

Banco de México
Documentos de Investigación

Banco de México
Working Papers

N° 2009-05

**Uso de Modelos Estacionales para Pronosticar la
Inflación de Corto Plazo en México**

Carlos Capistrán
Banco de México

Christian Constandse
Banco de México

Manuel Ramos-Francia
Banco de México

Julio 2009

La serie de Documentos de Investigación del Banco de México divulga resultados preliminares de trabajos de investigación económica realizados en el Banco de México con la finalidad de propiciar el intercambio y debate de ideas. El contenido de los Documentos de Investigación, así como las conclusiones que de ellos se derivan, son responsabilidad exclusiva de los autores y no reflejan necesariamente las del Banco de México.

The Working Papers series of Banco de México disseminates preliminary results of economic research conducted at Banco de México in order to promote the exchange and debate of ideas. The views and conclusions presented in the Working Papers are exclusively of the authors and do not necessarily reflect those of Banco de México.

Uso de Modelos Estacionales para Pronosticar la Inflación de Corto Plazo en México*

Carlos Capistrán[†]
Banco de México

Christian Constandse[‡]
Banco de México

Manuel Ramos-Francia[§]
Banco de México

Resumen: Desde la adopción del esquema de objetivos de inflación, el componente estacional parece ser el que explica la mayor parte de la variación total de la inflación en México. En este contexto, se estudia el desempeño de modelos estacionales de series de tiempo para pronosticar la inflación de corto plazo. Mediante técnicas de evaluación para horizontes múltiples, se examina el desempeño en tiempo real de los pronósticos de cuatro modelos estacionales, utilizando datos de 16 índices del Índice Nacional de Precios al Consumidor (INPC), incluyendo la inflación general y la subyacente. Estos modelos consideran tanto estacionalidad determinística como estocástica. Una vez seleccionado el mejor modelo de pronóstico para cada uno de los índices, se aplican y comparan dos métodos de agregación de series de tiempo jerárquicas, el método *bottom-up* y un método de combinación óptima. Los mejores pronósticos logran competir con los reportados por las encuestas a especialistas. **Palabras Clave:** Combinación de pronósticos, evaluación de horizontes múltiples, objetivo de inflación, pronósticos agregados, raíces unitarias estacionales, series de tiempo jerárquicas.

Abstract: Since the adoption of inflation targeting, the seasonal appears to be the component that explains the major part of inflation's total variation in Mexico. In this context, we study the performance of seasonal time series models to forecast short-run inflation. Using multi-horizon evaluation techniques, we examine the real-time forecasting performance of four well-known seasonal models using data on 16 indices of the Mexican Consumer Price Index (CPI), including headline and core inflation. These models consider both, deterministic and stochastic seasonality. After selecting the best forecasting model for each index, we apply and compare two methods that aggregate hierarchical time series, the bottom-up method and an optimal combination approach. The best forecasts are able to compete with those taken from surveys of experts.

Keywords: Aggregated forecasts, bottom-up forecasting, forecast combination, hierarchical time series, inflation targeting, multi-horizon evaluation, seasonal unit roots.

JEL Classification: C22, C52, C53, E37.

*Agradecemos a Daniel Chiquiar, José Antonio Murillo, Michael Petersen, Carla Ysusi, y a los participantes del seminario del Banco Central de Chile y Banco de México por sus valiosos comentarios. Las opiniones expresadas en el presente documento son exclusivas de los autores y no necesariamente reflejan el punto de vista del Banco de México.

[†] Dirección General de Investigación Económica. Email: ccapistran@banxico.org.mx.

[‡] Dirección General de Investigación Económica. Email: cconstantse@banxico.org.mx.

[§] Dirección General de Investigación Económica. Email: mrfran@banxico.org.mx.

1. Introducción

Los modelos para pronosticar la inflación tradicionalmente se han enfocado en la tendencia de la inflación ya que este componente usualmente explicaría gran parte de la variación de la serie, en concordancia con el postulado de Granger (1966) que sostiene que gran parte de las variaciones en las series de tiempo económicas se explican a través de la tendencia de largo plazo. En particular, la tendencia de la inflación por lo general se ha modelado como estocástica a través de modelos que contienen una raíz unitaria (por ejemplo, Stock y Watson (2003)).

No obstante, bajo condiciones de la inflación estable, como la que se obtiene bajo un régimen confiable de objetivos de inflación, la tendencia pierde importancia como componente dominante (Stock y Watson, 2007). Actualmente ese parece ser el caso de México, en donde la inflación al parecer cambió de un proceso no estacionario a uno estacionario a fines de 2000 o inicio de 2001 (Chiquiar, et al., 2007). Como se muestra en el presente documento, el componente que parece haber reemplazado a la tendencia como componente dominante es el estacional.

Con el propósito de encontrar modelos capaces de producir buenos pronósticos de inflación mensual hasta 12 meses hacia delante, este documento trata a la inflación como una serie estacional y utiliza cuatro modelos de series de tiempo diseñados para modelar y pronosticar dichas series (Osborn 2002). Los modelos consideran tanto la estacionalidad estocástica como la estacionalidad determinística y se aplican a 16 series de inflación del Índice Nacional de Precios al Consumidor (INPC), incluyendo la inflación general y la subyacente. Cada modelo se evaluó mediante pronósticos fuera de la muestra, considerando todos los horizontes de pronóstico de manera simultánea.

Una vez que se ha determinado el mejor modelo para cada serie de inflación surge el problema de cómo agregar dichos pronósticos a manera de que los pronósticos resultantes sean consistentes con el orden jerárquico de cada serie (por ejemplo, el índice general de precios debe ser igual al promedio ponderado de los índices de precios subyacente y no subyacente). Para resolver dicho problema se comparan dos metodologías distintas: el método ampliamente utilizado *bottom-up* y un método de combinación óptima recientemente propuesto por Hyndman et al. (2007), modificado para el caso de México. Los pronósticos generados mediante el segundo método no sólo satisfacen las jerarquías, sino también presentan en la mayoría de los casos los Errores de Pronóstico Cuadráticos Medios (EPCM) (*Mean Squared Forecast Errors*, MSFE) más pequeños en comparación con los pronósticos obtenidos mediante el método *bottom-up* y el mejor modelo estacional para cada serie.

Este artículo está organizado de la siguiente manera: la sección 2 presenta la estructura

del INPC en México y documenta los cambios recientes del componente estacional de la inflación en México. La sección 3 presenta los cuatro modelos estacionales y su evaluación, utilizando los últimos 36 meses de la muestra para comparar los pronósticos con los valores actuales, con el fin de elegir el mejor modelo para cada una de las 16 series. En la sección 4 se presenta la discusión sobre si se deben agregar los pronósticos de las variables desagregadas o pronosticar la variable agregada directamente. De igual manera se presenta la evaluación de dos métodos alternativos para agregar los 16 pronósticos resultantes de tal manera que sean consistente con el orden jerárquico de las series. Finalmente, se presentan las conclusiones en la sección 5.

2. El componente estacional de la inflación en México

2.1. Datos

Cada mes, el Banco de México compila 170,000 precios de bienes y servicios específicos, agrupándolos en 315 genéricos (Banco de México, 2002b).¹ Cada genérico tiene cierta ponderación dentro del INPC, dependiendo de la importancia de cada bien y servicio dentro de la canasta básica que representa al consumidor mexicano promedio.² Dichos genéricos están clasificados en grupos que a su vez forman parte de grupos más grandes, creando una estructura jerárquica. En la presente investigación se consideran los 4 niveles más altos de la jerarquía, que en el caso del INPC en México representa 16 series. Dicha agrupación es la más utilizada para monitorear la inflación en México. El cuadro 1 presenta la estructura jerárquica del INPC en México, mientras que la gráfica 1 muestra las series de tiempo de los 16 índices analizados. La primera desagregación del índice general es entre los índices subyacente y no subyacente. El índice subyacente incluye los genéricos con menor volatilidad y normalmente responde a cambios en la economía agregada y en la política monetaria. Por ejemplo, los precios en este índice generalmente responden con cierto rezago a variables macroeconómicas nacionales como la tasa de interés, el tipo de cambio y los salarios. Dicho índice subyacente está desagregado en los índices de precios de mercancías y servicios, y éstos a su vez se desagregan en los índices de alimentos y otras mercancías; y el índice de vivien-

¹El Banco de México es el banco central de México. Su sitio web es <http://www.banxico.org.mx>.

²La información respecto a la importancia relativa que cada genérico tiene en la canasta básica se obtiene por medio de una encuesta que el Instituto Nacional de Estadística y Geografía (INEGI) formula para los hogares mexicanos, llamada Encuesta Nacional de Ingresos y Gastos de los Hogares (ENIGH). Para más información sobre la composición y los ponderadores actuales del INPC en México, ver Banco de México (2002a, 2002b).

da, de educación, y de otros servicios, respectivamente.³ El índice no subyacente incluye al grupo de agropecuarios, el cual es altamente volátil, y al grupo de precios administrados y concertados como los de la gasolina, la electricidad, el servicio telefónico y el transporte local, entre otros (Banco de México, 2002b). Este índice responde principalmente a precios internacionales y a fuerzas domésticas que no son de mercado. En el primer caso porque la mayoría de los productos agrícolas y de energía son bienes primarios (*commodities*) y en el segundo, porque gran parte de los precios administrados y concertados están determinados por el sector público. Específicamente, la mayoría de los precios de la energía que pertenecen al grupo de administrados están determinados por el Gobierno Federal (por ejemplo, la gasolina), mientras que una parte considerable de los precios del grupo de concertados están manejados por los gobiernos regionales y/o locales (por ejemplo, derecho de suministro de agua).⁴

La estructura jerárquica de las series de tiempo que se analizan conlleva a la discusión de si se debe pronosticar directamente una variable agregada o pronosticar variables desagregadas y posteriormente agregarlas. En primer lugar, los pronósticos de inflación de los 16 índices deben ser congruentes en el sentido de que tienen que cumplir con las jerarquías. En segundo lugar, ciertos métodos de agregación pueden mejorar al menos algunos de los pronósticos individuales (Espasa, et al., 2002).

2.2. Importancia del componente estacional

Entre las definiciones más aceptadas sobre estacionalidad está la de Hylleberg (1992, p.4): “La estacionalidad es el movimiento interanual y sistemático, aunque no necesariamente regular, provocado por cambios en el clima, el calendario, el momento de la toma de decisiones, directa o indirectamente a través de las decisiones de producción y consumo que los agentes de la economía toman.” Debido a que es un movimiento sistemático, es previsible y por eso la consideración de factores estacionales resulta relevante para el pronóstico de series de tiempo.

En México, la parte estacional de la inflación ha cobrado importancia recientemente ya que en la actualidad explica gran parte de la variación total de la inflación. Esto se observa al analizar la evolución del espectro de las series de inflación. El espectro representa la

³La medición de la inflación subyacente utilizada en este documento incluye a la educación. Esta definición de inflación subyacente es la que actualmente utiliza el Banco de México (Banco de México (2007)); sin embargo, antes de enero de 2008, el Banco de México consideraba a la educación como parte de la inflación no subyacente. La serie histórica utilizada en este estudio está disponible en el sitio web del Banco de México.

⁴A excepción de las tarifas telefónicas, las cuáles son determinadas por empresas del sector privado. Sin embargo, dichas tarifas se consideran en el grupo de precios concertados porque gran parte se encuentra bajo concesión.

contribución que ciclos de diferentes frecuencias aportan a la varianza de una serie. Éste toma valores más altos en aquéllas frecuencias cuyos ciclos tienen una mayor contribución en la varianza de las series observadas. Por lo tanto, las series dominadas por tendencias de largo plazo muestran una forma muy particular, con una porción más grande de la densidad concentrada en frecuencias más bajas, en lo que se conoce como la “forma típica del espectro” de una variable económica, un término que Granger (1996) utilizó por primera vez. Por otro lado, el espectro de una serie mensual con un patrón estacional significativo mostrará aumentos alrededor de las frecuencias que corresponden a 6, 5, 4, 3, 2 ó 1 ciclos por año, lo que corresponde a ciclos que se repiten cada 2, 2.4, 3, 4, 6 y 12 meses (Ghysels y Osborn, 2001). En la gráfica 2 se presentan los espectros estimados para la inflación general, subyacente y no subyacente en dos muestras distintas: de abril de 1995 a abril de 2001, y de mayo de 2001 a mayo de 2007 (72 observaciones por cada muestra).⁵ En la segunda muestra hay dos cambios obvios: la caída del pico en la frecuencia cero y el aumento de los picos estacionales.⁶

Los cambios en el espectro indican que la estacionalidad podría ser el componente que recientemente explica gran parte de la variación total en la inflación.⁷ Para calcular la proporción de la variación explicada a través del componente estacional, se estima una serie de regresiones para la inflación mensual y sus componentes, en donde cada regresión incluye 12 variables *dummy* estacionales como variables independientes. La primera variable *dummy* tiene el valor 1 cada enero y 0 en los otros meses, la segunda variable *dummy* tiene el valor 1 cada febrero y 0 en los demás meses, etc. En la primera regresión, la muestra consiste en los primeros cinco años de cada serie. En la segunda regresión se descarta la primera observación y se agrega una nueva observación al final de la muestra, de tal manera que la muestra siempre contenga cinco años de datos (es decir, se utilizan ventanas móviles para la estimación). La R^2 de cada regresión mide el porcentaje de la variación de inflación que está explicado mediante el componente estacional. En la gráfica 3 se muestra la serie resultante de R^2 s para cada componente de inflación. La muestra utilizada en cada caso está restringida por la disponibilidad de datos.

Para la inflación general, el componente estacional explica desde menos de 30 por ciento de la variación total de la serie durante los ochentas y la primera mitad de los años noventa,

⁵Se eligió dividir la muestra en abril de 2001 en base a los resultados de Chiquiar et al. (2007), que sugieren la existencia de un cambio estructural en la persistencia de la inflación alrededor de esas fechas. Además, para efectos de comparación se incorpora el mismo número de observaciones en cada muestra.

⁶Otra observación interesante es la disminución de la varianza total, medida como el área debajo de la curva de la densidad espectral, en la muestra más reciente de la inflación general y subyacente. Esto parece no ocurrir en el caso de la varianza total de la inflación no subyacente, excepto en casos de frecuencias muy bajas.

⁷Otros componentes tales como la volatilidad también podrían haber incrementado su proporción en la variación total de inflación. Más adelante en este documento se comprueba claramente que tal es el caso de la inflación de frutas y verduras.

hasta casi 60 por ciento durante los primeros cinco años de la década de 2000, alcanzando 70 por ciento en la última muestra.

Para la inflación subyacente también existe un incremento importante en la capacidad del componente estacional para explicar la varianza total, alcanzando casi 70 por ciento en los últimos cinco años. Para el caso de mercancías dicho componente explica desde niveles menores a 5 por ciento hasta 60 por ciento de la variación en las mercancías. Con respecto a la inflación de servicios, este componente explica desde 10 por ciento durante los noventa hasta casi 70 por ciento de la variación total en la última muestra. En el caso de los componentes de la inflación de mercancías (disponibles al inicio de 1995), se observa que el aumento de la importancia de la estacionalidad se muestra principalmente en el componente de otras mercancías, mientras que para la inflación de los alimentos, el componente estacional explica entre 20 y 65 por ciento de la variación total, pero sin mostrar un patrón específico.⁸ La importancia de la estacionalidad en los componentes de servicios se ha mantenido relativamente constante en el tiempo, siendo un caso especial el de la educación, la cual está determinada casi en su totalidad por el componente estacional (con una R^2 de cerca de 90 por ciento). Para algunas muestras es posible explicar casi toda la variación de la educación utilizando únicamente el componente estacional (por ejemplo, la muestra de agosto de 1995 a agosto de 2000). Este patrón estacional tan marcado en la educación se debe a que la mayoría de las escuelas privadas ajustan sus precios al inicio del año académico, es decir, en septiembre (y algunas en enero).

El componente estacional ha sido muy importante en la inflación no subyacente, explicando cerca de 50 por ciento de la varianza total de la serie, y recientemente ha alcanzado 70 por ciento. La importancia de este componente aumenta para la inflación en el sector agropecuario durante los últimos años de los noventa y los primeros años de la década de 2000. Sin embargo, recientemente ha disminuido tal importancia (actualmente explica cerca de 30 por ciento de la variación de la serie) debido al comportamiento de la categoría de frutas y verduras, en la que es posible que el componente irregular domine la varianza de la serie.⁹ Por otra parte, es notable el pronunciado aumento en la importancia de la estacionalidad de la inflación de los precios administrados. A últimas fechas, el componente estacional

⁸En México, como en muchos otros países, los alimentos procesados están clasificados como parte de la inflación subyacente, mientras que los no procesados son parte de la no subyacente. Sin embargo, y tal como se aprecia en este documento, los precios de los alimentos procesados se comportan como los precios de los alimentos no procesados. Esto se debe en parte a que algunos de los precios de los alimentos procesados cambian significativamente de acuerdo con los precios de los *commodities* (por ejemplo, el precio del cereal puede responder hasta en 90 por ciento al precio del trigo). Por tal motivo, es discutible si los alimentos procesados podrían clasificarse como parte de la inflación no subyacente.

⁹Otras fuerzas pudieran estar interviniendo; por ejemplo, los cambios climáticos a nivel mundial pudieran estar modificando la estacionalidad y la variabilidad de los precios de los productos agrícolas.

explica más de 90 por ciento de la variación total de la serie, mostrando la regularidad con la que se modifican algunos precios y tarifas, tales como las tarifas de electricidad. También se observa una tendencia creciente en la importancia del componente estacional para la inflación de precios concertados.

A pesar de que la importancia del componente estacional ha cambiado a través del tiempo, se espera que el porcentaje de la variación total explicado por la parte estacional se establezca alrededor de sus valores actuales, lo que parece razonable, siempre y cuando la inflación permanezca estacionaria.

2.3. Factores estacionales

Los cambios en el componente estacional van más allá del aumento de su contribución relativa a la varianza total de la serie. Los factores estacionales también han cambiado. En la gráfica 4 se presentan los factores estacionales para la inflación general, subyacente y no subyacente, estimados para 1996 y para cada año entre 2003 y 2007. Tales factores se estiman por medio de la metodología TRAMO-SEATS (Gómez y Maravall, 1996).¹⁰ Se observa que la estacionalidad de la inflación se ha aplanado, en el sentido de que ahora enero y diciembre tienen una contribución menos significativa en la serie. Dicho aplanamiento es incluso más evidente en la inflación subyacente. Parte del cambio en los factores estacionales se debe al cambio de los ponderadores utilizados en el cálculo del INPC en junio de 2002 (Banco de México, 2002b). Dicho cambio se realizó con el fin de actualizar las estimaciones de las proporciones del gasto que las familias asignan a cada bien y servicio incluido en el índice, y también para cambiar la canasta básica de bienes y servicios considerados.¹¹ Otro factor importante que también pudiera haber influido en el cambio en los factores estacionales es la transición de una inflación alta a una baja.

Recientemente, los factores estacionales se han mantenido estables, como se observa en la gráfica 5, que muestra la inflación anual general, subyacente y no subyacente de 2003 a 2007 y el promedio de 1998 a 2000. Al comparar el promedio de 1998 a 2000 con los otros años, se observan varias características: primero, la disminución de la importancia en la tendencia de largo plazo; segundo, el cambio en la contribución relativa de cada mes; y, finalmente, que la inflación ha seguido un patrón estacional bastante estable, por lo menos desde 2003. Los factores estacionales aparentemente estables muestran que la inflación subyacente es más alta durante los primeros meses del año y en septiembre, lo que resulta debido a que los precios de

¹⁰Las conclusiones de esta subsección son robustas con respecto al uso de X12-ARIMA para la obtención de los factores estacionales. Sin embargo, algunos índices de la parte no subyacente como el índice de frutas y verduras se modelan más fácilmente utilizando TRAMO-SEATS.

¹¹Se agregaron 36 bienes como agua embotellada, tortillas de harina y servicios de Internet, mientras que se excluyeron otros como las tarifas de ferrocarriles.

bienes y servicios (específicamente vivienda y educación) se ajustan a principios de año y en septiembre, debido a que los precios de la educación se ajustan a principios del año académico. La inflación no subyacente es más alta durante la segunda mitad del año y notablemente baja durante mayo. Los niveles tan bajos en mayo y tan altos en noviembre corresponden al inicio y al final, respectivamente, del subsidio otorgado a las tarifas eléctricas para la temporada de calor. En agosto y septiembre se presentan niveles relativamente altos, en parte como resultado de los incrementos en los precios de las frutas y verduras (posiblemente como consecuencia de la temporada de huracanes). En enero, la inflación es relativamente alta debido a que los cambios en los precios de bienes y servicios concertados han ocurrido al principio del año (por ejemplo, los cambios en los precios del transporte público).

Los factores estacionales probablemente permanezcan estables, al menos hasta que los ponderadores del INPC se ajusten nuevamente, siempre y cuando la inflación permanezca en un nivel bajo.¹² Con respecto a este último punto, Gagnon (2007), utilizando datos de México, muestra que cuando la inflación está por debajo de 10-15 por ciento por año, la frecuencia de cambios en los precios sólo está ligeramente correlacionada con la inflación, particularmente en el caso de bienes, mientras que dicha frecuencia está altamente correlacionada si la tasa de inflación anual es alta (arriba de 10-15 por ciento). Por lo tanto, cuando la inflación es baja, las decisiones sobre los precios están en concordancia con modelos de determinación de precios que dependen del tiempo. Lo anterior es congruente con patrones estacionales estables de determinación de precios. Por el contrario, cuando la inflación es alta, las decisiones de determinación de precios muestran una fuerte estado-dependencia, por lo que la decisión acerca del tiempo adecuado para los cambios de los precios se convierte en una decisión endógena, creando una distorsión en la estacionalidad de los cambios en los precios.

En este contexto, los modelos específicamente diseñados para modelar y pronosticar series de tiempo estacionales podrían instrumentarse exitosamente para pronosticar la inflación en México y sus componentes en el corto plazo.

3. Modelos para pronosticar series de tiempo estacionales

En esta sección se analizan dos tipos distintos de modelos estacionales. El primero corresponde a modelos que asumen raíces unitarias estacionales. Este tipo de modelo sugiere que para poder inducir estacionariedad es necesario diferenciar las series estacionalmente. El segundo tipo consiste en modelos que asumen estacionalidad determinística, en donde la

¹²Lo más probable es que un cambio en los ponderadores o en la canasta básica de bienes y servicios para calcular el INPC ajuste los factores estacionales, aunque pudiera darse el caso de que dichos factores no cambien.

estacionalidad puede considerarse utilizando variables *dummy* estacionales. Se evalúan cuatro modelos, dos por cada tipo de estacionalidad. La literatura ha sugerido que estos modelos son adecuados para predecir series de tiempo con fuertes componentes estacionales (Osborn, 2002).¹³

Si bien existe la posibilidad de realizar pruebas de raíz unitaria estacional (Hylleberg et al. (1990) y Rodrigues y Osborn (1999), entre otros) que serían útiles para seleccionar los mejores modelos para pronosticar las series, generalmente estas pruebas requieren mucha información y no tienen mucho poder.¹⁴ El problema se agrava con muestras pequeñas, como las que se utilizan en este análisis. No obstante, si la estacionalidad es estocástica, eso tiene consecuencias a largo plazo y cualquier modelo que utilice esta información debería generar pronósticos más precisos que un modelo que no la considera, ya que la presencia de raíces unitarias estacionales hace que los movimientos interanuales sean impredecibles en el largo plazo (Ghysels et al., 2005). Por lo tanto, la estrategia a seguir es que la evaluación de pronósticos fuera de la muestra indique, para cada serie, qué supuesto sobre la naturaleza estocástica de la estacionalidad produce mejores pronósticos.

3.1. Modelos estacionales

3.1.1. Modelos con raíces unitarias estacionales

Modelo 1:

$$\phi(L) \Delta_{12} \pi_t = \mu + \varepsilon_t, \quad (1)$$

donde π_t es la inflación en tiempo t , $\phi(L) = 1 - \phi_1 L - \phi_2 L - \dots - \phi_p L$ es un polinomio autoregresivo, con todas sus raíces fuera del círculo unitario (este supuesto se mantiene para todos los modelos siguientes), $L\pi_t = \pi_{t-1}$, $\Delta_{12}\pi_t = \pi_t - \pi_{t-12}$, μ es una constante, y ε_t sigue un proceso de ruido blanco (también en los siguientes modelos). Dicho modelo asume que la serie π_t tiene una raíz unitaria en la frecuencia cero y una raíz unitaria estacional cada mes. Así se puede ver este modelo como 12 procesos distintos, todos integrados de orden uno, donde cada uno representa un mes del año.

Modelo 2:

$$\phi(L) \Delta_1 \Delta_{12} \pi_t = \varepsilon_t. \quad (2)$$

Este modelo es similar al modelo 1, en el sentido de que asume una raíz unitaria estacional

¹³Cuando una serie de tiempo muestra un componente estacional fuerte que cambia lentamente a través del tiempo, lo más recomendable para pronosticar es utilizar modelos periódicos o con parámetros que cambian en el tiempo (Franses, 2007). Sin embargo, dado que tales modelos requieren series de tiempo largas, con más de tres décadas de datos estacionales (Franses, 1996), no se consideran en este documento.

¹⁴Ver Diebold & Kilian (2000) para el uso de pruebas de raíz unitaria para seleccionar modelos de pronóstico.

cada mes. Sin embargo, el modelo 2 asume dos raíces unitarias en la frecuencia cero. Al aplicar el operador de doble diferencia $\Delta_1\Delta_{12}$ el modelo incluye dos primeras diferencias convencionales. Dejando a un lado las raíces unitarias estacionales, esto implica que la serie es integrada de orden dos. A este modelo se le conoce como “*Airline Model*” porque fue instrumentado con éxito para modelar la demanda de pasajeros del transporte aéreo, que muestra una estacionalidad muy fuerte (Box et al., 1994).¹⁵

3.1.2. Modelos con estacionalidad determinística

Modelo 3:

$$\phi(L)\Delta_1\pi_t = \alpha_1D_{1t} + \dots + \alpha_{12}D_{12t} + \varepsilon_t, \quad (3)$$

donde D_{it} son variables *dummy* estacionales que tienen valor uno cuando la observación t ocurre en el mes i ; y, en todos los demás casos, el valor de la variable es cero. Este modelo asume que la estacionalidad es determinística, pero que existe una tendencia estocástica de largo plazo. Este modelo permite que la media varíe con el mes, de manera determinística.

Modelo 4:

$$\phi(L)\pi_t = \alpha_1D_{1t} + \dots + \alpha_{12}D_{12t} + \beta t + \varepsilon_t. \quad (4)$$

Este modelo es similar al modelo 3, pero asume una tendencia determinística de largo plazo, en lugar de una estocástica. Se debe resaltar que procesos estocásticos que no tienen una tendencia específica pueden acomodarse a través de este modelo (con $\beta = 0$).

3.2. Selección del mejor modelo estacional

Se estiman los cuatro modelos para cada una de las 16 series a través de Mínimos Cuadrados Ordinarios (MCO) en forma recursiva. La muestra inicia en junio de 2002.¹⁶ La primera muestra termina en enero de 2005. Cada vez que se estima un modelo, se selecciona el orden de los polinomios de rezago de acuerdo con el criterio de información bayesiano (*Bayesian Information Criterion*, BIC) (Schwarz, 1978). El ejercicio de selección utiliza los meses de febrero de 2005 a diciembre de 2007 para evaluar los pronósticos fuera de la muestra. Para la primera muestra se estiman los pronósticos para 1 a 12 pasos adelante (es decir, con la información hasta enero de 2005 se calculan los pronósticos de febrero de 2005 a enero de 2006). En la segunda muestra que termina en febrero de 2005 se computan otros 12 pronósticos de marzo de 2005 a febrero de 2006. Este ejercicio se repite hasta diciembre de 2006 cuando se pronostican los meses de enero de 2007 a diciembre de 2007. Al final del ejercicio

¹⁵Como puede observarse, el modelo 1 es un modelo tipo “*Airline Model*” aplicado al índice de precios.

¹⁶La muestra inicia en junio de 2002 debido a que los factores estacionales son estables desde esta fecha y a que la inflación parece ser estacionaria, como se documentó anteriormente.

se obtiene para cada una de las 16 series 24 pronósticos de horizontes múltiples, en donde cada pronóstico de horizontes múltiples incluye pronósticos de uno a doce pasos adelante.

En base a Capistrán (2006), se considera la preferencia de un modelo respecto a otro, cuando su pérdida esperada, definida a través de horizontes múltiples, es menor. Para la evaluación se utiliza la función de Pérdida de Error Cuadrático (PEC) (*Squared Error Loss*, SEL):

$$\mathbf{L}_{t+1:t+12} = \mathbf{e}'_{t+1:t+12} \mathbf{\Delta} \mathbf{e}_{t+1:t+12}, \quad (5)$$

con $\mathbf{e}_{t+1:t+12} = [e_{t+1}, \dots, e_{t+12}]'$, $e_{t+h} = \pi_{t+h} - f_{t+h,t}$, donde π_{t+h} es la variable de interés, en este caso la inflación, en el período $t+h$, y $f_{t+h,t}$ es el pronóstico de $t+h$ utilizando información hasta el período t . $\mathbf{\Delta}$ es una matriz diagonal de 12×12 utilizada como ponderador. Al ser $\mathbf{\Delta}$ una matriz diagonal, se obtiene:

$$\mathbf{L}_{t+1:t+12,t} = \mathbf{e}'_{t+1:t+12,t} \mathbf{I}_{12} \mathbf{e}_{t+1:t+12,t} = \sum_{i=1}^{12} (\pi_{t+i} - f_{t+i,t})^2. \quad (6)$$

Para cada serie y modelo se calculan secuencias de pérdida con 24 elementos para cada una. A continuación se toma el promedio y la raíz cuadrada para calcular la Raíz del Error de Pronóstico Cuadrático Medio (REPCM) (RMSFE, por sus siglas en inglés), de horizontes múltiples. Es importante notar que cuando se utiliza la matriz identidad, se asignan ponderadores iguales a cada horizonte y $E[\mathbf{L}_{t+1:t+h,t}]$ es la traza de la matriz del Error Cuadrático Medio (ECM). En este caso, la PEC está relacionada con el caso en que se minimiza el Error Cuadrático Medio (ECM) para cada horizonte (Capistrán, 2006). Al utilizar esta función de pérdida, se asume divisibilidad entre horizontes, que todos los horizontes son igualmente relevantes, y que los costos de los errores son simétricos para cada horizonte. Si el usuario de los pronósticos da más importancia a ciertos horizontes, la función de pérdida (5) puede acomodar estas preferencias, cambiando $\mathbf{\Delta}$ según corresponda. Por ejemplo, si se considera que los primeros tres horizontes son más importantes, entonces las primeras tres entradas en la diagonal $\mathbf{\Delta}$ deberían tomar valores más altos que el resto de las entradas de la diagonal.

El cuadro 2 presenta las REPCM para cada modelo e índice. Los mejores modelos son aquéllos que tienen una REPCM más pequeña. Entre los modelos que asumen raíces unitarias estacionales, el modelo 1 resulta ser mucho mejor que el modelo 2, presentando un mejor desempeño en todas las series. Entre los modelos con estacionalidad determinística, el modelo 4 es mejor que el modelo 3 para casi todas las series, con la excepción de mercancías y alimentos. Tomando en cuenta modelos con ambos tipos de estacionalidad, los modelos con estacionalidad determinística parecen tener un mejor desempeño para pronosticar la inflación general y sus componentes. Sólo en el caso de servicios y educación, el modelo 1 con raíces

unitarias estacionales resulta tener una REPCM más pequeña.

Este resultado presenta evidencia a favor de la hipótesis de que el componente estacional de la inflación probablemente es determinístico en la mayoría de las series, al menos en las muestras utilizadas en este análisis. En ejercicios que no se reportan en este estudio se observó que existe una tendencia en el tiempo en donde los modelos de estacionalidad determinística han venido superando a los modelos de estacionalidad estocástica.¹⁷ Lo anterior indica que la inflación y algunos de sus componentes pudieron haber tenido raíces unitarias estacionales que han desaparecido gradualmente, lo que resultaría congruente con el esquema de objetivos de inflación establecido por el Banco de México desde 2001. De igual manera estaría de acuerdo con los resultados de Chiquiar et al. (2007) que demuestran que la raíz unitaria de frecuencia cero parece haber desaparecido en la inflación general y subyacente.

4. Agregación de pronósticos de modelos estacionales

Cuando se pronostica cada serie de inflación de forma independiente, como se realizó en la sección anterior, los pronósticos no respetan las jerarquías entre las series. Esto significa, por ejemplo, que el pronóstico de la inflación general que puede ser integrado mediante la agregación del mejor pronóstico de la inflación subyacente y de la inflación no subyacente, será diferente al pronóstico de inflación general generado utilizando el mejor modelo estacional seleccionado en la sección 3.

Para resolver este problema se evalúan dos métodos de agregación: el método más comúnmente utilizado de *bottom-up* y un método recientemente propuesto por Hyndman, et al. (2007), denominado “pronóstico de combinación óptima para series de tiempo jerárquicas” (que en lo sucesivo se denominará “HAA”). Ambos métodos resuelven el problema. El primero, a pesar de que se utiliza ampliamente, descarta información porque sólo emplea los pronósticos del nivel más bajo (en este caso, 9). El segundo método utiliza todos los pronósticos (16), y realiza la agregación no sólo cumpliendo con las jerarquías sino además combinando los pronósticos de tal manera que en un principio generaría pronósticos con la varianza más pequeña posible entre las agregaciones que cumplen con las jerarquías. Independientemente del método de agregación, los pronósticos base son los elegidos en la sección 3.

Un aspecto importante es que los ponderadores del gasto que el Banco de México utiliza para construir los índices de precios aplican directamente a los índices y no a la inflación. Por lo tanto, a pesar de que se pronostica la inflación, para la agregación se utilizan los

¹⁷Por ejemplo, si se utilizan datos anteriores a 2002, los modelos que asumen raíces unitarias estacionales tienen un desempeño relativamente mejor.

pronósticos implícitos para los índices y, una vez realizada dicha agregación, se transforman los índices nuevamente a la inflación.

4.1. Métodos de agregación para series de tiempo jerárquicas

Siguiendo la notación de Hyndman et al. (2007) y considerando el caso del INPC en México, a la serie más agregada, es decir el INPC general, se le asigna el nivel 0. El nivel 1 es el primer nivel de desagregación que en este caso incluye a los índices subyacente y no subyacente. El nivel 2 consiste en el INPC de mercancías y servicios (dentro del índice subyacente), productos agropecuarios, y bienes y servicios con precios administrados y concertados (dentro del índice no subyacente). Finalmente, el nivel 3 contiene las demás series: alimentos, otras mercancías, vivienda, educación, otros servicios, frutas y verduras, carnes y huevo (pecuarios), precios administrados y concertados. De esta manera, el nivel 3 contiene 9 series.

Se denomina m_i el número total de las series al nivel i , $i = 0, 1, 2, 3$. En total, existen $m = m_0 + m_1 + m_2 + m_3 = 16$ series. En términos de matriz y vectores, $\mathbf{P}_{i,t}$ será el vector para todas las observaciones del nivel i en tiempo t , y $\mathbf{P}_t = [P_{0,t}, \mathbf{P}_{1,t}, \mathbf{P}_{2,t}, \mathbf{P}_{3,t}]'$. Nótese que:

$$\mathbf{P}_t = \mathbf{S}\mathbf{P}_{3,t}, \quad (7)$$

donde \mathbf{S} es una matriz ponderadora de orden $m \times m_3$. Hyndman et al. (2007) utilizan una matriz \mathbf{S} que únicamente contiene ceros y unos, mientras que en este estudio se requiere incorporar los ponderadores que reflejen la composición del INPC en México (como se menciona anteriormente y se ilustra en el cuadro 1). En este caso, la matriz \mathbf{S} y el vector \mathbf{P}_t

tienen la siguiente estructura:

$$\mathbf{S} = \begin{bmatrix} 0.15 & 0.22 & 0.18 & 0.05 & 0.15 & 0.03 & 0.05 & 0.08 & 0.09 \\ 0.20 & 0.30 & 0.23 & 0.07 & 0.20 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.13 & 0.19 & 0.31 & 0.36 \\ 0.40 & 0.60 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.47 & 0.14 & 0.39 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.41 & 0.59 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0.45 & 0.55 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{P}_t = \begin{bmatrix} P_{G,t} \\ P_{S,t} \\ P_{N,t} \\ P_{SM,t} \\ P_{SS,t} \\ P_{NAg,t} \\ P_{NAc,t} \\ P_{SMA,t} \\ P_{SMO,t} \\ P_{SSV,t} \\ P_{SSE,t} \\ P_{SSO,t} \\ P_{NAgF,t} \\ P_{NAgC,t} \\ P_{NAcA,t} \\ P_{NAcC,t} \end{bmatrix},$$

donde P_G es el INPC general, P_S es el INPC subyacente, P_N es el INPC no subyacente, P_{SM} es el índice de mercancías, P_{SS} es el índice de servicios, P_{NAg} es el índice de agropecuarios, P_{NAc} es el índice de precios administrados y concertados, P_{SMA} es el índice de alimentos, P_{SMO} es el índice de otras mercancías, P_{SSV} es el índice de vivienda, P_{SSE} es el índice de educación, P_{SSO} es el índice de otros servicios, P_{NAgF} es el índice de frutas y verduras, P_{NAgC} es el índice de carnes y huevo (pecuarios), P_{NAcA} es el índice de precios administrados, y P_{NAcC} es el índice de precios concertados.

Utilizando la matriz \mathbf{S} y los mejores pronósticos estacionales de horizontes múltiples computados en la sección anterior, que se denotarán como $\hat{\mathbf{P}}$, los pronósticos agregados se calculan de la siguiente manera:

$$\tilde{\mathbf{P}} = \mathbf{S}\mathbf{Q}\hat{\mathbf{P}}, \quad (8)$$

donde $\tilde{\mathbf{P}}$ y $\hat{\mathbf{P}}$ son matrices de 16×12 , cuyos elementos son los pronósticos de cada una de las 16 series para los 12 horizontes; \mathbf{S} es la matriz ponderadora, y \mathbf{Q} es una matriz de orden $m_3 \times m$, que varía según el método de combinación¹⁸ El propósito de \mathbf{Q} es extraer y combinar los elementos relevantes de los pronósticos base, $\hat{\mathbf{P}}$, para obtener pronósticos combinados del nivel más bajo (en este caso, nivel 3), los cuales son ponderados por \mathbf{S} para

¹⁸La matriz \mathbf{Q} es equivalente a la matriz \mathbf{P} en Hyndman, et al. (2007).

obtener pronósticos de los distintos niveles, $\tilde{\mathbf{P}}$. Tales pronósticos son combinaciones lineales de los pronósticos base que cumplen con las jerarquías. Adicionalmente, Hyndman et al. (2007) muestran que los pronósticos resultantes no están sesgados siempre y cuando los pronósticos base tampoco estén sesgados y:

$$\mathbf{SQS} = \mathbf{S}. \quad (9)$$

4.1.1. Método *Bottom-up*

Este método sólo utiliza los pronósticos de las series más desagregadas, las del nivel 3, y las agrega por medio de los ponderadores correspondientes en la matriz \mathbf{S} , para obtener pronósticos para los otros niveles de la jerarquía: niveles 0, 1 y 2.

En este caso, la matriz \mathbf{Q} tiene la siguiente forma:

$$\mathbf{Q} = \left[\mathbf{0}_{m_3 \times (m-m_3)} \mid \mathbf{I}_{m_3} \right], \quad (10)$$

donde $\mathbf{0}$ es una matriz nula de orden 9×7 y \mathbf{I}_{m_3} es una matriz identidad de orden 9×9 . Claramente, $\mathbf{SQS} = \mathbf{S}$ ya que por su construcción genera pronósticos sin sesgo siempre y cuando los pronósticos del nivel 3 no estén sesgados.

4.1.2. Método HAA

Este método utiliza pronósticos de todos los niveles y en este caso la matriz \mathbf{Q} tiene la siguiente forma:

$$\mathbf{Q} = (\mathbf{S}'\mathbf{S})^{-1} \mathbf{S}'. \quad (11)$$

Hyndman et al. (2007) muestran que este método genera pronósticos que cumplen con la jerarquía, que no presentan sesgo cuando los pronósticos base tampoco están sesgados (ya que $\mathbf{SQS} = \mathbf{S}$) y que, bajo ciertos supuestos, minimizan la varianza entre las combinaciones posibles que cumplen con los dos puntos anteriores. La intuición detrás del método HAA es que existen pronósticos de los niveles más bajos de la jerarquía implícitos en los niveles más agregados (como resultaría si se aplicara el método *top-down*). Sin embargo, estos pronósticos implícitos fueron generados condicionados a un conjunto de datos que probablemente es más amplio que el utilizado para construir los pronósticos para el nivel más bajo. Si se combinan todos los pronósticos posibles para formar mejores pronósticos de los niveles más bajos (en este caso, 9 series) implícitamente se combinan los conjuntos condicionales utilizados para calcular todos los pronósticos (16 para esta aplicación). La matriz \mathbf{Q} contiene los ponderadores de combinación mientras que la matriz \mathbf{S} contiene los ponderadores de agregación. Es

importante notar que los ponderadores en \mathbf{Q} no dependen de los datos y que la condición (9) implica que la combinación de todos los pronósticos posibles implícitos para cada serie en particular del nivel más bajo de la jerarquía es convexa (es decir, los ponderadores suman uno).

4.2. Evaluación de métodos de agregación

En esta subsección primero se compara la capacidad predictiva de los dos métodos de agregación anteriormente descritos y posteriormente la capacidad predictiva de los pronósticos agregados con la de los mejores modelos individuales.

4.2.1. *Bottom-up* vs. HAA

Para poder comparar el desempeño de ambos métodos de agregación se utiliza la siguiente hipótesis para cada serie:

$$H_0: E[L_{t+1:t+12,t}^{BU} - L_{t+1:t+12,t}^{HAA}] = 0$$

$$H_1: E[L_{t+1:t+12,t}^{BU} - L_{t+1:t+12,t}^{HAA}] \neq 0,$$

donde el superíndice BU indica que los pronósticos se agregaron utilizando el método *bottom-up* y el superíndice HAA indica que se utilizó el método de combinación HAA. La hipótesis nula implica capacidades iguales de predicción y la hipótesis alternativa implica que un pronóstico tiene un EPCM menor (de horizontes múltiples), en la población. Posteriormente se genera el estadístico de prueba en base a Capistrán (2006), que propone pruebas de tipo Diebold-Mariano-West (Diebold y Mariano, 1995; West 1996) aplicadas a este tipo de funciones de pérdida multivariadas. Después se compara el estadístico de prueba con una distribución normal estándar, como se propone por los autores previos.

Los resultados se presentan en el cuadro 3, donde la columna llamada BU vs. HAA presenta la media muestral del diferencial de pérdida entre BU y HAA, que forma la base para la prueba Diebold-Mariano-West. Los métodos parecen tener el mismo poder predictivo para 10 de las 16 series. El método HAA es mejor que el bottom-up en 3 series: servicios, educación, y otros servicios. El método *bottom-up* supera al método HAA en 3 series: otras mercancías, pecuarios, y precios concertados. Por tal motivo, los métodos parecen tener capacidades similares de predicción. Sin embargo, nótese que a pesar de no ser estadísticamente significativo en algunos casos, el método HAA tiene una pérdida promedio menor en 11 de las 16 series (como se observa por el signo positivo de la media muestral del diferencial de pérdida), por lo que pudiera preferirse ligeramente al método *bottom-up*.

En particular, HAA parece ser el mejor método para casi todas las series que no pertenecen al nivel más bajo de la jerarquía, con excepción de la serie de administrados y concertados. Este último resultado es consistente con los resultados de Hyndman et al. (2007).

4.2.2. Pronósticos de series individuales vs. pronósticos agregados a través de desagregados

Un aspecto empírico interesante que se puede investigar mediante los pronósticos obtenidos en este trabajo es el de realizar pronósticos de una serie agregada directamente o pronosticar las series desagregadas y posteriormente agregarlas (Hubrich, 2005). Para poder realizar dichos pronósticos, se repite el ejercicio de evaluación, pero esta vez comparando el desempeño del método HAA con el mejor modelo estacional (sin agregación, como se derivó en la sección 3) para cada una de las 16 series. Los resultados se presentan en la columna denominada Estacional vs. HAA en el cuadro 3, en donde el número mostrado para cada serie es el promedio del diferencial de pérdida de horizontes múltiples entre los pronósticos resultantes de los mejores pronósticos individuales y los del método HAA. El HAA tiene mejor capacidad predictiva para 6 series, mientras que los modelos individuales sólo para tres series. Todas las series donde los modelos individuales presentan un mejor desempeño pertenecen al nivel más bajo de la jerarquía. Además, en todas las series que no pertenecen al nivel 3 de la jerarquía, el método HAA es mejor (a pesar de que la diferencia no siempre es estadísticamente significativa). Por lo tanto, los resultados obtenidos en el presente documento indican que, en este caso, pronosticar los componentes y posteriormente agregarlos parece producir mejores pronósticos, en comparación con pronosticar directamente los agregados.

5. Conclusiones

La capacidad de pronóstico de modelos de series de tiempo se ha documentado ampliamente (por ejemplo, Granger y Newbold (1986)) y, en general, este tipo de modelos constituye una buena manera de resumir lo que el pasado de las series puede informar sobre su futuro. En esta investigación se han utilizado un subconjunto particular de modelos de series de tiempo -aquéllos que específicamente modelan el componente estacional- para pronosticar la inflación de corto plazo en México. Los cuatro modelos que se han considerado tienen distintos supuestos acerca de las propiedades estocásticas de la tendencia y de los componentes estacionales de las series. El mejor modelo fue elegido para las 16 series de la inflación utilizando una función de pérdida de horizontes múltiples, y posteriormente agregando los pronósticos resultantes de tal manera que cumplan con las jerarquías. Al parecer, los mejores modelos, en términos de la REPCM fuera de la muestra, son los que asumen que

la estacionalidad y la tendencia (cuando es significativa) son determinísticas. Los mejores pronósticos se obtienen a través de la combinación de modelos individuales, haciendo mejor uso de la información contenida en los pronósticos de todos los niveles, al mismo tiempo que se satisfacen las jerarquías. Los pronósticos resultantes se pueden obtener en tiempo real automáticamente en el sentido de que, una vez que se recibe información sobre la inflación de un nuevo mes, tarda sólo segundos volver a estimar los modelos, seleccionar el mejor para cada serie, y combinar los mejores pronósticos individuales. Por lo tanto, los pronósticos obtenidos con los métodos de esta investigación pueden servir como un buen punto de inicio en el proceso recurrente de pronosticar la inflación hasta un año hacia delante. Una vez que se obtienen los pronósticos automáticos se pueden ajustar para incorporar información que no está incluida en el pasado de las series (por ejemplo, ajustarlos a un cambio conocido de precios administrados) o combinarlos con pronósticos de otras fuentes.

Los mejores pronósticos de inflación general de este documento compiten sorprendentemente bien con el consenso de especialistas que responden la encuesta mensual de los especialistas en economía del sector privado elaborada por el Banco de México (EEBM). En la gráfica 6 se muestran los pronósticos de consenso, los pronósticos del método HAA, y el valor observado de la inflación. Los pronósticos corresponden a los horizontes uno y doce y es evidente que dichos pronósticos son muy similares. La prueba formal de habilidad de predicción de tipo Diebold-Mariano-West que utiliza la función de pérdida de horizontes múltiples produce un valor-p de 0.49, lo que indica que no hay suficiente evidencia para rechazar la hipótesis nula de que la capacidad predictiva es igual entre los pronósticos. Si se considera que los pronósticos de las encuestas de especialistas parecen tener un mejor desempeño que otro tipo de pronósticos de inflación (ver Ang et al. (2007) para Estados Unidos, y Capistrán y López-Moctezuma (2008) para México), este resultado muestra que los pronósticos obtenidos por medio de los modelos estacionales se pueden utilizar de manera confiable como un primer pronóstico automático de la inflación de corto plazo, con la ventaja adicional de que los métodos utilizados en esta investigación se pueden utilizar para pronosticar cualquier nivel de la jerarquía de las series de inflación, mientras que los pronósticos de las encuestas corresponden típicamente a los primeros dos niveles de la jerarquía.

Existen varias maneras de mejorar los pronósticos presentados en este documento. En particular, el método de agregación sugiere que obtener mejores modelos individuales -posiblemente incorporando variables predictivas a alguno o incluso a todos ellos- podría ser una manera parsimoniosa de introducir información adicional. Además, los ponderadores de combinación implícitos en el método de agregación HAA no dependen de los datos y están restringidos a sumar 1, lo que implica que existen posibilidades de mejorar dichos modelos. Las investigaciones a futuro deberían considerar estos aspectos.

Referencias

- [1] Ang, A., G. Bekaert, y M. Wei, 2007. Do macro variables, asset markets or surveys forecast inflation better? *Journal of Monetary Economics* 54, 1163-1212.
- [2] Banco de México, 2002a. Metodología para el cambio de base del INPC. <http://www.banxico.org.mx/eInfoFinanciera/Infecon/cuadros/CambioBaseINPC.pdf>
- [3] Banco de México, 2002b. El Índice Nacional de Precios al Consumidor: características y actualización de su base al año 2002. <http://www.banxico.org.mx/inpc/pdf/inpc2.pdf>
- [4] Banco de México, 2007. Reporte sobre la Inflación Julio-Septiembre 2007.
- [5] Box, G.E.P., G.M. Jenkins, y G.C. Reinsel, 1994. *Time Series Analysis Forecasting and Control*. Volumen 2, Prentice Hall.
- [6] Capistrán, C., 2006. On comparing multi-horizon forecasts. *Economics Letters* 93, 176-181.
- [7] Capistrán, C., y G. López-Moctezuma, 2008. Las expectativas macroeconómicas de los especialistas: Una evaluación de pronósticos de corto plazo en México. Documento de Investigación 2008-11, Banco de México. Próximo a publicarse en *El Trimestre Económico*.
- [8] Chiquiar, D., E.A. Noriega, y M. Ramos-Francia, 2007. A time series approach to test a change in inflation persistence: The Mexican experience. Documento de Investigación 2007-1, Banco de México. Próximo a publicarse en *Applied Economics*.
- [9] Diebold, F.X., y L. Kilian, 2000. Unit root tests are useful for selecting forecasting models. *Journal of Business and Economic Statistics* 18, 265-273.
- [10] Diebold, F.X., y R.S. Mariano, 1995. Comparing predictive accuracy. *Journal of Business and Economic Statistics* 13, 134-144.
- [11] Espasa, A., E. Senra y R. Albacete, 2002. Forecasting inflation in the European Monetary Union: A disaggregated approach by countries and by sectors. *European Journal of Finance* 8(4), 402-421.
- [12] Franses, P.H., 1996. *Periodicity and Stochastic Trends in Economic Time Series*. Oxford University Press. Oxford: U.K.
- [13] Franses, P.H., 2007. Constant vs. changing seasonality. *Foresight* 6, 24-25.

- [14] Gagnon, E., 2007. Price setting during low and high inflation: Evidence from Mexico. International Finance Discussion Papers 896, Board of Governors of the Federal Reserve System. Próximo a publicarse en *The Quarterly Journal of Economics*.
- [15] Ghysels, E., y D.R. Osborn, 2001. *The Econometric Analysis of Seasonal Time Series*. Cambridge University Press.
- [16] Ghysels, E., D.R. Osborn, y P.M. Rodriguez, 2005. Forecasting seasonal time series. En G. Elliott, C.W.J. Granger, y A. Timmermann, (eds), *Handbook of Economic Forecasting*, North-Holland.
- [17] Gómez, V., y A. Maravall, 1996. Programs TRAMO (Time Series Regression with ARIMA noise, Missing Observations and Outliers) and SEATS (Signal Extraction in ARIMA Time Series). Instructions for the user. Working paper 9628, Banco de España.
- [18] Granger, C.W.J., 1966. The typical spectral shape of an economic variable. *Econometrica* 34, 150-161.
- [19] Granger, C.W.J. y P. Newbold, 1986. *Forecasting Economic Time Series*. Volumen 2, Academic Press, San Diego.
- [20] Hylleberg, S., R. Engle, C.W.J. Granger, y S. Yoo, 1990. Seasonal integration and cointegration. *Journal of Econometrics* 44, 215-238.
- [21] Hylleberg, S., 1992. *Modeling Seasonality*. Oxford: Oxford University Press.
- [22] Hyndman, R., R. Ahmed, y G. Athanasopoulos, 2007. Optimal combination forecasts for hierarchical time series. Working Paper 09/07. Department of Econometrics and Business Statistics, Monash University.
- [23] Hubrich, K., 2005. Forecasting Euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy? *International Journal of Forecasting* 21, 119-136.
- [24] Osborn, D., 2002. Unit-root versus deterministic representations of seasonality for forecasting. En Clements, M.P. y D.F. Hendry, Eds. *A Companion to Economic Forecasting*, Blackwell.
- [25] Rodrigues, P.M. y D. Osborn, 1999. Performance of seasonal unit root tests for monthly data. *Journal of Applied Statistics* 26(8), 985-1004.
- [26] Schwarz, G., 1978. Estimating the dimension of a model. *The Annals of Statistics* 6, 461-64.

- [27] Stock, J. y M. Watson, 2003. Forecasting inflation. *Journal of Monetary Economics* 44, 293-335.
- [28] Stock, J. y M. Watson, 2007. Has inflation become harder to forecast? *Journal of Money, Credit and Banking* 44, 293-335.
- [29] West, K.D., 1996. Asymptotic inference about predictive ability. *Econometrica* 64, 1067-84.

Cuadro 1: Estructura del Índice de Precios al Consumidor en México

	Pesos
General	100 %
Subyacente	75 %
Mercancías	37 %
Alimentos	15 %
Otras mercancías	22 %
Servicios	38 %
Vivienda	18 %
Educación	5 %
Otros servicios	15 %
No subyacente	25 %
Agropecuarios	8 %
Frutas y verduras	3 %
Pecuarios	5 %
Administrados y concertados	17 %
Administrados	8 %
Concertados	9 %

Nota: La ponderación representa el peso porcentual de cada índice en el índice general.

Fuente: Banco de México.

Cuadro 2: REPCM para determinar el mejor modelo estacional

	1	2	3	4	Ganador
General	1.013	2.554	1.121	0.725	4
Subyacente	0.364	0.737	0.366	0.341	4
Mercancías	0.484	1.190	0.466	0.496	3
Alimentos	1.023	2.708	0.964	1.030	3
Otras mercancías	0.318	1.614	0.314	0.302	4
Servicios	0.511	1.800	0.557	0.521	1
Vivienda	0.648	2.235	0.588	0.544	4
Educación	0.601	6.194	1.919	1.477	1
Otros servicios	0.899	2.176	0.928	0.860	4
No subyacente	3.892	8.094	4.342	2.694	4
Agropecuarios	13.661	26.299	12.730	8.880	4
Frutas y verduras	30.133	49.277	31.934	21.134	4
Pecuarios	3.279	6.597	3.824	3.245	4
Administrados y concertados	1.952	9.861	2.151	1.594	4
Administrados	3.484	15.455	3.882	2.897	4
Concertados	0.809	2.410	1.078	0.799	4

Nota: Las REPCM se calcularon con pronósticos recursivos fuera de la muestra de febrero 2005 a diciembre 2007. El modelo ganador es el que tiene la REPCM más pequeña.

Fuente: Cálculos de los autores elaborados con información del Banco de México.

Cuadro 3: Prueba de Diebold-Mariano-West para determinar el mejor pronóstico

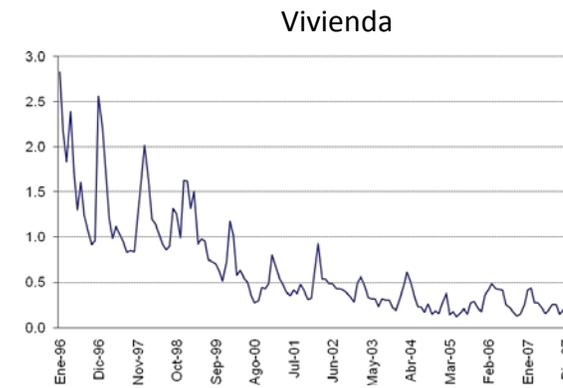
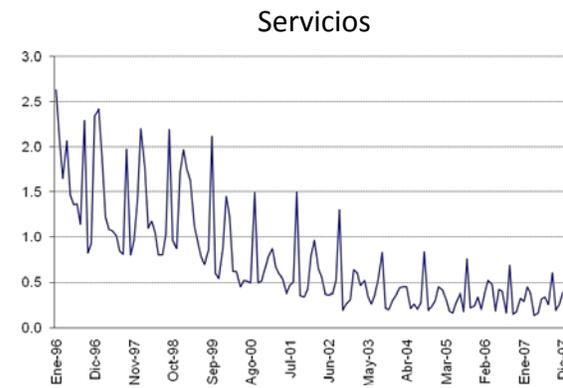
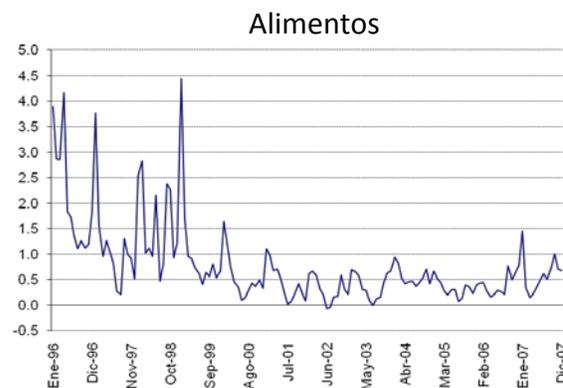
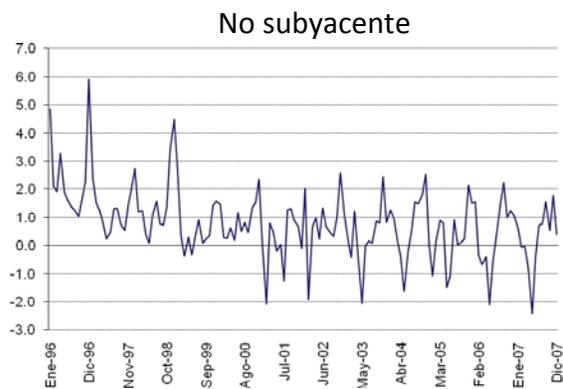
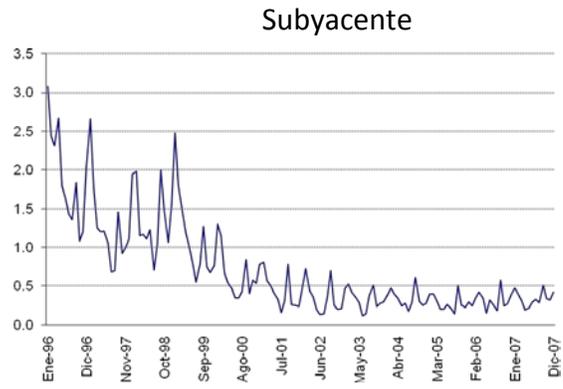
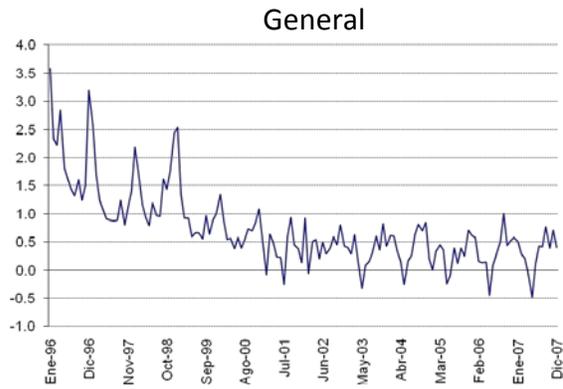
	BU vs. HAA	Estacional vs. HAA
General	0.010	0.012
Subyacente	0.002	0.008
Mercancías	0.004	0.025**
Alimentos	0.015	0.015
Otras mercancías	-0.011**	-0.011**
Servicios	0.011***	0.044***
Vivienda	-0.002	-0.002
Educación	0.005***	0.005***
Otros Servicios	0.025***	0.025***
No subyacente	0.182	0.157
Agropecuarios	0.427	2.095**
Frutas y verduras	1.184	1.184
Pecuarios	-0.568**	-0.568**
Administrados y concertados	-0.052	0.100**
Administrados	-0.065	-0.065
Concertados	-0.050*	-0.050*

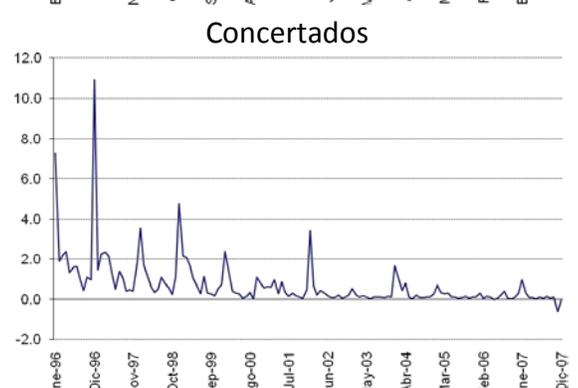
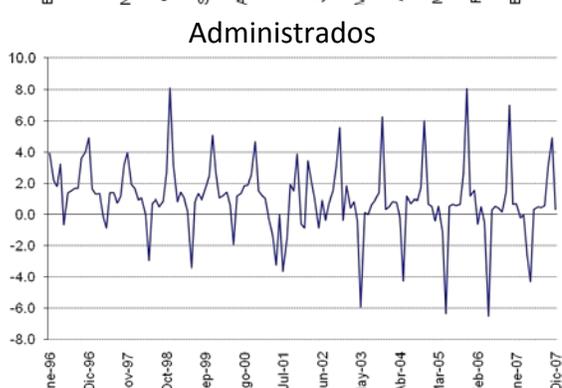
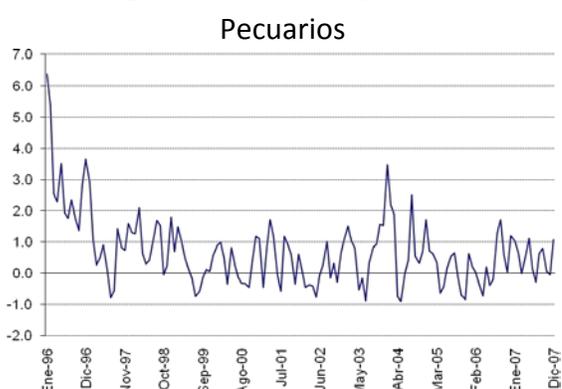
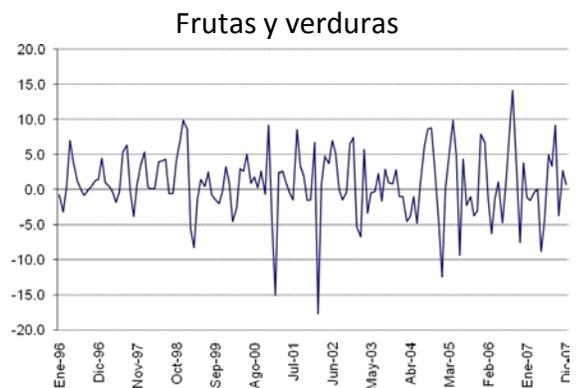
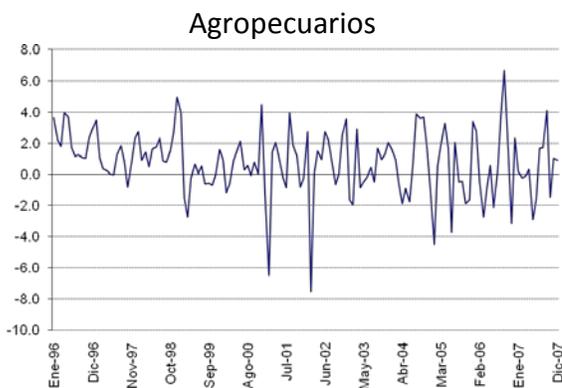
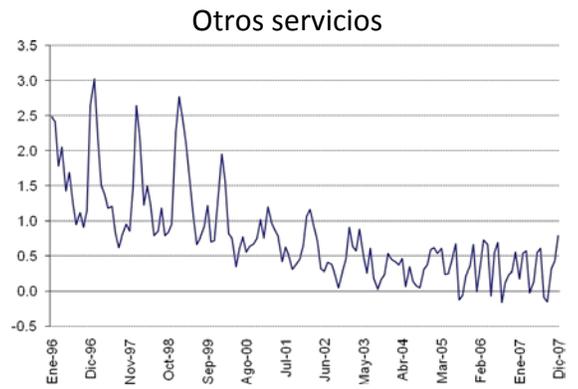
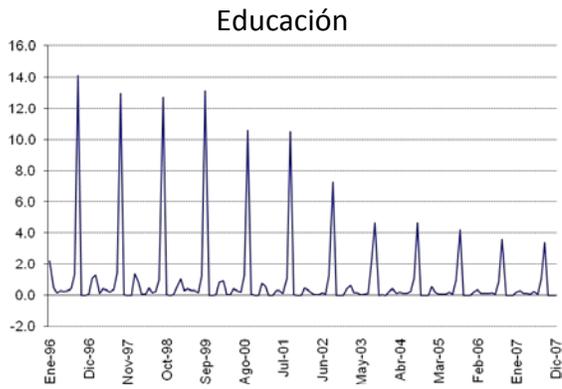
Nota: Cada prueba utiliza pronósticos recursivos fuera de la muestra de febrero 2005 a diciembre 2007. *, **, y *** denotan significancia estadística al 10, 5 y 1 por ciento, respectivamente.

El número reportado es el diferencial de pérdida promedio.

Fuente: Cálculos de los autores elaborados con información del Banco de México.

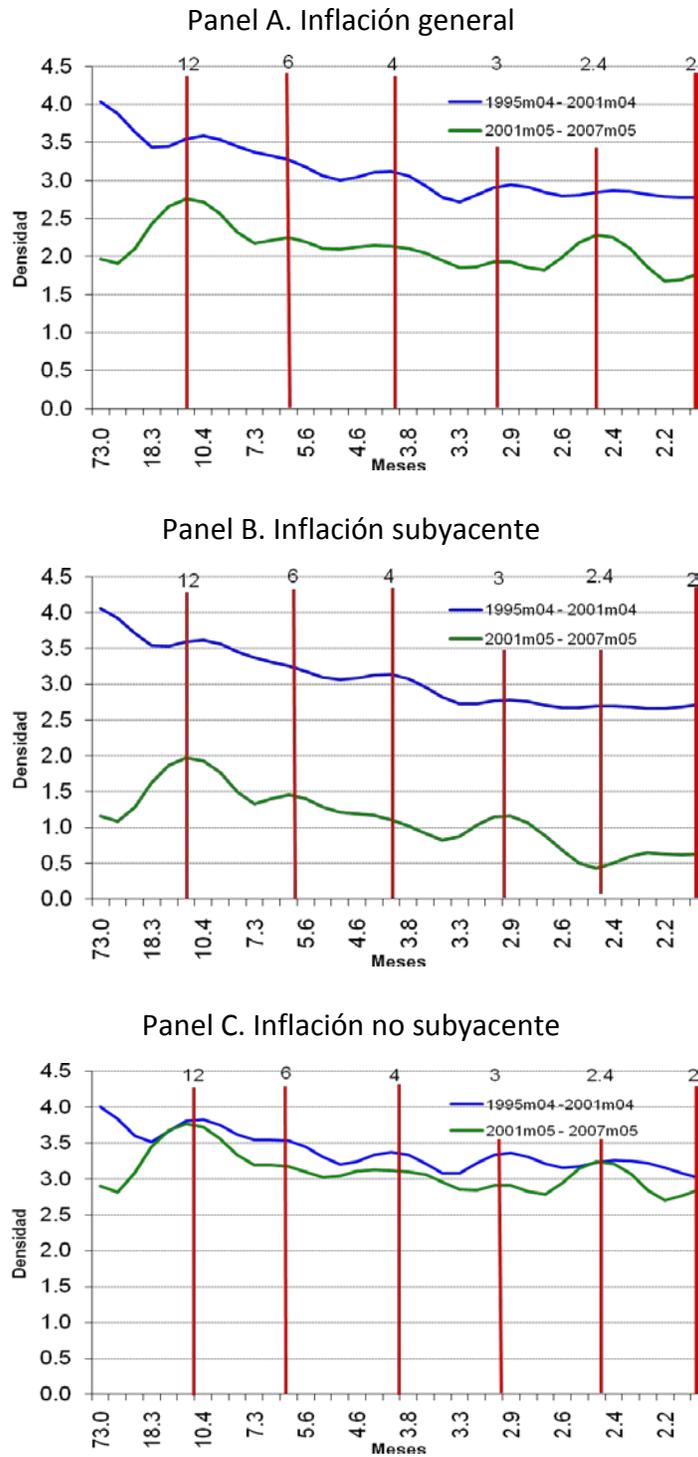
Gráfica 1: Inflación





Fuente: Banco de México.

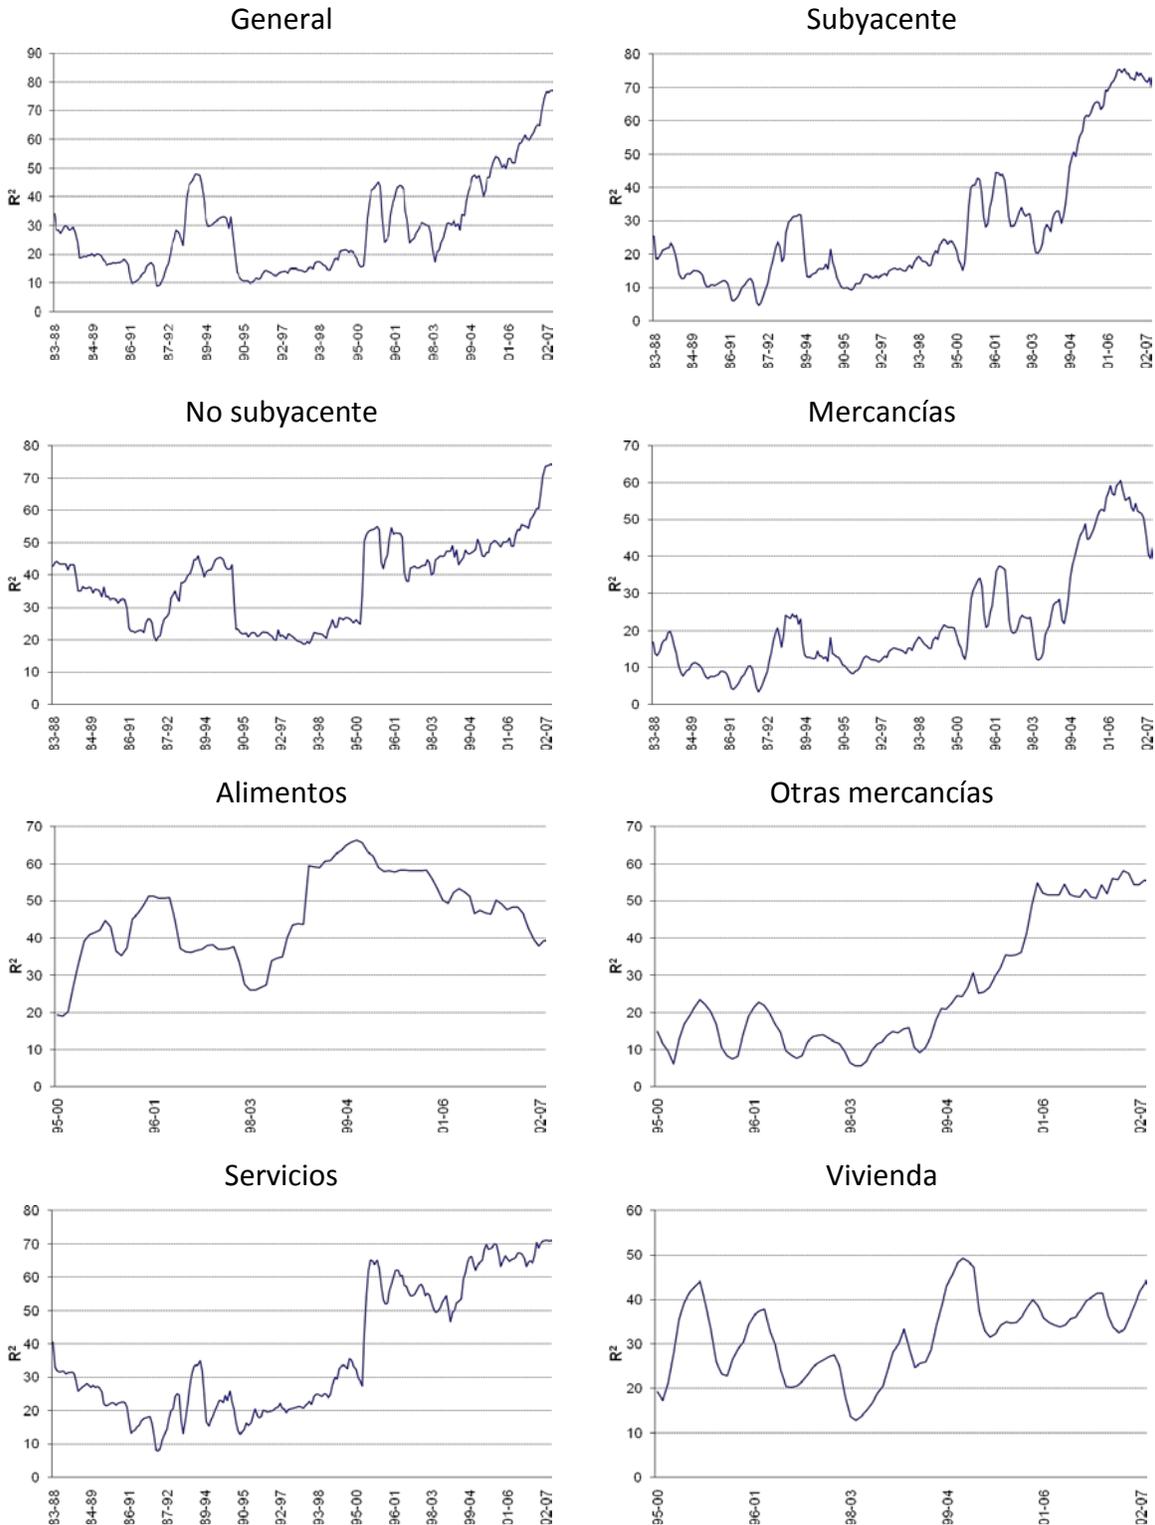
Gráfica 2: Densidades espectrales

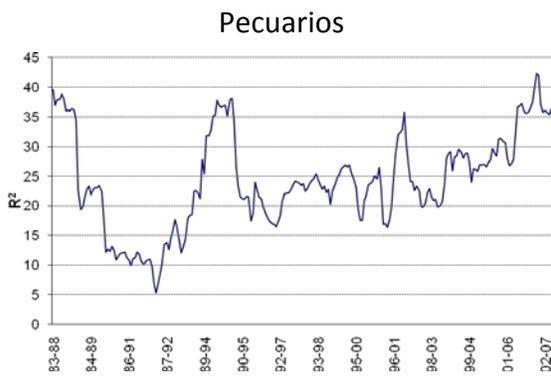
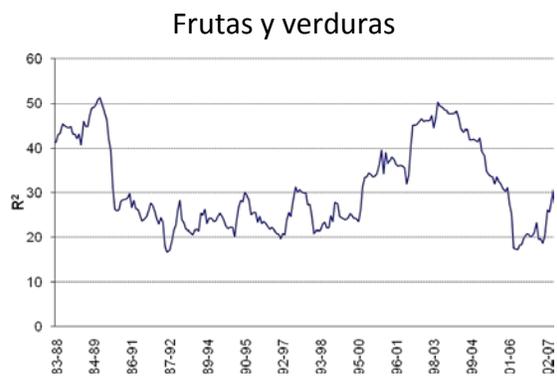
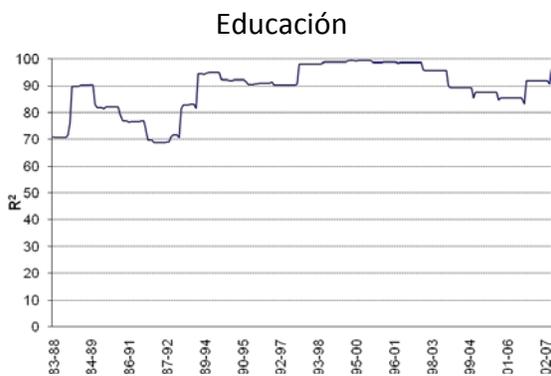


Nota: Densidades estimadas con ventanas de Bartlett.

Fuente: Cálculos de los autores elaborados con información del Banco de México.

Gráfica 3: Bondad del ajuste de regresiones conformadas únicamente por 12 variables estacionales dicotómicas



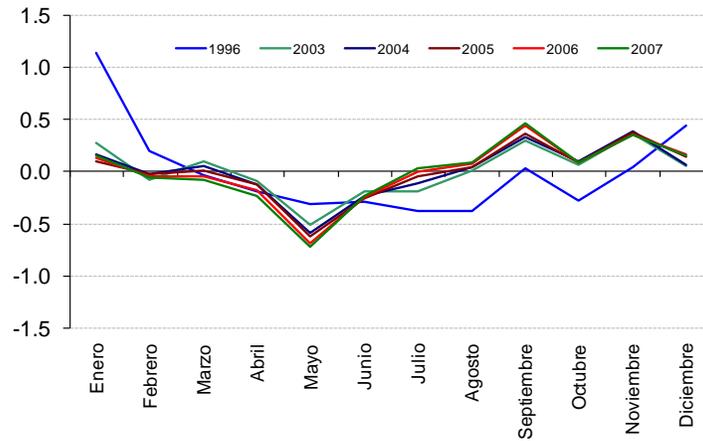


Nota: R²s de regresiones de inflación sobre *dummies* estacionales utilizando ventanas móviles de 5 años.

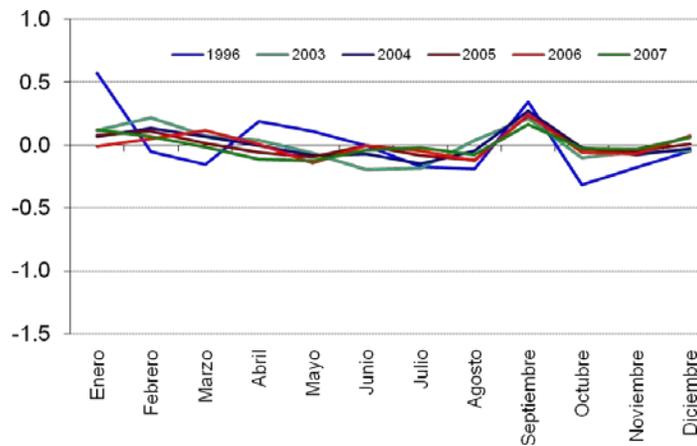
Fuente: Cálculos de los autores elaborados con información del Banco de México.

Gráfica 4: Factores estacionales

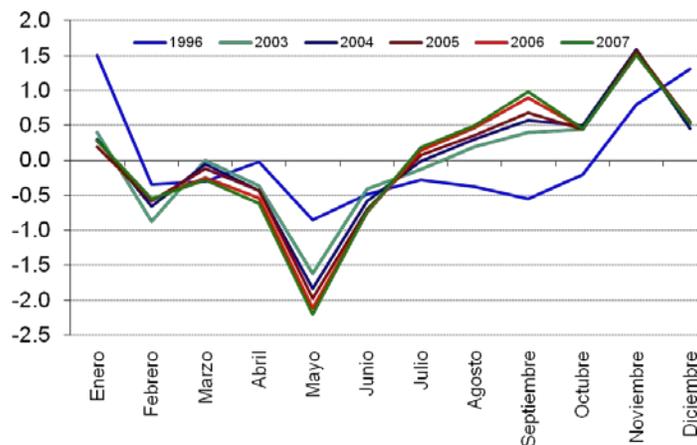
Panel A. Inflación general



Panel B. Inflación subyacente



Panel C. Inflación no subyacente

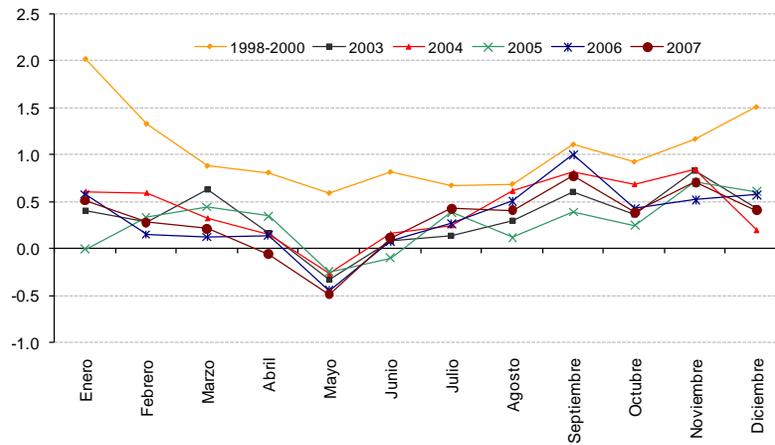


Nota: Factores estacionales calculados con Tramo-Seats.

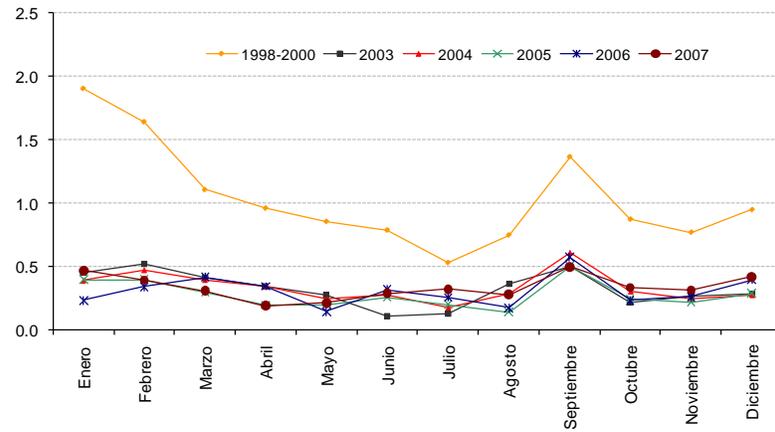
Fuente: Cálculos de los autores elaborados con información del Banco de México.

Gráfica 5: Dinámica inflacionaria

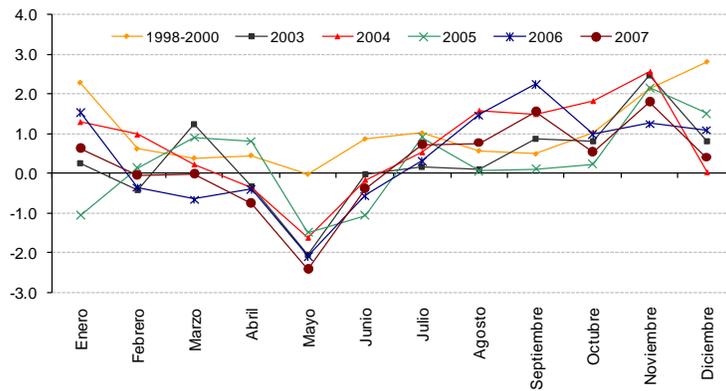
Panel A. Inflación general



Panel B. Inflación subyacente



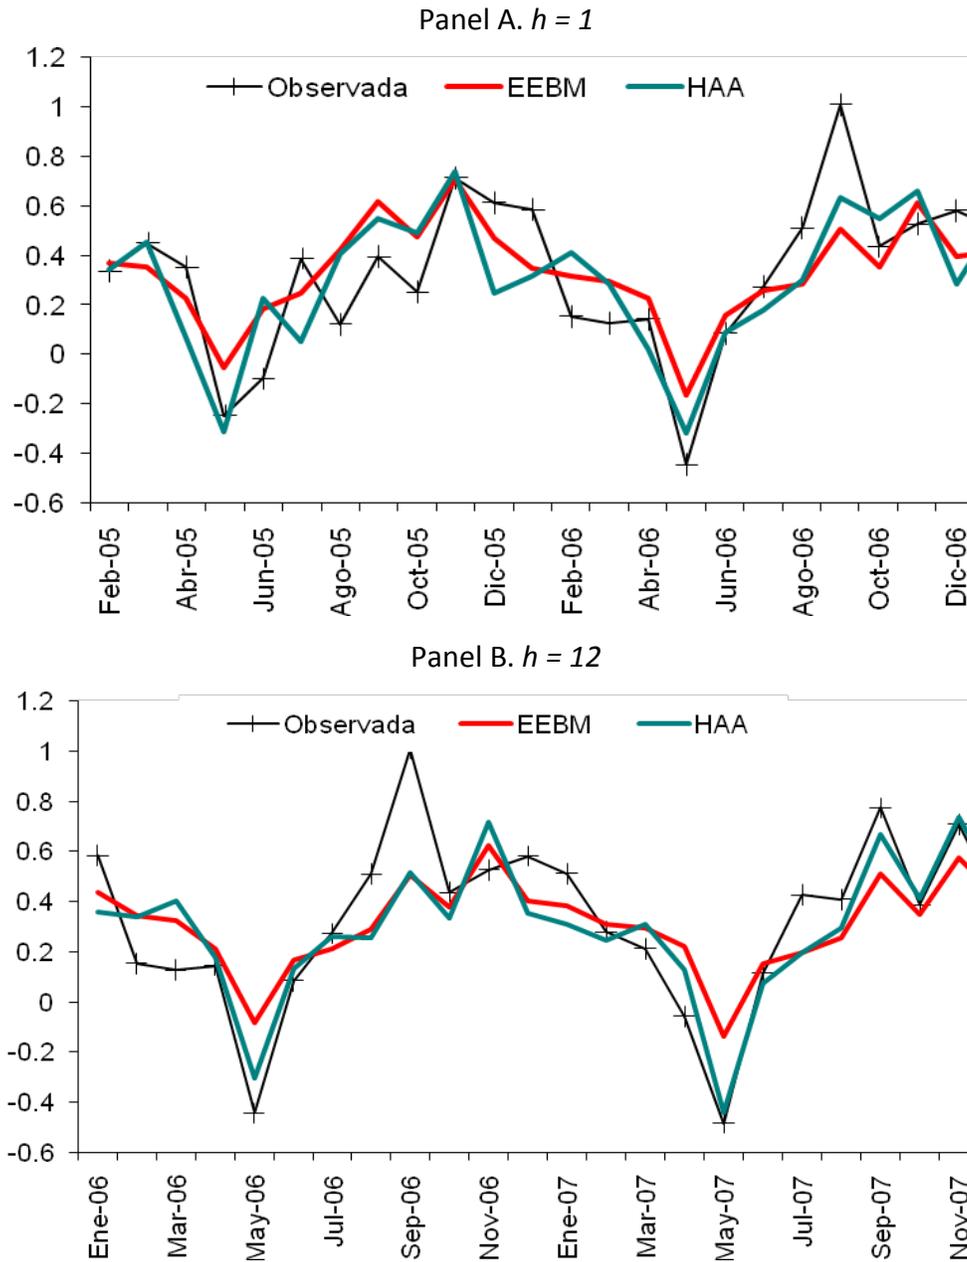
Panel C. Inflación no subyacente



Nota: La curva 1998-2000 corresponde al promedio de los años 1998, 1999 y 2000.

Fuente: Banco de México.

Gráfica 6: Comparación de combinaciones de pronóstico: inflación general



Notas: HAA: combinación de pronósticos recursivos fuera de la muestra utilizando el método de Hyndman et al. (2007). EEBM: pronósticos de consenso de la Encuesta de Especialistas Económicos del Sector Privado realizada por Banco de México.

Fuente: HAA: Cálculos de los autores elaborados con información del Banco de México. EEBM: Banco de México.