



DOCUMENTO DE TRABAJO

N.º 03 | 2024

Modelos FAVAR con factores estáticos y dinámicos para pronosticar la inflación en Costa Rica

Carlos Segura-Rodriguez

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

Modelos FAVAR con factores estáticos y dinámicos para pronosticar la inflación en Costa Rica

Carlos Segura-Rodriguez[†]

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

Resumen

Este estudio propone una metodología para pronosticar la inflación en Costa Rica utilizando un modelo FAVAR (VAR aumentados por factores) que integra 156 series de tiempo relevantes. El proceso se divide en dos etapas: primero, se estiman factores estáticos y dinámicos que se incorporan a un modelo VAR para proyectar la variación anual del índice de precios al consumidor. La innovación de este estudio radica en aplicar criterios automáticos para seleccionar las variables a utilizar en los factores, así como la cantidad factores, rezagos y restricciones a imponer en el VAR. Se generan ocho pronósticos de inflación, que se combinan mediante tres promedios: simple, con base en el error cuadrático medio y bayesiano. Los resultados indican que la metodología propuesta supera a modelos VAR bivariados y otros métodos simples (ARMA (2,2), ARMA con selección automática y modelos FAVAR tradicionales), en términos de precisión, según pruebas de Diebold-Mariano y de permutaciones. Esto sugiere que el enfoque permite integrar la información eficazmente sin requerir conocimiento previo sobre su relevancia.

Palabras clave: Inflación, pronóstico, factores, dinámicos, FAVAR.

Clasificación JEL: C38, C55, E31, E37.

[†]Departamento de Investigación Económica. División Económica, BCCR. segurarc@bccr.fi.cr.

FAVAR Models with Static and Dynamic Factors to Forecast Inflation in Costa Rica

Carlos Segura-Rodriguez[†]

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

Summary

This study proposes a methodology to forecast inflation in Costa Rica using a FAVAR model (Factor-Augmented VAR) that integrates 156 relevant time series. The process is divided into two stages: first, static and dynamic factors are estimated and incorporated into a VAR model to project the annual variation of the consumer price index. The innovation of this study lies in applying automatic criteria to select the variables to be used in the factors, as well as the number of factors, lags, and restrictions to impose in the VAR. Eight inflation forecasts are generated and combined using three averaging methods: simple, based on the mean squared error, and Bayesian. The results indicate that the proposed methodology outperforms bivariate VAR models and other simple methods (ARMA (2,2), ARMA with automatic selection and traditional FAVAR models) in terms of accuracy, according to Diebold-Mariano and permutation tests. This suggests that the approach is effective in integrating information without requiring prior knowledge of its relevance.

Key words: Inflation, forecasting, factors, dynamic, FAVAR.

JEL Codes: C38, C55, E31, E37.

[†]Departamento de Investigación Económica. División Económica, BCCR. segurarc@bccr.fi.cr.

1. Introducción

En un régimen de metas de inflación, el Banco Central debe contar con pronósticos de inflación lo más certeros posible: en este régimen el Banco Central utiliza la tasa de interés de política monetaria como su principal instrumento, pero aumentos (disminuciones) en esta tasa solo se espera que generen reducciones (incrementos) en el valor de la inflación futura. Esto se debe a que se requiere un tiempo para que la política monetaria tenga efectos sobre la economía. Así, las decisiones de política por parte del Banco Central deben ser prospectivas y otorgar mayor preponderancia al valor esperado de la inflación que al nivel observado, por lo que un pronóstico preciso de la inflación permite tomar decisiones más certeras.

En este trabajo se desarrolla una metodología que permite brindar al Banco Central una herramienta, adicional a los ya disponibles, para obtener pronósticos de inflación de corto plazo. De manera concreta, el objetivo es utilizar una gran cantidad de variables con las que cuenta el Banco Central de Costa Rica (BCCR) y que desde un punto de vista teórico podrían aportar información para obtener un pronóstico de inflación más preciso.

Con este propósito, se recolectaron datos para 156 series de tiempo. Debido a la gran cantidad de variables, no es posible incluirlas a todas ellas en un único modelo estadístico y el econometrista enfrenta un problema de selección. En este estudio se utiliza la metodología de factores estáticos y dinámicos (véase Stock y Watson (2016)) con el fin de expresar el mayor porcentaje del contenido informativo de muchas variables en unos pocos factores o variables latentes. Luego, se implementa el modelo Vectorial Autorregresivo Aumentado por Factores (FAVAR, por sus siglas en inglés), desarrollado por Bernanke, Boivin y Elias (2005), que posibilita utilizar la información extraída en los factores para obtener un pronóstico de inflación. Se consideran dos especificaciones del modelo FAVAR: uno lineal y otro en el que se controla por tres niveles de inflación: alta, mediana y baja, lo que permite capturar por la presencia de no linealidades.

Adicionalmente, se implementan una serie de criterios de selección automática que se basan en la raíz del error cuadrático medio del pronóstico fuera de muestra para el horizonte de un mes. Para esto consideran los errores en el pronóstico que se observaron durante los 6 o 12 meses previos al periodo para el cuál se desea realizar la predicción. Estas reglas se utilizan para definir, en primer lugar, el conjunto de variables que se utiliza para estimar los factores,

y, en el modelo VAR, cuántos factores incorporar, cuántos rezagos incluir y cuáles parámetros se restringen a tomar un valor de cero. El fin de estos criterios es reducir el ruido que podrían incorporar variables o factores no relevantes. La forma en que se definieron dichos criterios posee dos ventajas. Por un lado, el que sean automáticas permite hacer un uso fácil de estos pronósticos en el futuro. Por otro lado, es posible conocer cada una de las decisiones del método, lo que facilita el análisis de dichos pronósticos en caso de que sea necesario.¹

Finalmente, debido a que se utilizan dos técnicas de estimación de los factores, dos especificaciones del modelo FAVAR y dos ventanas de periodos distintas en los criterios de selección, se obtienen ocho pronósticos de inflación diferentes. Para obtener un único pronóstico se utilizan tres promedios comúnmente utilizados en la literatura: simple, con base en el error cuadrático medio y bayesiano.

Finalmente, se compara la bondad de ajuste de pronóstico de estos promedios con el que se obtiene de modelos más simples comúnmente utilizados en la literatura, para lo que se utilizan las pruebas de Diebold-Mariano y una de permutaciones. El principal resultado del estudio es que el método que se propone supera a modelos VAR bivariado y otros métodos simples (ARMA (2,2) ARMA con selección automática y modelos FAVAR convencionales) en términos de la precisión de los pronósticos.

Esto contrasta con los resultados en la literatura, donde se ha observado que en muchos casos los modelos FAVAR no siempre proveen mejores pronósticos que modelos más simples. Por ejemplo, Faust y Wright (2013) concluye que los modelos FAVAR no son capaces de proveer un mejor pronóstico de la inflación que un modelo autorregresivo muy simple. Mandalinci (2017) estima pronósticos de inflación para diferentes economías emergentes, y en ninguno de los países u horizontes analizados, el modelo FAVAR se encuentra entre los que brinda un mejor pronóstico. La ventaja de la metodología propuesta en este estudio es que los criterios de selección permiten excluir el ruido que el uso de muchas variables podría introducir en la estimación de los factores.

En el caso de Latinoamérica existen estudios que han utilizado modelos FAVAR para generar pronósticos de inflación. Por ejemplo, Rodrigues y Guillén (2013) para el caso de Brasil,

¹En este sentido, es particularmente importante que es posible recuperar cuáles variables se utilizan para estimar los factores que se incluyen en el modelo FAVAR, y cómo se relacionan estos factores con cada una de estas variables. Esto posibilita obtener información sobre cuáles características de la coyuntura económica se espera tengan mayor incidencia sobre la inflación en un futuro cercano.

Winkelried (2003) para el caso de Perú y Caffaro y Pérez (2018) para el caso de República Dominicana. Sin embargo, los criterios de selección que se definen en este documento, para el conocimiento del autor, no han sido utilizados anteriormente.

En el caso de Costa Rica, los trabajos más cercanos son los de Durán-Viquez y Kikut-Valverde (2006) y Chavarría y Chaverri (2015). En ambos utilizan una cantidad importante de variables y estiman factores estáticos. En el primero, los factores estáticos se incluyen en una regresión lineal que explica la inflación. En el segundo, se utilizan técnicas bayesianas que permiten promediar entre múltiples modelos lineales que se diferencian por las variables que incluyen.

Adicionalmente, el Banco Central ha utilizado una variada de métodos para obtener pronósticos de inflación. En primer lugar, hay abundantes aplicaciones de métodos univariados para pronosticar la inflación (Hoffmaister, Solano, Solera y Vindas (1999); Muñoz-Salas (2008); Vindas-Quesada (2011)). En segundo lugar, se han aplicado modelos que consideran una variable específica que podría explicar la inflación (Segura-Rodríguez y Vásquez-Carvajal (2011) para el caso del petróleo, Hoffmaister, Saborío y Vindas (2000) para el caso de los bienes agrícolas y Vásquez-Carvajal y Vindas-Quesada (2011) para los mecanismos de transmisión de política).

En tercer lugar, Álvarez y Torres (2011) estimaron curvas tipo Phillips para los sectores transable y no transable, y mostraron que la combinación de los pronósticos de inflación de estas curvas es más preciso que el que se obtiene de una curva de Phillips agregada. Finalmente, en los últimos años se ha analizado el uso de técnicas de aprendizaje automático para el pronóstico de la inflación: Solera-Ramírez (2005) y Esquivel-Monge (2009) aplicaron la técnica de redes neuronales artificiales para pronosticar inflación y Rodríguez-Vargas (2020) consideró modelos de *K-Nearest Neighbours*, bosques aleatorios, *extreme gradient boosting* y *long short-term memory*, y muestra que estos modelos son capaces de generar mejores pronósticos de inflación que modelos autorregresivos.²

El resto del documento se estructura de la siguiente manera. La sección 2 describe los datos que se utilizan y las transformaciones que se le aplica a cada una de las variables para garantizar que sean estacionarias. La sección 3 presenta en detalle la metodología que se

²Previo a este estudio, el Banco Central utilizaba de manera activa los modelos univariados, el modelo de combinación bayesiana y las técnicas de aprendizaje automático para obtener pronósticos de inflación, en especial para horizontes de 1 a 6 meses.

utiliza para obtener pronósticos. En ella se discute las metodologías de factores estáticos y dinámicos, los modelos FAVAR, los criterios de selección y las metodologías para obtener promedios de pronósticos. La sección 4 presenta los resultados de aplicar la metodología descrita y la sección 5 resume las principales conclusiones del estudio.

2. Datos

La metodología de factores, que se describirá en la siguiente sección, se implementa para resumir la información de una gran cantidad de variables que pueden ser utilizadas para realizar pronósticos de inflación. Todas las variables que se usan en este estudio tienen una frecuencia mensual y el periodo de análisis corresponde a los meses entre setiembre de 2009 y diciembre de 2023. El rango de tiempo que se emplea está determinado tanto por que algunas variables están disponibles solo a partir de mediados de la década de los 2000, como por que a partir del año 2009 se presentó una reducción importante en los niveles de inflación de Costa Rica, por lo que se decidió incorporar información solo para el periodo posterior a dicho cambio estructural (para pruebas de identificación de este cambio estructural, véase Torres-Gutiérrez (2012)).

El cuadro 3 en el Anexo A presenta el detalle de las variables que se utilizaron en este estudio como posibles pronosticadores de la inflación. En el cuadro, las variables se agruparon en nueve grandes grupos: monetarias, demanda agregada, tasas de interés, costos de producción, expectativas, tipo de cambio, precios de materias primas, inflación internacional e indicadores (diferentes del IPC) de precios internos.

Los primeros cinco grupos están conformados por variables que normalmente se relacionan con el pronóstico de inflación. Por su parte, las variables en el último grupo capturarían la persistencia de la inflación y el efecto coyuntural que un grupo particular de bienes podría tener en la evolución de precios en la economía. Finalmente, el tipo de cambio (y sus expectativas), los precios de materias primas, y la inflación internacional permiten incorporar el hecho de que al ser Costa Rica es una economía abierta, pequeña y parcialmente dolarizada, los precios de bienes importados y el tipo de cambio pueden afectar directamente el nivel de inflación local.

Todas las variables se desestacionalizan y a cada variable se le aplica la transformación apro-

piada (diferencias simples y de logaritmos tanto mensuales como anuales o eliminación de tendencia)³ para asegurarse que las series de tiempo que se utilizan para realizar pronósticos sean estacionarias. Para este fin se utilizaron las pruebas de Dickey-Fuller aumentada y Phillips-Perron.

Cuando la transformación apropiada es la diferencia simple o de logaritmos, y tanto las variaciones mensuales como anuales resultan en una serie de tiempo estacionaria, se incluyen ambas variables como posibles pronosticadores de la inflación. Intuitivamente, la diferencia en la frecuencia generaría que la variación mensual capture mejor el comportamiento de muy corto plazo mientras que la variación anual refleja variaciones más permanentes.

Así, después de aplicar las transformaciones señaladas se cuenta con una base de datos con 156 series de tiempo que se pueden utilizar para pronosticar la inflación.

3. Metodología

Esta sección presenta en detalle la metodología que se utiliza para obtener los pronósticos de inflación.

3.1. Justificación

La lista de variables que podrían ser utilizadas para pronosticar la inflación es muy extensa. Por un lado, la teoría macroeconómica señala los agregados monetarios, la demanda agregada, las tasas de interés y los costos de las empresas como determinantes del comportamiento de la inflación. Por otro lado, en una economía abierta, como la costarricense, los movimientos en el tipo de cambio, en los precios internacionales de las materias primas (como el precio del petróleo) y en los niveles de inflación internacionales influyen en los costos de las empresas locales y los precios en moneda local de los bienes importados. Además, debido a su persistencia, se podría utilizar los movimientos previos en el IPC o algunos componentes del IPC para pronosticar variaciones futuras en la inflación.


Por tanto, es posible justificar el considerar un gran número de variables para realizar un pronóstico de la inflación. Sin embargo, la pérdida de grados de libertad impide incorporar todas ellas en un único modelo estadístico. Ante esto, una posibilidad es seleccionar unas

³Para simplificar la exposición, la lista de transformaciones que se le aplica a cada una de las series no se especifica en el documento, pero puede ser consultada al autor.

pocas variables para realizar el pronóstico de la inflación, pero existe el riesgo de que alguna de las variables excluidas sea muy importante para pronosticar la inflación en una coyuntura puntual.

En el gráfico 1, se presentan algunas estadísticas de la raíz del error cuadrático medio (RECM) de los pronósticos con horizontes a un mes y tres meses que se hubieran obtenido para los años 2021, 2022 y 2023 si se hubiera utilizado un modelo de vectores autorregresivos (VAR) bivariado que incluye la inflación intermensual del IPC y de manera individual cada una de las variables que se utilizan en este estudio. El punto relleno representa el valor mínimo de la RECM entre todas las variables, la circunferencia representan el valor máximo y la estrella la mediana de estos valores.

Gráfico 1. Raíz del error cuadrático medio para pronósticos de VAR bivariados. 2021-2023



Fuente: Estimación propia.

Nota: Para 2021 se utiliza a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses.

Del gráfico se puede concluir que existe una gran diversidad en la precisión de las predicciones entre los diferentes modelos. Así, si se elige *a priori* alguna(s) de ella(s) podría terminar incluyendo una de las variables que genera peores pronósticos. Además, aún si se selecciona con base en la precisión de los pronósticos en el pasado reciente, eso no necesariamente garantiza tener buenos pronósticos en el futuro.⁴

Por ejemplo, si se hubiera elegido con base en los pronósticos a un horizonte de un mes, en el 2021 se habría utilizado la variación mensual del índice de reponderación por persistencia, en el 2022 se habría seleccionado la variación anual del precio de bienes agrícolas y en el

⁴En el cuadro 4, en el anexo B, se presentan otros estadísticos que permiten evaluar la precisión del pronóstico. En todos los casos, se concluye que existe una diversidad en la calidad del pronóstico similar a la que se presenta en el gráfico.

2023 se habría elegido la variación mensual del crédito para actividades empresariales. Este cambio en cuál es el mejor VAR bivariado para generar pronósticos podría provocar reducciones en la calidad del pronóstico: si se utiliza la variación mensual del índice de reponderación por persistencia, la variable más precisa en el 2021 de acuerdo con la RECM, en el 2022 se hubiera obtenido una RECM un 23,8% mayor a la menor posible y en 2023 una RECM un 24,3% mayor a la menor posible.

En la siguiente subsección, se presenta la metodología de factores que se utiliza como una alternativa que permite resolver esta disyuntiva y evitar el problema de selección, y, con base en Stock y Watson (2016), se discuten los dos métodos que se utilizan en este artículo para estimar los factores. Posteriormente, se describen las diferentes especificaciones del modelo de vectores autorregresivos aumentado por factores (FAVAR) que se emplean para realizar pronósticos de inflación. Luego, se discuten los criterios de selección automática que permiten establecer qué variables se utilizan para estimar los factores, cuáles de ellos se incluyen en el modelo FAVAR, cuántos rezagos se consideran y cuáles parámetros se restringen en dicho modelo. Finalmente, se presentan tres métodos que permiten agregar los pronósticos que se obtienen con cada una de las especificaciones.

3.2. Estimación de factores

En este trabajo se emplea la técnica de factores no observados (o latentes) para resumir el contenido informativo de las variables disponibles en solo unos pocos factores. De acuerdo con Stock y Watson (2016), la idea de esta técnica es que los movimientos de una gran cantidad de variables económicas provienen del comportamiento de un número pequeño de factores no observables. Algunos ejemplos de variables latentes que se mencionan comúnmente en la literatura son la actividad económica y las presiones inflacionarias. Estas variables no son observables directamente, pero las agencias de estadísticas proveen una serie de indicadores que en conjunto permiten aproximar su comportamiento. Por ejemplo, existen indicadores relacionados como la movilidad, el consumo de energía eléctrica, el volumen de transacciones o los índices de producción industrial que proveen señales sobre el nivel de actividad económica subyacente.

Así, la estimación de factores permite resolver la disyuntiva de cuáles variables utilizar para realizar pronósticos, ya que una vez que se ha estimado el factor, se puede prescindir del

comportamiento de cada una de las variables de forma individual y solo utilizar el comportamiento del factor para realizar pronósticos. Esto soluciona el problema de selección y tiene la ventaja de que el factor no observable “resume” las fuerzas económicas subyacentes.

3.2.1. Factores estáticos

Una primera aproximación, es suponer que existe un vector de r factores, F_t , que se asocian linealmente con el comportamiento de un conjunto de variables X de dimensión $N \times T$. En este caso, dicho vínculo se puede expresar como:

$$X_t = \Lambda F_t + e_t, \quad (1)$$

donde Λ es una matriz de parámetros de dimensiones $N \times r$ y e_t es un vector de errores de dimensión $N \times 1$.

A este modelo se le conoce como de **factores estáticos**. Note primero que la ecuación no está debidamente identificada. Esto se debe a que tanto Λ como F_t son valores desconocidos, y el multiplicar Λ por una constante y F_t por el inverso multiplicativo de dicha constante no afecta la ecuación. Por esta razón, es necesario normalizar dichos valores y lo más común es suponer que las columnas de la matriz de parámetros Λ son ortonormales y que la matriz de covarianza de F_t es diagonal.

Bajo estos supuestos, el análisis de Componentes Principales permite estimar los factores estáticos. En este caso, se eligen los valores de Λ y F_t que minimizan los errores cuadráticos en la ecuación 1, con la normalización que se describió anteriormente. Si denotamos por $\hat{\Sigma}_X$ la varianza muestral de las variables observadas, X_t , que corresponde a $\hat{\Sigma}_X = T^{-1} \sum_{t=1}^T X_t X_t'$, es posible mostrar que el valor estimado de la matriz de parámetros, $\hat{\Lambda}$, corresponde a la matriz compuesta por los r vectores propios de $\hat{\Sigma}_X$ asociados a los r mayores valores propios, y que el vector de factores estimado corresponde a $\hat{F}_t = N^{-1} \hat{\Lambda}' X_t$. Bajo supuestos estándar sobre los errores, y si se supone que F_t es un vector de parámetros, el análisis de Componentes Principales provee el mejor estimador lineal insesgado de la ecuación 1.

3.2.2. Factores dinámicos

La deficiencia que puede presentar la especificación con factores estáticos es que no incorpora el hecho de que las fuerzas subyacentes en la economía, al igual que la mayoría de

series de tiempo, pueden ser persistentes. Esto ha llevado a que en la literatura se desarrolle el modelo de factores **dinámicos**. En este se supone que las variables observadas se pueden representar por q factores dinámicos, f_t , y estos factores evolucionan de acuerdo con un modelo VAR. El modelo de factores **dinámicos** corresponde a

$$X_t = \lambda(L)f_t + \epsilon_t \quad (2)$$

$$f_t = \alpha(L)f_{t-1} + \eta_t \quad (3)$$

donde las matrices polinomiales de rezagos $\lambda(L)$ y $\alpha(L)$ son de dimensiones $N \times q$ y $q \times q$, respectivamente. Además, η_t es un vector de dimensión $q \times 1$ de errores en la evolución de los factores. Se supone que este vector no se correlaciona de manera contemporánea, con rezagos o con adelantos del vector de choques no explicados en las variables observadas, ϵ_t .

Si este es el verdadero modelo, la omisión de la estimación dinámica de los parámetros generaría un sesgo por omisión de variables, por lo que al estimar el modelo de factores dinámicos es posible resumir de mejor manera las variables que se desean utilizar para pronosticar la inflación.⁵

El contrapunto es que la estimación de factores dinámicos es considerablemente más difícil que la de los estáticos. En esta investigación se utiliza el método de estimación de Doz, Giannone y Reichlin (2011) que se implementa en R con el uso del paquete DFMs (véase Krantz (Krantz)).⁶

Doz et al. (2011) proponen utilizar una estimación de dos etapas que combina el uso del análisis de Componentes Principales que se explicó anteriormente y la aplicación directa del filtro de Kalman en el modelo de estado-espacio que definen las ecuaciones 2 y 3. En una primera etapa se obtiene una estimación preliminar de λ y f_t al utilizar el método de componentes principales y los coeficientes α se obtienen de un modelo VAR de la estimación preliminar de f_t . Estos valores se utilizan en la segunda etapa como valores iniciales para maximizar la función de verosimilitud asociada al filtro de Kalman que permite estimar todos los parámetros

⁵Stock y Watson (2016) muestran que es posible reescribir el modelo dinámico como uno estático con más factores. Sin embargo, en el modelo estático se requeriría estimar más factores y a la hora de realizar la estimación del modelo FAVAR podría ser que los rezagos de un factor no sea uno de los factores estáticos con un mayor aporte a la explicación de la varianza de los datos, por lo que no se consideraría en dicho modelo.

⁶Se supone que el número de rezagos del modelo VAR es 1, que la matriz de covarianza de ϵ_t es diagonal, que no existe correlación entre los valores contemporáneos de las variables observadas y ningún rezago de los factores, y que no existe correlación serial para ninguno de los términos de error y para ningún rezago.

en el modelo de estado-espacio en las ecuaciones 2 y 3.

3.3. Modelos FAVAR

Para pronosticar la inflación se utiliza el modelo de vectores autorregresivos aumentado por factores (FAVAR) propuesto por Bernanke et al. (2005). En este se supone que la dinámica conjunta de la inflación y los factores no observables está dada por

$$\begin{bmatrix} \pi_t \\ F_t \end{bmatrix} = \Phi(L) \begin{bmatrix} \pi_{t-1} \\ F_{t-1} \end{bmatrix} + v_t, \quad (4)$$

donde $\Phi(L)$ es un polinomio de rezagos de orden d y $\mathbb{E}[v_t] = 0$. Este sistema se basa en la idea de que el comportamiento de la inflación solo depende en la inflación pasada y el comportamiento de unos pocos factores no observables que resumen toda la información disponible. La estimación de este modelo permite obtener pronósticos del comportamiento futuro de la inflación.

En este estudio, π_t corresponde a la variación mensual del IPC. Así, los pronósticos corresponden a la inflación mensual esperada, y para obtener el indicador usual, que es la variación interanual del IPC, se anualizan los pronósticos: si se quiere obtener el pronóstico de la inflación interanual a $n \leq 12$ meses, se debe considerar la variación mensual π_{t+1-j} para $j = 1, 2, \dots, 12 - n$ (si $12 - n > 0$) y los pronósticos de variación mensual π_{t+i}^f para $i = 1, 2, \dots, n$. El pronóstico de la inflación interanual π_{t+n}^{fa} es igual a $\pi_{t+n}^{fa} = \prod_{j=1}^{12-n} (1 + \pi_{t+1-j}) \prod_{i=1}^n (1 + \pi_{t+i}^f) - 1$.

Esta representación del pronóstico de la inflación interanual hace explícita la ventaja de utilizar un modelo FAVAR con variaciones mensuales: si se desea realizar un pronóstico a $n < 12$ meses hacia adelante, este procedimiento utiliza como información ya observada la inflación mensual de los últimos $12 - n$ meses. En su lugar, si en el modelo FAVAR se utilizara la variación interanual el modelo no incorpora que parte de la inflación en n meses es el resultado de esas variaciones mensuales que ya se observaron.⁷

⁷Se realizaron pruebas de Diebold-Mariano para comparar la capacidad de pronóstico de modelos VAR que incluyen una serie de tiempo y la variación, mensual o anual, del IPC. El p-value de la prueba de Diebold-Mariano es menor a 5% para todos los VAR con la inflación mensual cuando se considera la hipótesis de que estos modelos proveen un mejor pronóstico a un mes plazo que la variable anual que generó una menor RECM. Esta ventaja se reduce cuando se consideran horizontes de pronóstico más largos. Aún así, al comparar los modelos VAR que son más precisos de acuerdo con el RECM, a horizontes de 3 y 6 meses, la prueba de Diebold-Mariano es significativa al 5% para los tres meses y 10% para los seis meses, cuando la hipótesis alternativa es que el modelo que incluye la variación mensual es mejor que el que contiene la

Para estimar este modelo FAVAR se utiliza la estimación de dos etapas propuesta por Bernanke et al. (2005), en la que primero se utiliza la información observada, X_t , para obtener un valor estimado de los factores \hat{F}_t , y una vez que se tiene esta estimación se estima un modelo VAR condicional para el vector (π_t, \hat{F}_t) . Para obtener \hat{F}_t se utiliza uno de los dos procedimientos que se describieron en los apartados previos.

Finalmente, uno podría estar interesado en incluir la presencia de no linealidades para el pronóstico de la inflación. Con este fin se supone que existen tres estados de inflación: baja, media y alta. Para esto, en la estimación del modelo VAR, se incluyen dos variables dicotómicas que se definen a partir de los percentiles de inflación y que capturan comportamientos diferenciados de la inflación de acuerdo con los niveles que se han observado en periodos recientes.⁸ El valor exacto de los percentiles que define cada uno de los niveles de inflación, se eligen como aquellos que generan una menor RECM del pronóstico a un horizonte de un mes durante los meses previos (6 o 12 meses).

En total se consideran 4 especificaciones del modelo FAVAR:

- FAVAR con factores estáticos.
- FAVAR con factores dinámicos.
- FAVAR con factores estáticos y tres estados de inflación.
- FAVAR con factores dinámicos y tres estados de inflación.

3.4. Selección de variables y modelos

Antes de aplicar la metodología, es necesario establecer cuales variables se utilizan para el cálculo de los factores, cómo se definen los factores que se incluyen en la estimación del modelo FAVAR y cómo se define las propiedades del modelo FAVAR que se emplean.

Por un lado, el contar con una gran cantidad de variables entre las que podemos elegir para pronosticar la inflación genera la oportunidad de realizar estimaciones que capturen diferentes aspectos de la economía. Sin embargo, estas variables se eligieron con base en las que la

variación anual. Cuando se utiliza la prueba en la otra dirección en ningún caso la prueba es significativa a un valor estándar de significancia.

⁸Una posibilidad alternativa es utilizar factores cuadráticos en la cual se estiman los factores a partir de la matriz de datos (X_t, X_t^2) , lo que permite capturar los cambios en volatilidad de las variables observadas. Sin embargo, el análisis de los resultados mostró que con esta estimación se obtienen errores de pronóstico más altos, por lo que los resultados no se incluyen en este artículo.

teoría económica sugiere como relevantes y la información disponible, y no a partir de la relación empírica que tienen con la inflación.

El problema radica en que los factores solo resumen la información disponible sin discernir si cada variable es relevante para el pronóstico de la inflación o no. Así, la inclusión de variables que tienen poca relación con el proceso inflacionario podría provocar que los factores que se estiman no generen buenos pronósticos. Por esa razón, se decide reducir el conjunto de variables que se incluyen en la estimación de los factores.

Así, se eligen el 20% de las variables que, en el pasado reciente, han realizado un mejor pronóstico individual a un horizonte de un mes. Para esto, para cada variable, se estima un modelo de vectores autorregresivos (VAR) que incluye la variación mensual del índice de precios al consumidor (IPC) y dicha variable. Se eligen las variables que generan una menor raíz del error cuadrático medio (RECM) para el pronóstico fuera de muestra a un horizonte de un mes de la variación interanual del IPC de los últimos 6 (o 12) meses. Así, con base en el número de periodos que se incluye para seleccionar las variables, se alcanzan dos conjuntos de información distintos (con 31 variables cada uno) a partir de los cuáles se procede a estimar los factores (estáticos o dinámicos).

Por otro lado, a partir de un conjunto de 31 variables es posible obtener hasta 31 factores. Lo usual en la literatura es predefinir un número de factores o elegir los que expliquen una mayor proporción de la varianza. Sin embargo, cuando se desea pronosticar la inflación no necesariamente los factores que representan una mayor proporción de la varianza de los datos son los más importantes para generar mejores pronósticos. Así, limitarse a un número pequeño de factores podría dejar información relevante fuera del pronóstico. Sin embargo, al mismo tiempo, por criterios de parsimonia, es mejor un número de factores pequeño.

Para tratar de equilibrar entre representatividad y parsimonia, se elige el número de factores de una forma análoga a cómo se eligieron las variables. En el caso de factores estáticos, se utilizan hasta 7 factores que explican una mayor parte la varianza de los datos, y se ordenan de acuerdo a su aporte. Se estiman siete modelos VAR diferentes. En todos ellos se incluye la variación mensual del IPC, pero de manera secuencial se incorpora un factor extra en el modelo (es decir, el primer modelo incluye el primer factor, el segundo los dos primeros factores, y así sucesivamente). Para cada modelo se calcula el RECM del pronóstico fuera de muestra de la variación interanual del IPC al horizonte de un mes para los últimos 6 (o

12) meses. Se elige el número de factores que genera un menor RECM. Para los factores dinámicos se emplea el mismo procedimiento, pero el número máximo de factores que se considera es 5.⁹

Por tanto, el modelo FAVAR podría incluir hasta siete factores, por lo que se debe estimar un modelo VAR relativamente grande y podrían haber factores que se relacionen poco con el comportamiento de la inflación. Por tanto, por criterios de parsimonia y para evitar el problema de sobre especificación dentro de muestra, se utiliza un modelo VAR que se restringe de acuerdo con los valores del estadístico t de cada uno de los coeficientes del VAR y el número de rezagos se elige con el criterio de Akaike.

Para esto se predefine una malla de valores de búsqueda del estadístico t. Para cada valor, se estima un modelo VAR en el que todos los parámetros con estadístico t menor al preestablecido se restringen a tomar el valor de cero. Para cada modelo, se calcula el RECM del pronóstico fuera de muestra de la inflación interanual para el horizonte de un mes durante los últimos 6 (o 12) meses, y se elige el límite del estadístico que genera un menor RECM. Un punto importante es que, dada la restricción, puede ser que algún factor no aparezca directamente en la ecuación de la inflación, pero siempre existe la posibilidad que influya indirectamente en el pronóstico de la inflación a través del peso que tiene en el movimiento de los otros factores.

Así, se obtienen 8 pronósticos diferentes: 4 especificaciones del modelo FAVAR y para cada una de ellas dos horizontes que se utilizan en los criterios de selección (6 y 12 meses).¹⁰

3.5. Combinación de modelos

Para concluir con la metodología, es necesario definir cómo se combinan los ocho pronósticos de inflación que se obtienen con cada una de las especificaciones que se describieron en la sección anterior. En este apartado se presentan los tres métodos de combinación de pronósticos que se emplean en ese estudio, los cuales son ampliamente utilizados en la literatura.

En primer lugar, se utiliza un promedio simple, en el que cada pronóstico recibe el mismo

⁹Se intentó con 7 factores dinámicos, pero los pronósticos resultaron menos precisos. No es extraño utilizar menos factores dinámicos que estáticos, ya que de acuerdo con Stock y Watson (2016) siempre existe un modelo de factores estáticos que es equivalente al dinámico, pero en el que en el estático el número de factores es mayor.

¹⁰También se consideró realizar la selección con base en la precisión del pronóstico durante los 24 meses previos. Sin embargo, el análisis de los resultados mostró que en general esas especificaciones generaban un mayor error de pronóstico, por lo que se decidió no presentar los resultados.

ponderador. Esta combinación es sencilla y podría generar buenos resultados si algunos pronósticos tienden a tener un sesgo positivo y otros un sesgo negativo.

En segundo lugar, se utiliza un promedio ponderado con base en el error cuadrático medio. Para este cálculo, con el fin de eliminar pronósticos de mala calidad, se eliminan las especificaciones que han presentado un error cuadrático medio (para los últimos doce meses) superior al percentil 80. Denote por \mathcal{E}_t el conjunto de pronósticos que se selecciona para el mes t . A cada pronóstico $f_{kt} \in \mathcal{E}_t$ se le asigna un peso ω_{kt} que corresponde a

$$\omega_{kt} = \frac{\frac{1}{ECM_{kt}}}{\sum_{it \in \mathcal{E}_t} \frac{1}{ECM_{it}}}, \quad (5)$$

donde ECM_{it} corresponde al error cuadrático medio de la especificación i durante los doce meses previos al mes t .

Finalmente, se utiliza un promedio bayesiano de pronósticos con base en la metodología propuesta por Raftery, Gneiting, Balabdaoui y Polakowski (2005). Se supone que en cada período t existe un modelo que es el correcto, pero el investigador no conoce cuál es, y lo único que conoce es que dado un pronóstico f_{kt} el valor observado de inflación se distribuye normalmente con promedio f_{kt} y varianza σ_t^2 , esto es,

$$\pi_t | f_{kt} \sim N(f_{kt}, \sigma_t^2). \quad (6)$$

Dada esta especificación, el promedio bayesiano de pronósticos para el periodo t (que es el valor esperado de la inflación) corresponde a una combinación lineal de los pronósticos, donde a cada pronóstico f_{kt} se le asigna un ponderador ω_{kt} :

$$\mathbb{E}[\pi_t | f_{1t}, f_{2t}, \dots, f_{8t}] = \sum_{k=1}^8 \omega_{kt} f_{kt}. \quad (7)$$

Para estimar los ponderadores ω_{kt} se utiliza la información de los doce periodos previos, es decir, se supone que el ponderador para el periodo t es igual al que es óptimo para los doce meses previos. Así, el logaritmo de la función de verosimilitud de los parámetros está dada por

$$\ell(\omega_{1t}, \omega_{2t}, \dots, \omega_{8t}, \sigma^2) = \sum_{s=t-12}^{t-1} \sum_{k=1}^8 \omega_{ks} g(\pi_s | f_{ks}), \quad (8)$$

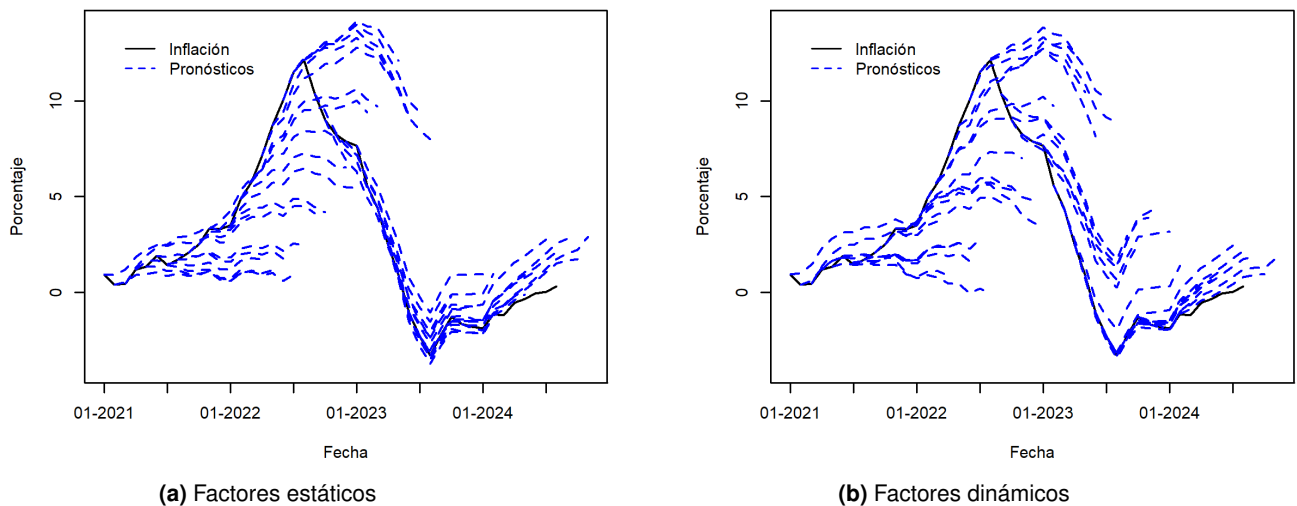
donde $g(\pi_s | f_{ks})$ corresponde a la densidad de una distribución normal con media f_{ks} y va-

rianza σ_s^2 . Dada la función de verosimilitud, se requiere maximizar dicha función para obtener los ponderadores ω_{kt} y la varianza σ_f^2 . Sin embargo, la maximización numérica directa de esta función de verosimilitud es compleja, por lo que, siguiendo a Raftery et al. (2005), se utiliza el algoritmo *Expected-Maximization* (EM, por sus siglas en inglés). Para detalles sobre cómo se implementa este algoritmo para maximizar dicha función de verosimilitud, véase Raftery et al. (2005).¹¹

4. Resultados

En esta sección se describen los pronósticos que se obtienen para cada una de las ocho especificaciones que se estiman. Luego, se presentan los resultados de las tres combinaciones de pronósticos que se utilizan en este documento. Por último, se realizan dos pruebas estadísticas para comparar la bondad de ajuste de los promedios con respecto a algunos modelos de referencia.

Gráfico 2. Pronósticos 12 meses hacia adelante. 2022-2024



Fuente: Elaboración propia.

En primer lugar, en el gráfico 2 se presentan los pronósticos hasta un horizonte de 12 meses que se hubieran obtenido tanto con el modelo de factores fijos como con el de factores dinámicos cuando se utilizan los criterios de selección con base en los 12 meses más recientes. Los pronósticos se presentan para el periodo entre enero de 2021 y diciembre de 2023. En general, en los dos gráficos se muestra una pintura similar de los valores esperados de la

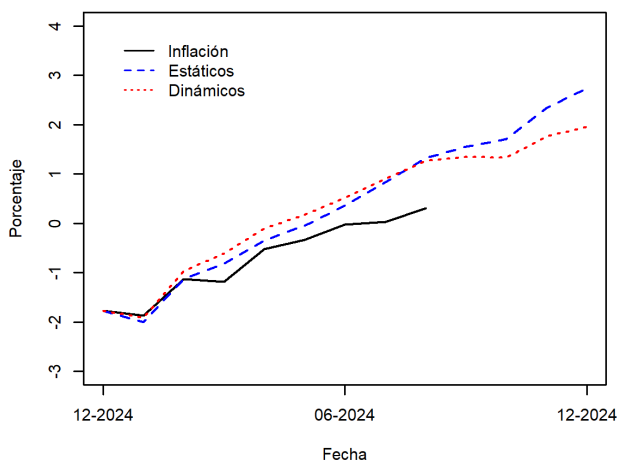
¹¹ Como se utilizan pocas observaciones, se impone un límite inferior de 0,025 en el peso que se asigna a cada pronóstico para evitar que información importante sea eliminada completamente del promedio bayesiano.

inflación futura: conforme al movimiento de la inflación observada, al inicio de la muestra, los pronósticos se incrementan y luego tienden a disminuir, y en los últimos meses coinciden en que se espera que la inflación aumente en el futuro cercano.

Sin embargo, en algunos momentos específicos se observan comportamientos distintos. Por ejemplo, entre noviembre de 2021 y enero de 2022, los pronósticos con factores dinámicos fueron prácticamente idénticos, mientras que con factores estáticos los pronósticos variaron entre los meses. Estas diferencias son las que hacen necesario considerar promedios de estos pronósticos, ya que el econometrista no necesariamente tiene información para afirmar en ese momento que un pronóstico es mejor que otro.

Otra característica común de ambos gráficos es que se observa que a finales de 2021 e inicios de 2022 ambos modelos predecían de manera repetida niveles de inflación por debajo de los que efectivamente se observaron y después de mediados de 2022 los modelos realizaron pronósticos que de manera reiterativa sobrestimaron la inflación que se presentó en los meses posteriores. Así, desde un punto de vista práctico, puede ser relevante que los pronósticos se ajusten de acuerdo con el *criterio de experto* para incorporar el efecto de este sesgo en los pronósticos.

Gráfico 3. Pronósticos en diciembre de 2023



Fuente: Elaboración propia.

Para explicar con mayor detalle la estimación con factores y la diferencia entre la metodología estática y la dinámica, en los siguientes párrafos se discute con mayor detalle la construcción de los pronósticos que se hubieran obtenido en diciembre de 2023. En el gráfico 3 se muestran dichos pronósticos. Es claro que los dos métodos generaron proyecciones para los primeros

ocho meses del año muy similares, pero a partir del noveno mes, la proyección del modelo estático es mayor que la del modelo dinámico. Además, el pronóstico de ambos modelos para enero y febrero de 2024 fue muy acertado. A partir de marzo de 2024 ambas proyecciones fueron ligeramente superiores a la inflación observada.

Esta diferencia en los niveles de la proyección de inflación se presenta aun cuando en ambos modelos se consideran el mismo conjunto de variables para estimar los factores. En diciembre de 2023, estas variables se asocian con

- tipo de cambio: variación mensual y anual del tipo de cambio de MONEX y del ITCER,
- precios de materias primas: variación mensual y anual del precio del petróleo *WTI*, de algunos componentes del índice de precios internacionales de materias primas importadas (anual del total, metales, combustibles, sin granos y sin combustibles; y mensual de combustibles), y de los índices de precios de materias primas de Bloomberg (mensual y anual de precios de contado de petróleo y energía y mensual del índice general de precios de contado y futuros).
- crédito: variación mensual y anual del crédito al sector privado total y para actividades empresariales,
- inflación internacional: variación mensual y anual de la inflación de los socios comerciales y de Estados Unidos,
- costos: variación mensual del índice de precios al productor de la manufactura,
- indicadores de variación de precios: variación mensual del componente de otros bienes no regulados y variación anual del precio de los bienes agrícolas y bienes y servicios diversos,
- tasa de interés: variación anual de la TPM.

En la estimación con factores estáticos se incluyen un total de seis factores que representan el 79,59 % de la varianza. Se utiliza un modelo VAR de orden dos en el que se restringe que el primer rezago del cuarto factor y los segundos rezagos de los factores 3, 5 y 6 no tienen influencia en la inflación. Los factores se asocian principalmente a las siguientes variables:

- Primer factor: variación anual del índice de precios de las materias primas importadas, del precio del petróleo *WTI* y de los índices de precios de materias primas de Bloom-

berg.

- Segundo factor: variación mensual del índice de precios de las materias primas importadas, del precio del petróleo *WTI* y de los índices de precios de materias primas de Bloomberg.
- Tercer factor: variación mensual y anual del crédito, variación mensual del tipo de cambio nominal y del ITCER.
- Cuarto factor: precios de los bienes agrícolas y bienes y servicios diversos, TPM, variación anual del crédito y del precio de los metales importados.
- Quinto factor: variación mensual del crédito y de la inflación de socios comerciales y de Estados Unidos, y variación anual del tipo de cambio nominal y real.
- Sexto factor: variación mensual del *WTI*, del precio de los combustibles e índices de materias primas de Bloomberg, y de la inflación de socios comerciales, y variación anual del tipo de cambio nominal y real.

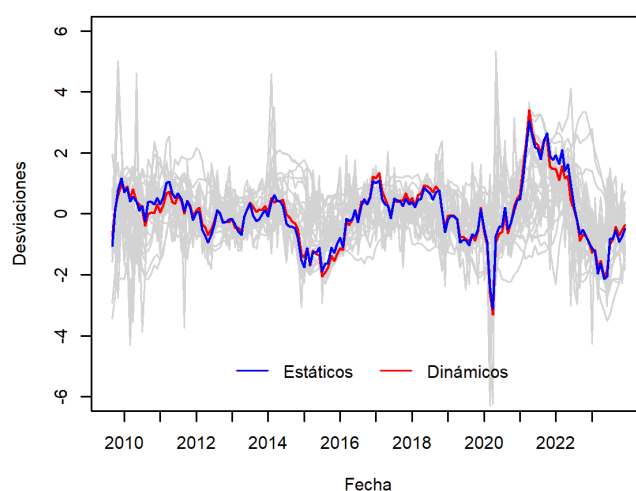
Así, los pronósticos a partir del modelo estático responden a variables que han sido señaladas como preponderantes para explicar el comportamiento de la inflación durante los últimos meses. Por un lado, la reducción de los precios de las materias primas y la apreciación de la moneda han generado una disminución del precio, expresado en colones, de las materias primas importadas. En consecuencia, los costos de producción se han reducido. Además, la política monetaria restrictiva que se basa en una mayor tasa de interés de política monetaria ha conllevado una reducción en la tasa de crecimiento del crédito en colones, con lo que se contrae la demanda agregada. Finalmente, la reducción del precio de los bienes agrícolas tuvo el mayor aporte en la reducción de la inflación durante los últimos meses de 2023 e inicios del 2024.

En su lugar, el modelo con factores dinámicos considera solo tres factores y se utiliza un modelo VAR con dos rezagos. En este modelo VAR se restringe que solo el primer rezago de los factores 1 y 3 tienen influencia directa en la inflación. Los factores dinámicos están relacionados con las mismas variables que los tres primeros factores estáticos.

En el gráfico 4 se presenta, en gris, el valor estandarizado de las variables que se utilizan en la estimación de los factores para diciembre de 2023, en azul la estimación del primer

factor con el modelo estático y en rojo la estimación del primer factor que se obtiene con el modelo dinámico. El valor de ambos factores se estandariza para facilitar la interpretación. Las dos estimaciones son muy similares, aunque el resultado de la estimación del modelo dinámico estima un factor con un comportamiento más suavizado, debido a que incorpora directamente en la estimación el hecho de que el factor presenta autocorrelación.¹² Además, los factores se comueven con los movimientos de las variables observadas, pero la variación es más acotada, con lo que se disminuye el riesgo de introducir ruido en los pronósticos de inflación.

Gráfico 4. Estimación factores. 2010-2023



Fuente: Elaboración propia

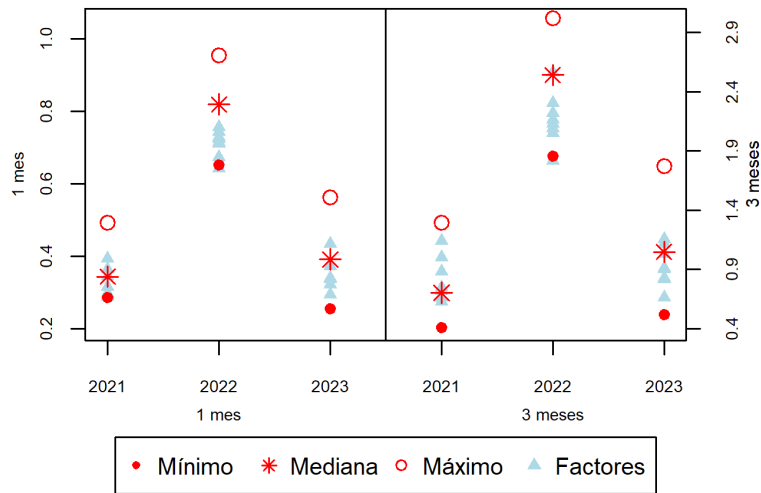
Nota: En gris se presenta cada una de las variables utilizadas. Todas en términos estandarizados con media cero y varianza uno.

En el gráfico 5 se presentan las raíces de los errores cuadráticos medios de los pronósticos que se obtienen con la estimación de los factores y se les compara con los que se hubieran obtenido si se utiliza cada variable individual para realizar pronósticos. En general, la estimación a partir de factores es capaz de generar pronósticos que en su mayoría son más precisos que la mediana de los pronósticos individuales y en algunos pocos casos son más precisos que el mejor pronóstico con una variable individual.

En el Anexo C se presentan la raíz del error cuadrático medio y el error absoluto medio para cada uno de los ocho modelos con factores. Hay dos elementos importantes que resaltar: los factores estáticos tienden a generar un pronóstico más preciso cuando se evalúa la RECM, pero esa diferencia no se presenta cuando se utiliza el EAM para comparar pronósticos. Por

¹²De hecho los coeficientes de autocorrelación estimados para el primer factor dinámico son ligeramente más altos que para el primer factor estático: 90,6 y 89,6 para el primer rezago y 81,2 y 79,4 para el segundo rezago, respectivamente.

Gráfico 5. RECM para pronósticos a uno y tres meses. 2021-2023.

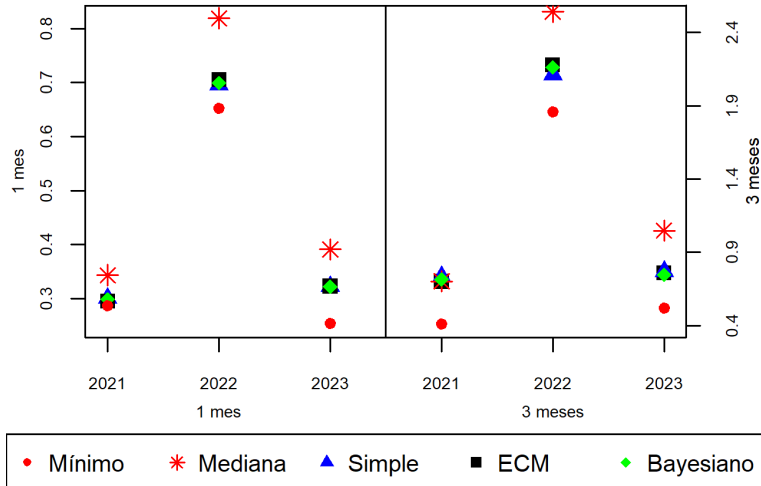


Fuente: Elaboración propia

Nota: Para 2021 se utilizan datos a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses.

otro lado, ninguno de los modelos muestra una mejor precisión para todos los periodos o horizontes de pronósticos. Estos hechos resaltan la relevancia de considerar la versión dinámica de los factores y la necesidad de utilizar promedios de pronósticos.

Gráfico 6. RECM para diferentes promedios de pronósticos.




Fuente: Elaboración propia.

Nota: Para 2021 se utiliza a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses.

En el gráfico 6 se presenta el error cuadrático medio, del pronóstico de inflación, de las distintas combinaciones de pronósticos. En el gráfico 7 se presenta la misma evaluación pero al utilizar el error absoluto medio.

En ambos casos se deben resaltar dos aspectos. En primer lugar, los promedios de pronósticos, en la mayoría de años, presentan un estadístico de error que es menor que la mediana

Gráfico 7. EAM para diferentes promedios de pronósticos.



Fuente: Elaboración propia.

Nota: Para 2021 se utiliza a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses.

de ese estadístico cuando se consideran pronósticos que incluyen solo una variable. En segundo lugar, todos los promedios de pronósticos presentan un error de pronóstico muy similar en la mayoría de años y horizontes que se grafican. El cuadro 6 en el Anexo D presenta en detalle el valor de diferentes estadísticos de ajuste. En todos los casos, la diferencia entre la bondad de ajuste es muy pequeña y no existe un patrón claro que permita determinar cuál de los promedios de pronósticos es mejor.

Una pregunta adicional es si estos promedios de pronósticos tienen una mejor bondad de ajuste que modelos alternativos más sencillos que se podrían utilizar para pronosticar la inflación. Para comparar la bondad de ajuste entre los promedios de pronósticos que se implementan en este artículo y modelos sencillos se utilizan la prueba de Diebold y Mariano (2002) (la versión modificada por Harvey, Leybourne y Newbold (1997)) y una prueba de permutaciones de los errores propuesta por Döhrn (2019).

El cuadro 1 presenta el resultado de estas pruebas cuando se comparan los promedios de pronósticos con respecto a modelos FAVAR convencionales con factores estáticos y dinámicos,¹³ y modelos univariados. Para los modelos univariados se utiliza un modelo ARMA (2,2) para todos los periodos, por ser uno de los modelos más utilizados en la literatura, y se utiliza el modelo que es mejor cada periodo según la función *auto.arima* de la librería *forecast* en el paquete estadístico *R*. Para este último, se eligió para cada periodo entre todos los modelos

¹³En ambos casos se incluye toda la información disponible en el cálculo de los factores, se utilizan 7 factores para el caso estático y 5 para el caso dinámico, y el número de rezagos en el VAR se elige de acuerdo con el criterio de Akaike.

con un máximo de cuatro rezagos autorregresivos, cuatro componentes de media móvil, un rezago autorregresivo estacional y un componente de media móvil estacional. El modelo a utilizar para cada período se elige con base en el criterio de Akaike modificado.

Cuadro 1. P- valores de pruebas de comparación de precisión del pronóstico. 2021-2023

Método	Diebold-Mariano		Prueba de permutaciones	
	1 mes	3 meses	1 mes	3 meses
Promedio bayesiano mejor que:				
Factores estáticos	0.00	0.30	0.00	0.55
Factores dinámicos	0.00	0.10	0.01	0.09
ARMA(2,2)	0.01	0.03	0.01	0.00
Auto selección ARMA	0.00	0.03	0.00	0.00
Promedio con ECM mejor que:				
Factores estáticos	0.00	0.31	0.00	0.55
Factores dinámicos	0.01	0.12	0.01	0.13
ARMA(2,2)	0.01	0.04	0.01	0.00
Auto selección ARMA	0.00	0.03	0.00	0.00
Promedio simple mejor que:				
Factores estáticos	0.00	0.99	0.00	1.00
Factores dinámicos	0.00	1.00	0.01	1.00
ARMA(2,2)	0.01	1.00	0.01	1.00
Auto selección ARMA	0.00	1.00	0.00	1.00

Fuente: Elaboración propia.

Nota: Los p-valores corresponden a la prueba de una cola en que el promedio es mejor que el pronóstico simple de acuerdo con el EAM.

De ambas pruebas se concluye que los promedios de pronósticos brindan una mejor bondad de ajuste para el pronóstico un mes hacia adelante que cualquiera de los modelos simples alternativos. En el caso del horizonte de tres meses, solo el promedio bayesiano y el basado en el error cuadrático medio tienen un mejor bondad de ajuste que los modelos univariados, y ambos promedios muestran evidencia ligera de ser mejores pronosticadores que el modelo FAVAR con factores dinámicos (p-value cercano a 0.10). En todos los casos, el p-value del promedio bayesiano es menor al de los otros dos promedios.¹⁴

¹⁴De manera adicional, se realizaron pruebas para comparar entre la capacidad de pronóstico de los cuatro modelos simples. En ninguno de los casos, la prueba fue estadísticamente significativa. Esto concuerda con la evidencia que presentan, entre otros, Faust y Wright (2013) y Mandalinci (2017).

Cuadro 2. Porcentaje de series de tiempo para las que promedio bayesiano es mejor que VAR bivariado


Nivel de significancia	Diebold-Mariano		Prueba de permutaciones	
	1 mes	3 meses	1 mes	3 meses
5 %	97,4 %	59,0 %	92,9 %	100 %
10 %	98,7 %	80,1 %	97,4 %	100 %

Fuente: Elaboración propia.

Nota: Prueba de una cola en que el pronóstico del promedio bayesiano es mejor que el del VAR bivariado de acuerdo con el EAM.

Además, se implementaron las mismas pruebas para comparar si el promedio bayesiano de los pronósticos generan un pronóstico que el que se obtendría al utilizar un VAR bivariado que incluye la variación mensual del IPC y cada una de las series de tiempo en la base de datos. El cuadro 2 resume los resultados. En el caso de los pronósticos a un horizonte de un mes ambas pruebas concluyen que para una gran mayoría de los casos el promedio bayesiano es mejor que el VAR bivariado.¹⁵ Para el horizonte de tres meses las pruebas muestran resultados disímiles, pero en ambos casos para un porcentaje importante de variables el pronóstico del promedio bayesiano es mejor.

Gráfico 8. Pronósticos a un mes e inflación observada



Fuente: Elaboración propia.

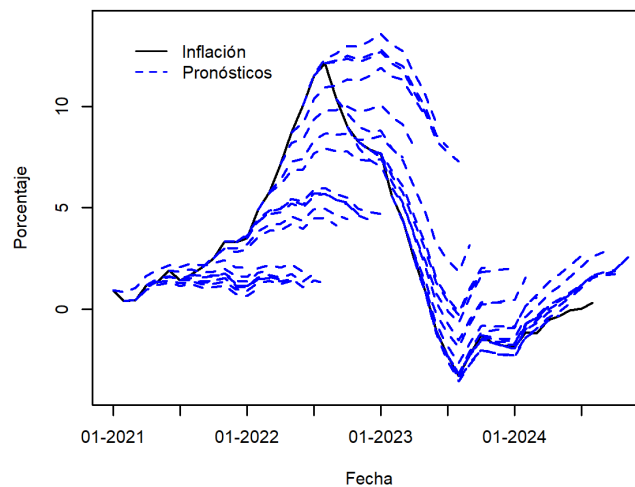
Para concluir con esta sección de resultados se presenta los pronósticos que se habrían obtenido en el pasado con el uso del promedio bayesiano. En primer lugar, el gráfico 8 presenta el pronóstico fuera de muestra con horizonte de un mes: en la mayoría de meses el pronóstico

¹⁵Para el horizonte de un mes, las únicas dos variables para las que la prueba de Diebold-Mariano no concluye que, al 10 % de significancia, el promedio bayesiano es mejor que el VAR bivariado son la variación mensual del precio de otros bienes no regulados y la variación anual del precio de los hidrocarburos. En ningún caso la prueba es significativa en la dirección contraria.

fue muy similar a la inflación interanual que se observó.

Por otra parte, en el gráfico 9 se presentan los pronósticos a horizontes de 12 meses que se hubieran obtenido con el promedio bayesiano de pronósticos. Los resultados que se presentan en este gráfico muestran un comportamiento similar al que ya se había señalado para los pronósticos con factores estáticos y dinámicos en el gráfico 2. El promedio bayesiano tiende a asignar un mayor peso a unos pocos modelos en particular. Por ejemplo, en junio de 2022, que fue el mes en que se pronosticó un mayor nivel de inflación, el promedio bayesiano asignó un peso de 35,41 % al modelo con factores estáticos con selección basada en los últimos 6 meses y tres estados de inflación, un peso muy por encima del de una distribución uniforme.

Gráfico 9. Pronósticos 12 meses hacia adelante de promedio bayesiano



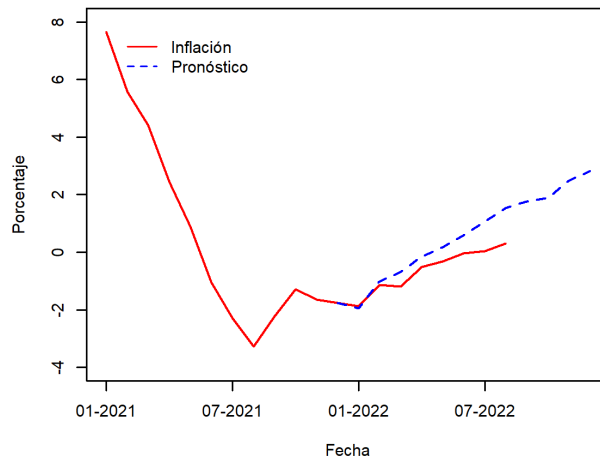
Fuente: Elaboración propia.

Finalmente, en el gráfico 10 se presenta el valor pronosticado de la evolución de la inflación durante el 2024 con información a diciembre de 2023. En el gráfico se presentan los valores que, a la hora de escribir este artículo, se han observado de la inflación durante los primeros ocho meses del 2024, y se aprecia que el pronóstico ha sido bastante acertado, pero en general ha sobre estimado la inflación observada. En los últimos meses el pronóstico se ha encontrado más de un punto porcentual por encima del valor observado.

5. Conclusiones

En este estudio se ha desarrollado una metodología que permite obtener pronósticos de inflación acertados a partir del uso de 156 series de tiempo disponibles que desde un punto de

Gráfico 10. Pronósticos de inflación a 12 meses plazo



vista teórico podrían estar relacionadas con el comportamiento de la inflación en Costa Rica.

Esta metodología se base en la estimación de un modelo FAVAR que se estima en dos etapas: a partir de las variables observadas se estiman los factores (estáticos o dinámicos) que resumen la información que estas contienen, y luego se estima un modelo VAR que incorpora como variables observadas la inflación intermensual y los factores que se estimaron de forma previa.

Lo novedoso de este estudio es que se utilizan una serie de criterios de selección con base en la precisión de los pronósticos en los meses previos a la proyección que se desea realizar para elegir cuáles variables se utilizan para estimar los factores, y en el modelo VAR cuántos factores se consideran, cuántos rezagos se utilizan y cuáles coeficientes se restringen a tomar un valor igual a cero. Estos criterios de selección pueden ser aplicados de forma automática, lo que facilita el uso de esta metodología en el futuro. Pero al mismo tiempo, estos métodos de selección son rastreables, por lo que, en caso de ser necesario, un analista puede interpretar los resultados a partir de cuáles variables, cuáles factores y cuál especificación del modelo VAR se utiliza para realizar el pronóstico.

Finalmente, se analizó la posibilidad de utilizar tres métodos para promediar los pronósticos que se obtienen de los 8 modelos que resultan de utilizar diferentes criterios de selección, metodologías de estimación de los factores y especificaciones del modelo FAVAR. De este análisis se concluyó que los tres promedios generan un pronóstico con una bondad de ajuste similar. Sin embargo, si se comparan los cuadros 4 y 6 se puede observar que, para el periodo entre 2021 y 2023, la precisión del pronóstico a un horizonte de un mes de estos

promedios (medida por la RECM, la EAM o la U de Theil) es mejor al que se hubiera obtenido si de antemano el econometrista hubiera conocido cuál VAR bivariado iba a generar un mejor pronóstico. A un horizonte de 3 meses la ventaja no es tan superior, pero claramente se encuentra por debajo de la mediana.

Además, se realizaron dos pruebas que permiten comparar entre la bondad de ajuste de los pronósticos (Diebold-Mariano y una prueba de permutaciones). De ellas se concluyen que el promedio bayesiano provee un pronóstico a un horizonte de un mes que es mejor que modelos FAVAR tradicionales con factores estáticos o dinámicos y que modelos univariados (ARMA (2,2) y un modelo seleccionado automáticamente a partir del criterio de Akaike modificado), y que la mayoría de VAR bivariados. A un horizonte de tres meses, el pronóstico del promedio bayesiano es aún mejor que los modelos univariados y los VAR bivariados.

Por tanto, se recomienda utilizar el promedio bayesiano de pronósticos como uno de los pronósticos de corto plazo que realiza el Banco Central. Sin embargo, para asegurarse que en el futuro el método de pronóstico es aún adecuado, se sugiere dar seguimiento a los errores de pronóstico del promedio bayesiano y del promedio basado en el error cuadrático medio, y en caso que el error de pronóstico del primero sea mucho mayor que el del segundo, se utilice este último en el análisis de pronóstico de inflación que realiza el Banco Central.

Referencias

- Álvarez, C. y Torres, C. (2011). Modelos de Inflación de Corto Plazo para los Sectores Transable y No Transable de la Economía Costarricense. *DT-004-2011. Departamento de Investigación Económica. Banco Central de Costa Rica.*
- Bernanke, B., Boivin, J., y Elias, P. (2005). Measuring the effects of monetary policy: a factor-augmented vector autoregressive (FAVAR) approach. *The Quarterly journal of economics*, 120(1), 387–422.
- Caffaro, G. y Pérez, J. (2018). Modelo FAVAR Óptimo para Proyecciones de Corto Plazo: Aplicación a la República Dominicana. *Serie de Documentos de Investigación.*
- Chavarría, J. D. y Chaverri, C. (2015). Pronósticos de inflación mediante técnicas bayesianas. *Economía y Sociedad*, 20(48), 1–27.

- Diebold, F. X. y Mariano, R. S. (2002). Comparing predictive accuracy. *Journal of Business & economic statistics*, 20(1), 134–144.
- Döhrn, R. (2019). Comparing forecast accuracy in small samples. (833).
- Doz, C., Giannone, D., y Reichlin, L. (2011). A two-step estimator for large approximate dynamic factor models based on Kalman filtering. *Journal of Econometrics*, 164(1), 188–205.
- Durán-Viquez, R. y Kikut-Valverde, A. (2006). Pronóstico de inflación mediante el uso de análisis factorial. *DT-004-2006. Departamento de Investigación Económica.*
- Esquivel-Monge, M. (2009). Performance of Artificial Neural Networks in Forecasting Costa Rican Inflation. *DT-29-2009. Departamento de Investigación Económica. Banco Central de Costa Rica.*
- Faust, J. y Wright, J. (2013). Forecasting inflation. In *Handbook of economic forecasting*, volumen 2 (pp. 2–56). Elsevier.
- Harvey, D., Leybourne, S., y Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of forecasting*, 13(2), 281–291.
- Hoffmaister, A., Saborío, G., y Vindas, K. (2000). Proyecciones de Inflación: Innovaciones en los Precios Agrícolas y Regulados, y Ajustes. *DT-007-2000. Departamento de Investigación Económica.*
- Hoffmaister, A., Solano, I., Solera, Á., y Vindas, K. (1999). Modelos univariados de la inflación. *Ciencias económicas*, 19(1-2), 139–194.
- Krantz, S. Introduction to dfms. *dim (BM14_M)*, 1(357), 92.
- Mandalinci, Z. (2017). Forecasting inflation in emerging markets: An evaluation of alternative models. *International Journal of Forecasting*, 33(4), 1082–1104.
- Muñoz-Salas, E. (2008). Validación del Modelo Univariable de Inflación empleado en la combinación de pronósticos. *NT-08-2008. Departamento de Investigación Económica.*
- Raftery, A., Gneiting, T., Balabdaoui, F., y Polakowski, M. (2005). Using Bayesian model averaging to calibrate forecast ensembles. *Monthly weather review*, 133(5), 1155–1174.

- Rodrigues, F. y Guillén, O. (2013). Forecasting Brazilian consumer inflation with FAVAR models using target variables. Technical report, mimeo.
- Rodríguez-Vargas, A. (2020). Forecasting Costa Rican inflation with machine learning methods. *Latin American Journal of Central Banking*, 1(1-4), 100012.
- Segura-Rodriguez, C. y Vásquez-Carvajal, J. P. (2011). Validación del modelo VAR del impacto de los precios del petróleo en Costa Rica. *NT-004-2011. Departamento de Investigación Económica.*
- Solera-Ramírez, Á. (2005). Pronóstico de inflación en Costa Rica: una estimación con redes neuronales artificiales. *DT-155-2005. Departamento de Investigación Económica.*
- Stock, J. y Watson, M. (2016). Dynamic factor models, factor-augmented vector autoregressions, and structural vector autoregressions in macroeconomics. In *Handbook of macroeconomics*, volumen 2 (pp. 415–525). Elsevier.
- Torres-Gutiérrez, C. (2012). Costa Rica: Determinación de cambios estructurales en el nivel de la tasa de inflación: periodo 1997-2011. *DT-29-2009. Departamento de Investigación Económica. Banco Central de Costa Rica.*
- Vásquez-Carvajal, J. P. y Vindas-Quesada, A. (2011). Validación del modelo VAR de mecanismos de transmisión de la política monetaria en Costa Rica. *NT-005-2011. Departamento de Investigación Económica.*
- Vindas-Quesada, A. (2011). Validación del modelo ARMA para la proyección de la inflación en CR. *NT-03-2011. Departamento de Investigación Económica.*
- Winkelried, D. (2003). Hacia una meta explícita de inflación: Anticipando la inflación en el Perú. *Revista Estudios Económicos*, (9), 11–40.

A. Descripción de variables

Cuadro 3. Variables que se consideran para pronóstico

Grupo de variables	Variables
Monetarias	M1 Base monetaria Emisión monetaria Crédito al sector privado Crédito para construcción Crédito para actividades empresariales
Demanda agregada	IMAE Serie original Por régimen definitivo y especial Brecha del IMAE total y por régimen Desagregación del IMAE en quince componentes Empleo formal Índice de producción industrial de EEUU
Tasas de interés	Tasa Básica Pasiva real Tasa de Política Monetaria Tasa LIBOR 6 meses/ SOFR a 6 meses
Costos de producción	Índice de precios al productor de la manufactura Índice de precios al productor de servicios Índice de salarios mínimos nominales
Tipo de cambio	Tipo de cambio promedio mensual en MONEX Índice de Tipo de Cambio Real Efectivo
Expectativas	Expectativas de inflación de encuesta a 12 meses Expectativas de inflación de mercado a 6, 12 y 24 meses Expectativas de variación cambiaria de mercado a 6, 12 y 24 meses

Cuadro 3. Variables que se consideran para pronóstico (continuación):

Grupo de variables	Variables
Precios materias primas	<p>Precio de cóctel de hidrocarburos</p> <p>Precios de petróleo tipo <i>West Texas Intermediate</i></p> <p>Índice de precios internacionales de materias primas importadas</p> <ul style="list-style-type: none">Índice totalCombustiblesGranosSin granosSin combustibles <p>Índice de materias primas de Bloomberg</p> <ul style="list-style-type: none">Precios futurosPrecios futuros un mes hacia adelantePrecios de contadoPrecios de contado de metales industrialesPrecios de contado de la energíaPrecios de contado de granosPrecios de contado del petróleo
Inflación internacional	<p>Inflación EEUU</p> <p>Inflación de socios comerciales</p>

Cuadro 3. Variables que se consideran para pronóstico (continuación):

Grupo de variables	Variables
Indicadores de precios	Índice de precios al consumidor por grupos
	Categorías del índice de precios al consumidor
	Regulados
	No regulados
	Servicios regulados
	Servicios no regulados
	Bienes agrícolas
	Otros no regulados
	Regulados sin combustible
	Sin productos agrícolas
	Sin combustible
	Inflación subyacente
	Índice de exclusión fija por volatilidad
	Índice de media truncada
	Índice de reponderación por volatilidad
	Índice de reponderación por persistencia
Índice de exclusión fija	
Promedio	

Fuente: Elaboración propia.

B. Estadísticas de bondad de ajuste de pronósticos individuales

Cuadro 4. Estadísticos de bondad de ajuste para pronósticos a 1 y 3 meses con modelos VAR individuales. 2021-2023

Estadístico		1 mes				3 meses			
		2021	2022	2023	Todos	2021	2022	2023	Todos
RECM	mediana	0.34	0.82	0.39	0.57	0.70	2.54	1.05	1.69
	min	0.29	0.65	0.25	0.49	0.41	1.86	0.52	1.31
	max	0.49	0.95	0.56	0.65	1.29	3.02	1.77	2.09
EAM	mediana	0.29	0.61	0.25	0.39	0.56	2.25	0.88	1.28
	min	0.24	0.48	0.19	0.34	0.35	1.59	0.39	0.96
	max	0.44	0.75	0.40	0.46	1.10	2.73	1.41	1.61
U-Theil	mediana	0.72	0.69	0.30	0.53	0.79	0.83	0.30	0.60
	min	0.60	0.55	0.19	0.46	0.50	0.60	0.15	0.46
	max	1.03	0.80	0.43	0.61	1.33	0.98	0.51	0.74
Sesgo	mediana	0.06	0.14	0.21	0.02	0.14	0.52	0.77	0.07
	min	0.00	0.00	0.02	0.00	0.00	0.04	0.12	0.00
	max	0.25	0.31	0.34	0.13	0.78	1.09	1.28	0.45
Signo	mediana	0.82	0.92	0.92	0.89	0.91	0.83	1.00	0.92
	min	0.36	0.83	0.75	0.75	0.36	0.67	0.92	0.69
	max	0.91	1.00	1.00	0.94	1.00	1.00	1.00	0.97

Fuente: Elaboración propia

Notas: Para 2021 se utiliza a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses. Los estadísticos se definen de la siguiente forma: RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: Coeficiente U de Theil de exactitud del pronóstico, Sesgo: valor absoluto del error medio y Signo: porcentaje de veces que el cambio pronosticado de la inflación coincide con el observado.

C. Estadísticas de bondad de ajuste para pronósticos de factores

Cuadro 5. Estadísticos de bondad de ajuste para pronósticos a 1 y 3 meses con modelos de factores. 2021-2023

Estadístico	Promedio	1 mes				3 meses			
		2021	2022	2023	Todos	2021	2022	2023	Todos
RECM	Est 12 m	0.34	0.72	0.34	0.51	0.72	2.05	0.66	1.35
	Est 6 m	0.36	0.67	0.29	0.48	1.00	2.09	0.83	1.45
	Est 12 m cam	0.39	0.64	0.43	0.50	1.14	1.82	1.16	1.43
	Est 6 m cam	0.31	0.74	0.34	0.51	0.66	2.56	0.82	1.66
	Din 12 m	0.31	0.73	0.37	0.51	0.75	2.13	1.11	1.50
	Din 6 m	0.29	0.71	0.32	0.49	0.73	2.22	0.90	1.49
	Din 12 m cam	0.29	0.71	0.37	0.50	0.88	2.16	1.03	1.52
	Din 6 m cam	0.30	0.76	0.34	0.51	0.63	2.31	0.91	1.53
EAM	Est 12 m	0.30	0.50	0.23	0.35	0.59	1.49	0.48	0.88
	Est 6 m	0.31	0.46	0.22	0.33	0.85	1.71	0.61	1.08
	Est 12 m cam	0.32	0.49	0.34	0.38	0.85	1.66	1.02	1.20
	Est 6 m cam	0.26	0.55	0.22	0.35	0.55	2.30	0.65	1.22
	Din 12 m	0.27	0.50	0.20	0.33	0.56	1.72	0.67	1.02
	Din 6 m	0.24	0.52	0.22	0.33	0.49	1.90	0.67	1.07
	Din 12 m cam	0.26	0.49	0.21	0.32	0.73	1.72	0.67	1.06
	Din 6 m cam	0.23	0.59	0.22	0.35	0.42	2.10	0.71	1.14

Fuente: Elaboración propia.

Notas: Para 2021 se utiliza a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses. RECM corresponde a la raíz del error cuadrático medio y EAM al error absoluto medio.

D. Estadísticas de bondad de ajuste para promedio de pronósticos de factores

Cuadro 6. Estadísticos de bondad de ajuste para promedios de pronósticos. 2021-2023

Estadístico	Promedio	1 mes				3 meses			
		2021	2022	2023	Todos	2021	2022	2023	Todos
RECM	Simple	0.30	0.70	0.32	0.48	0.73	2.11	0.77	1.41
	ECM	0.30	0.71	0.32	0.48	0.70	2.18	0.76	1.44
	Bayesiano	0.30	0.70	0.32	0.48	0.71	2.16	0.75	1.43
EAM	Simple	0.26	0.48	0.19	0.31	0.55	1.81	0.56	1.01
	ECM	0.25	0.48	0.20	0.31	0.49	1.83	0.58	1.01
	Bayesiano	0.25	0.49	0.20	0.31	0.53	1.87	0.55	1.02
U-Theil	Simple	0.63	0.58	0.25	0.45	0.76	0.69	0.22	0.50
	ECM	0.62	0.59	0.25	0.45	0.72	0.71	0.22	0.51
	Bayesiano	0.63	0.59	0.25	0.45	0.74	0.70	0.21	0.50
Sesgo	Simple	-0.04	-0.02	0.09	0.01	-0.45	-0.09	0.40	-0.01
	ECM	-0.03	-0.01	0.08	0.01	-0.37	0.04	0.36	0.04
	Bayesiano	-0.04	-0.03	0.07	0.00	-0.42	-0.10	0.33	-0.03
Signo	Simple	0.82	0.92	1.00	0.91	0.56	0.83	1.00	0.82
	ECM	0.82	0.92	1.00	0.91	0.78	0.83	1.00	0.88
	Bayesiano	0.82	0.92	1.00	0.91	0.67	0.83	1.00	0.85

Fuente: Elaboración propia

Notas: Para 2021 se utiliza a partir de febrero para el pronóstico de un mes y a partir de abril para el de tres meses. Los estadísticos se definen de la siguiente forma: RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: Coeficiente U de Theil de exactitud del pronóstico, Sesgo: valor absoluto del error medio y Signo: porcentaje de veces que el cambio pronosticado de la inflación coincide con el observado.