

PREDICCIÓN DE LA INFLACIÓN EN MÉXICO CON MODELOS DESAGREGADOS POR COMPONENTE *

Robinson Durán y Evelyn Garrido

Universidad de Concepción

Carolina Godoy

Banco Central de Chile

Juan de Dios Tena

Università di Sassari y Universidad Carlos III

Resumen: Se realiza un análisis empírico sobre el nivel óptimo de desagregación sectorial y la mejor estrategia de modelización econométrica para la predicción de la inflación en México. Se comparan diferentes estrategias de modelización desagregada basadas en: 1) modelos ARIMA univariantes, 2) metodologías de datos de panel, 3) modelos de corrección del equilibrio y 4) modelos de factores dinámicos. Se encuentra que la consideración de desagregación sectorial es útil a la hora de predecir la tasa de inflación agregada en México. Es más, la predicción de la inflación basada en modelos con datos de panel, modelos de corrección del equilibrio y factores dinámicos superan a simples estrategias extrapolativas basadas en modelos ARIMA univariantes.

Abstract: This article is an empirical analysis on the optimal level of disaggregation by sectors and the best econometric strategy in order to forecast Mexican inflation. We compare different disaggregate modeling strategies based on: 1) univariate ARIMA models, 2) panel data methodology, 3) vector error correction models, and 4) dynamic common factor models. It is found that disaggregation by sectors is useful in order to forecast the Mexican inflation rate. Moreover, inflation forecasts based on panel data, vector correction models and dynamic factor models improves those obtained from simple extrapolative devices based on ARIMA models.

Clasificación JEL/JEL Classification: C2, C3, C5

Palabras clave/keywords: predicción de la inflación, México, vectores de corrección del equilibrio, modelos de efectos fijos, factores dinámicos, forecasting Mexican inflation, vector error correction models, fixed effect models, dynamic factors

Fecha de recepción: 02 II 2011

Fecha de aceptación: 04 III 2012

* robinsonduran@udec.cl, cgodoy@bcentral.cl, evelyn Garrido@udec.cl, juande@uniss.it.

1. Introducción

Este artículo es un estudio empírico de las diferentes estrategias de predicción de la inflación mexicana, mediante la modelización econométrica de sus desagregados sectoriales. Disponer de un conocimiento preciso de la evolución futura de la tasa de inflación es una actividad clave a la que se enfrentan los bancos centrales, debido a que el efecto de las políticas monetarias sólo afecta a la evolución dinámica de los precios con un considerable retardo de tiempo. Esta predicción resulta también de utilidad para resolver la incertidumbre en la interacción entre agentes económicos, por ejemplo, entre patronales y sindicatos o prestamistas y prestatarios. La discusión y el análisis comparativo de diferentes procedimientos para mejorar la predicción de la inflación han adquirido una especial relevancia en los últimos años. De forma general, el debate se ha centrado en dos puntos fundamentales. Primero, conocer cuál es la desagregación sectorial relevante que debe ser usada en la proyección de la inflación. En principio parece lógico pensar que modelos econométricos que consideran una información más detallada van a capturar mejor la heterogeneidad de choques macroeconómicos que afectan al agregado de inflación. Sin embargo, en la práctica, un mayor número de series a analizar incrementa la dificultad de especificar modelos econométricos adecuados que capturen su dinámica. La evidencia empírica sobre dicho aspecto es aún contradictoria y ha generado un interesante debate; véase, por ejemplo, Hubrich (2005), Espasa y Albacete (2007) y Tena, Espasa y Pino (2010) con las referencias allí mencionadas.

El segundo punto, íntimamente ligado a la discusión anterior, se refiere al uso de modelos econométricos que capturen toda la heterogeneidad contenida en bases de datos muy desagregadas de forma parsimoniosa. Diferentes estrategias aplicadas a las distintas divisiones sectoriales que componen un índice de precios engloban, entre otras, el uso de: 1) modelos univariantes (Godoy y Tena 2006), 2) funciones de transferencia con indicadores adelantados (Zellner y Tobias 2000), 3) vectores de corrección del equilibrio (Espasa y Albacete 2007, Tena, Espasa y Pino 2010 y 4) modelos con factores dinámicos (Stock y Watson 2002, 2005).

Aquí analizamos empíricamente el nivel óptimo de desagregación sectorial y la mejor estrategia de modelización econométrica en la predicción de la inflación en México. En la literatura económica previa pueden encontrarse intentos de predicción de la inflación en ese país, por ejemplo, Bailliu *et al.* (2003) obtienen proyecciones de la tasa de inflación en México mediante modelos econométricos uniecuacionales, cuya forma funcional está basada en la teoría económica. En

concreto, se centran en tres tipos de modelos: 1) *mark-up* sobre la estimación de costo, 2) monetarios y 3) curvas de Phillips. Se encuentra que la mejor predicción se obtiene de los primeros, con una raíz cuadrada del error cuadrático medio de predicción 3 meses hacia adelante de 3,7%. En un artículo más reciente, Ibarra-Ramirez (2010) considera el uso de factores comunes, estimados a partir de un grupo de variables macroeconómicas para predecir la inflación en México, mediante su desagregación sectorial en 243 componentes. Nuestro trabajo está especialmente relacionado con el de Ibarra (2010), al considerar la predicción de la inflación en México a partir de sus desagregados sectoriales. No obstante, existen dos importantes diferencias con respecto a él. La primera es que, en nuestro caso, se consideran datos con frecuencia mensual (en lugar de trimestral), lo que consigue mejorar la precisión de nuestras proyecciones cuando se comparan en términos del error cuadrático medio de predicción. La segunda diferencia es que consideramos una amplia variedad de modelizaciones alternativas de componentes desagregados como: 1) modelos ARIMA univariantes, 2) modelos de cointegración con mecanismos de corrección del equilibrio, 3) modelos adaptados para datos de panel y 4) modelos de factores comunes basados tanto en información sectorial como de variables macroeconómicas.

En el presente documento se encuentra que la consideración de la desagregación sectorial conduce a una mejora en la predicción de la inflación en México, respecto a la modelización agregada. Además, dentro de los modelos para series desagregadas, se encuentra que las predicciones obtenidas mediante modelos ARIMA univariantes son superadas de forma significativa por especificaciones econométricas más sofisticadas.

El resto del artículo está estructurado como sigue. En la siguiente sección se presentan los datos usados en el análisis y se explican algunas de sus principales características. Luego, describimos formalmente la forma en que se han especificado los modelos univariantes, de efectos fijos dinámicos, corrección del equilibrio y factores dinámicos. Estas metodologías se utilizan en la sección 4 para el análisis comparativo de la predicción de la inflación mexicana bajo diferentes estrategias. Finalmente, las principales conclusiones aparecen en la última sección.

2. Análisis descriptivo de las series

La base de datos disponible incluye la serie agregada del índice nacional de precios al consumidor, INPC. La tasa de crecimiento anual

del INPC constituye el principal indicador de inflación considerado por el Banco de México y su predicción es nuestro objetivo. Además, se consideran las series que componen el INPC a partir de dos niveles de desagregación. El primer nivel engloba los índices de precios para los ocho grandes grupos que componen el INPC general: alimentos, bebidas y tabaco; ropa, calzado y accesorios; vivienda; muebles, aparatos y accesorios domésticos; salud y cuidado personal; transporte; educación y esparcimiento; y otros servicios. Un segundo nivel, más detallado, lo componen 77 subgrupos cuyos nombres hemos puesto en el apéndice por brevedad (ver anexo 1). Existe un tercer nivel de desagregación, compuesto por 315 índices de precios desagregados, que no es considerado aquí. La razón es que, la predicción de la inflación con información de 77 grupos de precios, ya constituye un nivel de desagregación mucho mayor al utilizado habitualmente en la literatura.

Todas las series son mensuales y han sido transformadas en logaritmos naturales para su modelización econométrica, cubre homogéneamente el periodo 2002:07-2008:07 debido a que, para el nivel de desagregación de 77 subgrupos, existen datos disponibles sólo desde esa fecha. Utilizar información para un periodo tan breve es necesario en nuestro caso particular, ya que la literatura económica apunta a un importante cambio estructural de la inflación en México a partir del año 2001, cuando se adoptaron los llamados objetivos de inflación y ésta pasa de ser un proceso no estacionario a uno estacionario (Chiquiar, Noriega y Ramos, 2010). Además, en el 2002 se produce un cambio de base en los genéricos que componen el índice de precios al consumidor, lo que también aconseja iniciar nuestro análisis a partir de dicho cambio.

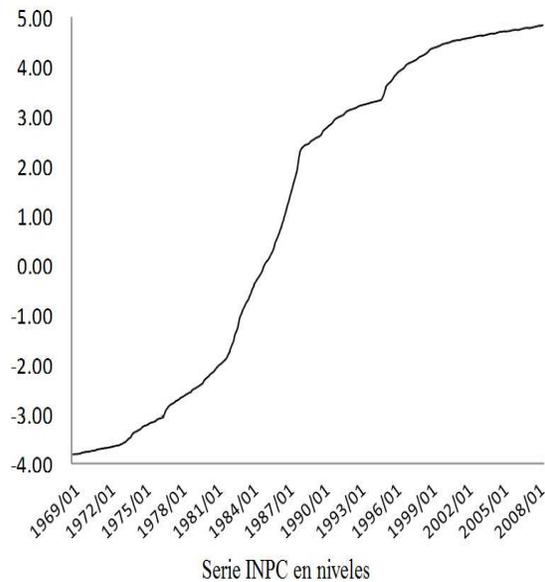
Debido a la escasa dimensión temporal de las series y a que nuestro objetivo es la predicción económica de la tasa de inflación anual, hemos considerado el periodo 2002:07-2006:07 para la especificación y estimación de los modelos econométricos y el periodo 2006:08-2008:07 para la evaluación de la predicción de la inflación mediante las diferentes estrategias de análisis. En todos los casos la información muestral fue obtenida del Banco de México a partir de su página en *internet*.

La evolución histórica del índice de precios agregado puede observarse en la gráfica 1. La serie en niveles muestra una dinámica suave y con crecimiento sistemático. Al tomar primeras diferencias, la serie parece tener una dinámica estacionaria, aunque dicha dinámica se ve afectada por importantes choques estructurales en distintos momentos del tiempo. En concreto, se observa una abrupta caída de la inflación mensual a finales de 1987 debido, probablemente, a la

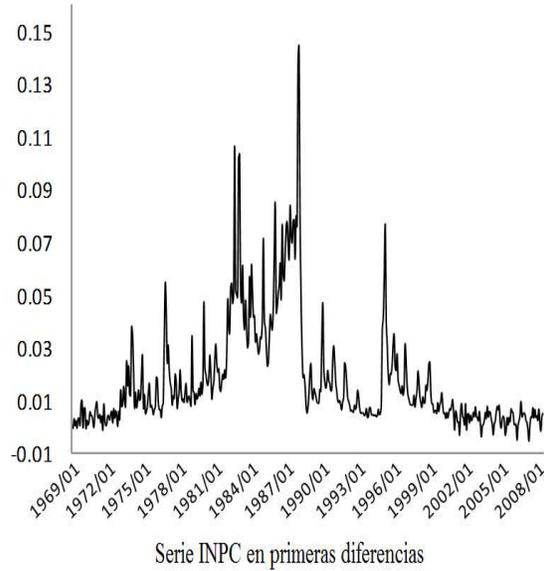
contracción de la demanda provocada por la crisis financiera. Posteriormente, el crecimiento de los precios se ha mantenido relativamente estable, salvo por un brusco incremento en 1995 provocado por la devaluación de la moneda en 1994.

Gráficas de las series desagregadas en ocho grupos se muestran en el apéndice al final del documento (ver anexo 2). Aunque todas estas series están afectadas por los choques macroeconómicos que han golpeado el INPC agregado, muestran una importante heterogeneidad en su comportamiento, que se hace aún más manifiesta en los 77 grupos de precios que componen el segundo nivel de desagregación; lo que confiere un especial interés a la modelización econométrica de los diferentes grupos de series como forma de capturar su heterogeneidad.

Gráfica 1
Índice de precios nacionales al consumo INPC
(en logaritmos naturales)



Gráfica 1
(continuación)



Hemos realizado un análisis más formal sobre la presencia de raíces unitarias en las series con base en la metodología propuesta por Osborn *et al.* (1988) (OCSB en adelante) quienes extienden el procedimiento de Hasza y Fuller (1982) a series temporales estacionales para datos mensuales. Aunque estamos conscientes de la existencia de procedimientos más sofisticados para investigar la presencia de raíces unitarias estacionales, como la prueba de Franses (1991) o Beaulieu y Miron (1993), hemos escogido el contraste OCSB por su simplicidad, lo que nos permite determinar si tomar o no diferencias estacionales, en lugar de contrastar por raíces unitarias en cada una de las frecuencias armónicas del ciclo estacional.

Al seguir a OCSB nuestra regresión de contraste para una variable p_t toma la forma:

$$\begin{aligned} \Delta\Delta_{12}p_t = & c + \sum_{s=1}^{11} \delta_s D_{st} + \beta_1 \Delta_{12}p_{t-1} + \beta_2 \Delta p_{t-12} \\ & + \sum_{i=1}^p \Psi_i \Delta\Delta_{12}p_{t-i} + \varepsilon_t \end{aligned} \quad (1)$$

donde c es un término constante, D_{st} es una variable estacional centrada para el mes s , Δ y Δ_{12} denotan, respectivamente, el operador de diferencias regulares y estacionales, p es el número de retardos en la ecuación, que en nuestro caso ha sido escogido basándose en el criterio de Schwarz y con un máximo de 12, y $\varepsilon_t \sim iid(0, \sigma^2)$ es el término de error.

Si p_t no es estacionario, pero $\Delta\Delta_{12}p_t$ es un proceso estacionario e invertible, entonces, al seguir OCSB, p_t se denota como I(2,1s), lo que indica que esta variable es integrada de orden 2 con 11 raíces estacionales. La hipótesis nula I(2,1s), $\beta_1 = \beta_2 = 0$, puede ser contrastada al utilizar un estadístico F .

Una alternativa a la hipótesis nula I(2,1s) es que se obtenga estacionariedad después de tomar primeras diferencias. Esta hipótesis alternativa, denotada como I(1,0s), puede ser representada en la ecuación (1) por $\beta_1 = 0$ y $\beta_2 < 0$. Una segunda alternativa es que el proceso requiera una diferencia anual para que sea estacionaria. La hipótesis alternativa I(1,1s) se captura en la ecuación (1) por $\beta_1 < 0$ y $\beta_2 = 0$. Si seguimos a OCSB, para distinguir entre estas dos alternativas, pueden usarse estadísticos t por separado para $\beta_1 = 0$ y $\beta_2 = 0$.

El cuadro 1 muestra los resultados de la prueba t para el INPC total, la desagregación en ocho grupos y los 77 subgrupos. A 5% de confianza la mayoría de los precios pueden ser considerados como I(1,0s). Las dos hipótesis, I(2,1s) y I(0) sólo son representativas en pocos casos. La estacionalidad puede considerarse determinista en la mayoría de los casos que se presenta.

Cuadro 1

Contraste de raíces unitarias regulares y estacionales para los índices de precios al consumo en los diferentes subgrupos de México

Variable	β_1	β_2	$F_{1,2}$	$F_s^{(1)}$	Retardos
INPC	-0.34	-4.87	12.19**	2.63*	1
G1	-0.11	-6.20	22.4**	1.85	5
G2	1.25	-4.85	11.97**	3.70*	1
G3	-0.53	-6.71	24.44**	4.51**	1
G4	0.97	-5.27	14.62**	1.63	12
G5	0.03	-5.42	16.71**	2.22*	12
G6	-0.23	-6.68	28.12**	1.38	11

Cuadro 1
(continuación)

<i>Variable</i>	β_1	β_2	$F_{1,2}$	$F_s^{(1)}$	<i>Retardos</i>
G7	-0.20	-5.74	17.47**	3.92**	5
G8	0.02	-5.65	20.01**	3.37*	4
R1	0.11	-9.60**	49.51**	3.16 **	12
R2	1.06	-4.59	10.81	0.76	12
R3	1.80	-4.32	9.33	0.90	1
R4	-0.49	0.00	0.15	1.00	12
R5	-0.46	-3.81	10.75	1.03	4
R6	2.28	-8.93**	43.69**	2.03	12
R7	2.75	-8.51**	40.58**	1.62	12
R8	2.60	-8.84**	41.09**	1.44	12
R9	1.26	-6.78**	24.50**	3.13*	1
R10	0.25	-5.91*	18.70*	3.51*	1
R11	1.77	-5.66	26.16**	1.84	8
R12	0.52	-9.90**	54.39**	5.05**	12
R13	2.01	-7.49**	29.77**	1.34	12
R14	1.64	-5.79*	21.08*	1.74	11
R15	2.13	-7.78**	31.63**	2.78*	9
R16	1.15	-2.87	5.09	0.88	12
R17	-0.23	-6.17*)	29.00**	3.45 *	1
R18	-2.24*	-4.07	16.88	2.26	1
R19	0.49	-4.55	12.07	0.95	11
R20	0.47	-6.21*	21.83*	1.67	12
R21	0.02	-8.53**	38.98**	2.01	12
R22	0.12	-4.24	10.27	1.33	1
R23	-0.07	-3.71	10.23	3.03*	1
R24	1.18	-4.94	12.19	1.64	1
R25	1.81	-5.83*	17.17	2.17	1
R26	1.63	-5.57	24.72**	1.52	9
R27	0.05	-3.99	8.99	1.29	5
R28	4.06	-9.79**	48.23**	3.99 **	2
R29	-0.82	-4.42	12.24	1.14	5
R30	-0.42	-9.32**	52.47**	5.53 **	12
R31	-0.19	-6.36*	23.77**	2.73 *	5
R32	-0.14	-5.61	17.87	2.20 *	10

Cuadro 1
(continuación)

<i>Variable</i>	β_1	β_2	$F_{1,2}$	$F_s^{(1)}$	<i>Retardos</i>
R33	-1.22	-3.82	10.38	2.10	1
R34	-2.33*	-11.20**	79.78**	4.14**	12
R35	-2.57*	-7.50**	34.45**	5.90**	1
R36	-1.60	-9.17**	56.40**	2.93**	9
R37	-2.47*	1.00	3.48	1.32	4
R38	2.59	-12.15**	94.00**	14.52**	6
R39	-0.05	-8.46**	41.40**	2.61 *	12
R40	-1.09	-5.70*	18.03	3.09*	1
R41	-0.31	-4.29	10.49	1.52	1
R42	0.97	-8.25**	50.04**	3.21**	11
R43	-0.39	-5.34	17.55	2.55*	12
R44	0.52	-4.88	15.21	2.75*	1
R45	2.40	-12.01**	74.28**	8.70**	1
R46	-0.42	-2.59	4.35	1.46	1
R47	2.69	-7.09**	26.31**	4.11**	12
R48	-0.29	-6.69**	26.49**	1.59	12
R49	-0.41	-6.91**	26.83**	2.51*	10
R50	-2.65*	-6.34*	34.61**	1.09	9
R51	-0.24	-9.05**	45.42**	5.55**	1
R52	3.11	-7.38**	27.39**	1.93	5
R53	1.69	-7.12**	27.67**	1.44	12
R54	-0.15	-6.82**	25.30**	0.96	12
R55	2.46	-4.82	12.42	3.25 *	1
R56	2.39	-6.39**	20.61*	2.64*	2
R57	1.92	-7.91**	34.45**	4.29**	5
R58	-2.00	-6.96**	28.83**	3.37*	1
R59	-0.07	-6.31*	26.41**	1.89	2
R60	-0.05	-6.57**	22.70*	2.75*	6
R61	-0.52	-4.13	11.83	1.05	6
R62	-1.81	-7.29**	31.31**	4.63**	1
R63	0.69	-5.44	16.84	2.36 *	12
R64	1.15	-7.23**	29.19**	1.04	12
R65	-1.75	-7.53**	31.35**	4.05**	1
R66	-0.01	-7.10**	26.20**	4.66**	1

Cuadro 1
(continuación)

<i>Variable</i>	β_1	β_2	$F_{1,2}$	$F_s^{(1)}$	<i>Retardos</i>
R67	2.26	-16.54**	160.09**	0.22	3
R68	-1.21	-3.66	11.35	1.20	5
R69	-1.16	-7.18**	31.17**	4.26**	11
R70	0.30	-5.46	22.61*	2.32	2
R71	-0.87	-5.98*	21.62*	3.78**	12
R72	1.60	-6.83**	26.41**	3.01**	12
R73	0.70	-5.40	18.82*	0.59	5
R74	1.65	-6.63**	22.94**	0.88	12
R75	-0.07	-5.84*	21.41*	2.77*	4
R76	-1.53	-2.53	5.81	1.67	12
R77	2.14	-7.81**	34.46**	6.61**	1

Notas: * y ** = rechazo de la hipótesis nula a un nivel de significancia de 5% y 1%, respectivamente. (1): estadístico F para contrastar la significatividad conjunta de las variables estacionales.

En vista de estos resultados, parece lógico suponer que las series de precios en México, en términos generales, son estacionarias tras una diferencia regular.

3. Estrategias de predicción

La consideración de un grado de desagregación, tan amplio como el descrito en la sección anterior, implica un importante esfuerzo de modelización econométrica para capturar, de forma adecuada, la dinámica de las series. Los modelos considerados se detallan a continuación.

3.1. Modelos ARIMA univariantes

Una posible opción es la modelización mediante simples modelos ARIMA univariantes con la incorporación de estacionalidad determinista en los casos que corresponda. En nuestro caso utilizamos una especificación similar a la considerada por Capistrán, Constandse y Ramos

(2010), debido al buen desempeño de dicho modelo para pronósticos de corto plazo con un periodo de estudio muy similar al del presente artículo. Concretamente la forma funcional considerada es:

$$\phi(L)\Delta^2 p_t = c + \sum_{j=1}^{11} \beta_j S_{jt} + \varepsilon_t \quad (2)$$

donde $\phi(L)$ es un polinomio autorregresivo en el operador de retardos L , c un parámetro constante, S_{jt} son variables estacionales que toman valor 1 en el mes j y 0 en otro caso. En la especificación final las variables estacionales son incluidas en el modelo cuando son significativamente diferentes de cero de manera conjunta y el número de retardos autorregresivos óptimo se ha seleccionado mediante el criterio de información de Schwarz. A primera vista, el modelo (2) puede parecer restrictivo al imponer una diferencia en la tasa de inflación junto con elementos deterministas, lo que implica asumir que la inflación crece en el tiempo con una pendiente determinista. Sin embargo, como se mostrará en las siguientes secciones, los diferentes pronósticos obtenidos con este modelo son adecuados y sus RMSE muestran valores ligeramente mejores a otras estrategias univariantes alternativas. En concreto, los pronósticos mostrados bajo la especificación (2) son superiores a los de algunos experimentos realizados, no mostrados en este artículo por razones de espacio, que se basan en especificaciones ARIMA mediante TRAMO/SEATS y también a proyecciones bajo modificaciones de la expresión (3) con el uso de tendencia determinista tal y como consideran Capistrán, Constandse y Ramos (2010) en algunos de sus modelos.

Igual que en Capistrán, Constandse y Ramos (2010), estimamos el porcentaje de la variación total de la inflación que se explica por las variables estacionales. Los resultados se muestran en el cuadro 2, como se puede observar en la inflación agregada el porcentaje es cercano a 70%. No obstante, a nivel desagregado éste es muy variable y llega a ser superior a 90% en sectores como vivienda, mientras el impacto de la variación estacional es prácticamente despreciable en la inflación de muebles, aparatos y accesorios.

3.2. Modelo dinámico con efectos fijos

Una peculiaridad importante de la información más desagregada que se considera en nuestro trabajo reside en que son series observadas

durante un periodo relativamente corto para la desagregación de 77 subgrupos. Por ello, parece lógico probar el comportamiento en predicción de técnicas estándar de modelización de datos de panel.

Cuadro 2

Porcentaje de variabilidad explicada por el componente estacional

<i>Variable</i>	<i>Porcentaje</i>	<i>Variable</i>	<i>Porcentaje</i>
INPC	0.69	R35	0.44
G1	0.11	R36	0.38
G2	0.59	R37	0.39
G3	0.91	R38	0.60
G4	0.00	R39	0.30
G5	0.49	R40	0.15
G6	0.20	R41	0.00
G7	0.78	R42	-0.03
G8	0.41	R43	0.31
R1	0.13	R44	0.95
R2	0.00	R45	0.08
R3	-0.08	R46	-0.03
R4	-0.07	R47	0.73
R5	0.24	R48	0.18
R6	0.05	R49	0.19
R7	0.14	R50	0.21
R8	0.05	R51	0.04
R9	-0.09	R52	-0.04
R10	0.52	R53	-0.07
R11	0.02	R54	0.12
R12	0.28	R55	-0.06
R13	-0.03	R56	0.15
R14	-0.02	R57	0.04
R15	0.40	R58	0.28
R16	-0.01	R59	0.15
R17	0.36	R60	0.29
R18	0.17	R61	0.12
R19	-0.07	R62	0.22
R20	0.25	R63	0.23

Cuadro 2
(continuación)

<i>Variable</i>	<i>Porcentaje</i>	<i>Variable</i>	<i>Porcentaje</i>
R21	0.05	R64	0.11
R22	0.03	R65	0.11
R23	0.35	R66	0.10
R24	0.08	R67	-0.03
R25	0.07	R68	0.90
R26	0.00	R69	0.54
R27	0.15	R70	0.36
R28	0.16	R71	0.57
R29	0.04	R72	0.17
R30	0.45	R73	0.00
R31	0.27	R74	0.04
R32	0.51	R75	0.37
R33	0.39	R76	0.21
R34	0.52	R77	0.44

Aquí consideramos un modelo de efectos fijos dinámicos que relaciona la inflación sectorial en México con su propio pasado. Para especificar el modelo, denotamos la inflación anual de un determinado precio observado en el mes t , p_t , como $\Pi_t = p_t - p_{t-12}$. La variable p_t se compone de n series de precios desagregadas $p_{i,t}$ $i = 1, 2, \dots, n$ y $\Pi_{i,t}$ es su tasa de inflación asociada.

Así, un simple modelo dinámico con efectos fijos estaría definido como:

$$\Pi_{i,t} = \eta_i + \Psi \Pi_{i,t-1} + a_{i,t} \tag{3}$$

donde η_i y Ψ son parámetros escalares a ser estimados y $a_{i,t}$ es un término de error estocástico.

La especificación (3) permite distintas tasas de inflación de equilibrio para los diferentes componentes desagregados que constituyen un grupo de precios. El parámetro autorregresivo Ψ es forzado a ser igual en los n componentes. Si la dinámica inflacionista a corto plazo de los componentes desagregados es idéntica, las predicciones de la

inflación mediante el modelo (3) pueden superar a las obtenidas bajo estrategias alternativas, dado que el parámetro Ψ es estimado con un mayor número de grados de libertad que cuando éste se estima para cada componente por separado. Sin embargo, tales predicciones pueden ser bastante deficientes si la dinámica de inflación de los diferentes índices desagregados es muy heterogénea.

3.3. Modelos de vectores con corrección del equilibrio (MVCE)

En nuestro contexto se han especificado y estimado modelos de corrección del equilibrio (MVCE) en el que cada una de las series desagregadas evoluciona en una relación de cointegración con su equivalente agregado. Es decir, que cada una de las 77 series de subgrupos se relaciona con el grupo que las contiene en el primer nivel de desagregación.

De manera más formal, sean $p_{i,t}$ y p_t dos variables aleatorias que indican la transformación logarítmica del nivel del subgrupo i -ésimo de precios y su correspondiente agregado. De acuerdo con el análisis en la sección anterior, los contrastes de raíces unitarias indican que ambas variables son procesos integrados de orden 1. Además, es lógico suponer que, al menos en un número importante de casos, las variables $p_{i,t}$ y p_t tengan una dinámica en el largo plazo idéntica, al ser afectadas por choques económicos similares. Por supuesto, esta última hipótesis será contrastada de una manera formal en la siguiente sección.

Bajo dicha hipótesis es posible representar la dinámica de las series desagregadas mediante el siguiente modelo de vectores con corrección del equilibrio (véase, por ejemplo, Johansen, 1988):

$$\Delta P_t = \gamma + \alpha [\beta, \delta] \begin{bmatrix} P_{t-1} \\ 1 \end{bmatrix} + \Phi \Delta P_{t-1} + \Gamma D_t + \varepsilon_t \quad (4)$$

donde P_t es un vector de dimensión (2x1) que incluye las variables $p_{i,t}$ y p_t , α y β son, respectivamente, vectores de ajuste y de cointegración de dimensión (2x1); Φ es una matriz de parámetros de dimensión (2x2); γ un vector de dimensión (2x1) que permite la presencia de constante fuera de la relación de cointegración; δ es un parámetro escalar; D_t incluye elementos deterministas tales como intervenciones para datos atípicos o variables estacionales y Γ es la

matriz de parámetros asociada a dichos elementos deterministas; finalmente, ε_t es un vector (2x1) de errores serialmente incorrelacionados.

La ecuación (4) es especialmente útil en la predicción a corto plazo de p_t y $p_{i,t}$ cuando existe una relación de equilibrio estable a largo plazo entre dichas variables. Nótese que la expresión (4) no permite la presencia de tendencia determinista en la relación de cointegración, dado que es difícil justificar, desde un punto de vista económico, la presencia de una relación de equilibrio en el que los precios van alejándose en el tiempo de acuerdo con un elemento determinista. En cualquier caso, los resultados de predicción no sufren ninguna modificación significativa si se altera este supuesto.

Bajo la existencia de cointegración si las variables de interés están fuera de su estado de equilibrio a largo plazo en cualquier momento t , este simple modelo de corrección del equilibrio especifica la manera en la que el desagregado y su agregado correspondiente retornan a la relación de cointegración. Sin embargo, dicho procedimiento podría ser inadecuado si no existen relaciones de cointegración o si éstas no son constantes durante el periodo de predicción, véase Hendry (2006) y sus referencias. Por ejemplo, si las relaciones de cointegración cambian en algún punto sin ser modelizado de forma explícita, entonces el modelo interpretará erróneamente este choque como un desequilibrio y preverá que las variables retornen a un equilibrio que ya no existe. Así, un aspecto clave a la hora de ver la conveniencia de los modelos MVCE es juzgar la probabilidad de cambios estructurales en las relaciones de equilibrio durante el periodo de predicción. En este contexto, las series de precios en México son sujetas a importantes cambios estructurales durante el periodo de análisis. El analizar si aun en presencia de dichos choques los modelos econométricos resultan útiles en predicción es una cuestión empírica relevante a considerar.

3.4. Modelos de factores dinámicos

El cuarto método alternativo para predecir la inflación en México consiste en obtener unos pocos factores latentes que contengan una gran proporción de la información de la variabilidad de la inflación sectorial. En particular, bajo tal metodología la evolución de la inflación en el sector i puede ser descrita mediante la siguiente ecuación (véase, por ejemplo, Stock y Watson, 2002):

$$\Pi_{it} = \lambda_i F_t + e_{it} \tag{5}$$

donde, en nuestro caso, F_t es un vector de factores comunes (que puede incluir también rezagos de dichos factores) para todas las tasas de inflación sectoriales; λ_i un factor de carga asociado a F_t y e_{it} es el componente idiosincrático de Π_{it} . El producto $\lambda_i' F_t$ se denomina el componente común de Π_{it} . Nótese que los factores, sus cargas y los errores idiosincráticos no son observables.

Cuando el número de variables en el modelo es pequeño, el modelo factorial puede ser expresado en forma de espacio de los estados, se asume normalidad y los parámetros pueden ser estimados mediante máxima verosimilitud, véase Stock y Watson (1989), por ejemplo. No obstante, como indican Bai y Ng (2002), este procedimiento deja de ser adecuado cuando el número de parámetros se incrementa. Entonces, los factores comunes pueden ser estimados mediante el método de componentes principales asintóticos (Forni y Lippi, 2001; Stock y Watson, 1998, entre otros).

Para obtener predicciones mediante factores dinámicos la premisa básica es que, el movimiento de un gran número de series macroeconómicas, puede ser dirigido por un número pequeño de factores no observables. Stock y Watson (1998, 1999) muestran que dicho procedimiento de predicción es superior a muchos otros métodos alternativos. Aquí seguimos una técnica similar a la usada en De Mol, Giannone y Reickin (2006) y obtenemos predicciones de $\Delta_{12} p_{it}$ mediante proyecciones lineales. Bajo este procedimiento, una vez que los factores comunes han sido estimados, se puede obtener la predicción k -periodos hacia adelante de Π_{it} en $t + k$ de la proyección lineal:

$$\hat{\Pi}_{iT+k} = \hat{\lambda}_{i,k}' \hat{F}_T \quad (6)$$

en donde $\hat{\lambda}_{i,k}$ es el estimador OLS de la regresión de $\hat{\Pi}_{it+k}$ en \hat{F}_T , con la información disponible hasta el momento T . Esta estrategia resulta bastante estándar ya que no requiere la predicción de los factores comunes.

4. Evaluación de las predicciones

En esta sección comparamos el desempeño de diferentes estrategias a la hora de predecir la inflación anual agregada en México, para el periodo 2006:8-2008:7. En particular, contrastamos las predicciones obtenidas mediante nuestra estrategia de comparación (C a partir de ahora), –un modelo autorregresivo univariante con estacionalidad determinista especificado para la serie agregada–, con las logradadas bajo

siete estrategias alternativas. La primera y segunda estrategias alternativas (denotadas por S1 y S2, respectivamente) están basadas en modelos autorregresivos univariantes que incorporan variables estacionales, si corresponde, para cada uno de los ocho subíndices y la desagregación en 77 subgrupos que componen el INPC agregado. Las estrategias S3 y S4 consideran, respectivamente, los modelos econométricos definidos en la sección anterior para cada uno de los 77 subgrupos: 1) modelos dinámicos con efectos fijos y 2) modelos de corrección del equilibrio.

Finalmente, se han considerado modelos con factores dinámicos estimados mediante componentes principales, que consideran la desagregación en 77 componentes (S5), incluyen otras variables macroeconómicas (S6) y además incorporan rezagos de los factores para la serie agregada (S7).¹ Las predicciones con factores comunes se han obtenido mediante proyecciones lineales con la ecuación (6). En el resto de los modelos las predicciones se han obtenido de forma iterativa. En todos los casos las predicciones se han obtenido siguiendo un esquema recursivo, ver, por ejemplo, Faust, Rogers y Wright (2005) y West (2006). Bajo este procedimiento, el tamaño de la muestra usada para estimar los parámetros crece conforme uno hace predicciones para sucesivas observaciones; lo que permite a los parámetros del modelo econométrico cambiar de acuerdo con la nueva información que aparece en la muestra, y tiene la ventaja de que la longitud temporal de nuestra base de datos, que en principio resulta excesivamente corta, se va ampliando con el ejercicio de predicción. Aunque la presencia de un esquema de ventanas rodantes resulta especialmente preferible cuando existen cambios estructurales en la serie a predecir (Giacomini y White, 2006), esto no es un problema en nuestro contexto particular ya que, como ha sido discutido en la sección 2, existe suficiente evidencia en la literatura sobre el hecho de que la inflación en México se ha comportado como un proceso estacionario a partir del año 2001 (Chiquiar, Noriega y Ramos, 2010).

Para los modelos MVCE hemos seleccionado una especificación simple en parámetros similar a la del modelo (4), pero que permite capturar la dinámica de corto y largo plazo de las variables. Dicha especificación está justificada dada las pocas observaciones de la muestra usada y, además, es preferible en la mayoría de los casos a otras especificaciones con mayor número de parámetros, de acuerdo con el criterio de Schwarz. El cuadro 3 muestra los resultados de la prueba

¹ Se ha modelizado esta estrategia para el índice agregado, los ocho grupos y los 77 subgrupos, el primero de ellos es el que otorga un menor RMSE en todos los horizontes.

de traza sobre la hipótesis nula, de ninguna relación de cointegración en cada uno de los modelos MVCE considerados. La hipótesis no se rechaza en un gran número de casos, lo que puede deberse a la dificultad de encontrar relaciones de largo plazo en series con un ajuste temporal tan lento como son los precios. Aun así, no hemos excluido la posibilidad de considerar el desempeño de estos modelos en comparación con otras estrategias alternativas a la hora de predecir la inflación en México.

Cuadro 3

Resultados de la prueba de cointegración para los índices de precios al consumo en los diferentes subgrupos de México

<i>Sub-grupo</i>	<i>Prueba de traza</i>	<i>Probabilidad</i>	<i>Caso⁺</i>	<i>Sub-grupo</i>	<i>Prueba de traza</i>	<i>Probabilidad</i>	<i>Caso⁺</i>
R1	24.73	0.00**	1	R40	11.45	0.19	3
R2	15.44	0.01*	1	R41	32.85	0.00**	1
R3	4.60	0.85	3	R42	31.72	0.00**	3
R4	12.01	0.16	3	R43	24.40	0.00**	3
R5	16.33	0.04*	3	R44	27.22	0.00**	3
R6	19.77	0.00**	1	R45	8.03	0.46	3
R7	17.49	0.01*	1	R46	8.30	0.43	3
R8	5.04	0.80	3	R47	12.73	0.13	3
R9	24.99	0.00**	1	R48	14.21	0.02*	1
R10	20.81	0.01**	3	R49	15.00	0.06	3
R11	18.09	0.01*	1	R50	22.51	0.00**	1
R12	14.18	0.02*	1	R51	24.29	0.00**	1
R13	15.47	0.01*	1	R52	25.59	0.00**	1
R14	15.58	0.01*	1	R53	20.34	0.05*	2
R15	18.61	0.00**	1	R54	15.40	0.05*	3
R16	5.51	0.75	3	R55	14.73	0.02*	1
R17	19.99	0.00**	1	R56	25.80	0.00**	1
R18	24.00	0.00**	3	R57	12.08	0.15	3
R19	10.17	0.27	3	R58	12.65	0.13	3
R20	17.48	0.02*	3	R59	19.64	0.00**	1
R21	4.78	0.83	3	R60	17.19	0.01*	1
R22	11.32	0.19	3	R61	12.20	0.15	3
R23	21.98	0.00**	1	R62	34.42	0.00**	1

Cuadro 3
(continuación)

<i>Sub-grupo</i>	<i>Prueba de traza</i>	<i>Probabilidad</i>	<i>Caso⁺</i>	<i>Sub-grupo</i>	<i>Prueba de traza</i>	<i>Probabilidad</i>	<i>Caso⁺</i>
R24	11.12	0.20	3	R63	25.30	0.00**	1
R25	16.31	0.01*	1	R64	18.07	0.01*	1
R26	23.16	0.00**	1	R65	8.83	0.38	3
R27	18.99	0.00**	1	R66	21.94	0.00**	1
R28	19.72	0.01*	3	R67	22.50	0.02*	2
R29	14.20	0.08	3	R68	12.31	0.14	3
R30	23.78	0.00**	1	R69	10.76	0.23	3
R31	11.21	0.20	3	R70	5.53	0.75	3
R32	19.35	0.00**	1	R71	14.61	0.07	3
R33	16.89	0.03*	3	R72	14.56	0.07	3
R34	28.02	0.00**	3	R73	6.00	0.70	3
R35	7.33	0.54	1	R74	3.05	0.96	3
R36	20.59	0.01**	3	R75	15.17	0.06	3
R37	39.12	0.00**	2	R76	15.46	0.05	3
R38	14.64	0.02*	1	R77	11.98	0.16	3
R39	20.44	0.01**	3				

Notas: * y ** = rechazo de la hipótesis nula a un nivel de significancia de 5% y 1%, respectivamente. + = 1: sin elementos deterministas, 2: con constante restringida a la relación de cointegración y 3: con constante sin restringir.

Los modelos de factores dinámicos bajo las estrategias que denotamos por S5, S6 y S7 han sido especificados de la forma indicada en la ecuación (5). De forma más específica, bajo S5 los factores comunes han sido estimados a partir de la información proporcionada por las tasas de inflación desagregadas para los 77 subgrupos sectoriales. La estrategia S6 construye factores comunes usando indicadores macroeconómicos similares a los de Marcelino, Stock y Watson (2003) e Ibarra (2010). Las series aquí incluidas se muestran en el anexo 3. Por otro lado, S7 incorpora rezagos de los factores en la modelización del INPC agregado. Aunque consideramos de gran interés la elección de un mayor número de rezagos mediante un criterio de información, en nuestro caso particular, dado el escaso número de observaciones temporales, no se ha considerado la inclusión de más de un rezago. En estos últimos tres casos se han examinado las predicciones basadas en

Cuadro 5
*Raíz del error cuadrático medio de predicción
 cuatro periodos hacia adelante*

	<i>C</i>	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>	<i>S5</i>	<i>S6</i>	<i>S7</i>
<i>RMSFE</i>	0.80	1.01	0.79	0.39	0.64	0.33	0.34	0.32
<i>Prueba de Diebold y Mariano</i>								
<i>C</i>	**	-2.21 (0.04)	0.11 (0.91)	3.50 (0.00)	1.30 (0.21)	4.07 (0.00)	3.97 (0.00)	4.26 (0.00)
<i>S1</i>		**	2.24 (0.04)	3.97 (0.01)	2.31 (0.03)	4.38 (0.00)	4.33 (0.00)	4.57 (0.00)
<i>S2</i>			**	3.19 (0.00)	1.23 (0.23)	3.51 (0.00)	3.60 (0.00)	3.75 (0.00)
<i>S3</i>				**	-2.02 (0.06)	1.68 (0.11)	1.83 (0.08)	1.67 (0.11)
<i>S4</i>					**	2.41 (0.03)	2.56 (0.02)	2.68 (0.01)
<i>S5</i>						**	-0.30 (0.77)	0.45 (0.65)
<i>S6</i>							**	0.62 (0.54)
<i>S7</i>								**

Cuadro 6
*Raíz del error cuadrático medio de predicción
 ocho periodos hacia adelante*

	<i>C</i>	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>	<i>S5</i>	<i>S6</i>	<i>S7</i>
<i>RMSFE</i>	1.43	2.10	1.74	0.39	0.71	0.41	0.40	0.38
<i>Prueba de Diebold y Mariano</i>								
<i>C</i>	**	-3.48 (0.00)	-1.38 (0.19)	3.59 (0.00)	2.58 (0.02)	3.66 (0.00)	3.73 (0.00)	3.87 (0.00)
<i>S1</i>		**	1.60 (0.13)	4.73 (0.00)	4.35 (0.00)	4.72 (0.00)	4.84 (0.00)	5.00 (0.00)
<i>S2</i>			**	3.51 (0.00)	2.86 (0.01)	3.54 (0.00)	3.61 (0.00)	3.66 (0.00)

Cuadro 6
(continuación)

	<i>C</i>	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>	<i>S5</i>	<i>S6</i>	<i>S7</i>
S3				**	-2.76 (0.01)	-0.56 (0.58)	-0.27 (0.79)	0.25 (0.80)
S4					**	2.30 (0.04)	2.81 (0.01)	3.11 (0.01)
S5						**	0.46 (0.65)	0.76 (0.46)
S6							**	0.72 (0.48)
S7								**

Cuadro 7
*Raíz del error cuadrático medio de predicción
doce periodos hacia adelante*

	<i>C</i>	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>	<i>S5</i>	<i>S6</i>	<i>S7</i>
<i>RMSFE</i>	1.87	3.08	2.80	0.51	0.41	0.53	0.53	0.52
<i>Prueba de Diebold y Mariano</i>								
<i>C</i>	**	-3.28 (0.01)	-1.36 (0.20)	3.03 (0.01)	3.63 (0.00)	2.95 (0.01)	2.95 (0.01)	3.00 (0.01)
<i>S1</i>		**	0.53 (0.61)	3.93 (0.00)	4.22 (0.00)	3.87 (0.00)	3.87 (0.00)	3.92 (0.00)
<i>S2</i>			**	2.59 (0.02)	2.89 (0.01)	2.54 (0.03)	2.56 (0.03)	2.58 (0.02)
<i>S3</i>				**	0.82 (0.43)	-0.89 (0.39)	-0.94 (0.37)	-0.31 (0.76)
<i>S4</i>					**	-0.86 (0.41)	-0.96 (0.36)	-0.89 (0.39)
<i>S5</i>						**	-0.06 (0.95)	0.38 (0.71)
<i>S6</i>							**	0.62 (0.55)
<i>S7</i>								**

Nota: valores *p* entre paréntesis.

De manera general, los resultados muestran ventajas significativas al usar la máxima desagregación para predecir la inflación en México, aunque ésta sólo es evidente a partir de un horizonte de cuatro meses. Además, la estrategia de modelización desagregada es importante. Concretamente en los horizontes de predicción a cuatro, ocho y doce periodos la modelización ARIMA desagregada (estrategia S2) arroja siempre los peores resultados de predicción comparados con el resto de estrategias desagregadas (S3 a S7). No obstante, resulta difícil discriminar el desempeño predictivo de las estrategias basadas en modelos MVCE, modelos de efectos fijos y de factores comunes, al no observarse, en ningún caso, que uno de estos procedimientos otorgue resultados de predicción significativamente superiores a los demás.

Un aspecto de especial interés en la comparación entre diferentes metodologías de estimación reside en conocer si la poca eficiencia relativa de los modelos autorregresivos (S1 y S2) frente a modelos de factores comunes pudiera deberse al uso de una tecnología de modelización más sofisticada o es la consecuencia de usar un método directo de predicción mediante proyecciones lineales, en el caso de factores comunes, frente a un procedimiento iterativo. En general, el método iterativo produce estimaciones más eficientes que el método directo, pero tiene un sesgo mayor, sobre todo cuando el modelo no está correctamente especificado. Por lo tanto, un aspecto de especial interés en este análisis consiste en investigar si el pobre desempeño de las estrategias S1 y S2 en horizontes de cuatro, ocho y doce periodos adelante se debe, exclusivamente, al uso del método iterativo. Los RMSE con el uso de proyecciones directas de las estrategia S1 son 1.11%, 0.98% y 1.06%, para cuatro, ocho y doce periodos hacia adelante y los RMSE equivalentes para S2 son 1.10%, 1.06% y 1.06%, respectivamente. Esto supone una mejora respecto a las estrategias S1 y S2 basadas en un procedimiento iterativo, pero aún son claramente inferiores al resto de estrategias econométricas usadas en el presente artículo.

Como conclusión, la predicción de la inflación en México puede ser mejorada claramente mediante la desagregación y el uso de modelos econométricos adecuados que recojan más información que la contenida en simples estrategias de extrapolación univariante.

Para apreciar en mayor medida la relevancia de los resultados obtenidos es de interés compararlos con trabajos previos en la literatura para países desarrollados. En ellos se dispone de series desagregadas para un periodo temporal más amplio y la evolución de su dinámica inflacionista es menos errática que la de un país como

México. Sin embargo, a pesar de estas dificultades, encontramos que nuestros errores de previsión son similares, incluso más eficientes en algunos casos, a los obtenidos por ejemplo por Hubrich (2005) para la inflación en la euro área con una raíz cuadrada del error cuadrático de predicción en torno a 0.06% y 0.5% en predicciones para uno y doce periodos hacia adelante, respectivamente. También, Tena, Espasa y Pino (2010) realizan un ejercicio de predicción de la inflación en España mediante modelos desagregados sectorial y geográficamente y obtienen valores de la raíz cuadrada del error cuadrático medio de predicción en torno a 0.3% y 0.7% en predicciones para uno y doce meses hacia adelante.

5. Conclusiones

Este artículo analiza empíricamente las ventajas que se derivan de la modelización desagregada de los 77 subgrupos que componen el INPC de México. Con base en diferentes estrategias se encuentra que el uso de modelos desagregados mejora en todos los horizontes la predicción de la tasa de inflación anual, excepto en el horizonte a un mes hacia adelante.

Simple modelos autorregresivos se revelan como una forma eficiente a la hora de predecir la inflación agregada un periodo hacia adelante; no obstante, al aumentar el horizonte de proyección esta capacidad se ve disminuida frente a otras estrategias. En el mediano plazo, modelos econométricos más complejos que consideran relaciones de cointegración, modelos con efectos fijos o con factores dinámicos aplicados a series desagregadas se muestran como los procedimientos más eficientes.

Referencias

- Bai, J. y S. Ng. 2002. Determining the number of factors in approximate factor models, *Econometrica*, 70(1): 191-221.
- Bailliu, J., D. Garcés, M. Kruger y M. Messmacher. 2003. Explicación y predicción de la inflación en mercados emergentes: el caso de México, Serie documentos de investigación, núm. 2003-3, Banco de México.
- Banco de México. 2011. *Estadísticas*, < <http://www.banxico.org.mx>>.
- Beaulieu, J.J. y J.A. 1993. Seasonal unit roots in aggregate US data, *Journal of Econometrics*, 55: 305-328.
- Box, G.E.P., G.M. Jenkins y G.C. Reinsel. 1994. *Time series analysis: Forecasting and control*, Prentice Hall, 3a ed., Englewood Cliffs, NJ.
- Capistrán, C., C. Constandse y M. Ramos-Francia. 2010. Multi-horizon inflation forecast using disaggregated data, *Economic Modelling*, 27: 666-677.
- Chiquiar, D., A. Noriega y M. Ramos-Francia. 2010. A time series approach to test a change in inflation persistence: The Mexican experience, *Applied Economics*, 42: 3067-3075.
- De Mol, C., D. Giannone y L. Reichlin. 2006. Forecasting using a large number of predictors: is Bayesian regression a valid alternative to principal components? CEPR Discussion Papers, núm. 5829.
- Diebold, F. y R. Mariano. 1995. Comparing predictive accuracy, *Journal of Business and Economic Statistics*, 13: 253-265 (publicado nuevamente en 2002, 20(1): 135-145).
- Espasa, A. y R. Albacete. 2007. Econometric modelling for short-term inflation forecasting in the EMU, *Journal of Forecasting*, 26: 303-316.
- Faust, J., J. Rogers y J. Wright. (2005). News and noise in G-7 GDP announcements, *Journal of Money, Credit and Banking*, 37: 403-419.
- Forni, M. y M. Lippi. 2001. The generalized factor model: Representation theory, *Econometric Theory*, 17: 1113-1141.
- Franses, P.H. 1991. Seasonality, nonstationarity and the forecasting of monthly time series, *International Journal of Forecasting*, 7: 199-208.
- Giacomini, R. y H. White. 2006. Tests of conditional predictive ability, *Econometrica*, 74(6): 1545-1578.
- Godoy, C. y J.D. Tena. 2006. ¿Cuál es el nivel óptimo de desagregación para predecir el IPC chileno? *Revista Economía y Administración*, 67: 7-30.
- Hasza, D.P. y W.A. Fuller. 1982. Testing for nonstationary parameter specifications in seasonal time series models, *The Annals of Statistics*, 10: 1209-1216.
- Hendry, D.F. 2006. Robustifying forecasts from equilibrium-correction systems, *Journal of Econometrics*, 135: 399-426.
- Hubrich, K. 2005. Forecasting euro area inflation: does aggregating forecasts by HICP components improve forecasts accuracy? *International Journal of Forecasting*, 21: 119-136.
- Ibarra-Ramirez, R. 2010. Forecasting inflation in Mexico using factor models: Do disaggregated CPI data improve forecast accuracy, Serie documentos de investigación, núm. 2010-01, Banco de México.

- IHS Global Insight. 2011. *IHS Global Insight: Economic Forecasts, Analysis & Data for Countries & Industries*, < <http://myinsight.ihsglobalinsight.com/servlet/cats?>>.
- Johansen, S. 1988. Statistical analysis of cointegrating vectors, *Journal of Economic Dynamics and Control*, 12: 231-254.
- Juselius, K. 2006. *The cointegrated VAR model: Methodology and applications*, Oxford University Press.
- Marcelino, M., J.H. Stock y M. Watson. 2003. Macroeconomic forecasting in the euro area: country specific *versus* euro wide information, *European Economic Reviews*, 47: 1-18.
- Osborn, D.R., A.P. Chui, J.P. Smith y C.R. Birchenhall. 1988. Seasonality and the order of integration for consumption, *Oxford Bulletin of Economics and Statistics*, 50: 361-377.
- Stock, J.H. y M. Watson. 1989. New indexes of coincident and leading economic indicators, *NBER Macroeconomic Annual*, 4: 351-409.
- . 1998. Asymptotically median unbiased estimation of coefficient variance in a time varying parameter model, *Journal of the American Statistical Association*, 93: 349-358.
- . 1999. Forecasting inflation, *Journal of Monetary Economics*, 44: 293-335.
- . 2002. Forecasting using principal components from a large number of predictors, *Journal of the American Statistical Association*, 97: 1167-1179.
- . 2005. Implications of dynamic factor models for VAR analysis, NBER Working Paper Series, núm. 11467.
- Tena, J.D., A. Espasa y G. Pino. 2010. Forecasting Spanish inflation using the maximum disaggregation level by sectors and geographical areas, *International Regional Science Review*, 33: 181-204.
- West, K.D. 2006. Forecast evaluation, en G. Elliott, C.W.J. Granger y A. Timmermann (comps.), *Handbook of Economic Forecasting*, North Holland.
- Zellner, A. y J. Tobias. 2000. A note on aggregation, disaggregation and forecasting performance, *Journal of Forecasting*, 19: 457-469.

Anexo 1

Cuadro A1
Subíndices y subgrupos con sus respectivas ponderaciones

<i>Subíndices</i>	<i>Ponderación</i>
G1: Alimentos, bebidas y tabaco	22.74
G2: Ropa, calzado y accesorios	5.59
G3: Vivienda	26.41
G4: Muebles, aparatos y accesorios domésticos	4.86
G5 : Salud y cuidado personal	8.58
G6 : Transporte	13.41
G6 Educación y esparcimiento	11.54
G8 : Otros servicios	6.88
<i>Subgrupos</i>	
R1 : Tortillas y derivados del maíz	1.29
R2 : Pan	0.98
R3 : Galletas, pastas y harinas de trigo	0.36
R4 : Arroz y cereales preparados	0.41
R5 : Carne de ave	1.2
R6 : Carne y vísceras de cerdo	0.41
R7 : Carne y vísceras de res	2.2
R8 : Otros cortes de carne	0.05
R9 : Carnes frías, secas y embutidos	0.92
R10 : Pescados y mariscos	0.39
R11 : Pescados y mariscos en conserva	0.17
R12 : Leche fresca	1.86
R13 : Leche procesada	0.16
R14 : Derivados de leche	0.97
R15: Huevo	0.53
R16 : Aceites y grasas vegetales comestibles	0.32
R17 : Frutas frescas	1.29

Cuadro A1
(continuación)

<i>Subgrupos</i>	<i>Ponderación</i>
R18 : Hortalizas frescas	1.63
R19 : Legumbres secas	0.37
R20 : Frutas y legumbres procesadas	0.38
R21 : Azúcar	0.21
R22 : Café	0.15
R23 : Refrescos envasados y agua purificada	1.81
R24 : Condimentos	0.18
R25 : Chocolates y golosinas	0.32
R26 : Alimentos cocinados fuera de casa	1.36
R27 : Cerveza	1.46
R28 : Vinos y licores	0.74
R29 : Cigarrillos	0.6
R30 : Camisas y ropa interior para hombre	0.41
R31: Pantalones, trajes y otras prendas para hombre	0.75
R32: Blusas y ropa interior para mujer	0.42
R33: Pantalones para mujer	0.39
R34: Vestidos, faldas y conjuntos para mujer	0.39
R35 : Ropa para niños	0.51
R36 : Ropa para bebés	0.15
R37 : Ropa de abrigo	0.23
R38 : Uniformes escolares	0.25
R39 : Calzado	1.62
R40: Limpieza del vestido	0.33
R41 : Accesorios personales	0.14
R42 : Vivienda alquilada	2.52
R43 : Vivienda propia	14.16
R44 : Electricidad	2.27
R45 : Gas doméstico	1.84

Cuadro A1
(continuación)

<i>Subgrupos</i>	<i>Ponderación</i>
R46 : Servicio telefónico	3.52
R47 : Servicios de la vivienda	2.09
R48 : Muebles de cocina	0.34
R49 : Muebles de madera	0.82
R50 : Aparatos eléctricos	0.58
R51 : Aparatos electrónicos	0.82
R52 : Accesorios domésticos	0.16
R53 : Utensilios domésticos	0.33
R54: Accesorios textiles de uso en el hogar	0.29
R55: Detergentes y productos similares	1.53
R56 : Medicamentos	1.2
R57 : Aparatos médicos	0.26
R58 : Servicios médicos	2.55
R59 : Servicios para el cuidado personal	0.55
R60 : Artículos para el cuidado personal	2.62
R61 : Artículos de papel para higiene personal	1.4
R62 : Transporte público urbano	3.84
R63 : Transporte público foráneo	0.89
R64 : Vehículos automotores y de pedal	3.33
R65 : Gasolinas y aceites lubricantes	3.8
R66 : Refacciones y accesorios automotrices	0.21
R67 : Servicios para el automóvil	1.34
R68 : Educación privada	5.2
R69 : Libros	1.02
R70 : Material escolar	0.82
R71: Hoteles y gastos turísticos	0.87
R72: Otros servicios de esparcimiento	2.18
R73: Periódicos y revistas	0.37

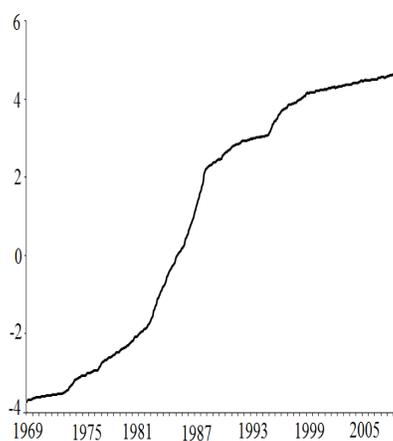
Cuadro A1
(continuación)

<i>Subgrupos</i>	<i>Ponderación</i>
R74: Otros artículos de esparcimiento	1.08
R75 : Restaurantes, bares y similares	6.5
R76 : Servicios profesionales	0.18
R77: Servicios diversos	0.19

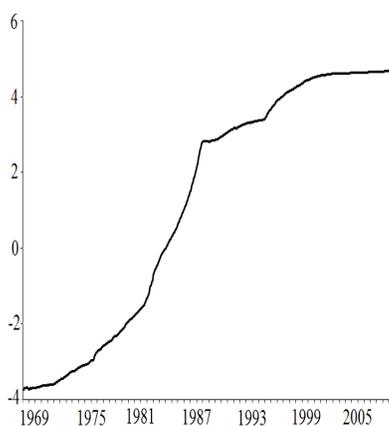
Anexo 2

Gráficas del índice de los ocho grupos que componen el INPC agregado en México

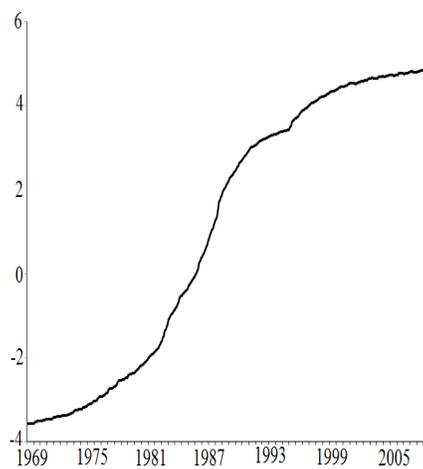
G1: Alimentos, bebidas y tabaco



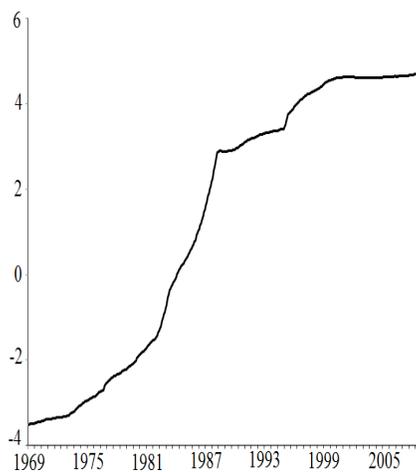
G2: Ropa, calzado y accesorios



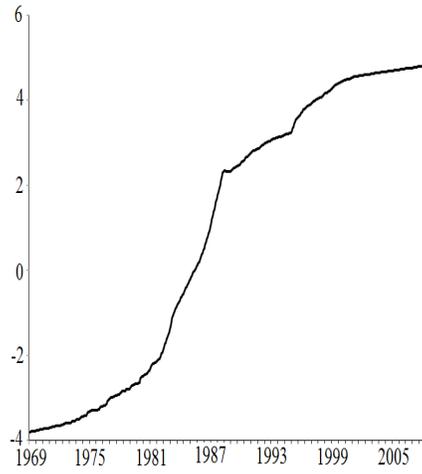
G3: Vivienda



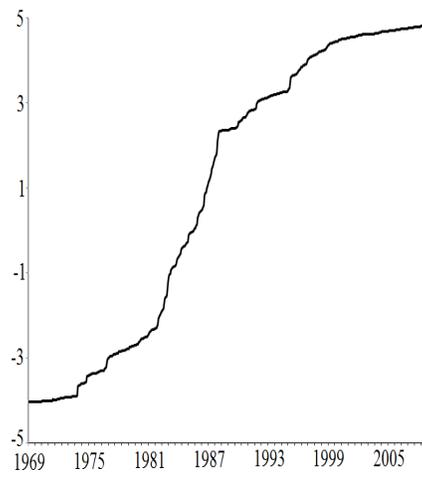
G4: Muebles, aparatos y accesorios



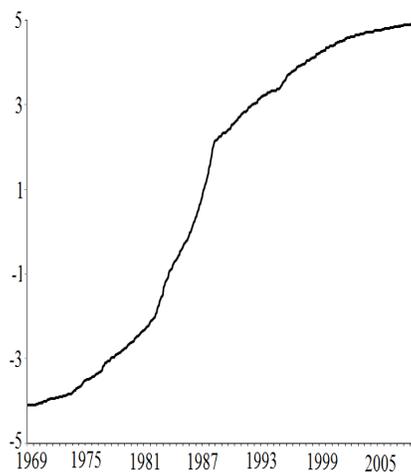
G5: Salud y cuidado personal



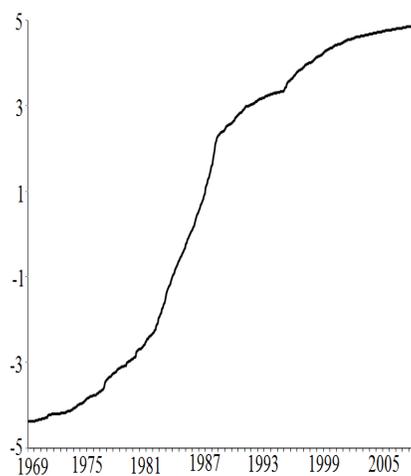
G6: Transporte



G7: Educación y esparcimiento



G8: Otros servicios



Anexo 3

VARIABLES MACROECONÓMICAS UTILIZADAS EN LA ESTIMACIÓN DE FACTORES COMUNES MEDIANTE COMPONENTES PRINCIPALES

Todas las series usadas en este ejercicio son referidas a México y han sido descargadas de la base de datos *Global Insight*. En concreto, se ha incluido la transformación estacionaria de las siguientes series:

- Empleo: número de empleados y tasa de desempleo.
- Precios al consumo: índice de precios para ocho subíndices.
- Precios industriales: textiles, vestidos y pieles, productos metálicos, maquinaria y equipo, madera, productos minerales no metálicos excepto petróleo y carbón, productos químicos, petróleo y plásticos, papel productos del papel, publicidad e imprenta.
- Agregados monetarios: M1, M2 y M4.
- Tipos de interés: letras del tesoro a un mes, letras del tesoro a tres meses, letras del tesoro a seis meses, tipo de interés interbancario (TIIE 28 días), tipos de depósitos a un mes netos de impuestos, tipos de depósitos a tres meses netos de impuestos, tipos de depósitos a seis meses netos de impuestos, rentabilidad de bonos federales a diez años, tipos de seguros del tesoro a 364 días y tipos de seguros del tesoro a 364 días.
- Precios bursátiles: bolsa (INPC general).
- Tipos de cambio: tipo de cambio efectivo real, pesos por libra, pesos por dólares y pesos por euro.
- Balanza de pagos: recibos de remesas en millones de dólares.