

Ensayos Económicos | 76

Mayo de 2021

Factores macroeconómicos de la inflación en Argentina 2013-2019

Alberto Manuel López Galván



BANCO CENTRAL
DE LA REPÚBLICA ARGENTINA

Ensayos Económicos es una revista editada por la Subgerencia General de Investigaciones Económicas

ISSN 1850-6046
Edición electrónica

Banco Central de la República Argentina
San Martín 235 / Edificio San Martín Piso 7, Oficina 701 (C1003ABF)
Ciudad Autónoma de Buenos Aires / Argentina
Tel.: (+5411) 4348-3582/3814
Email: ensayos.economicos@bcra.gob.ar
Página Web: http://www.bcra.gob.ar/PublicacionesEstadisticas/Ensayos_economicos.asp

Fecha de publicación: Mayo de 2021

Diseño de tapa e interior | Gerencia Principal de Comunicación y Relaciones con la Comunidad, BCRA
Diagramación | Subgerencia General de Investigaciones Económicas, BCRA

Ensayos Económicos está orientada a la publicación de artículos de economía de carácter teórico, empírico o de política aplicada, y busca propiciar el diálogo entre las distintas escuelas del pensamiento económico para contribuir a diseñar y evaluar las políticas adecuadas para sortear los desafíos que la economía argentina enfrenta en su proceso de desarrollo. Las opiniones vertidas son exclusiva responsabilidad de los autores y no se corresponden necesariamente con la visión institucional del BCRA o de sus autoridades.

Esta revista apoya el acceso abierto a su contenido bajo el principio de que la libre disponibilidad de la investigación para el público estimula un mayor desarrollo global del intercambio de conocimiento. Para facilitar una mayor difusión y utilización, los artículos se encuentran bajo la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional.



Esta licencia permite copiar y redistribuir el material en cualquier medio o formato, y transformar y construir a partir del material original, mientras no sea con fines comerciales, se mencione el origen del material de manera adecuada, brindando un enlace a la licencia e indicando si se han realizado cambios, y se distribuya bajo la misma licencia del original.

Factores macroeconómicos de la inflación en Argentina 2013-2019

Alberto Manuel López Galván*

Universidad de Buenos Aires

Resumen

El objetivo de este trabajo es investigar el uso del análisis factorial para identificar el rol que tienen las principales variables macroeconómicas sobre la inflación en la Argentina. Los predictores macroeconómicos que usualmente impactan sobre la inflación se resumen utilizando un número menor de factores construidos por los componentes principales. Esta construcción nos permite identificar y cuantificar el efecto de los factores no observables asociados al crecimiento del dinero, las expectativas, el tipo de cambio, el déficit fiscal y la tasa de interés, entre otros. Luego usamos estos factores para construir modelos econométricos para pronosticar la inflación. Específicamente, utilizamos modelos univariados y multivariados, como los modelos autorregresivos clásicos, factoriales y FAVAR. Los resultados del pronóstico sugieren que los modelos que incorporan la información económica mediante factores superan a los modelos clásicos. Además, utilizando test de causalidad en el sentido de Granger y funciones de impulso respuesta, se estudia la dinámica de corto plazo de la inflación ante *shocks* sobre los factores principales.

Clasificación JEL: C38, E31, E37.

Palabras clave: análisis factorial, dinero, inflación, modelos factoriales, pronósticos.

Presentado: 15 de mayo de 2020 - *Aprobado:* 15 de septiembre de 2020.

* Las opiniones vertidas en este trabajo son responsabilidad del autor y no reflejan necesariamente las del BCRA o sus autoridades. Email: manuel.lgalvan@uba.ar, amlopezgalvan@gmail.com, mlopezgalvan@hotmail.com.

Macroeconomic factors for inflation in Argentina 2013-2019

Alberto Manuel López Galván

Universidad de Buenos Aires

Summary

The aim of this paper is to investigate the use of the factor analysis in order to identify the role of the relevant macroeconomic variables in driving the inflation. The macroeconomic predictors that usually affect the inflation are summarized using a small number of factors constructed by the principal components. This allows us to identify the crucial role of money growth, inflation expectations and exchange rate in driving the inflation. Then we use these factors to build econometric models to forecast inflation. Specifically, we use univariate and multivariate models such as classical autoregressive, Factor models and FAVAR models. Results of forecasting suggest that models which incorporate more economic information outperform the benchmarks. Furthermore, causality test and impulse response are performed in order to examine the short-run dynamics of inflation to shocks in the principal factors.

Clasificación JEL: C38, E31, E37.

Keywords: factor analysis, factor models, forecasting, inflation, money.

Submitted: May 15, 2020 – *Approved:* September 15, 2020.

1. Introducción

En los últimos 10 años, Argentina ha experimentado una de las tasas de inflación más altas a nivel mundial y por lo tanto es un caso interesante para estudiar el efecto y las relaciones de sus principales variables macroeconómicas con la tasa de inflación.

Existen varios trabajos sobre los efectos de la relación entre la inflación y la política monetaria y también con medidas como la brecha del producto o la tasa de interés. Por ejemplo, Basco, D'Amato y Garegnani (2006) estudiaron la dinámica de corto plazo del dinero y los precios en periodos de alta y baja inflación y constataron que la proporcionalidad se mantiene para un período de alta inflación, pero es más débil en regímenes de baja inflación.

La mayoría de los economistas están de acuerdo con que la alta inflación generalmente comienza cuando el Banco Central emite dinero para financiar un desequilibrio fiscal; este argumento fue desarrollado inicialmente por Cagan (1956) para explicar la hiperinflación. El problema de la inflación ha sido superado hace décadas por los países desarrollados centrandose su atención principalmente en los instrumentos monetarios. En Argentina, el tipo de cambio desempeña un rol crucial en la formación de los precios de los bienes transables, sin embargo, se ha visto que la inflación ha continuado sin cambios repentinos en el tipo de cambio. Por otro lado, los salarios y las tasas de interés son un componente muy importante de los costos de producción y en la composición de los precios de los bienes no transables, además, las empresas y los agentes tienen en cuenta la tasa de inflación esperada en las decisiones de fijación de precios y de contratos. Todas estas razones pueden tener efecto en la inflación, sin embargo, no está claro por qué persiste una tasa de inflación alta, aunque el déficit no crezca o aunque no haya variaciones bruscas en el tipo de cambio. Por lo tanto, es posible que la dinámica de precios también pueda explicarse por factores no observables o latentes relacionados con las presiones observables de la inflación y es por ello que puede ser conveniente abordarla desde un punto de vista multivariado utilizando el análisis factorial. En este trabajo investigamos cuáles son los determinantes más importantes de la inflación y usamos esta información para construir modelos de pronóstico.

Los modelos econométricos clásicos, como AR, ADL o VAR, pueden utilizarse para modelar simultáneamente la interacción de sólo un puñado de variables. Por ejemplo, en los modelos VAR el número de parámetros a estimar aumenta geométricamente con el número de variables y proporcionalmente con el número de rezagos incluidos. El análisis factorial es una técnica utilizada para descubrir clústeres de variables de modo que las variables de cada grupo estén altamente correlacionadas. Así, se reduce una serie de variables correlacionadas a un número menor de factores ortogonales que explican la mayor variabilidad del conjunto de datos. Stock y Watson (2002) exploraron el uso del análisis factorial en modelos de pronóstico. Dado un gran número de variables macroeconómicas, se estima una serie temporal de los factores a partir de los predictores y luego se realiza una regresión lineal entre la variable a pronosticar y los factores.

La estructura de este trabajo es la siguiente: en la Sección 2 desarrollamos el marco teórico de los modelos factoriales con sus respectivos supuestos, en la Sección 3 analizamos los datos a utilizar

y verificamos las hipótesis del marco teórico, en la Sección 4 desarrollamos el análisis factorial y analizamos la relación entre los factores y las variables. En la Sección 5 desarrollamos los pronósticos a través de los modelos factoriales estáticos, univariados y multivariados. En la Sección 6, estudiamos la causalidad en el sentido de Granger y desarrollamos el análisis de impulso respuesta. Finalmente, la Sección 7 concluye.

2. Modelos factoriales

2.1. Modelo de pronóstico factorial

El modelo de pronóstico que se aplicará a la inflación en Argentina sigue el enfoque de componentes principales en dos etapas de Stock y Watson (2002). En primer lugar, una serie temporal de los factores se estima a partir de los predictores mediante el uso de la metodología de componentes principales y luego se realiza una regresión lineal entre la variable que se va a pronosticar y los factores estimados. Más precisamente, recordando Stock y Watson (2002), supongamos que π_t es la serie temporal a pronosticar y sea $X_t = (X_{ti})$ una serie temporal N -dimensional de predictores, ($t = 1, 2, \dots, T$, $i = 1, 2, \dots, N$) luego la representación del modelo factorial para los datos (X_{ti}, π_t) es:

$$X_{ti} = F_t \lambda_i' + \epsilon_{ti} \quad (1)$$

y

$$\pi_{t+h} = \eta + \alpha' F_t + \beta' Z_t + \varepsilon_{t+h} \quad (2)$$

donde F_t es un vector de r factores, λ_i son los ponderadores de los factores, ϵ_t es la matriz de error idiosincrásico, transversalmente independiente y temporalmente *iid*, Z_t es un vector $m \times 1$ de variables observables (por ejemplo, rezagos de π_t) y ε_{t+h} es el error de pronóstico.

Para estimar el modelo factorial es necesario estimar primero F_t y luego la matriz $\Lambda = (\lambda_i) \in N \times r$ suponiendo las restricciones de ortogonalidad $\Lambda' \Lambda = I$ y $T > N$. En efecto, aplicando el método de mínimos cuadrados, minimizamos la siguiente función:

$$V(F, \Lambda) = \sum_{i=1}^N \sum_{t=1}^T (X_{it} - \lambda_i F_t')^2 = tr (X' - \Lambda F')' (X' - \Lambda F') \quad (3)$$

donde λ_i está en la i -ésima fila de Λ y tr denota la traza habitual. El estimador de mínimos cuadrados para los factores resulta:

$$\tilde{F} = (\Lambda' \Lambda)^{-1} \Lambda' X' = \Lambda' X' \quad (4)$$

Luego reemplazando el estimador de los factores y aplicando propiedades de la traza se tiene:

$$V(\tilde{F}, \Lambda) = tr(X' X) - tr(\Lambda' X' X \Lambda). \quad (5)$$

Aquí el mínimo se alcanza cuando se maximiza $tr(\Lambda'X'X\Lambda)$ y esto es equivalente al problema de encontrar las combinaciones lineales que maximizan la varianza del vector $X\Lambda$ sujeto a $\Lambda'\Lambda = I$. Por lo tanto, esto resulta en el problema clásico de los componentes principales donde el estimador es:

$$\tilde{F}' = X\tilde{\Lambda} \quad (6)$$

donde $\tilde{\Lambda}$ tiene como columnas los primeros autovectores de la matriz de covarianza de X .

2.1.1. Pronóstico estático (o un paso por delante)

Sea $P < T$ una serie de observaciones, para construir un pronóstico estático para π_t sobre $\{t = T - P + 1, \dots, T\}$, primero formamos los componentes principales de los datos $\{X_t\}_{t=1}^T$ para servir como estimaciones de los factores y luego hasta el momento $T - P$ realizamos la regresión lineal de π_t en los factores estimados \tilde{F}_{t-1} y en Z_{t-1} . Sean $\hat{\alpha}$, $\hat{\beta}$ y $\hat{\eta}$ los coeficientes estimados, entonces los pronósticos se construyen como:

$$\hat{\pi}_t = \hat{\eta} + \hat{\alpha}' \tilde{F}_{t-1} + \hat{\beta}' Z_{t-1} \quad (7)$$

donde t va desde $T - P + 1$ hasta T .

2.1.2. Pronóstico dinámico

Para construir el pronóstico dinámico bajo la metodología del modelo de factores tendríamos que asumir una dinámica conjunta para (F_t, π_t) , entonces se estiman dos ecuaciones y la dinámica conjunta se da por:

$$\begin{bmatrix} F_t \\ \pi_t \end{bmatrix} = \phi(L) \begin{bmatrix} F_{t-1} \\ \pi_{t-1} \end{bmatrix} + \varepsilon_t \quad (8)$$

donde $\phi(L)$ es un polinomio de rezagos. Más precisamente, el modelo asume que F_t y π_t siguen conjuntamente un proceso VAR. A este modelo se lo conoce en la literatura como modelo FAVAR y fue introducido por Bernanke (2005). A continuación, el pronóstico se obtiene recursivamente utilizando los niveles estimados del paso anterior:

$$\begin{aligned} \hat{F}_t &= \hat{\phi}_{11} \hat{F}_{t-1} + \hat{\phi}_{12} \hat{\pi}_{t-1} \\ \hat{\pi}_t &= \hat{\phi}_{21} \hat{F}_{t-1} + \hat{\phi}_{22} \hat{\pi}_{t-1} \end{aligned} \quad (9)$$

donde t va desde $T - P + 1$ hasta T y son $\hat{\phi}_{ij}$ son los estimadores de mínimos cuadrados hasta el momento $T - P$

2.2. Evaluación de pronósticos

2.2.1. Medidas de desempeño

Para comparar el desempeño de los pronósticos, se utilizarán dos métricas en este trabajo; el error cuadrático medio (RMSE) y los estadísticos U de Theil. El modelo autorregresivo de orden uno, AR(1), se utilizará como modelo base para comparar los desempeños. Dadas $P < T$ observaciones, el Error Cuadrático Medio (RMSE) se define como:

$$RMSE_P = \left[\frac{1}{P} \sum_{t=T-P+1}^T (\pi_t - \hat{\pi}_t)^2 \right]^{\frac{1}{2}} \quad (10)$$

dónde $\{\pi_t\}$ son los valores observados y $\{\hat{\pi}_t\}$ los pronósticos. Los estadísticos U de Theil o el coeficiente de desigualdad de Theil es un error cuadrático medio relativo, más específicamente definimos el U-Theil como:

$$U_P = \frac{\left[\frac{1}{P} \sum_{t=T-P+1}^T (\pi_t - \hat{\pi}_t)^2 \right]^{\frac{1}{2}}}{\left[\frac{1}{P} \sum_{t=T-P+1}^T \pi_t^2 \right]^{\frac{1}{2}} + \left[\frac{1}{P} \sum_{t=T-P+1}^T \hat{\pi}_t^2 \right]^{\frac{1}{2}}} \quad (11)$$

La medida U-Theil está acotada entre 0 y 1 y los niveles más cercanos a 0 indican un mejor desempeño predictivo de los modelos evaluados. Otros estadísticos se presentan como ratios del RMSE y de la medida U-Theil respecto del modelo autorregresivo. Más precisamente definimos:

$$RRMSE_P = \frac{RMSE_P(Model)}{RMSE_P(AR)}, \quad RU_P = \frac{U_P(Model)}{U_P(AR)} \quad (12)$$

Por lo tanto, cuando la relación es menor que la unidad, el modelo (en el contexto RMSE o U-Theil) es mejor que el modelo autorregresivo tomado como base.

2.2.2. Pruebas para comparar el poder de pronóstico

Diebold y Mariano (1995) desarrollaron un test de hipótesis para comparar la capacidad predictiva de dos pronósticos. Dados dos pronósticos competidores $\hat{\pi}_{1t}$ y $\hat{\pi}_{2t}$ de π_t , sean $\{e_{1t}\}$ y $\{e_{2t}\}$ los errores de pronóstico asociados y $g(e_{it})$ la función de pérdida del error de pronóstico. El diferencial de pérdida se define como, $d_t = g(e_{1t}) - g(e_{2t})$ y la hipótesis nula del test es $H_0: E(d_t) = 0 \forall t$ contra la alternativa $H_a: E(d_t) \neq 0 (< 0 \text{ o } > 0)$. Sea \bar{d} la media del diferencial de pérdida, $\bar{d} = \frac{1}{T} \sum_{t=1}^n d_t$, el estimador HAC para la varianza asintótica de \bar{d} es:

$$\widehat{Var}(\bar{d}) = \hat{\gamma}_0 + 2 \sum_{k=1}^{K-1} \hat{\gamma}_k \quad (13)$$

donde $\hat{\gamma}_k$ denota la covarianza muestral del rezago k de la secuencia $\{d_t\}$ y K el rezago en el que se trunca. Bajo la hipótesis nula de igual capacidad de pronóstico el estadístico es:

$$S(1) = \sqrt{T} \frac{\bar{a}}{\sqrt{\text{var}(\bar{a})}} \sim N(0,1) \quad (14)$$

Por otro lado, Giacomini y White (2004) evalúan las diferencias en la capacidad predictiva centrándose en encontrar el mejor método de pronóstico para el futuro pertinente y se basa en expectativas condicionales. En este test la hipótesis a probar es:

$$H_0: E(h_t(g(e_{1t+\tau}) - g(e_{2t+\tau})) | \mathcal{F}_t) = 0 \quad (15)$$

para todas las \mathcal{F}_t funciones medibles h_t y el horizonte τ de pronóstico.

En la práctica, este test consiste en realizar una regresión entre las diferencias en las funciones de pérdida y una constante y evaluar la significatividad utilizando el estadístico t habitual para la hipótesis nula de un coeficiente 0, en el caso de un horizonte de pronóstico de $\tau = 1$. En el caso de $\tau > 1$, el error estándar se calcula utilizando el estimador de la matriz de varianzas y covarianzas de Newey-West que permite la existencia de heterocedasticidad y autocorrelación.

3. Variables utilizadas

En esta sección se describen las variables que se incluirán en todos los modelos y cómo deben controlarse.

3.1. Manejo de variables

Las series elegidas para la construcción de los datos a utilizar incluyen algunas de las principales variables macroeconómicas que cubren los aspectos determinantes de la inflación. La muestra de datos a utilizar incluye las variables de las principales teorías de inflación que se presentan en la literatura. Además, con el fin de medir las presiones de los diferentes tipos de bienes, incluimos subíndices del índice general de precios. Dado que el marco de trabajo se basa en la metodología de comprensión de la información de Stock y Watson, el conjunto de datos se construye con la variable dependiente y varias variables asociadas. A continuación, explicamos las diferentes presiones inflacionarias y las variables a utilizar.

- **Presión de los precios de los bienes y servicios:** con el fin de obtener una descripción más precisa y cercana de la variable dependiente incluimos subíndices que están relacionados con la variable objetivo. Dado que la metodología se aplicará sin la inclusión del nivel del índice general, no habrá ningún problema con el ruido. Por ejemplo, Kunovac (2007) utiliza diferentes índices de bienes y tipos de cambio para la aplicación de la metodología.

- **Presión de costos:** aquí el objetivo es cuantificar las diferentes presiones que las empresas tienen en las decisiones de formación de precios. En la ecuación de costos, los salarios y las tasas de interés tienen una contribución muy importante.
- **Presión del tipo de cambio:** dado que los bienes transables son proporcionales al tipo de cambio, su dinámica tiene un gran impacto en el nivel general de precios.
- **Presión de expectativas:** las expectativas también desempeñan un papel muy importante en todos los agentes económicos y podrían ser adaptativas o racionales. Cagan (1956) en el marco del proceso de expectativas adaptativas y los supuestos de equilibrio, establece que la tasa de inflación puede expresarse como una combinación lineal de la expansión monetaria nominal y la tasa de inflación esperada.
- **Presión de la cantidad de dinero y tasas de política monetaria:** aquí la expansión monetaria nominal está respaldada por la teoría cuantitativa del dinero. Dado que el nivel de precios es proporcional a la cantidad de dinero y velocidad y también inversamente proporcional al nivel de producción, entonces la tasa de crecimiento del dinero nominal impacta en la tasa de crecimiento de los precios.
- **Presión de la demanda:** el enfoque keynesiano asume que la inflación no es sólo un fenómeno monetario, sino que simplemente ocurre cuando la demanda agregada efectiva de bienes y servicios es mayor que la oferta disponible. Con el fin de evitar posibles sesgos en la estimación del producto potencial, consideraremos a la demanda agregada como una medida de esta presión.
- **Presión del déficit financiero:** el déficit financiero del sector público suele ser cubierto mediante la emisión de dinero o deuda. Por lo tanto, puede afectar el equilibrio monetario y también afectar a las expectativas. Dado que el objetivo es construir una combinación lineal de varianza máxima, es suficiente considerar la tasa de crecimiento de esta variable en su aspecto nominal. Esta variable es negativa en todo su dominio.

La muestra de datos presenta distintas frecuencias. Precisamente comprende frecuencias diarias, mensuales y trimestrales; y el período comprende desde el 1 de enero de 2013 hasta el 31 de diciembre de 2019.

En la lista siguiente se describen todas las variables del conjunto de datos y sus fuentes:

- **IPCGL:** nivel general del índice de precios de la Ciudad de Buenos Aires. Fuente: Instituto de Estadística GCBA. Frecuencia: mensual.
- **IPCG:** nivel del índice de precios de bienes de la Ciudad de Buenos Aires. Fuente: Instituto de Estadística GCBA. Frecuencia: mensual.
- **IPCS:** nivel del índice de precios de servicios de la ciudad de Buenos Aires. Fuente: Instituto de Estadística GCBA. Frecuencia: mensual.
- **W:** salario promedio de trabajadores estables (RIPE). Fuente: Ministerio de Trabajo, Empleo y Seguridad Social de Argentina. Frecuencia: mensual.

- **E**: tipo de cambio nominal peso-dólar. Fuente: Banco Central de Argentina (BCRA). Frecuencia: diaria.
- **E π** : expectativas de inflación. Fuente: CIF - UTDT. Frecuencia: mensual.
- **Y**: Producto Bruto Interno a precios constantes (2004). Fuente: Instituto Nacional de Estadística y Censos de Argentina (INDEC). Frecuencia: trimestral.
- **M3**: agregado monetario. Fuente: Banco Central de Argentina (BCRA). Frecuencia: diaria.
- **M**: billetes y monedas en manos del público. Fuente: Banco Central de Argentina (BCRA). Frecuencia: diaria.
- **r**: tasa de interés de depósitos a plazo fijo. Fuente: Banco Central de Argentina (BCRA). Frecuencia: diaria.
- **FD**: déficit financiero, definido como el resultado primario menos los intereses de deuda. Esta variable es negativa en todo su dominio. Fuente: Ministerio de Hacienda de Argentina. Frecuencia: mensual.
- **D**: deuda externa total. Fuente: Instituto Nacional de Estadística y Censo de Argentina (INDEC). Frecuencia: trimestral.

La tasa de inflación es la tasa de crecimiento del Nivel General del Índice de Precios de la Ciudad de Buenos Aires (IPCBA) y se mide por la primera diferencia del logaritmo del nivel del índice de precios, de manera similar también se mide la tasa de crecimiento de los precios de bienes y servicios:

$$\pi_{GL_t} = \Delta \log(IPCGL_t) = \log(IPCGL_t) - \log(IPCGL_{t-1}), \quad (16)$$

$$\pi_{G_t} = \Delta \log(IPCG_t) = \log(IPCG_t) - \log(IPCG_{t-1}), \quad (17)$$

$$\pi_{S_t} = \Delta \log(IPCS_t) = \log(IPCS_t) - \log(IPCS_{t-1}) \quad (18)$$

El conjunto de datos tratado contiene series temporales en diferentes escalas y frecuencias. Dado que nuestro estudio se basa en la frecuencia mensual, primero necesitamos transformar los datos. El proceso de transformación implica promediar los niveles diarios para transformarlos en niveles mensuales, y los niveles trimestrales se interpolan con un procedimiento de *spline* cúbico a niveles mensuales. Se aplica también la transformación de logaritmos con el fin de reducir la posible fuente de heterocedasticidad y también para adaptar las series a una misma escala. Dado que el enfoque de componentes principales de Stock-Watson requiere estacionariedad, se realizó en todas las series el test de Dickey y Fuller (1979) (ADF) y se diferenciaron las series no estacionarias. La selección del rezago para el test ADF se realizó utilizando el criterio de información de Akaike (AIC) en un orden de rezago máximo definido por la regla Schwert. De hecho, si $k_{max} = [12(T/100)^{(1/4)}]$ es el rezago máximo sugerido por la regla Schwert, y:

$$AIC(k) = \log(\hat{\sigma}^2(k)) + \frac{2k}{T} \quad (19)$$

es el criterio de información de Akaike; el modelo de regresión del ADF de orden k es:

$$\Delta y_t = d_t + \rho y_{t-1} + \sum_{j=1}^k \gamma_j \Delta y_{t-j} + u_t, \quad (t = k_{max} + 1, \dots, T), \quad (20)$$

donde d_t denota la especificación (*drift* o *trend*). Dado que el modelo de regresión del ADF comienza en $k_{max} + 1$, todos los modelos competidores con diferentes k están utilizando el mismo número de observaciones efectivas y, por lo tanto, el criterio AIC es comparable seleccionando el rezago óptimo como:

$$k_{opt} = \arg \min_{k \leq k_{max}} AIC(k) \quad (21)$$

La especificación del test ADF fue elegida de acuerdo con la teoría económica general y también se pensó en una inspección gráfica de todas las series temporales. Las variables relativas a los precios, el producto, el tipo de cambio y las cantidades nominales se consideraron con tendencia y las variables como la tasa de interés y la expectativa se consideraron con *drift*. Los resultados de la prueba ADF se muestran en el Cuadro 1.

Cuadro 1 | Test ADF para los niveles

Variable	Tipo	AIC óptimo	k	Estadístico	p -value
log(IPCGL)	Trend	-465,43	1	-1,29	0,889
log(IPCG)	Trend	-436,55	1	-0,97	0,948
log(IPCS)	Trend	-421,62	2	-2,35	0,403
log(W)	Trend	-416,63	0	-2,24	0,469
log(E)	Trend	-218,47	1	-1,82	0,697
log($E\pi_{GL}$)	Drift	-148,61	1	-2,15	0,017
log(Y)	Trend	-874,11	10	-2,37	0,397
log(M3)	Trend	-411,97	8	-2,36	0,398
log(M)	Trend	-367,79	11	-2,48	0,336
log(r)	Drift	-182,66	1	-1,50	0,068
log(FD)	Trend	47,83	11	-1,72	0,740
log(D)	Trend	-712,64	9	-2,32	0,422

Fuente: Elaboración propia.

Los valores p utilizados en el test corresponden a la aproximación MacKinnon (1994) para la especificación con tendencia. Para la especificación con *drift*, que incluye constante distinta de cero y tendencia no significativa, el estadístico del test de Dickey-Fuller es asintóticamente gaussiano

por Hamilton (1994) y por lo tanto pueden usarse los valores- p clásicos. Al nivel de significatividad del 10%, el test ADF indicó la presencia de raíz unitaria en los niveles de precios del IPCBA, el nivel salarial, el nivel del tipo de cambio, el nivel de producto, el nivel de M3, el nivel de dinero en poder del público, el nivel del resultado financiero y, por otro lado, el test confirmó estacionariedad para el nivel de tasa de interés y de las expectativas. Las series no estacionarias fueron diferenciadas y luego se realizó de nuevo el test ADF en todas las series transformadas. El Cuadro 2 presenta el test ADF para todas las series transformadas.

Cuadro 2 | Test ADF para las diferencias

Variable	Tipo	AIC óptimo	k	Estadístico	p-value
$\Delta\log(\text{IPCGL})$	drift	-459,36	0	-4,56	0,00001
$\Delta\log(\text{IPCG})$	drift	-431,47	0	-4,36	0,00002
$\Delta\log(\text{IPCS})$	drift	-413,98	0	-6,39	0,00000
$\Delta\log(W)$	drift	-408,81	0	-9,35	0,00000
$\Delta\log(E)$	drift	-215,35	1	-6,26	0,00000
$\Delta\log(Y)$	drift	-859,19	9	-3,45	0,00051
$\Delta\log(M3)$	drift	-403,31	7	-4,47	0,00002
$\Delta\log(M)$	drift	-364,51	10	-2,32	0,01100
$\Delta\log(FD)$	drift	50,93	10	-4,82	0,00001
$\Delta\log(D)$	drift	-683,66	6	-1,40	0,08200

Fuente: Elaboración propia.

Luego de esta transformación, el conjunto de datos que se utilizará para emplear la metodología es:

$$X_t = \{\pi_{G_t}, \pi_{S_t}, \Delta\log(W)_t, \Delta\log(E)_t, \Delta\log(Y)_t, \Delta\log(M3)_t, \Delta\log(M)_t, \log(r)_t, \log(E\pi_{GL_t}), \Delta\log(FD)_t, \Delta\log(D)_t\} \quad (22)$$

Por último, todas las series fueron estandarizadas para tener media cero y varianza igual a uno.

4. Análisis factorial

En esta sección se realiza el análisis factorial mediante la metodología de Componentes Principales. Aquí calculamos los Componentes Principales y también calculamos el estimador de los factores de Componentes Principales \tilde{F} . Además, estudiaremos la relación entre los factores estimados y las variables.

4.1. Estimación de los factores

Para evaluar la viabilidad del análisis factorial es necesario primero analizar el conjunto de datos construido (X_t). Para ello se realizaron sobre la muestra el test de Kaiser-Meyer-Olkin (KMO) y el

test de esfericidad de Bartlett. La medida de KMO es una medida de la adecuación del muestreo donde niveles superiores a 0,5 indican que los datos son aceptables para realizar el análisis factorial. Para el test de Bartlett la hipótesis nula es H_0 : las variables no están intercorrelacionadas. El Cuadro 3 muestra el resultado de ambos test:

Cuadro 3 | Test de KMO y Bartlett sobre la muestra

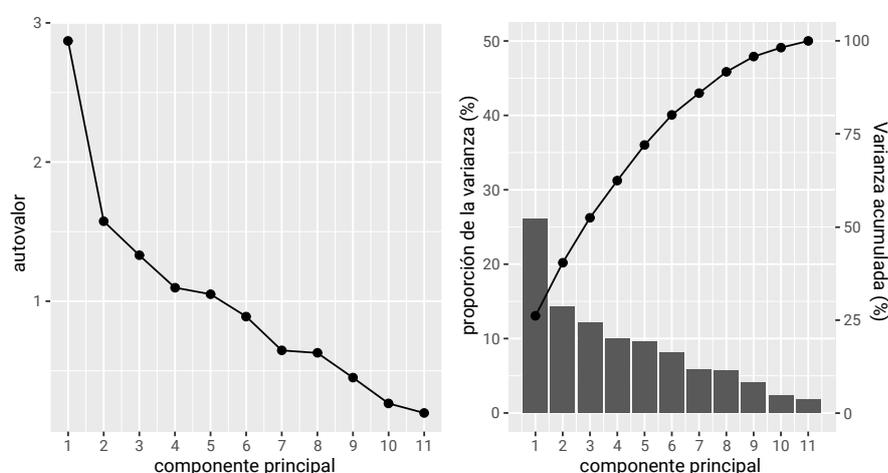
KMO medida de muestreo	0,519	
Bartlett test de esfericidad	Chi-Square	219,439
	Grados de libertad	55
	<i>p-value</i>	0,000

Fuente: Elaboración propia.

Los test han demostrado que el conjunto de datos (X_t) podría utilizarse para realizar el análisis de factores. En los pasos siguientes calculamos los componentes principales con el objetivo de resumir la varianza total en el conjunto de datos. El criterio del autovalor mayor a uno (criterio Kaiser) conduce a seleccionar cinco componentes, sin embargo, este es un límite inferior para el número de componentes para extraer. El *scree plot* muestra que la pendiente del gráfico va de empinada a plana después del cuarto componente, sugiriendo la posibilidad de considerar solo cuatro factores.

El Gráfico 1 ilustra el *scree plot* y la distribución de varianza.

Gráfico 1 | Scree plot y distribución de varianza sobre los componentes



Fuente: Elaboración propia.

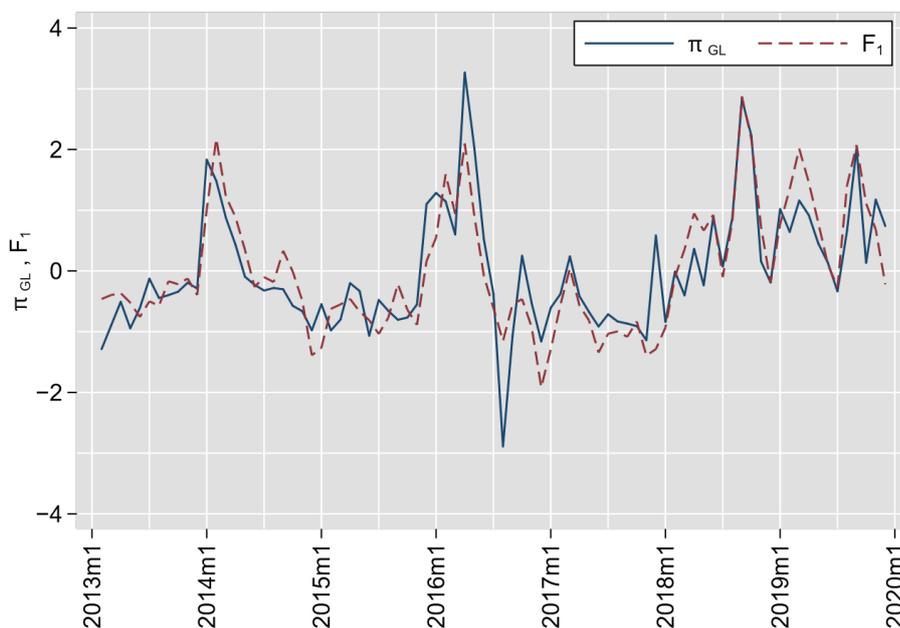
Los primeros cuatro componentes explican el 62% de la varianza total de los datos; el primer componente captura el 26% de la varianza total, el segundo 14%, el tercero 12% y el cuarto 9,9%. Al

examinar los autovectores de la matriz de correlación del conjunto de datos de la muestra, es posible calcular los estimadores de los factores o *scores*, \tilde{F} , como la suma de los productos de los autovectores multiplicados por los valores observados para la variable original para cada período. Las siguientes ecuaciones describen la estimación de los dos factores principales y el Gráfico 2 ilustra la tasa de inflación y el primer factor.

$$\begin{aligned} \tilde{F}_{1t} = & 0,493\pi_{Gt} + 0,339\pi_{St} + 0,233\Delta\log(W)_t + 0,244\Delta\log(E)_t \\ & + 0,380\log(E\pi_{GL})_t + 0,348\log(r)_t - 0,285\Delta\log(M3)_t - 0,321\Delta\log(M)_t \\ & - 0,257\Delta\log(Y)_t - 0,046\Delta\log(FD)_t - 0,087\Delta\log(D)_t \end{aligned} \quad (23)$$

$$\begin{aligned} \tilde{F}_{2t} = & 0,234\pi_{Gt} + 0,162\pi_{St} - 0,329\Delta\log(W)_t + 0,481\Delta\log(E)_t \\ & - 0,080\log(E\pi_{GL})_t + 0,276\log(r)_t + 0,543\Delta\log(M3)_t + 0,362\Delta\log(M)_t \\ & - 0,043\Delta\log(Y)_t - 0,096\Delta\log(FD)_t + 0,242\Delta\log(D)_t \end{aligned} \quad (24)$$

Gráfico 2 | Primer componente e inflación, variables estandarizadas



Fuente: Elaboración propia.

El análisis visual indica que el primer factor muestra fuertes comovimientos con la tasa de inflación, evidenciando una fuerte asociación con la dinámica de precios. Con el fin de cuantificar la asociación entre los factores estimados y la tasa de inflación calculamos las correlaciones. El Cuadro 4 muestra las correlaciones y el t-test de significatividad $H_0 : \text{Corr}(\pi_{GL}, F_j) = 0$.

Cuadro 4 | Correlaciones entre la tasa de inflación y los factores estimados

Factor	Corr(π_{GL}, F_i)	t	p-value
F_1	0,840	13,98	0,000
F_2	0,300	2,80	0,006
F_3	-0,012	-0,11	0,900
F_4	-0,210	-1,92	0,057

Fuente: Elaboración propia.

Los resultados muestran que los factores uno, dos y cuatro están correlacionados con la tasa de inflación y las estimaciones son significativas; mientras que la correlación con el factor tres resultó no significativa.

4.2. Interpretación de los factores

La correlación entre las variables observadas y los factores permite comprender cómo se organizan las variables en el espacio de factores comunes y, por lo tanto, detectar clústeres de variables. El mapa de factores es un gráfico de dispersión de las correlaciones de las variables y los dos primeros factores, $\text{Corr}(X_i, F_1)$ y $\text{Corr}(X_i, F_2)$. La calidad de la representación en el mapa de factores se mide por el coseno cuadrado; dada una variable X_i y un componente F_j , definimos el ij -coseno cuadrado como:

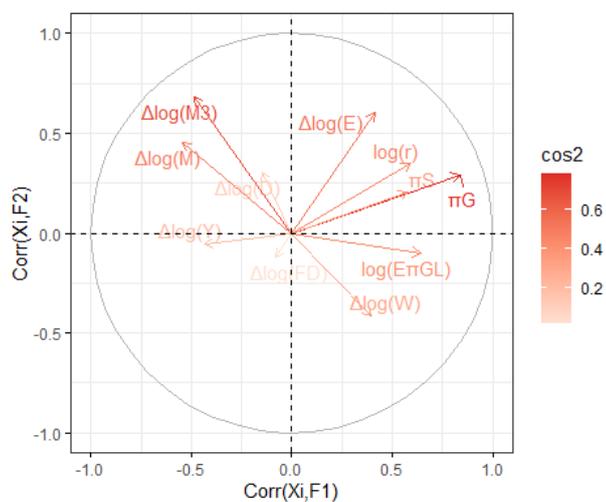
$$\cos 2_{ij} = \text{Corr}(X_i, F_j)^2 \quad (25)$$

La suma de $\cos 2_{ij}$ sobre todos los componentes es igual a uno. Si una variable está perfectamente representada por sólo dos componentes principales, entonces la suma de éstos dos es uno y en este caso las variables se colocarán sobre el círculo. Dada una variable X_i definimos el coseno cuadrado como la norma cuadrada del vector $(\text{Corr}(X_i, F_1), \text{Corr}(X_i, F_2))$, es decir, como:

$$\cos 2 = \text{Corr}(X_i, F_1)^2 + \text{Corr}(X_i, F_2)^2 = \cos 2_{i1} + \cos 2_{i2} \quad (26)$$

Un nivel de $\cos 2$ alto indica una buena representación de la variable en el componente y en este caso la variable se coloca cerca de la circunferencia del círculo de correlación. Por otro lado, un nivel de $\cos 2$ bajo indica que la variable no está perfectamente representada por los componentes y en este caso la variable está cerca del centro del círculo. El Gráfico 3 ilustra el mapa de factores y la medida $\cos 2$ mediante un mapa de color según sus niveles de $\cos 2$.

Gráfico 3 | Mapa de Factores y cos2 para cada variable



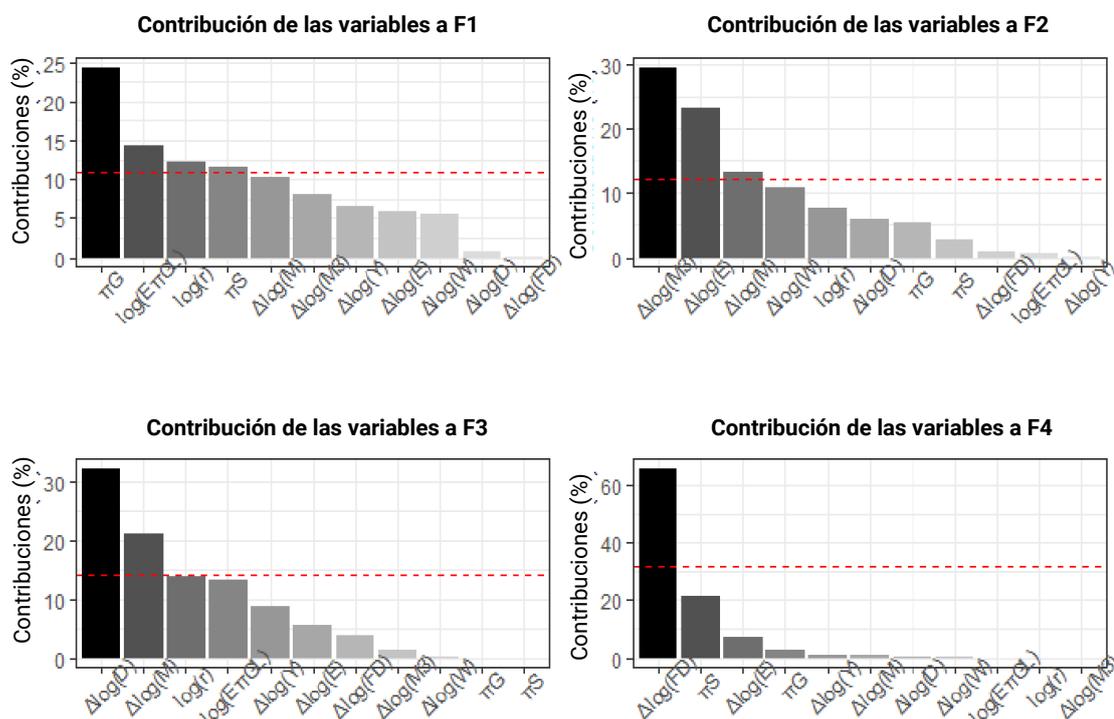
Fuente: Elaboración propia.

En el estudio de las variables, también es muy útil mirar las contribuciones de las variables a cada eje para obtener ayuda en la interpretación y significado de los factores. La contribución de una variable X_i a un componente principal F_j se define como el ij -coseno cuadrado relativo:

$$ctr_{ij} = \frac{\cos^2_{ij}}{\sum_i \cos^2_{ij}} \quad (27)$$

Cuanto mayor sea el nivel de este ratio, más contribuye la variable al componente. El Gráfico 4 muestra las contribuciones de las variables para los cuatro componentes principales.

Gráfico 4 | Contribución de las variables a los cuatro componentes principales



Fuente: Elaboración propia.

La línea roja discontinua en el gráfico anterior indica el promedio de las contribuciones significativas que podría utilizarse como un límite para considerar una variable como importante para el componente. Dado un factor j , la contribución de corte se calcula como:

$$\text{media}(crt_{ij}) \text{ sujeto a } \text{Corr}(X_i, F_j) \neq 0 \text{ a un nivel del } 10\%, \quad (28)$$

entonces una variable con una contribución mayor que este límite podría considerarse importante para contribuir al componente. Del gráfico de contribuciones se puede ver que los factores están relacionados principalmente con cuatro grupos diferentes de variables; el primer factor está impulsado principalmente por los precios de los bienes y servicios, las expectativas de inflación y el nivel de la tasa de interés. La contribución más importante para el primer factor está dada por el precio de los bienes con el 25% y luego seguido por las expectativas de inflación con una contribución cercana al 15%. Esto demuestra que el primer factor tiende a describir los componentes de precio del sistema. Para el segundo factor, las variables del crecimiento del dinero M3, el tipo de cambio y el crecimiento del dinero en poder del público son las que más contribuyen. En este caso, la contribución principal está impulsada por el crecimiento del dinero M3 con un nivel cercano al 30% y seguido por el tipo de cambio con un nivel de contribución cercano al 23%. Estos resultados indican que el segundo factor tiende a describir los aspectos monetarios y cambiarios. El tercer grupo está principalmente relacionado con el crecimiento de la deuda con una contribución cercana al 33% y el cuarto factor está fuertemente asociado con el déficit financiero con una contribución de más del 60%. Por otro lado, es importante remarcar que los salarios y la producción han mostrado una contribución muy débil sobre los factores. El análisis de las contribuciones de las

variables sobre los componentes nos permitió comprender mejor las interpretaciones económicas de los factores latentes. En resumen, el Cuadro 5 muestra los grupos de variables que más contribuyen a los cuatro factores principales.

Cuadro 5 | Interpretación de los componentes y principales contribuciones

F ₁ : Precios	F ₂ : Monetaria y cambiaria	F ₃ : Deuda	F ₄ : Fiscal
π_G	$\Delta \log(M3)$	$\Delta \log(D)$	$\Delta \log(FD)$
$\log(E\pi_{GL})$	$\Delta \log(E)$	$\Delta \log(M)$	
$\log(r)$	$\Delta \log(M)$		
π_S			

Fuente: Elaboración propia.

5. Estimación de los modelos factoriales y resultados de pronóstico

5.1. Modelo factorial estático

Consideremos ahora el modelo de regresión dado por los cuatro factores principales no observables:

$$\pi_{GL_t} = \alpha_1 F_{1t} + \alpha_2 F_{2t} + \alpha_3 F_{3t} + \alpha_4 F_{4t} + \varepsilon_t \quad (29)$$

Dado que los factores estimados tienen interpretación económica podemos dar una interpretación económica al coeficiente cuando utilizamos a \tilde{F}_{it} como regresor. El Cuadro 6 muestra el modelo estimado:

Cuadro 6 | Estimación del modelo de factores estático, estadístico t entre paréntesis

Parámetros	Estimación
α_1	0,840*** (18,55)
α_2	0,297*** (6,57)
α_3	-0,012 (-0,28)
α_4	-0,209*** (-4,62)
R^2	0,839

* p < 0,05, ** p < 0,01, *** p < 0,001.

Fuente: Elaboración propia.

El resultado de la regresión mostró que los factores uno, dos y cuatro son estadísticamente significativos a un nivel inferior al 5%. Los coeficientes tienen una interpretación porcentual y de acuerdo con la interpretación de los factores, los signos obtenidos están en línea con la literatura. Un aumento de una unidad en el factor uno, relacionado con los precios, aumenta el nivel general de precios en 0,840%, mientras que un aumento en el factor dos, asociado con el crecimiento monetario y el tipo de cambio, aumenta el nivel general de precios en 0,297%. El efecto del deterioro de las cuentas fiscales en el nivel de precios se confirma por el signo negativo del factor cuatro asociado con el déficit financiero, aquí una caída de una unidad genera un aumento del 0,209% en los precios. Por otra parte, el factor tres, asociado con el crecimiento de la deuda, no fue significativo para ningún nivel aceptable de confianza; por lo tanto, podría sugerir que la financiación del déficit a través de la emisión de deuda tiene un impacto menor en la inflación que la financiación con emisión monetaria.

5.2. Pronósticos

En esta sección desempeñamos los modelos factoriales siguiendo la metodología dada en la Sección 0. Aquí el objetivo es pronosticar la tasa de inflación π_{GL} siguiendo las dos metodologías de pronóstico, utilizando datos de fuera de la muestra para los diferentes horizontes de pronóstico. Los modelos factoriales se prueban contra varios modelos de referencia. El primer modelo de referencia elegido para comparar fue un modelo autorregresivo (AR) cuya estructura se determinó mediante el análisis de la función de autocorrelación parcial y el criterio de información de Akaike y el orden resultante fue uno. Los niveles bajos de RMSE y U-Theil reflejan un error de pronóstico más bajo indicando mejor capacidad predictiva. También se realiza el test de Diebold y Mariano (1995) (DM) con respecto al modelo de referencia utilizando el módulo Stata creado por Baum (2003). La función de pérdida considerada es $g(e_{it}) = e_{it}^2$ y la estructura de rezagos de la función de autocovarianza se toma cerca de la raíz cúbica del número de observaciones. Puesto que el test es de dos colas, el rechazo de la hipótesis nula en favor de la alternativa sugiere que si el estadístico $S(1)$ es negativo se prefiere el modelo de referencia, caso contrario se preferiría el modelo de factores. El test de Giacomini y White (2004) se realiza regresando las diferencias $g(e_{1t}) - g(e_{2t})$ en función de una constante dada y luego observando el test de significatividad para la estimación del intercepto. Se definen tres horizontes distintos de pronóstico; el primero (P_1) desde enero de 2019 hasta diciembre de 2019, el segundo (P_2) desde mayo de 2019 hasta diciembre de 2019 y el tercero (P_3) desde septiembre de 2019 hasta diciembre de 2019.

5.2.1. Desempeño del pronóstico estático

En esta sección presentamos el desempeño predictivo del modelo de pronóstico utilizando un modelo factorial de uno y dos factores. Específicamente, consideramos los siguientes dos modelos factoriales (1 FM) y (2 FM) respectivamente:

$$\begin{aligned} \pi_{GLt} &= \eta + \pi_{GLt-1} + \alpha_1 \tilde{F}_{1t-1} + \varepsilon_t \\ \pi_{GLt} &= \eta + \pi_{GLt-1} + \alpha_1 \tilde{F}_{1t-1} + \alpha_2 \tilde{F}_{2t-1} + \varepsilon_t \end{aligned} \tag{30}$$

Los cuadros 7 y 8 presentan el desempeño de los pronósticos en los test RMSE, U-Theil, Diebold y Mariano y los resultados de Giacomini y White, respectivamente, comparando el modelo de factores con un modelo AR(1).

Cuadro 7 | Criterios de evaluación de pronósticos estáticos

Periodo	Modelo	RMSE _P	U _P	RRMSE _P	RU _P	DM-test		
						S(1)-statistic	p-value	K lag
	AR	0,824	0,565	1,000	1,000			
P ₁	1 FM	0,744	0,461	0,902	0,815	2,790	0,0053	3
	2 FM	0,667	0,378	0,809	0,669	2,647	0,0081	3
	AR	0,865	0,577	1,000	1,000			
P ₂	1 FM	0,788	0,485	0,910	0,840	1,660	0,0969	3
	2 FM	0,736	0,398	0,850	0,689	1,961	0,0499	3
	AR	1,118	0,568	1,000	1,000			
P ₃	1 FM	0,982	0,473	0,878	0,832	1,974	0,0483	2
	2 FM	0,856	0,365	0,765	0,642	1,618	0,1050	2

Fuente: Elaboración propia.

Cuadro 8 | Test de Giacomini y White para el pronóstico estático

Periodo	Modelo	Estadístico	p-value (Normal)
P ₁	2 FM vs AR	1,45	0,073
P ₂	2 FM vs AR	1,33	0,091
P ₃	2 FM vs AR	1,30	0,096

Fuente: Elaboración propia.

Todos los ratios del RMSE y U-Theil contra el modelo autorregresivo son menores que la unidad en todos los horizontes y también se observa que el modelo de 2 factores es mejor que el modelo de 1 factor. El estadístico S(1) fue significativo al nivel del 10% y, por lo tanto, sugiere que los factores extraídos del grupo de series observables tienen un cierto potencial en el pronóstico de la dinámica

del índice de precios al consumidor. Además, el test de Giacomini y White demostró una buena capacidad predictiva al rechazar la hipótesis nula y así confirmar la diferencia de ambos modelos.

Con el fin de garantizar el poder predictivo del modelo de 2 factores, elegimos otros modelos más sofisticados que un simple AR(1) para comparar. Los modelos que elegimos son:

- *Regresión multivariada (modelos ADL)*: aquí realizamos una regresión lineal multivariada por MCO utilizando todas las variables en el conjunto de datos (excluyendo los subíndices):

$$\begin{aligned} \pi_{GL_t} = & \eta + \alpha_1 \pi_{GL_{t-1}} + \alpha_2 \Delta \log(W)_{t-1} + \alpha_3 \Delta \log(E)_{t-1} + \alpha_4 \Delta \log(Y)_{t-1} \\ & + \alpha_5 \Delta \log(M3)_{t-1} + \alpha_6 \Delta \log(M)_{t-1} + \alpha_7 \log(r)_{t-1} + \alpha_8 \log(E\pi_{GL_{t-1}}) \\ & + \alpha_9 \Delta \log(FD)_{t-1} + \alpha_{10} \Delta \log(D)_{t-1} + \varepsilon_t \end{aligned} \quad (31)$$

- *Modelo de Lasso*: se basa en el enfoque de penalización. Minimiza el error cuadrático medio sujeto a una penalización sobre el valor absoluto de la magnitud de los coeficientes estimados, de hecho, denotando por x_{t-1} al vector de variables explicativas utilizadas en la ecuación de arriba en el momento $t - 1$ y α al vector de coeficientes realizamos:

$$\hat{\alpha}_{lasso} = \operatorname{argmin} \frac{1}{n} \sum_{t=1}^n (\pi_{GL_t} - x_{t-1} \alpha')^2 + \frac{\lambda}{n} \sum_{j=1}^{10} |\alpha_j| \quad (32)$$

donde λ es un parámetro de ajuste que controla el nivel de penalización general.

El Cuadro 9 presenta el desempeño de pronósticos en las medidas RMSE y U-Theil comparando el modelo de dos factores con los modelos Multivariados y Lasso. Para los modelos Lasso se utilizó el criterio de información EBIC desarrollado en Chen (2008) para encontrar el parámetro de ajuste λ óptimo.

Cuadro 9 | Evaluaciones alternativas de comparación

Periodo	Modelo	RMSE _P	U _P
P ₁	Multivariado	0,726	0,400
	Lasso ($\lambda = 22,94$)	0,763	0,561
	2 FM	0,667	0,378
P ₂	Multivariado	0,859	0,416
	Lasso ($\lambda = 18,62$)	0,681	0,419
	2 FM	0,736	0,398
P ₃	Multivariado	0,933	0,364
	Lasso ($\lambda = 17,38$)	0,862	0,413
	2 FM	0,856	0,364

Fuente: Elaboración propia.

El modelo de dos factores funciona mejor que los modelos Multivariado y Lasso en los periodos P_1 y P_3 , mientras que en el periodo P_2 el modelo Lasso registró un menor RMSE que el modelo de dos factores, sin embargo, la medida U-Theil fue menor para este último. El Gráfico 5 ilustra el pronóstico estático para los modelos AR(1), Lasso, Multivariado y Factorial en los tres periodos.

5.2.2. Desempeño del pronóstico dinámico

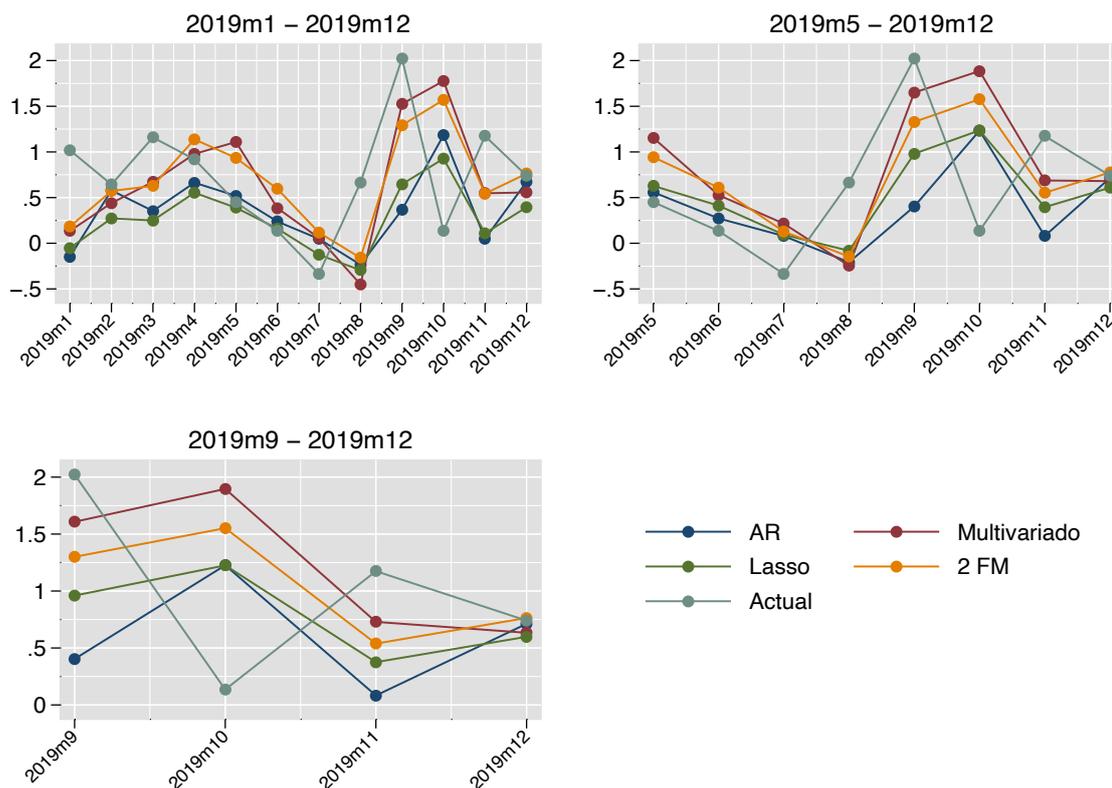
Para desempeñar el pronóstico dinámico, específicamente consideramos los siguientes dos modelos FAVAR con un rezago:

$$\text{FAVAR1} : \begin{bmatrix} \tilde{F}_{1t} \\ \pi_{GLt} \end{bmatrix} = \begin{pmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{pmatrix} \begin{bmatrix} \tilde{F}_{1t-1} \\ \pi_{GLt-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix} \quad (33)$$

$$\text{FAVAR2} : \begin{bmatrix} \tilde{F}_{1t} \\ \tilde{F}_{2t} \\ \pi_{GLt} \end{bmatrix} = \begin{pmatrix} \phi_{11} & \phi_{12} & \phi_{13} \\ \phi_{21} & \phi_{22} & \phi_{23} \\ \phi_{31} & \phi_{32} & \phi_{33} \end{pmatrix} \begin{bmatrix} \tilde{F}_{1t-1} \\ \tilde{F}_{2t-1} \\ \pi_{GLt-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ \varepsilon_{3t} \end{bmatrix} \quad (34)$$

Los cuadros 10 y 11 presentan el desempeño de los pronósticos en el marco de las medidas RMSE y U-Theil y también los test para la comparación de pronósticos de Diebold-Mariano y Giacomini-White.

Gráfico 5 | Comparación de los pronósticos estáticos utilizando distintos modelos y horizontes



Fuente: Elaboración propia.

Cuadro 10 | Criterios de evaluación de pronósticos dinámicos

<i>Periodo</i>	<i>Modelo</i>	<i>RMSE_P</i>	<i>U_P</i>	<i>RRMSE_P</i>	<i>RU_P</i>	<i>DM-test</i>		
						<i>S(1)-statistic</i>	<i>p-value</i>	<i>K lag</i>
	AR	1,011	0,981	1,000	1,000			
<i>P₁</i>	FAVAR1	1,016	0,980	1,004	0,998	-3,370	0,0008	3
	FAVAR2	0,862	0,797	0,852	0,812	2,311	0,0208	3
	AR	0,886	0,755	1,000	1,000			
<i>P₂</i>	FAVAR1	0,814	0,579	0,918	0,766	0,9217	0,3567	3
	FAVAR2	0,841	0,561	0,949	0,743	0,4282	0,6685	3
	AR	1,013	0,684	1,000	1,000			
<i>P₃</i>	FAVAR1	0,808	0,456	0,797	0,666	5,155	0,0000	2
	FAVAR2	0,681	0,287	0,672	0,419	3,276	0,0011	2

Fuente: Elaboración propia.

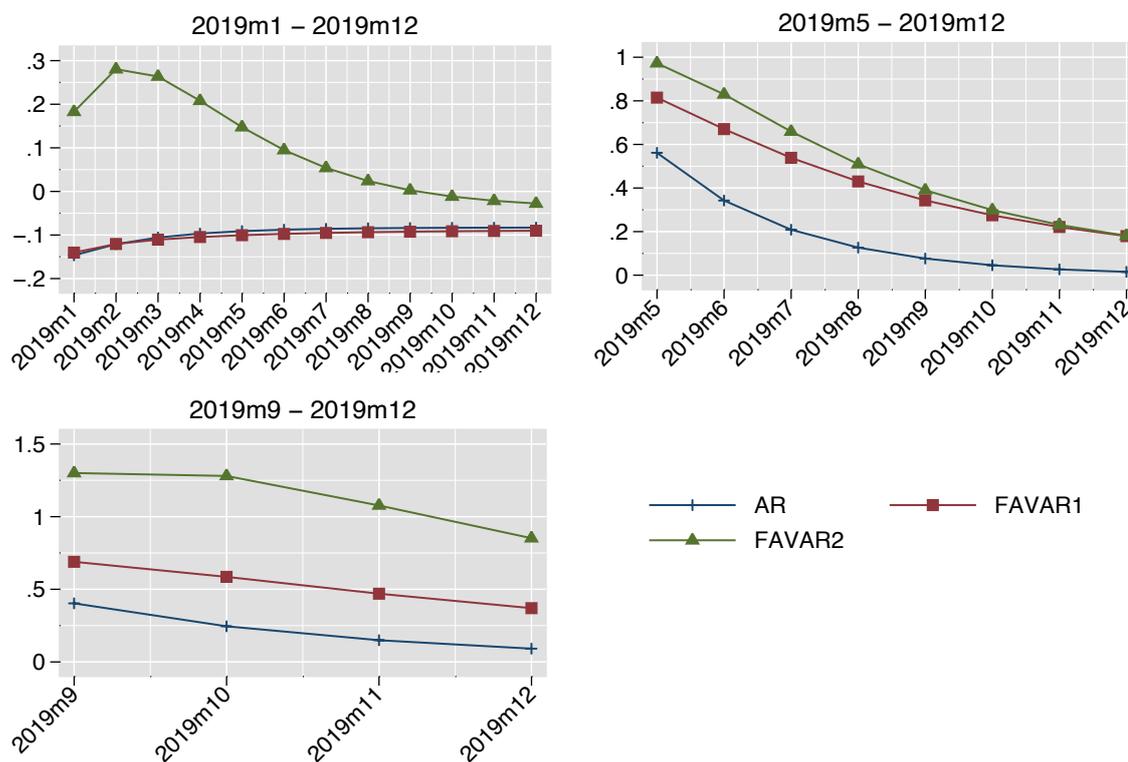
Cuadro 11 | Test de Giacomini y White para el pronóstico dinámico

<i>Periodo</i>	<i>Modelo</i>	<i>Estadístico (Newey-West)</i>	<i>p-value (Normal)</i>
<i>P₁</i>	FAVAR2 vs AR	2,85 lag=1	0,0021
<i>P₂</i>	FAVAR2 vs AR	0,34 lag=1	0,3660
<i>P₃</i>	FAVAR2 vs AR	1,51 lag=2	0,0650

Fuente: Elaboración propia.

El Gráfico 6 ilustra los pronósticos dinámicos.

Gráfico 6 | Comparación de los pronósticos dinámicos utilizando distintos modelos y horizontes



Fuente: Elaboración propia.

Para el pronóstico dinámico, se encuentra el mejor desempeño para el modelo FAVAR2 en el primer y tercer período, mostrando ambos valores menores a la unidad y también con un estadístico $S(1)$ significativo al nivel del 10%. Para el segundo período los modelos FAVAR1 y FAVAR2 tuvieron un desempeño muy similar para ambas métricas y también superior al del modelo de referencia AR en términos de las medidas de desempeño predictivo. Sin embargo, el estadístico $S(1)$ no resultó ser estadísticamente significativo en ambos casos. El test de Giacomini y White también produce una conclusión similar que el test de DM, mostrando diferencias significativas entre el modelo FAVAR2 y AR(1) en los períodos P_1 y P_3 .

6. Funciones de Impulso Respuesta y Causalidad de Granger

6.1. Test de Granger

En esta sección realizamos el test de causalidad en el sentido de Granger en el modelo FAVAR utilizando los cuatro factores principales. Las pruebas de causalidad realizadas por Granger (1969) sugieren qué variables del sistema tienen impactos significativos en los niveles futuros de cada una de las variables del sistema. Sin embargo, los resultados no indican, por construcción, cuánto tiempo estos impactos seguirán siendo efectivos y las funciones de impulso respuesta pueden dar esta información. Después de ajustar el modelo FAVAR podemos saber si una variable causa en

sentido Granger a otra. Para cada ecuación en el modelo FAVAR podemos probar las hipótesis de que cada una de las otras variables endógenas no causa en el sentido de Granger a la variable dependiente en esa ecuación. Consideramos el siguiente modelo FAVAR utilizando los cuatro factores principales con una especificación de un rezago:

$$FAVAR4 : \begin{bmatrix} \tilde{F}_{1t} \\ \tilde{F}_{2t} \\ \tilde{F}_{3t} \\ \tilde{F}_{4t} \\ \pi_{GLt} \end{bmatrix} = \begin{pmatrix} \phi_{11} & \dots & \phi_{15} \\ \phi_{21} & \dots & \phi_{25} \\ \vdots & & \vdots \\ \phi_{51} & \dots & \phi_{55} \end{pmatrix} \begin{bmatrix} \tilde{F}_{1t-1} \\ \tilde{F}_{2t-1} \\ \tilde{F}_{3t-1} \\ \tilde{F}_{4t-1} \\ \pi_{GLt-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ \varepsilon_{3t} \\ \varepsilon_{4t} \\ \varepsilon_{5t} \end{bmatrix} \quad (35)$$

El Cuadro 12 informa el estadístico F de la prueba de Granger.

Cuadro 12 | Test de Granger para el modelo FAVAR4

Ecuación	Var. excluida	F	df	p-value
\tilde{F}_1	\tilde{F}_2	12,294	1	0,0008
	\tilde{F}_3	0,237	1	0,6276
	\tilde{F}_4	0,344	1	0,5590
	π_{GL}	3,938	1	0,0508
	<i>todas</i>	3,155	4	0,0187
\tilde{F}_2	\tilde{F}_1	2,099	1	0,1515
	\tilde{F}_3	1,694	1	0,1969
	\tilde{F}_4	6,165	1	0,0152
	π_{GL}	1,177	1	0,2814
	<i>todas</i>	2,253	4	0,0711
\tilde{F}_3	\tilde{F}_1	9,515	1	0,0028
	\tilde{F}_2	0,0125	1	0,9111
	\tilde{F}_4	1,923	1	0,1696
	π_{GL}	3,087	1	0,0829
	<i>todas</i>	4,4831	4	0,0026
\tilde{F}_4	\tilde{F}_1	11,478	1	0,0011
	\tilde{F}_2	4,493	1	0,0373
	\tilde{F}_3	8,039	1	0,0059
	π_{GL}	12,388	1	0,0007
	<i>todas</i>	4,810	4	0,0016
π_{GL}	\tilde{F}_1	6,408	1	0,0134
	\tilde{F}_2	4,287	1	0,0418
	\tilde{F}_3	0,198	1	0,6574
	\tilde{F}_4	2,225	1	0,1399
	<i>todas</i>	3,826	4	0,0069

Fuente: Elaboración propia.

El Cuadro 12 se lee de la siguiente manera, para cada ecuación del sistema FAVAR el test F de Granger se realiza suponiendo en cero a la variable excluida. Por ejemplo, en la primera ecuación para \tilde{F}_1 se realiza una prueba F sobre el rezago de \tilde{F}_2 y en este caso se rechaza la hipótesis nula de que \tilde{F}_2 no causa en sentido Granger a \tilde{F}_1 . Para el segundo y el tercer test las variables excluidas

son \tilde{F}_3 y \tilde{F}_4 , respectivamente, y las respectivas hipótesis no se rechazan. En las últimas dos pruebas las hipótesis son rechazadas.

En resumen, tenemos los siguientes mapas de Causalidad en el sentido de Granger en pares:

$$\tilde{F}_2 \rightarrow \tilde{F}_1, \pi_{GL} \rightarrow \tilde{F}_1, \tilde{F}_2 \tilde{F}_3 \tilde{F}_4 \pi_{GL} \rightarrow \tilde{F}_1$$

$$\tilde{F}_4 \rightarrow \tilde{F}_2, \tilde{F}_1 \tilde{F}_3 \tilde{F}_4 \pi_{GL} \rightarrow \tilde{F}_2$$

$$\tilde{F}_1 \rightarrow \tilde{F}_3, \pi_{GL} \rightarrow \tilde{F}_3, \tilde{F}_1 \tilde{F}_2 \tilde{F}_4 \pi_{GL} \rightarrow \tilde{F}_3$$

$$\tilde{F}_1 \rightarrow \tilde{F}_4, \tilde{F}_2 \rightarrow \tilde{F}_4, \tilde{F}_3 \rightarrow \tilde{F}_4, \pi_{GL} \rightarrow \tilde{F}_4, \tilde{F}_1 \tilde{F}_2 \tilde{F}_3 \pi_{GL} \rightarrow \tilde{F}_4$$

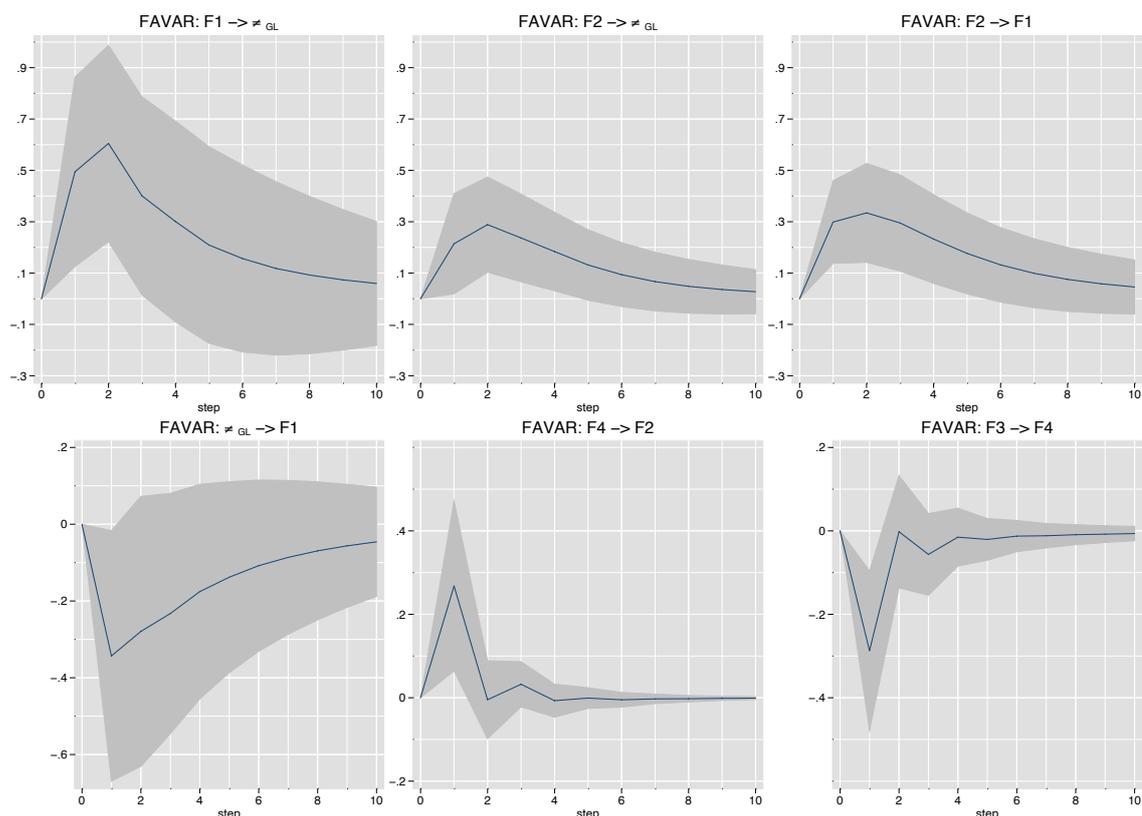
$$\tilde{F}_1 \rightarrow \pi_{GL}, \tilde{F}_2 \rightarrow \pi_{GL}, \tilde{F}_1 \tilde{F}_2 \tilde{F}_3 \tilde{F}_4 \rightarrow \pi_{GL}$$

De acuerdo con las identificaciones de los factores, estos resultados también están en línea con la literatura. Dado que el segundo factor está asociado a hechos no observables de los aspectos monetarios y cambiarios, es muy probable que esta variable pueda tener un efecto contemporáneo en el primer factor que se representa como las expectativas de inflación y el precio de los bienes y, por lo tanto, efecto en el nivel general de la tasa de inflación. Otra interpretación económica se da con el factor cuatro y el factor dos, respondiendo a la ecuación de financiación del presupuesto.

6.2. Impulso respuesta

Las funciones de impulso respuesta trazan la capacidad de respuesta de las variables dependientes del sistema VAR a los *shocks* sobre cada una de las variables. Una característica distintiva de estos enfoques generalizados es que los resultados de estos análisis son invariantes al orden de las variables que entran en el sistema VAR. Para cada variable de cada ecuación por separado, se aplica un *shock* unitario al error y se observan los efectos sobre el sistema VAR a lo largo del tiempo. Los resultados de las funciones de impulso respuesta para el sistema FAVAR considerado con los cuatro factores principales se presentan en el Gráfico 7.

Gráfico 7 | Función de impulso respuesta para el modelo FAVAR4 de cuatro factores



Fuente: Elaboración propia.

Según estos resultados, la respuesta de la tasa de inflación a un *shock* unitario en el primer factor es positiva y luego de un mes alcanza un valor cercano a 0,6. La interpretación convencional de esto es que los *shocks* al primer factor están impulsados principalmente por las expectativas de inflación y los precios de los bienes y, por lo tanto, generan un efecto positivo sobre la inflación. Los shocks al segundo factor también tienen un efecto positivo en la tasa de inflación con un nivel máximo de 0,3 luego de dos meses. Dado que el factor dos está asociado a factores no observables vinculados al crecimiento monetario y cambiario, la respuesta de la inflación está en línea con lo esperado. La respuesta del primer factor por un *shock* en el segundo factor también es esperada; la contribución del tipo de cambio del segundo factor impulsa los precios de los bienes transables y, por lo tanto, también las expectativas de inflación. El efecto del factor dos luego de un *shock* sobre el factor cuatro se explica por la relación de éste con el resultado financiero del sector público; un deterioro del frente fiscal aumenta la emisión monetaria la cual está fuertemente asociada con el factor dos. Finalmente, el efecto de un *shock* sobre el factor tres impacta negativamente en el factor cuatro por medio del aumento de la participación de los intereses de deuda en el resultado financiero.

7. Conclusión

Este trabajo tiene dos objetivos principales; en primer lugar, investigar la relación entre las principales variables macroeconómicas y la tasa de inflación utilizando el análisis factorial y, en segundo lugar, evaluar el desempeño de los modelos factoriales cuando se utilizan para predecir la tasa de inflación. El estudio de las contribuciones demostró que los cuatro primeros factores o componentes principales tienen una interpretación económica. El primer factor está fuertemente asociado con el crecimiento de los precios de los bienes, el nivel de las expectativas, el nivel de la tasa de interés y el crecimiento de los precios de los servicios evidenciándose, así, la interpretación del factor como un componente no observable de la dinámica general de los precios. El segundo se ocupa de los aspectos no observables del crecimiento monetario y cambiario, el tercero está relacionado con el crecimiento de la deuda y el cuarto está relacionado con el déficit financiero. El modelo factorial estático nos permitió interpretar el efecto *ceteris paribus* de cada factor sobre la tasa de inflación. Aquí los factores uno y dos tuvieron efectos positivos, siendo el factor uno el de mayor impacto. El efecto del factor tres fue cercano a cero y estadísticamente no significativo, lo que evidenció un bajo impacto del crecimiento de la deuda sobre la tasa de inflación. Por otro lado, el efecto del factor cuatro fue negativo, reflejando un impacto positivo sobre la tasa de inflación frente al aumento del déficit financiero. Asimismo, el producto y los salarios no han mostrado contribuciones significativas sobre los factores principales. Los test de causalidad y las funciones de impulso-respuesta también sugirieron un efecto positivo de los factores uno y dos sobre la inflación, identificando así el rol crucial que tienen los precios de los bienes, las expectativas, el crecimiento monetario y cambiario para impulsar la dinámica inflacionaria. En segundo lugar, hemos desarrollado modelos de pronóstico utilizando uno y dos factores y los resultados han proporcionado evidencias de que los pronósticos de los modelos factoriales superan a los de los modelos de referencia en las versiones estática y dinámica. Esto demuestra que los factores extraídos del grupo de series observables tienen un cierto potencial para el pronóstico de la dinámica del índice de precios al consumidor. Todos estos resultados indican que el análisis multivariado permite una mejor comprensión de los diferentes impulsores de la inflación.

Referencias

Basco E., L. D' Amato y L. Garegnani (2006): "Understanding the money - prices relationship under low and high inflation regimes: Argentina 1970 – 2005". Documento de trabajo 200613, Departamento de Investigaciones Económicas (BCRA).

Baum C. F. (2003): *DMARIANO: Módulo Stata para calcular la comparación Diebold-Mariano de la precisión del pronóstico*. Departamento de Economía del Colegio de Boston.

Bernanke B. S., J. Boivin y P. Elias (2005): "Measuring the Effects of Monetary Policy: A Factor Augmented Vector Autoregressive (FAVAR) Approach". *The Quarterly journal of economics*, 120(1), pp. 387-422.

Cagan, P. (1956): "The Monetary Dynamics of Hyperinflation". En Friedman, Milton (ed.). *Studies in the Quantity Theory of Money*. Chicago: University of Chicago Press.

Chen, Jiahua (2008): "Extended Bayesian information criteria for model selection with large model spaces", *Biometrika*, 95 (13), pp. 759–771.

Dickey, D. A. y W. A. Fuller (1979): "Distribution of the estimators for autoregressive time series with a unit root". *Journal of the American Statistical Association*, 74, pp. 427-431.

Diebold, F. X. y R. Mariano (1995): "Comparing Predictive Accuracy". *Journal of Business and Economic Statistics*, 13, pp. 253-265.

Giacomini, R. A (2004). "Tests of conditional predictive ability". *Econometrica*, Vol. 74, N° 6, pp. 1545-1578.

Granger, C. W. (1969): "Investigating causal relations by econometric models and cross spectral methods". *Econometrica*, 37, pp. 428-38.

Hamilton, J. D. (1994): *Time Series Analysis*. Princeton: Princeton University Press.

Kunovac D. (2007): "Factor Models Forecasts of inflation in Croatia". *Financial Theory and Practice*, 31, (4), pp. 371-393.

MacKinnon, J. G. (1994): "Approximate asymptotic distribution functions for unit root and cointegration tests". *Journal of Business and Economic Statistics*, 12, pp. 167-176.

Stock, J. y M. Watson (2002): "Forecasting Using Principal Components from a Large Number of Predictors". *Journal of the American Statistical Association*, Vol. 97, N° 460.