0,0001**	**0,0461**		0,1914
12	**0,0178**	0,6305	0,1914	

GARCH(1,1), ARMA(1,1)

	1	3	6	12
1		**0,0002**	**0,0000**	**0,0001**
3	**0,0002**		**0,0273**	0,2391
6	**0,0000**	**0,0273**		0,4341
12	**0,0001**	0,2391	0,4341	

GARCH(1,1), AR(2) SAR(2)

	1	3	6	12
1		**0,0166**	**0,0017**	**0,0331**
3	**0,0166**		0,3309	0,8183
6	**0,0017**	0,3309		0,5330
12	**0,0331**	0,8183	0,5330	

GARCH(1,1), ARMA(3,2) SMA(1)

	1	3	6	12
1		**0,0118**	**0,0000**	**0,0034**
3	**0,0118**		**0,0239**	0,2847
6	**0,0000**	**0,0239**		0,3443
12	**0,0034**	0,2847	0,3443	

EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)

	1	3	6	12
1		**0,0003**	**0,0000**	**0,0001**
3	**0,0003**		**0,0325**	0,1875
6	**0,0000**	**0,0325**		0,5715
12	**0,0001**	0,1875	0,5715	

EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)

	1	3	6	12
1		**0,0198**	**0,0023**	0,0735
3	**0,0198**		0,3525	0,9157
6	**0,0023**	0,3525		0,3586
12	0,0735	0,9157	0,3586	

Cuadro 14 (cont.) Pruebas de igualdad de variancia

-Valores p de pruebas para pronósticos a horizontes indicados en fila/columna-

EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)

	1	3	6	12
1		**0,0145**	**0,0000**	**0,0111**
3	**0,0145**		**0,0304**	0,5054
6	**0,0000**	**0,0304**		0,2012
12	**0,0111**	0,5054	0,2012	

UC_TC

	1	3	6	12
1		0,3773	**0,0053**	0,0637
3	0,3773		**0,0453**	0,2398
6	**0,0053**	**0,0453**		0,5549
12	0,0637	0,2398	0,5549	

UC_TCS1

	1	3	6	12
1		**0,0372**	**0,0000**	**0,0004**
3	**0,0372**		**0,0062**	**0,0335**
6	**0,0000**	**0,0062**		0,8095
12	**0,0004**	**0,0335**	0,8095	

UC_TCS2

	1	3	6	12
1		**0,0098**	**0,0002**	**0,0000**
3	**0,0098**		**0,0000**	**0,0000**
6	**0,0002**	**0,0000**		**0,0000**
12	**0,0000**	**0,0000**	**0,0000**	

BMA

	1	3	6	12
1		0,1277	**0,0367**	**0,0115**
3	0,1277		0,5020	0,1587
6	**0,0367**	0,5020		0,4034
12	**0,0115**	0,1587	0,4034	

WALS

	1	3	6	12
1		0,1581	**0,0183**	**0,0011**
3	0,1581		0,2875	**0,0210**
6	**0,0183**	0,2875		0,1448
12	**0,0011**	**0,0210**	0,1448	

Factores dinámicos

	1	3	6	12
1		0,1242	**0,0038**	**0,0001**
3	0,1242		0,1283	**0,0022**
6	**0,0038**	0,1283		0,0538
12	**0,0001**	**0,0022**	0,0538	

Fuente: Elaboración propia

6.4. Robustez de resultados de la evaluación

Cuadro 15. Precisión de pronósticos, muestra alternativa enero-2013 – diciembre-2014.

	RECM				Theil [1/]			
	h = 1	h = 3	h = 6	h = 12	h = 1	h = 3	h = 6	h = 12
UC_MA SV	0.0061	0.0112	0.0173	0.0195	0.0617	0.1151	0.1823	0.19767
ARMA(1,1) SV	0.0060	0.0110	0.0176	0.0235	0.0598	0.1095	0.1758	0.2192
ARMA(1,1)	0.0062	0.0111	0.0183	0.0266	0.0618	0.1101	0.1791	0.23961
AR(2) SAR(2)	0.0088	0.0142	0.0195	0.0302	0.0863	0.1358	0.1861	0.26196
ARMA(3,2) SMA(1)	0.0071	0.0146	0.0253	0.0392	0.0696	0.1362	0.2206	0.31105
GARCH(1,1), ARMA(1,1)	0.0061	0.0109	0.0171	0.0227	0.0605	0.1101	0.1732	0.21604
GARCH(1,1), AR(2) SAR(2)	0.0090	0.0135	0.0180	0.0237	0.0889	0.1336	0.1801	0.22077
GARCH(1,1), ARMA(3,2) SMA(1)	0.0071	0.0129	0.0220	0.0337	0.0693	0.1234	0.2018	0.27984
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	0.0065	0.0126	0.0221	0.0370	0.0638	0.1200	0.2020	0.29827
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	0.0092	0.0141	0.0190	0.0277	0.0905	0.1370	0.1849	0.24511
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0.0078	0.0160	0.0297	0.0495	0.0750	0.1459	0.2494	0.36047
UC_TC	0.0062	0.0079	0.0144	0.0205	0.0622	0.0803	0.1515	0.2143
UC_TCS1	0.0066	0.0045	0.0105	0.0346	0.0660	0.0460	0.1105	0.39728
UC_TCS2	0.0116	0.0102	0.0104	0.0183	0.1236	0.1084	0.1133	0.19716
BMA	0.0076	0.0123	0.0178	0.0228	0.0759	0.1220	0.1803	0.23856
WALS	0.0075	0.0119	0.0185	0.0239	0.0739	0.1172	0.1841	0.24555
Factores dinámicos	0.0074	0.0117	0.0192	0.0248	0.0733	0.1159	0.1894	0.2522

Fuente: Elaboración propia

Cuadro 16. Resumen de evaluación de pronósticos, muestra alternativa enero-2013 – diciembre-2014.

	Insesgamiento [1]				Capacidad de pronóstico - HLN [2]					Porcentaje de acierto en dirección de cambios					Inclusión de pronósticos [3]					Autocorrelación de errores [4]				Variancia de errores de pronóstico			
	h = 1	h = 3	h = 6	h = 12	h = 1	h = 3	h = 6	h = 12	Suma	h = 1	h = 3	h = 6	h = 12	Promedio	h = 1	h = 3	h = 6	h = 12	Suma	h = 1	h = 3	h = 6	h = 12	h = 1	h = 3	h = 6	h = 12
UC_MA SV	**0.4776**	0.0174	0.0000	0.0000	4	-	-	4	8	0.4348	**0.6667**	0.4444	0.2500	0.4490	11	1	-	-	12	**0.3229**	**0.3995**	**0.3233**	**0.3173**	0.00004	0.00013	0.00032	0.00035
ARMA(1,1) SV	**0.3934**	0.0125	0.0000	0.0000	4	2	2	6	14	0.4348	**0.7143**	0.3889	0.1667	0.4262	11	-	-	-	11	**0.5945**	**0.4146**	**0.3243**	**0.3173**	0.00004	0.00012	0.00028	0.00031
ARMA(1,1)	**0.1515**	0.0039	0.0000	0.0000	4	1	2	5	12	**0.5217**	**0.7619**	0.4444	0.2500	0.4945	8	-	-	-	8	**0.2541**	**0.4921**	**0.3441**	**0.3173**	0.00004	0.00012	0.00028	0.00033
AR(2) SAR(2)	0.0217	0.0000	0.0000	0.0000	-	-	2	4	6	**0.5652**	0.4286	0.3889	0.1667	0.3873	-	-	-	-	-	0.0401	**0.2871**	**0.3807**	**0.3173**	0.00007	0.00016	0.00028	0.00033
ARMA(3,2) SMA(1)	**0.0791**	0.0000	0.0000	0.0000	1	-	-	1	2	**0.6087**	**0.7619**	**0.7222**	0.2500	**0.5857**	4	-	-	-	4	**0.2541**	**0.7670**	**0.4200**	**0.3173**	0.00005	0.00012	0.00020	0.00033
GARCH(1,1), ARMA(1,1)	**0.2143**	0.0113	0.0000	0.0000	4	1	2	4	11	**0.5217**	**0.7143**	0.5000	0.3333	**0.5173**	8	-	-	-	8	**0.3229**	**0.5564**	**0.3658**	**0.3173**	0.00004	0.00012	0.00028	0.00034
GARCH(1,1), AR(2) SAR(2)	**0.1348**	0.0005	0.0000	0.0000	-	-	1	5	6	0.4783	0.3333	0.3889	0.1667	0.3418	-	-	-	-	-	0.0033	**0.2385**	**0.3191**	**0.3173**	0.00008	0.00018	0.00030	0.00031
GARCH(1,1), ARMA(3,2) SMA(1)	0.0278	0.0000	0.0000	0.0000	2	1	1	2	6	**0.6522**	**0.6667**	**0.6667**	0.3333	**0.5797**	4	-	-	-	4	0.0498	**0.9988**	**0.3086**	**0.3173**	0.00005	0.00012	0.00026	0.00027
EGARCH(1,1) in mean (0)- L(1), ARMA(1,1)	**0.0589**	0.0000	0.0000	0.0000	4	1	1	1	7	**0.5217**	**0.7619**	0.5000	0.1667	0.4876	5	-	-	-	5	**0.1402**	**0.4419**	**0.3353**	**0.3173**	0.00004	0.00011	0.00025	0.00027
EGARCH(1,1) in mean (0)- L(1), AR(2) SAR(2)	**0.0818**	0.0001	0.0000	0.0000	-	-	2	4	6	0.4783	0.3333	0.3889	0.2500	0.3626	-	-	-	-	-	0.0025	**0.2215**	**0.3197**	**0.3173**	0.00008	0.00018	0.00029	0.00029
EGARCH(1,1) in mean (0)- L(1), ARMA(3,2) SMA(1)	0.0005	0.0000	0.0000	0.0000	1	-	-	-	1	**0.7391**	**0.7143**	**0.5556**	0.2500	**0.5647**	-	-	-	-	-	0.0049	**0.8010**	**0.3631**	**0.3173**	0.00004	0.00011	0.00024	0.00027
UC_TC	**0.1548**	**0.1131**	0.0001	0.0000	4	12	2	2	20	0.4348	**0.5238**	**0.6111**	**0.5833**	**0.5383**	11	12	-	-	23	**0.6592**	**0.4879**	**0.4275**	**0.3173**	0.00004	0.00006	0.00022	0.00044
UC_TCS1	0.0058	**0.3050**	0.0000	0.0000	2	16	5	-	23	0.4348	**0.6667**	**0.6111**	0.5000	**0.5531**	-	15	-	-	15	**0.9152**	**0.8897**	**0.3432**	**0.5478**	0.00005	0.00002	0.00012	0.00118
UC_TCS2	**0.0940**	**0.6604**	**0.2686**	0.0000	-	-	8	4	12	0.4348	0.4286	0.3889	0.1667	0.3547	-	10	15	-	25	0.0001	**0.2313**	**0.1857**	**0.3173**	0.00012	0.00011	0.00011	0.00036
BMA	0.0011	0.0000	0.0000	0.0000	1	-	-	1	2	**0.6957**	**0.8095**	**0.7222**	0.4167	**0.6610**	-	-	-	-	-	0.0111	**0.7801**	**0.2546**	**0.3714**	0.00006	0.00016	0.00033	0.00055
WALS	0.0014	0.0000	0.0000	0.0000	1	-	-	1	2	**0.6957**	**0.6667**	**0.6667**	0.5000	**0.6322**	-	-	-	-	-	0.0078	**0.8200**	**0.2479**	**0.4010**	0.00006	0.00014	0.00034	0.00059
Factores dinámicos	0.0020	0.0012	0.0000	0.0000	1	-	-	1	2	**0.6522**	**0.6667**	**0.6111**	0.5000	**0.6075**	-	-	-	-	-	0.0065	**0.8532**	**0.2502**	**0.4702**	0.00006	0.00014	0.00036	0.00063

1/ Valores p para estadístico Wald de la prueba de insesgamiento de Mincer y Zarnowitz (1969). Insesgados en negrita.
2/ Número de pronósticos a los cuales se supera en precisión, según la prueba de Harvey, Leybourne y Newbold (1997).
3/ Número de pronósticos a los cuales incluye el pronóstico de la fila, según prueba de Chong y Hendry (1986).
4/ Valor p de prueba de Wilcoxon/Dufour (h = 1) y Cumby y Huizinga (1992) (resto de horizontes).

Fuente: Elaboración propia