

DOCUMENTOS DE TRABAJO

ISSN 2409-1863
DT 011-Diciembre 2009
Banco Central de Nicaragua

Combinación de Pronósticos de Inflación en Nicaragua

Oknan Bello Dinartes



Banco Central de Nicaragua
Emitiendo confianza y estabilidad



Banco Central de Nicaragua

Combinación de Pronósticos de Inflación en Nicaragua*

Oknan Bello Dinartes[†]

Resumen

La naturaleza forward-looking de las decisiones de política económica implica que las proyecciones son un componente importante detrás de este proceso. Con el objetivo de mejorar la proyección central de la inflación nicaragüense, en este trabajo se implementan diferentes técnicas de combinación de pronósticos a diversos modelos de la inflación de Nicaragua. Para ganar eficiencia en la escogencia de los modelos a combinar se usa un procedimiento basado pruebas de abarcamiento. Los resultados de las estimaciones muestran ganancias en precisión estadísticamente significativas en los pronósticos obtenidos a través de las combinaciones de los modelos, comparados con los pronósticos del mejor modelo individual. Las máximas ganancias obtenidas fueron 19.4% para el horizonte de 3 meses, 18.3% en el caso del horizonte de 6 meses, y 14.2% y 12.4% para los horizontes de 9 y 12 meses, respectivamente.

* Las opiniones expresadas en este trabajo son exclusivas del autor y no comprometen al Banco Central de Nicaragua ni a su consejo directivo. El autor agradece los comentarios y sugerencias de Rigoberto Castillo, Oscar Gámez y Carlos Zambrana.

[†] E-mail: obello@bcn.gob.ni. Tel: (505) 2557171 Ext-252.

1. Introducción

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

Una práctica común en el trabajo de proyección ha sido desarrollar modelos empíricos para describir y pronosticar el comportamiento de la economía. Sin embargo, una serie de decisiones relacionadas a la modelación: escogencia y transformación de datos, período muestral de estimación, técnicas de estimación utilizadas, especificación dinámica, marco teórico utilizado, etc.; inestabilidades desconocidas (quiebres estructurales) que favorecen a uno u otro modelo; y la incorrecta exclusión o inclusión de algunos regresores en el proceso de selección (Timmerman, 2006), tendrán impacto en el producto- proyecciones- de los modelos. Éstos divergirán del verdadero proceso generador de datos de la economía, el cual será desconocido, y no tomarán en cuenta toda la información disponible

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

En esta línea, en este trabajo se implementan diversas técnicas de combinación de pronósticos con el objetivo de producir un pronóstico mejorado de la inflación en Nicaragua. Para cumplir con este propósito se combinan proyecciones fuera de muestra, obtenidas mediante regresiones rolling y recursivas, de cinco modelos de inflación para horizontes de pronósticos de 3, 6, 9 y 12 meses. Para seleccionar los modelos a combinar en cada horizonte, se usa un algoritmo basado en pruebas de abarcamiento propuesto por Costantini y Pappalardo (2008). Las técnicas de combinación utilizadas van desde métodos sencillos como un promedio simple, y técnicas más elaboradas que toman en cuenta las características de los errores de pronóstico como sesgo, autocorrelación y estacionariedad.

Los resultados de las estimaciones muestran ganancias en precisión estadísticamente significativas, medida mediante la raíz del error cuadrático medio de los errores de pronóstico (RMSFE)¹, obtenidas a través de la combinación de los modelos comparados al mejor modelo individual. Las máximas ganancias obtenidas fueron 19.4% para el horizonte de 3 meses, 18.3% en el caso del horizonte de 6 meses, y 14.2% y 12.4% para los horizontes de 9 y 12 meses, respectivamente.

¹ Una discusión sobre algunas medidas de evaluación de pronóstico se presenta en el anexo 1.

El resto del trabajo se organiza de la siguiente manera: en la sección 2 se realiza una breve discusión, empírica y teórica, acerca de las bondades de combinar pronósticos; en la sección 3 describimos el algoritmo usado para seleccionar los modelos a combinar y los diferentes métodos de combinación de pronósticos; la sección 4 se ocupa de los modelos a combinar; los resultados de la estimación se muestran en la sección 5; por último, en la sección 6 se presentan las conclusiones.

2. Evidencia de Combinación de Pronósticos

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

Otra razón para combinar pronósticos es que pueden existir quiebres estructurales desconocidos que favorezcan a un modelo en vez de otro. Algunos modelos se adaptan a estos quiebres rápidamente mientras otros modelos pueden tener parámetros que se ajustan lentamente después del quiebre, así, una combinación de diferentes modelos puede producir pronósticos más robustos (Diebold y Pauly, 1987). Un tercer argumento a favor de combinar pronósticos es que los pronósticos individuales pueden estar sujetos a sesgos debido a variables omitidas que son desconocidas para el operador del modelo, por lo que una combinación de éstos puede compensar estos sesgos mejorando la precisión del pronóstico.

La evidencia empírica, aunque mixta, favorece la idea de que una combinación de pronósticos tiende a mejorar la precisión de las proyecciones. Makridakis et al. (1982), usando un esquema de competencia de pronósticos a gran escala (1001 series de tiempo) conocido como *M-Competition*, compara el desempeño de una combinación de pronósticos usando un promedio simple versus una combinación usando promedios ponderados. Ellos encuentran que una combinación basada en un promedio simple produce los mejores pronósticos, y que ésta tiene un desempeño muy superior al mejor modelo individual. Una versión posterior de este trabajo fue realizada por Makridakis y Hibon (2000), donde evalúan el desempeño de diferentes técnicas de proyección. Ellos concluyen que: modelos estadísticos complejos algunas veces no son superiores en término de su calidad de pronósticos comparado a modelos más sencillos; la precisión de los pronósticos depende del horizonte de proyección; y que en promedio una combinación de modelos es superior al mejor modelo individual.

Stock y Watson (2004) en un estudio para los países del G-7, muestra que una combinación de pronóstico resulta en una proyección mejorada del crecimiento del producto, desempeñándose mejor que un modelo autorregresivo usado como marco de referencia. Igual que en otros estudios, modelos de combinación sencillos como una

media simple o una media truncada muestran un buen desempeño. Clark y McCracken (2008), al considerar la propensión de los modelos VAR a inestabilidades, combinan distintas especificaciones de modelos VAR para tratar de mejorar la precisión de los pronósticos. Ellos encuentran que una combinación de los diferentes modelos mejora la precisión de las proyecciones, comparadas con el mejor modelo incluido en la combinación.

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

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

3. Marco Metodológico

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

3.1 Prueba de abarcamiento de pronósticos

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

Para seleccionar los modelos a incorporar en la combinación usamos un algoritmo de abarcamiento propuesto por Costantini y Pappalardo (2008), el cual usa la prueba de abarcamiento propuesta por Harvey, Leybourne y Newbold (HLN, 1998).

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

modelo $j = 1, 2$ y $t = 1, 2, \dots, T^2$. Si los pronósticos tienen en promedio igual valor predictivo entonces $E(d_t) = 0$.

La prueba es basada en la media muestral dada por $\bar{d} = \frac{\sum_{t=1}^T d_t}{T}$. Si se asume estacionariedad en covarianza en la serie de diferencial de pérdidas, la prueba DM se distribuye asintóticamente normal estándar bajo la hipótesis nula de igual valor predictivo. La prueba estadística se puede expresar como en la ecuación (1)

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

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

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

Donde $\hat{\gamma}_k$ es la k -ésima autocovarianza de \bar{d} , estimada como $\hat{\gamma}_k = T^{-1} \sum_{t=k+1}^T (d_t - \bar{d})(d_{t-k} - \bar{d})$, $k = 0, 1, 2, \dots, h-1$.

Harvey, Leybourne, y Newbold (1997), recomendaron dos modificaciones al modelo DM que podrían mejorar el poder de la prueba en pequeñas muestras. Estos cambios consisten en comparar la prueba estadística DM con valores críticos de la distribución *t-Student* con $T-1$ grados de libertad para reducir las distorsiones de tamaño, y modificar la prueba haciendo uso de un estimador insesgado de la varianza de \bar{d} . La prueba DM modificada (MDM) es:

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

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

3.2 Algoritmo de abarcamiento y selección de modelos a combinar

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

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

Paso 1. Calcular el RMSFE de las proyecciones fuera de muestra de cada modelo. Ordenar los modelos de menor a mayor RMSFE.

Paso 2. Escoger el mejor modelo (el modelo con el menor RMSFE) y examinar secuencialmente si éste abarca a los otros modelos usando la prueba HLN. Si el mejor modelo abarca al modelo alternativo a un nivel de significancia α , elimine al modelo alternativo como candidato para la combinación de pronósticos.

Paso 3. Repetir el paso 2 con el segundo mejor modelo. La lista de modelos a examinar incluirá solamente los modelos no eliminados en el paso anterior y el mejor modelo.

Paso 4. Continuar con el tercer mejor modelo, y así en adelante, hasta que no existan modelos para los cuales se rechaza la hipótesis nula de abarcamiento.

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

Además del abarcamiento, para que un pronóstico se considere apropiado para formar parte de una combinación debería cumplir ciertas propiedades. Siguiendo a Diebold y López (1996), los pronósticos deben ser insesgados, es decir, la media de los errores de pronósticos debe ser igual a cero, y los errores de pronóstico un paso adelante no deben estar correlacionados con errores pasados³. Si estas propiedades no son satisfechas, sería recomendable reexaminar el modelo subyacente que produjo los pronósticos.

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

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

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

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

3.3 Técnicas de combinación de pronósticos

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

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

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

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

Promedio simple

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

Combinación basada en el MSFE

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

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

Donde $\lambda_{i,t} = \sum_{s=T_0}^{T-h} \delta^{T-h-s} (Y_s^h - \hat{Y}_{i,s|s-h})^2$, $w_{0,t} = 0$ y δ es un factor de descuento. Si $\delta < 1$,

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

Combinaciones basadas en regresiones

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

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

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

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

Procedimiento de Hallman y Kamstra (1989): En la práctica es común que los pronósticos a combinar no sean estacionarios, y por lo tanto, es necesario tomar en cuenta esta característica en el procedimiento de combinación⁴. Hallman y Kamstra (1989) fueron los primeros en notar esto e incorporan el concepto de cointegración en la regresión combinante.

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

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

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

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

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

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

$$(10) \begin{aligned} \hat{Y}_{t+h|t} &= w_0 + w_1 (f_{t+h|t}^1 - \hat{Y}_{t+h-1|t}) + w_2 (f_{t+h|t}^2 - \hat{Y}_{t+h-1|t}) + \\ &\dots + w_n (f_{t+h|t}^n - \hat{Y}_{t+h-1|t}) + \hat{Y}_{t+h-1|t} + \varepsilon_t \end{aligned}$$

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

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

Combinación de pronósticos basada en Mínimos Cuadrados Ponderados

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

Estos parámetros son estimados mediante Mínimos Cuadrados Ponderados (WLS), usando la siguiente matriz de ponderaciones⁵:

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

Donde $k, \gamma > 0$ y $t = 1, 2, \dots, T$. Bajo este esquema se da una influencia decreciente de forma no lineal a las observaciones pasadas en la estimación de los parámetros de la ecuación combinante. La estimación del parámetro γ se lleva a cabo usando un método de búsqueda de malla (grid search), donde la función objetivo es RMSFE. Es decir, dado un conjunto de valores posibles de γ , para cada uno de estos valores se estiman los parámetros de la ecuación combinante, los pronósticos combinados y finalmente el RMSFE. El valor óptimo de γ es seleccionado como aquel que produce el mínimo RMSFE. Estas estimaciones son realizadas para los modelos de Coulson y Robins y de Hallman y Kamstra para cada horizonte de pronóstico.

4. Modelos de Pronósticos

En esta parte se describen los modelos utilizados para pronosticar la inflación en Nicaragua: modelo Autorregresivo Integrado de Media Móvil (Arima), modelo de Vectores Autorregresivos (Var), modelo de Función de Transferencia (FT), modelo No Lineal Autorregresivo de Transición Suave (STR), y modelo Estructural (Estruc)⁶. Estos modelos forman parte de un conjunto de herramientas que utiliza el Banco Central de Nicaragua para realizar sus pronósticos de inflación.

Modelo Autorregresivo Integrado de Media Móvil (Arima)

El modelo Arima utilizado en este trabajo toma la forma:

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

Donde ipc es el logaritmo el índice de precios al consumidor; Δ es un operador de diferencia tal que $\Delta ipc_t = (1 - B)ipc_t$; B es un operador de rezagos tal que $B ipc_t = ipc_{t-1}$; $\phi_1, \theta_1, \delta_1$ son parámetros a estimar; y ε_t es un término de error ruido blanco. En el

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

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

proceso de identificación del modelo se tomó en cuenta criterios usuales de información (Akaike, Schwartz) y la significancia individual de los parámetros.

Mientras este tipo de modelos tienen las desventajas de no ser robusto a la presencia de cambios estructurales en la serie y no poder describir relaciones económicas entre las variables, tiene las ventajas de ser robusto a problemas de mala especificación debido a la escogencia incorrecta de las variables explicativas, es sencillo de estimar y ha probado tener una alta capacidad de pronóstico en el corto plazo.

Modelo de Vectores Autorregresivos (Var)

El modelo Var tiene la siguiente especificación:

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

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

Modelo de Función de Transferencia (FT)

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

$$(14) (1 - \phi_1 B - \phi_2 B^6)(1 - \theta_1 B^{12}) \Delta ipc_t = \omega_0 + \omega_1 B^4 \Delta cred_t + \omega_2 B \Delta poil_t + \omega_3 B \Delta pfood_t + (1 - \delta_1 B^{12}) \varepsilon_t$$

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

Modelo No Lineal Autorregresivo de Transición Suave (STR)

El modelo STR es un modelo no lineal donde se supone que el proceso generador de la serie oscila de forma suave entre dos regímenes extremos. Este tipo de modelos es especialmente útil para modelar asimetrías en la dinámica de algunas variables económicas y para modelar quiebres estructurales en las series (Terasvirta y Anderson 1992).

En este trabajo el modelo STR toma la forma:

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

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

Modelo Estructural (Estruc)

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

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

Donde tc es el logaritmo del tipo de cambio de córdobas por dólares; rem es la relación remesas PIB; pe es el logaritmo de un índice de precios externos, el cual incluye petróleo y alimentos; ind_lluvia es un índice excesos de precipitaciones fluviales; y $wprod$ es el salario nominal ajustado por productividad. El resto de las variables se definen como antes.

5. Resultados

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

5.1 Pronósticos rolling y recursivos

El periodo muestral utilizado para los análisis es 1994:1-2009:1. Esta muestra se divide en dos submuestras: la primera submuestra 1994:1-1998:12, es utilizada para estimar los parámetros de los diferentes modelos de pronóstico descritos en la sección 4; mientras la segunda submuestra 1999:1-2009:1, es utilizada para producir las proyecciones fuera de muestra de cada modelo individual, con las cuales se estimarán las ponderaciones de la ecuación de combinación (5). Los pronósticos producidos son de dos tipos: recursivos y

rolling. Ambos esquemas son utilizados para dar mayor robustez a los resultados y aprovechar las ventajas que cada uno posee⁷.

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

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

Las figuras 1 a 4 del anexo presentan los pronósticos rolling y recursivos para $h = 3, 6, 9, 12$ y la inflación observada para cada periodo. Como se puede observar, todos los modelos muestran bastante precisión para proyectar la inflación en el corto plazo ($h = 3$), sin embargo, a medida que el horizonte de pronóstico es mayor su capacidad predictiva decrece.

Por otra parte, para las proyecciones con horizontes mayores a 3 meses, el error de pronóstico es especialmente alto en los años 2007 y 2008. Este comportamiento podría ser indicativo de quiebre estructural en los errores, por lo que se hace necesario el uso de técnicas de combinación que incorporen quiebre estructural. Cabe destacar que en los años 2007 y 2008 la inflación fue cerca de 9 y 7 puntos porcentuales, respectivamente, mayor que el promedio de los últimos 8 años.

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

5.2 Evaluación de propiedades de los pronósticos

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

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

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

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

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

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

Siguiendo el algoritmo de abarcamiento descrito en la sección 3.2, la prueba HLN es aplicada sobre la tabla de clasificación 5 para eliminar los modelos para los cuales no se rechaza la hipótesis de abarcamiento. Dado del esquema de estimación y el tamaño del horizonte de pronóstico, la selección de los modelos a ser combinados depende del nivel de significancia utilizado en la prueba HLN. Entre más bajo es el nivel de significancia, más fuerte es la selección entre los modelos competidores, mientras que con un nivel de significancia mayor, un gran número de modelos será seleccionado para la combinación. Para balancear un poco entre estos dos escenarios, en este trabajo se utiliza un nivel de significancia de 10% para realizar la prueba de abarcamiento.

Los resultados son reportados en las tablas 6 y 7 del anexo 2. Para $h = 3$, los 5 modelos propuestos en este trabajo son seleccionados para la combinación tanto en el esquema recursivo y rolling. Para $h = 6$ los 5 modelos son seleccionados en el esquema recursivo, mientras en el esquema rolling son seleccionados solamente los modelos Estruc, Arima y Var. Para $h = 9$ se seleccionan los modelos Estruc y Arima bajo el esquema rolling y los modelos STR y Estruc en el esquema recursivo. Para $h = 12$ los modelos a combinar bajo el esquema rolling son Estruc y Arima, sin embargo, bajo el esquema recursivo, el modelo Estruc parece abarcar a los demás modelos, por lo que no se obtendrían ganancias de la

combinación de este modelo con el resto de modelos rivales. Es importante observar que los modelos seleccionados para la combinación en los distintos horizontes son un mixto del modelo estructural más algunos de los modelos de series de tiempo.

5.3 Resultado de la combinación de pronósticos

En esta sección se utilizan las diferentes metodologías de combinación de pronósticos descritas en la sección 3.3, para combinar los modelos seleccionados mediante el algoritmo de abarcamiento.

Los resultados de los métodos de combinación se presentan en las tablas 8 y 9 del anexo 2. Estos cuadros muestran el RMSFE de la proyección combinada relativo al del mejor modelo en cada horizonte de pronóstico, así, un valor menor a uno implica que el pronóstico combinado se desempeña mejor que el pronóstico del mejor modelo individual en ese horizonte. En general se puede observar que en términos del RMSFE, los pronósticos combinados muestran un mejor desempeño que el mejor pronóstico individual. Las mejores combinaciones bajo los dos esquemas son obtenidas mediante los procedimientos de de Granger y Ramanathan y Hallman y Kamstra.

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

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

Para verificar si las ganancias en precisión son estadísticamente significativas, se utiliza la prueba de Diebold y Mariano (DM 1995) descrita en la sección 3.1. En la tabla 10 del anexo 2 se muestran los resultados de la prueba de DM al comparar el pronóstico combinado obtenido por el método de Granger y Ramanathan con respecto al pronóstico derivado del mejor modelo individual. A un nivel de significancia del 10%, la tabla 10 confirma que el pronóstico combinado obtenido mediante el método de Granger y Ramanathan supera al pronóstico del mejor modelo.

6. Conclusiones

La naturaleza forward-looking de las decisiones de política económica implica que las proyecciones son un componente importante detrás de este proceso. De esta manera, mejorar la calidad de los pronósticos es una tarea obligada en el quehacer del Banco Central.

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

Las máximas ganancias en precisión para la mejor combinación comparada al mejor modelo fueron 19.4% para el horizonte de 3 meses, 18.3% en el caso del horizonte de 6 meses, y 14.2% y 12.4% para los horizontes de 9 y 12 meses, respectivamente.

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

7. Bibliografía

Armstrong, J. S. (1989). *Combining Forecasts: The End of the Beginning or the Beginning of the End*. International Journal of Forecasting, 5(4), pp. 585-588.

Bates, J.M. y C.W.J. Granger (1969). *The Combination of Forecasts*. Operacional Research Quarterly, Vol. 20, pp. 451-468.

Bessler, D.A., y Brandt, J.A. (1981). *Forecasting livestock prices with individual and composite methods*. Applied Economics 13, pp. 513-522.

Brouwer, G. y Ericsson N. (1998). *Modelling inflation in Australia*. Journal of Business and Economic Studies, Volume 15, pp. 433-449.

Capistrán, C. y A. Timmermann (2006). *Forecast Combination with Entry and Exit of Experts*. Documento de Investigación 2006-08, Banco de México.

Castaño, E. y L. F. Melo (1998). *Métodos de combinación de pronósticos: una aplicación a la inflación colombiana*. Borradores de Economía N° 109, Banco de la República.

Clark, T. E. y M. W. McCracken (2008). *Averaging forecasts from VARs with uncertain instabilities*. Journal of Applied Econometrics.

Clemen, R.T. (1989). *Combining Forecasts: A Review and Annotated Bibliography*. International Journal of Forecasting, 5(4), pp. 559-583.

Coletti, D. y S. Murchison (2002). *Models in policy-making*. Bank of Canada Review, pp. 19-26.

Coulson, N.E. y R. Robins. (1993). *Forecast Combination in a Dynamic Setting*. Journal of Forecasting, 12, pp. 63-67.

Costantini, M. y C. Pappalardo, (2008). *Combination of Forecast Methods Using Encompassing tests: An Algorithm-Based Procedure*. Economics Series 228, Institute for Advanced Studies, Viena.

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

Diebold, F.X. y R. Mariano. (1995). *Comparing Predictive Accuracy*. Journal of Business and Economic Statistics, 13, pp. 253-263.

Diebold, F. y J. Lopez, J. (1996). *Forecast Evaluation and Combination*. NBER, Technical working paper 192.

Diebold, F. y P. Pauly (1987). *Structural Change and the Combination of Forecasts*. Journal of Forecasting, 6, pp. 21-40.

Donaldson, R.G. y M. Kamstra. (1996). *Forecast Combining with Neural Networks*. Journal of Forecasting, 15, pp. 49-61.

Ericsson, N. R. (1992). *Parameter Constancy, Mean Square Forecast Errors, and Measuring Forecast Performance: An Exposition, Extensions, and Illustration*. Journal of Policy Modelling, 4, pp. 465-495.

Fair, R.C. y R. Shiller, (1990). *Comparing Information in Forecasts from Econometric Models*. American Economic Review, 80(3), pp. 375-389.

Granger, C.W.J. y R. Ramanathan. (1984). *Improved Methods for Combining Forecasts*. Journal of Forecasting, 3, pp. 197-204.

Hallman, J. y M. Kamstra (1989). *Combining Algorithms Based on Robust Estimation Techniques and Co-integrating Restrictions*. Journal of Forecasting, 8, pp. 189-198.

Harvey, D., S. Leybourne y P. Newbold (1997). *Testing the Equality of Mean Squared Errors*. International Journal of Forecasting, 13, pp. 281-291.

Harvey, D. I., Leybourne, S. y P. Newbold. (1998). *Tests for forecast encompassing*. Journal of Business and Economic Statistics, 16, pp. 254-259.

Holden, K y D. A. Peel (1986). *An Empirical Investigation of Combinations of Economic Forecasts*. Journal of Forecasting, 5, pp. 229-242.

Holden, K, y D.A. Peel (1989). *Unbiasedness, Efficiency and the Combination of Economic Forecasts*. Journal of Forecasting, 8, pp. 175-188.

Hubrich, K. (2004). *Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy*. International Journal of Forecasting, 21(1), pp. 119-136.

Kapetanios, G., V. Labhard, y S. Price (2008). *Forecast combination and the Bank of England's suite of statistical forecasting models*. Economic Modelling 25, pp. 772-792.

Makridakis, S., Anderson, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., Newton, J., Parzen, E., y R. Winkler. (1982), "The accuracy of extrapolation (time series) methods: Results of a forecasting competition", *Journal of Forecasting* 1, pp. 111-153.

Makridakis, S., Chatfield, C., Hibon, M., Lawrence, M., Mills, T., Ord, K., y Simmons, L. (1993). *The M-2 competition: A real-time judgementally based forecasting study*. *International Journal of Forecasting* 9, pp. 5-22.

Makridakis, S. y M. Hibon (2000). *The M3 competition: Results, conclusions, and implications*. *International Journal of Forecasting* 16, pp. 451-476.

Melo, L. y H. Núñez (2004). *Combinación de pronósticos de la inflación en presencia de cambios estructurales*. Borradores de Economía N° 286, Banco de la República.

Romer, C. D. y D. H. Romer (2008). *The FOMC versus the staff: Where can monetary policymakers add value?* *American Economic Review* 98 (2), pp. 230-35.

Teräsvirta, T. y H.M. Anderson, (1992). *Characterizing Nonlinearities in Business Cycles using Smooth Transition Autoregressive Models*. *Journal of Applied Econometrics*, Vol. 7, pp. 119-136.

Teräsvirta, T., (1994). *Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models*. *Journal of the American Statistical Association*. Vol. 89, 425, pp. 208-218.

Timmerman, A. (2006). *Forecast Combination*. In G. Elliott, C. W. J. Granger, and A. Timmerman (Eds.), *Handbook of Economic Forecasting*, Volume 1. Amsterdam: Elsevier

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

West, K. D. (1996). *Asymptotic inference about predictive ability*. *Econometrica* 64, pp. 1067-1084.

Anexo 1

Medidas de Evaluación de Pronósticos

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

Definiendo a Y_t como el valor observado de la serie en el período t , a $f_{t|t-h}^j$ como el valor pronosticado Y_t con información hasta $t-h$ y a T como el número de pronósticos, algunas de las medidas más usadas para evaluar la precisión de los pronósticos son:

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

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

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

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

Promedio de los valores absolutos de los errores de pronóstico:

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

Promedio porcentual de los valores Absolutos de los Errores de Pronóstico:

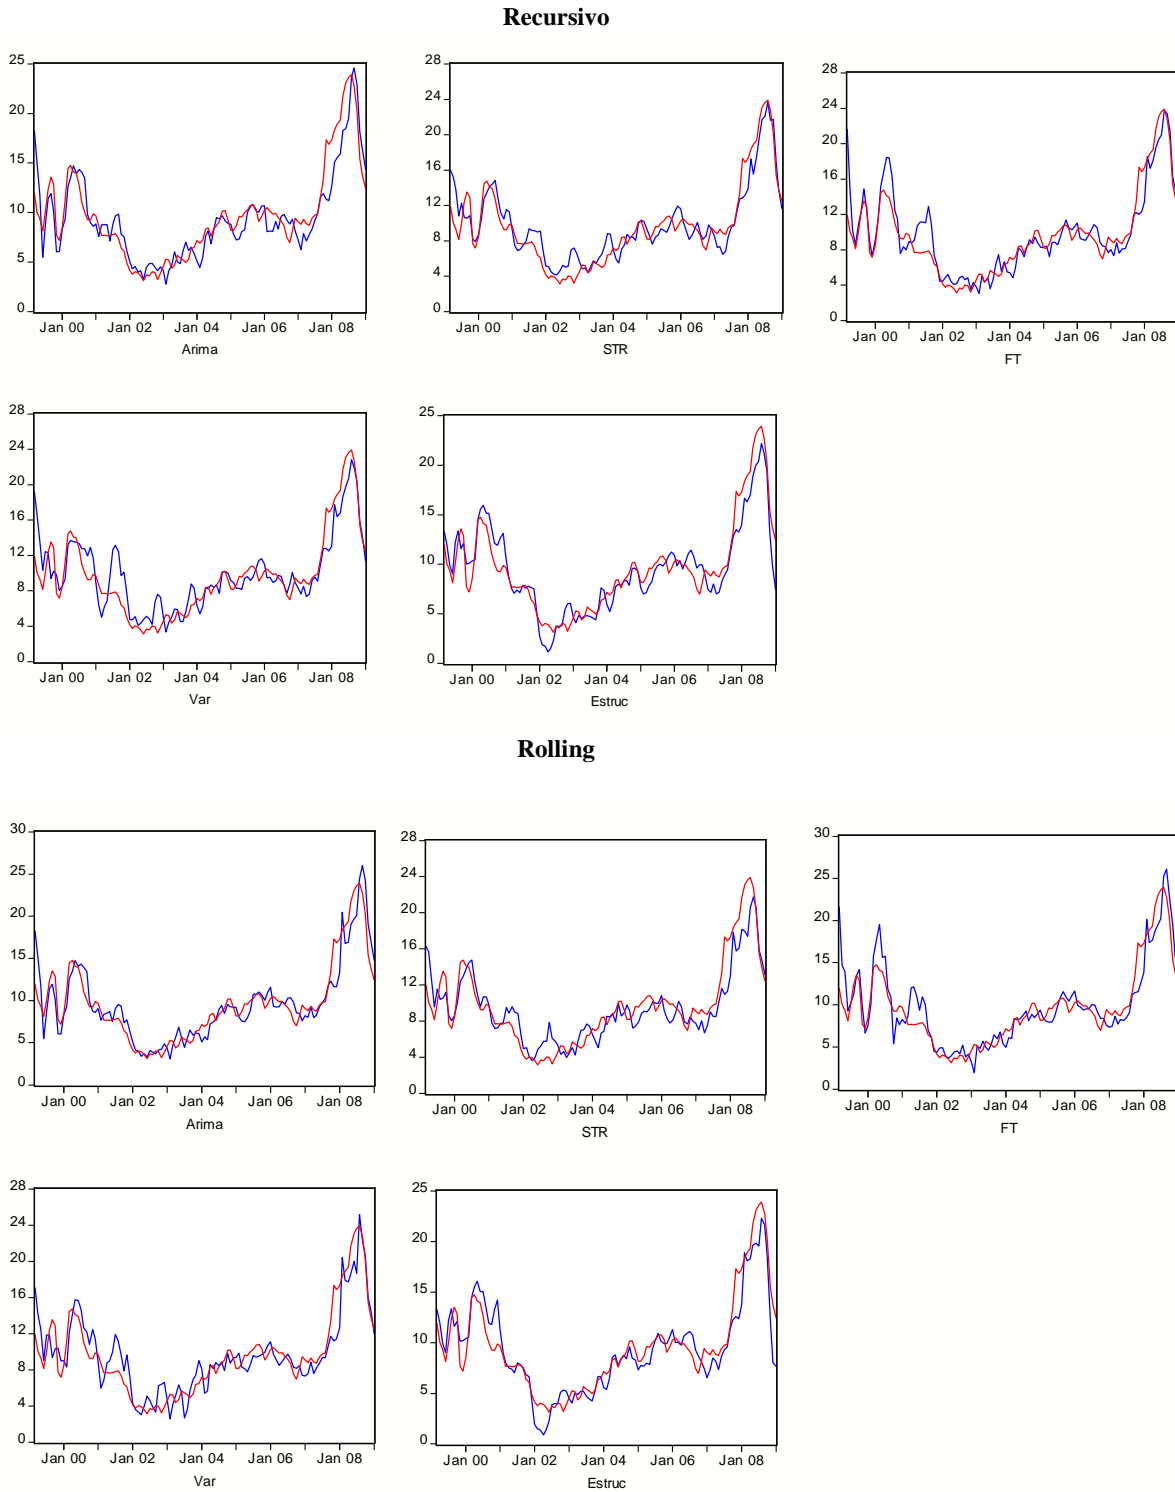
$$MAPFE = \frac{1}{T} \sum_{t=1}^T |(f_{t|t-h} - Y_t) / Y_t|$$

U-Theil:

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

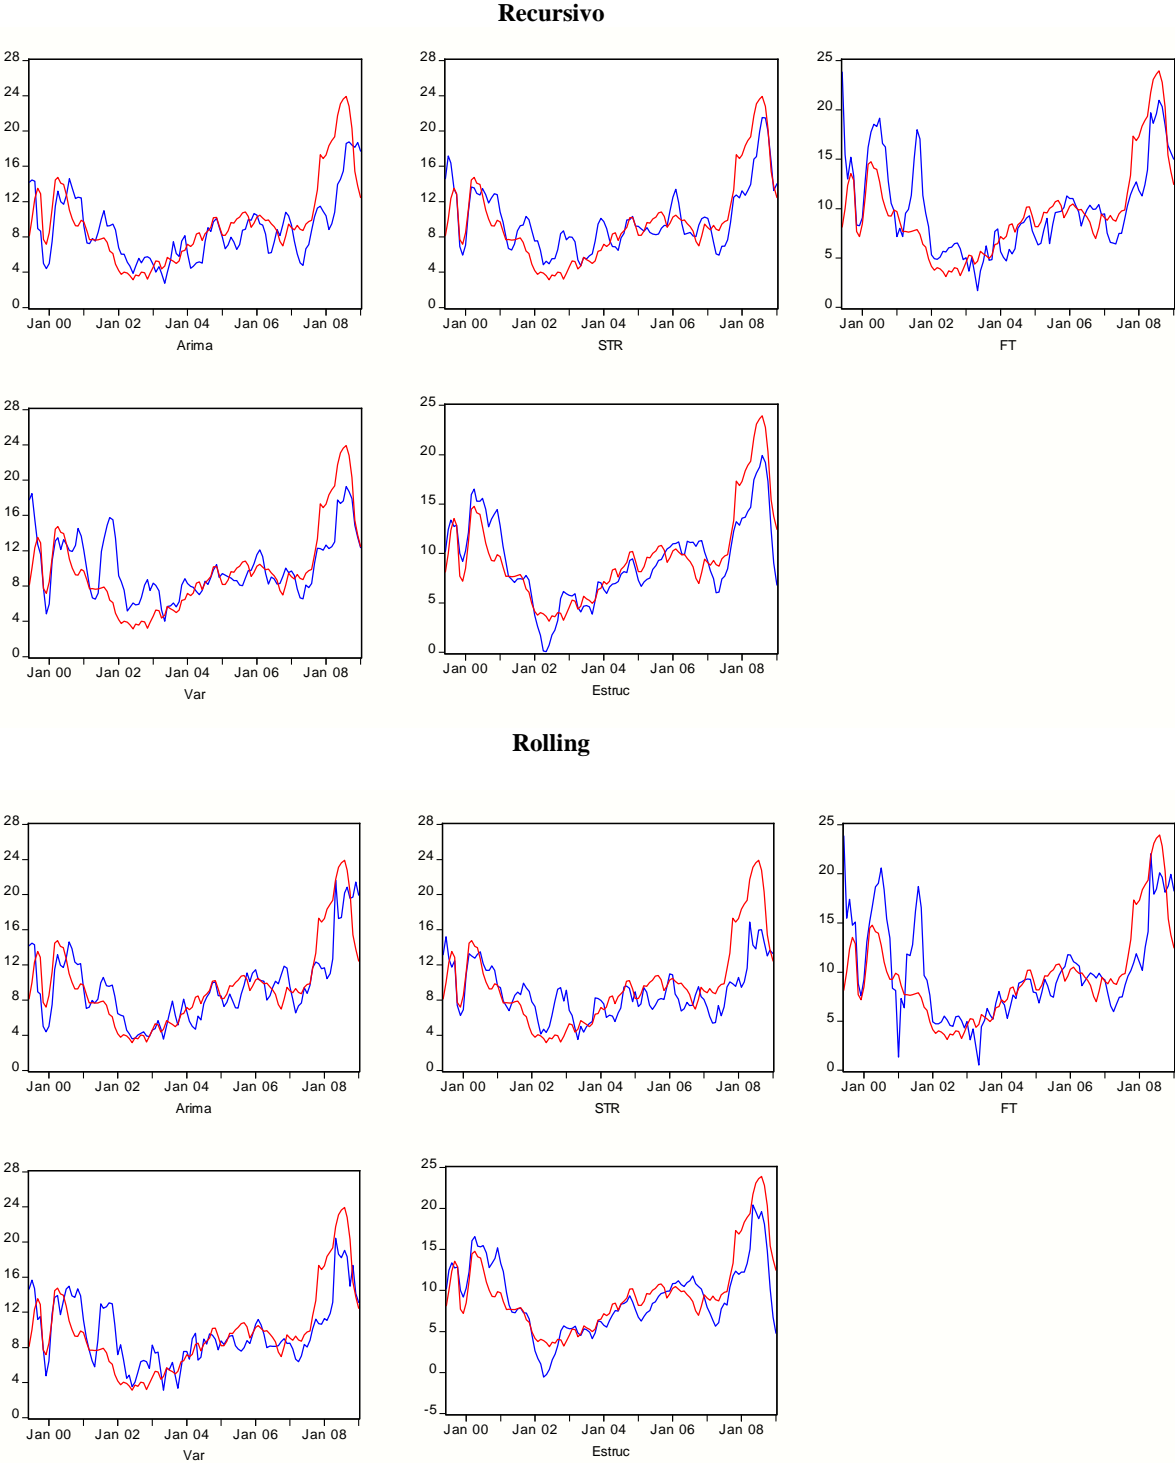
Anexo 2

Grafico 1: Inflación observada y proyectada (1999m3-2009m1). Horizonte 3 meses.



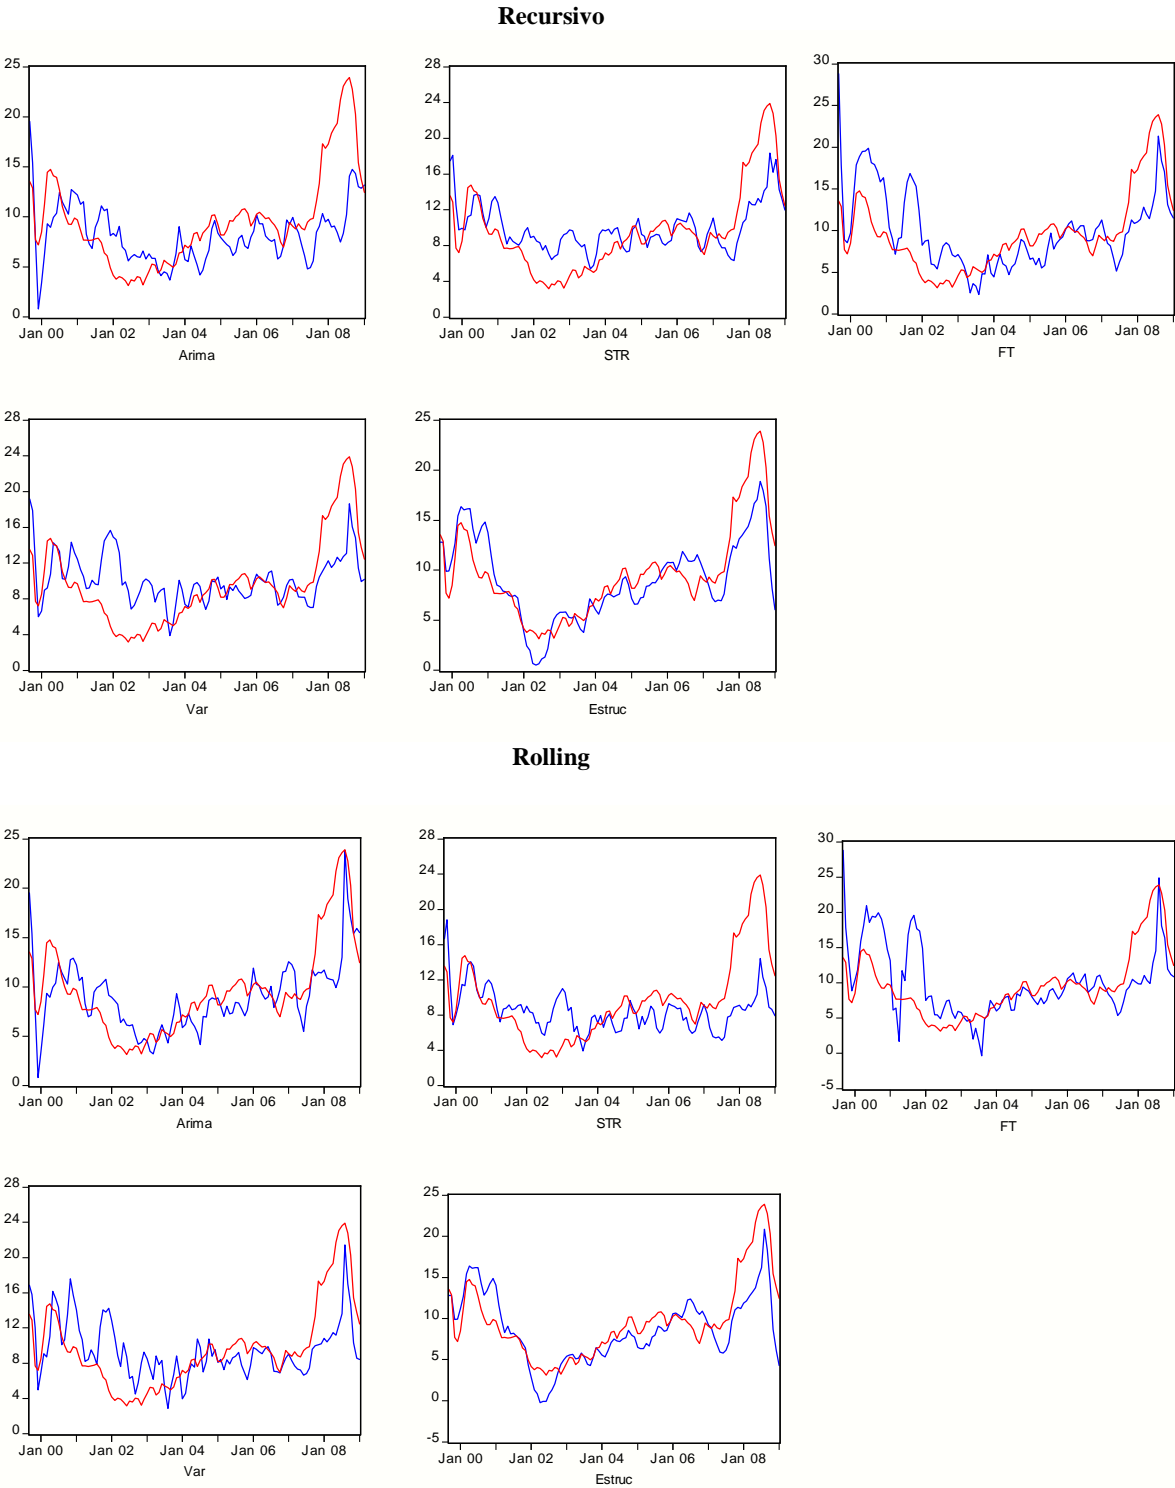
Nota: Inflación interanual. Observada (azul) y proyectada (rojo).

Grafico 2: Inflación observada y proyectada (1999m6-2009m1). Horizonte 6 meses.



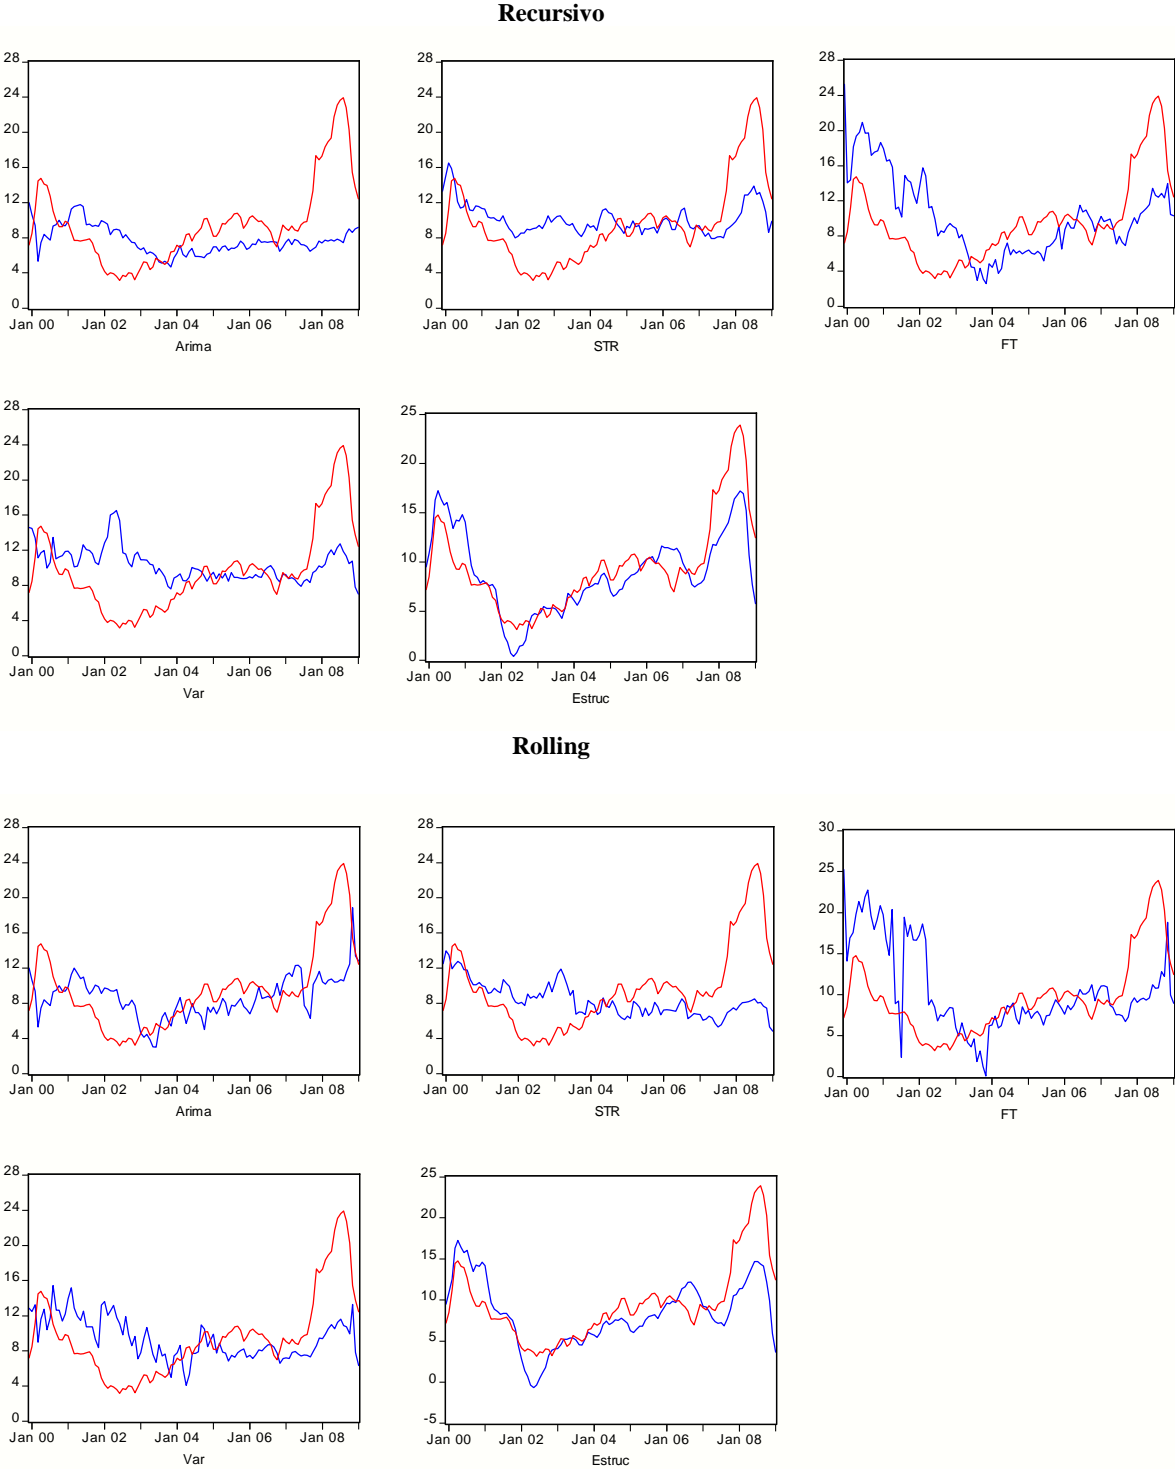
Nota: Inflación interanual. Observada (azul) y proyectada (rojo).

Grafico 3: Inflación observada y proyectada (1999m9-2009m1). Horizonte 9 meses.



Nota: Inflación interanual. Observada (azul) y proyectada (rojo).

Grafico 4: Inflación observada y proyectada (1999m12-2009m1). Horizonte 12 meses.



Nota: Inflación interanual. Observada (azul) y proyectada (rojo).

Tabla 1

Estadísticas de los Errores de Pronóstico de Inflación

		Prueba de Insegamiento Holden Peel				Prueba de Autocorrelación (Ljung-Box)*					
		Horizonte de Pronóstico				Horizonte de Pronóstico					
		h=3	h=6	h=9	h=12		h=1	h=3	h=6	h=9	h=12
Pronósticos Rolling											
FT	Media	-0.75	-0.69	-0.53	-0.749	Q-stat	22.57	93.38	188.27	399.16	546.58
	P Value	(0.46)	(0.49)	(0.6)	(0.46)	P Value	(0.60)	(0.00)	(0.00)	(0.00)	(0.00)
Arima	Media	0.02	0.53	0.95	1.050	Q-stat	18.97	81.97	138.23	233.58	312.9
	P Value	(0.99)	(0.6)	(0.34)	(0.3)	P Value	(0.8)	(0.00)	(0.00)	(0.00)	(0.00)
Var	Media	-0.12	0.05	0.22	0.189	Q-stat	17.31	94.04	329.02	540.93	695.81
	P Value	(0.91)	(0.96)	(0.83)	(0.85)	P Value	(0.87)	(0.00)	(0.00)	(0.00)	(0.00)
Estruc	Media	0.92	1.24	1.57	1.760	Q-stat	27.2	188.51	393.46	525.42	577.83
	P Value	(0.36)	(0.22)	(0.12)	(0.08)	P Value	(0.35)	(0.00)	(0.00)	(0.00)	(0.00)
STR	Media	0.82	1.33	1.30	1.154	Q-stat	32.78	182.22	471.82	709.76	806
	P Value	(0.41)	(0.19)	(0.2)	(0.25)	P Value	(0.14)	(0.00)	(0.00)	(0.00)	(0.00)
Pronósticos Recursivos											
FT	Media	-0.8	-0.62	-0.5	-0.58	Q-stat	35.97	148.68	290.77	559.8	725.66
	P Value	(0.42)	(0.54)	(0.62)	(0.56)	P Value	(0.07)	(0.00)	(0.00)	(0.00)	(0.00)
Arima	Media	0.95	1.47	1.83	1.89	Q-stat	29.48	102.81	207.65	403.52	548.51
	P Value	(0.34)	(0.15)	(0.07)	(0.06)	P Value	(0.24)	(0.00)	(0.00)	(0.00)	(0.00)
Var	Media	-0.76	-0.76	-0.66	-0.76	Q-stat	25.71	125.33	335.95	568.37	691
	P Value	(0.45)	(0.45)	(0.51)	(0.45)	P Value	(0.42)	(0.00)	(0.00)	(0.00)	(0.00)
Estruc	Media	0.79	0.9	1.08	1.17	Q-stat	45.18	223.45	405.61	515.05	559.39
	P Value	(0.43)	(0.37)	(0.28)	(0.24)	P Value	(0.01)	(0.00)	(0.00)	(0.00)	(0.00)
STR	Media	-0.69	-0.61	-0.53	-0.6	Q-stat	29.57	141.99	310.73	538.76	687.49
	P Value	(0.49)	(0.54)	(0.6)	(0.55)	P Value	(0.24)	(0.00)	(0.00)	(0.00)	(0.00)

Nota: *El numero de rezagos utilizados corresponde a la cuarta parte de las observaciones

Tabla 2

Pruebas de Raíz Unitaria Dickey-Fuller Aumentada y Phillips-Perron

Período 1999m3-2009m1

	Dickey-Fuller Aumentada		Phillips-Perron	
	Estadístico t	Decisión	Estadístico t	Decisión
Intercepto ¹	-2.64	I(0)	-2.09	I(1)
Tendencia e intercepto ²	-3.10	I(1)	-2.66	I(1)

Notas: 1/ Valores críticos: -3.44 al 5%, -3.14 al 10%. 2/ Valores críticos: -2.88 al 5%, -2.57 al 10%

Tabla 3

Pruebas de Raíz Unitaria Zivot-Andrews y Lee-Strazicich

Período 1999m3-2009m1

	Zivot-Andrews ¹		Lee-Strazicich ²	
	Estadístico t y Fecha	Decisión	Estadístico t y Fecha	Decisión
Cambio e Intercepto	-4.28 2001m1	I(1)	-2.46 2003m10	I(1)
Cambio en intercepto y tendencia	-4.55 2001m9	I(1)	-3.70 2007m12	I(1)

Notas: 1/ Valores críticos: cambio en intercepto -4.8 al 5%, -4.58 al 10%. Cambio en tendencia e intercepto -5.08 al 5%, -4.82 al 10%.

2/ Valores críticos para 100 obs: cambio en intercepto -3.56 al 5%, -3.21 al 10%. Cambio en tendencia e intercepto, $\lambda=0.9$, -4.5 al 5%, -4.21 al 10%.

Tabla 4**Tabla 3: Medida de error de proyección. Estimación rolling y recursiva**

Estimación (rolling)	RMSFE(3)	RMSFE(6)	RMSFE(9)	RMSFE(12)
FT	2.10	3.63	4.80	6.38
Arima	1.82	2.79	3.50	4.35
Var	1.98	2.91	4.00	4.97
Estruc	1.75	2.59	3.08	3.53
STR	1.98	3.21	4.35	5.33

Estimación (recursiva)	RMSFE(3)	RMSFE(6)	RMSFE(9)	RMSFE(12)
FT	1.93	3.29	4.32	5.63
Arima	1.95	3.21	4.22	5.26
Var	2.14	3.21	4.16	5.18
Estruc	1.70	2.30	2.63	2.83
STR	1.71	2.51	3.26	4.13

Tabla 5

Clasificación de Modelos según RMSE

	Rolling				Recursivo			
	h=3	h=6	h=9	h=12	h=3	h=6	h=9	h=12
1	EST	EST	EST	EST	EST	EST	EST	EST
2	AR	AR	AR	AR	STR	STR	STR	STR
3	VAR	VAR	VAR	VAR	FT	VAR	VAR	VAR
4	STR	STR	STR	STR	AR	AR	AR	AR
5	FT	FT	FT	FT	VAR	FT	FT	FT

Tabla 6

Resultados de las pruebas de inclusión (HLN). Estimación rolling.

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

Tabla 7

Resultados de las pruebas de inclusión (HLN). Estimación recursiva.

	h=3	h=6	h=9	h=12
1 ^{er} paso	Mejor Modelo	Mejor Modelo	Mejor Modelo	Mejor Modelo
	Estruc	Estruc	Estruc	Estruc
	0.085	0.085	0.160	0.309
	(Estruc vs Var)	(Estruc vs Var)	(Estruc vs Var)	(Estruc vs Var)
	0.036	0.223	0.421	0.448
	(Estruc vs Arima)	(Estruc vs Arima)	(Estruc vs Arima)	(Estruc vs Arima)
	0.016	0.036	0.053	0.297
2 ^{do} paso	STR	STR	STR	
	0.102	0.12		
	(STR vs Var)	(STR vs Var)		
	0.081	0.07		
	(STR vs Arima)	(STR vs FT)		
	0.003			
	(STR vs FT)			
3 ^{er} paso	FT	Var		
	0.018	0.016		
	(FT vs Var)	(Var vs FT)		
4 ^{to} paso	0.066			
	(FT vs Arima)			
4 ^{to} paso	Arima	Arima		
	0.009	0.077		
	(Arima vs Var)	(Arima vs FT)		

Tabla 8

RMSFE relativo al mejor modelo. Estimación rolling.

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

Tabla 9

RMSFE relativo al mejor modelo. Estimación recursiva.

	h=3	h=6	h=9
Mejor Modelo	Estruc	Estruc	Estruc
[RMSE]	[1.70]	[2.30]	[2.63]
Comb. Gr_Ram	0.81	0.87	0.87
Colson Robin_sce	1.13	1.13	1.40
Promedio_1	0.93	1.09	0.99
H_K_sce	0.81	0.88	0.87
Promedio_2	0.93	1.09	1.23
Colson Robin_ce	1.53	1.59	1.89
H_K_ce	1.20	1.70	1.35
DMFE 0.9	0.95	1.08	0.96
DMFE 0.95	0.94	1.07	0.96
DMFE 1	0.91	1.03	0.96

Tabla 10

Test de Diebold y Mariano				
Rolling				
	h=3	h=6	h=9	h=12
Estadístico	-1.59	-1.35	-1.72	-1.42
P_value	0.06	0.09	0.04	0.08
Recursiva				
	h=3	h=6	h=9	h=12
Estadístico	-1.89	-1.24	-3.49	
P_value	0.03	0.10	0.00	

Tabla 11**Abreviaturas**

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