BANCO CENTRAL DE COSTA RICA

DOCUMENTO DE TRABAJO

N.º 09|2025

Pronóstico de inflación en Costa Rica: el valor de variables exógenas en modelos desagregados por artículo

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.

Pronóstico de inflación en Costa Rica: el valor de variables exógenas en modelos desagregados por artículo

Carlos Segura-Rodriguez[†]

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

Resumen

Este estudio propone una metodología para el pronóstico de la inflación en Costa Rica basada en el análisis desagregado de los 289 artículos que conforman el Índice de Precios al Consumidor (IPC). Se emplean modelos ARIMA para la mayoría de los artículos y modelos ARIMAX —que incorporan variables exógenas— para aquellos con mayor ponderación y precios más volátiles. La inclusión de información específica, como el tipo de cambio, precios internacionales de materias primas y precios agrícolas semanales, mejora significativamente la precisión de los pronósticos en horizontes de corto plazo. El enfoque desagregado supera sistemáticamente a modelos más agregados o sin variables exógenas, al reducir errores en productos sensibles como alimentos, combustibles, bienes regulados y aquellos cotizados en dólares. Los resultados evidencian el valor de integrar información adicional en estrategias de pronóstico basadas en datos desagregados, y sugieren que esta metodología puede complementar eficazmente los modelos de pronóstico de corto plazo utilizados por el Banco Central.

Palabras clave: Inflación, pronóstico, modelos ARIMAX, artículos del IPC.

Clasificación JEL: C53, E31, E37.

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

Inflation Forecasting in Costa Rica: The Contribution of Exogenous Variables in Item-Level Disaggregated Models

Carlos Segura-Rodriguez[†]

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

Summary

This study proposes a methodology for forecasting inflation in Costa Rica based on a disaggregated analysis of the 289 items that comprise the Consumer Price Index (CPI). ARIMA models are used for most items, while ARIMAX models —which incorporate exogenous variables— are applied to those with higher weights and more volatile prices. The inclusion of specific information, such as the exchange rate, international commodity prices, and weekly agricultural prices, significantly improves forecast accuracy over short-term horizons. The disaggregated approach consistently outperforms more aggregated models or those without exogenous variables by reducing errors in sensitive items such as food, fuel, regulated goods, and products priced in U.S. dollars. The results highlight the value of integrating additional information into forecasting strategies based on disaggregated data and suggest that this methodology can effectively complement the short-term inflation forecasting models currently used by the Central Bank.

Key words: Inflation, forecasting, ARIMAX models, CPI items .

JEL Codes: C53, E31, E37.

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

Índice

1. Introducción **2**

2. Descripción de los datos **6**

3. Metodología **7**

3.1. Estimación inicial de modelos ARIMA 8

3.2. Selección de bienes para modelado específico 8

3.3. Modelos ARIMA con variables exógenas (ARIMAX) 9

4. Resultados para IPC general **13**

4.1. Impacto de los modelos ARIMAX 16

4.2. Modelos alternativos 20

5. Extensiones **23**

5.1. Resultados para inflación por grupos 23

5.2. Pronósticos de inflación subyacente 24

6. Conclusiones **25**

7. Apéndice **30**

7.1. Medidas de bondad de ajuste para modelos de artículos y factores 30

1. Introducción

En un régimen de metas de inflación, un banco central requiere disponer de información sobre los valores esperados de un conjunto de variables económicas, entre los que la inflación es uno de los indicadores de mayor relevancia. Esto se debe a que, bajo dicho régimen, las decisiones de política monetaria se adoptan con un enfoque prospectivo. En particular, los bancos centrales suelen guiarse por reglas tipo Taylor (Taylor, 1993), las cuales establecen que la tasa de interés de política debe reducirse cuando se anticipa una disminución en la inflación futura (o en la brecha del producto), y aumentarse en caso contrario.

En consecuencia, los bancos centrales revisan de forma continua los modelos utilizados para el pronóstico de la inflación de corto plazo. El Banco Central de Costa Rica (BCCR) no es la excepción, y actualmente emplea diversas metodologías con este propósito, entre las que se incluyen modelos univariados, bayesianos y modelos FAVAR. Adicionalmente, se realiza un pronóstico interno a partir del precio de cada uno de los artículos que conforman el Índice de Precios al Consumidor (IPC), para lo que utiliza promedios históricos y datos sobre cambios aprobados, pero con efecto en los siguientes meses, en los precios de bienes regulados.

El objetivo de este artículo es proponer una metodología para el pronóstico de la inflación basada en el análisis desagregado del comportamiento de los precios de los artículos que integran el IPC. El principal aporte consiste en la utilización de modelos ARIMA, que se complementan con variables exógenas que afectan la formación de precios de aquellos bienes y servicios cuyos precios son más volátiles y tienen un peso relevante en el IPC. Esto permite analizar si el introducir estas variables exógenas permite capturar de manera más precisa la dinámica de corto plazo de la inflación.

La idea de pronosticar componentes desagregados para luego agregarlos y obtener un pronóstico de la variable agregada no es novedosa. Sus orígenes se remontan a los trabajos de Theil y Theil (1954) y Grunfeld y Griliches (1960), quienes analizaron cómo las decisiones de los agentes microeconómicos pueden agregarse para derivar resultados macroeconómicos. Este enfoque, conocido en la literatura como $bottom\text{-}up$, ha sido aplicado en diversos contextos.

En el ámbito del pronóstico de la inflación, Hubrich (2005) fue uno de los pioneros en apli-

car esta metodología para estimar la variación interanual del Índice Armonizado de Precios al Consumidor en la zona euro. El autor identifica dos beneficios potenciales de la agregación de pronósticos: primero, la posibilidad de que los errores de pronóstico de los componentes se cancelen entre sí, como se plantea en la literatura sobre combinación de pronósticos (véase Timmermann (2006)); y segundo, la capacidad de incorporar variables específicas que afectan a los precios individuales o a la dinámica particular de cada componente, como lo argumenta Barker y Pesaran (2014). No obstante, también se señalan dos desventajas: la mayor probabilidad de especificación incorrecta en alguno de los múltiples modelos desagregados, lo cual puede afectar el pronóstico agregado (como ya lo advertía Grunfeld y Griliches (1960)); y la posibilidad de que choques comunes afecten simultáneamente a varios precios, lo que impide la cancelación de errores. Por ejemplo, Hubrich (2005) muestra que un choque en los precios del petróleo puede impactar múltiples componentes del índice, generando errores comunes en los pronósticos que se amplifican a nivel agregado.

El principal aporte de esta investigación es evidenciar la importancia de incorporar información específica relevante para el pronóstico de los precios individuales de los artículos. En ausencia de dicha información, la capacidad predictiva del modelo basado en la agregación de pronósticos desagregados (llamado enfoque indirecto) no difiere significativamente de la que tiene el modelo que utiliza el IPC a nivel agregado (conocido como enfoque directo). Sin embargo, al incluir variables exógenas en los modelos de aquellos productos que presentan mayor volatilidad y que tienen un peso significativo en el IPC, la precisión de los pronósticos mejora sustancialmente. Entre las variables adicionales consideradas se encuentran el tipo de cambio, el precio de los hidrocarburos, el índice de referencia $West\ Texas\ Intermediate\ (WTI)$ del precio del petróleo, los precios de granos importados y los precios sugeridos por el Consejo Nacional de Producción (CNP) para las ferias del agricultor[1]. Las pruebas de comparación de pronósticos propuestas por Diebold y Mariano (1995) y Döhrn (2019) permiten concluir que los pronósticos generados mediante esta metodología son más precisos que los obtenidos a partir de un conjunto de modelos alternativos.

Este hallazgo es consistente con la literatura, la cual no ofrece evidencia concluyente a favor

[1] Las ferias del agricultor son mercados al aire libre, que se llevan a cabo normalmente los sábados o domingos, en los que los agricultores pueden acceder a espacios para vender sus productos directamente a los consumidores. Cada viernes el CNP publica una lista de precios sugeridos para los productos agrícolas que más se transan en estos mercados. Hasta donde tiene conocimiento el autor, esta es la primera vez que dicha información se incorpora en modelos de pronóstico de inflación en Costa Rica. Su inclusión resulta particularmente relevante, porque permite anticipar la evolución de los precios de bienes agrícolas, los cuales tienden a ser altamente volátiles.

del enfoque directo o indirecto para el pronóstico de la inflación. Algunos estudios encuentran que el enfoque directo proporciona mejores resultados (véase Benalal, Diaz del Hoyo, Landau, Roma y Skudelny (2004) y Hubrich (2005) para la zona euro, y Harvey y Cushing (2014) para Ghana), mientras que otros destacan la superioridad del enfoque indirecto (por ejemplo, Duarte y Rua (2005) para Portugal, Bermingham y D'Agostino (2014) para Estados Unidos y la zona euro, y Carlo y Marçal (2016) para Brasil).

Asimismo, Bermingham y D'Agostino (2014) y Duarte y Rua (2005) sugieren que un mayor grado de desagregación de los datos y series temporales más extensas son factores que incrementa la efectividad del enfoque indirecto. Este estudio respalda dicha conclusión: al comparar los pronósticos generados a partir de las trece divisiones del IPC con aquellos obtenidos mediante la agregación de los pronósticos de los 289 artículos individuales, se observa una mayor precisión en este último caso. Esto se explica, en parte, por la capacidad de las variables exógenas para capturar información específica sobre la evolución de los precios de los artículos, información que no necesariamente se refleja a nivel de división.

Finalmente, la literatura empírica ha identificado como una de las principales dificultades del enfoque desagregado la alta volatilidad de ciertos precios, lo que complica la obtención de pronósticos precisos. En este sentido, tanto Hubrich (2005) como Benalal et al. (2004) destacan los desafíos asociados al pronóstico de componentes volátiles, como alimentos y energía, dentro del Índice Armonizado de Precios al Consumidor de la zona euro. En consecuencia, concluyen que el enfoque indirecto resulta más útil para estimar índices que excluyen dichos componentes[2]. Uno de los aportes de este estudio es demostrar que la incorporación de información adicional en los modelos de los artículos con precios más volátiles permite mejorar significativamente la precisión de los pronósticos de inflación. De hecho, una vez incluida esta información, la capacidad predictiva para la inflación general se asemeja a la obtenida para la inflación subyacente, la cual, al ser menos volátil, resulta más fácil de pronosticar.

Los métodos $bottom\text{-}up$ de pronóstico de la inflación han sido ampliamente aplicados en América Latina. Entre los estudios más destacados se encuentra el de Boaretto y Medeiros (2023), quienes emplean técnicas de aprendizaje automático para estimar la evolución de los componentes desagregados del IPC en Brasil. Sus resultados indican que, en contextos de alta

[2] En la misma línea, Demers y De Champlain (2005) encuentran que, para el caso de Canadá, el enfoque indirecto es superior al directo en la estimación de la inflación subyacente.

volatilidad —como el periodo posterior a la pandemia de COVID-19—, estas técnicas superan en precisión a las expectativas derivadas de encuestas a expertos. De manera similar, Cobb (2009) y Martínez-Rivera, González-Molano y Caicedo-García (2023), en los casos de Chile y Colombia respectivamente, concluyen que el enfoque indirecto, basado en la agregación de pronósticos de los componentes del IPC, puede generar estimaciones tan precisas como las obtenidas mediante el enfoque directo, dependiendo del contexto económico.

Asimismo, se han desarrollado estudios para República Dominicana y los países de Centroamérica. Ramírez y Ramírez (2019) concluyen que el enfoque indirecto presenta errores de pronóstico menores en comparación con los modelos agregados. En su análisis, identifican que los precios de los alimentos y de los productos vinculados al petróleo son particularmente difíciles de prever, y que estos componentes tienen un impacto significativo en el error total del pronóstico de la inflación. Por su parte, Muñoz y Quiñónez (2025) aplican modelos ARIMA tanto a nivel desagregado como agregado para países de Centroamérica, Panamá y República Dominicana. Sus hallazgos indican que, en la mayoría de los casos, el enfoque desagregado ofrece mejores resultados para horizontes de dos y tres meses; sin embargo, para Costa Rica, esta superioridad solo se observa en el horizonte de tres meses.

En el caso específico de Costa Rica, el Banco Central ha desarrollado históricamente pronósticos de inflación a partir del análisis individual de los precios de los artículos que componen el IPC. Esta práctica se basa en una heurística que combina el promedio geométrico de las variaciones mensuales históricas de cada artículo con la información disponible sobre ajustes tarifarios aprobados para bienes regulados. Además, el Banco ha implementado diversas metodologías para el pronóstico de corto plazo, entre las que se incluyen modelos univariados (Vindas Quesada, Brenes Soto, Jiménez Montero, Jiménez Morales y Sandí Esquivel, 2024), enfoques bayesianos (Chavarría Mejía y Chaverri Morales, 2015) y modelos FAVAR (Segura-Rodriguez, 2024).

El resto del documento se organiza de la siguiente manera: en la sección 2 se describen los datos utilizados en el análisis; la sección 3 presenta la metodología empleada para la estimación de los pronósticos; los principales resultados se discuten en la sección 4; la sección 5 explora extensiones del análisis, incluyendo pronósticos por grupos del IPC y medidas de inflación subyacente; finalmente, la sección 6 resume los hallazgos más relevantes del estudio.

2. Descripción de los datos

El principal insumo para los pronósticos de inflación desarrollados en este estudio es la evolución desagregada de los precios de los artículos que conforman el Índice de Precios al Consumidor.

El IPC vigente incluye información sobre 289 bienes y servicios, agrupados en 13 divisiones. La selección de estos artículos fue realizada por el Instituto Nacional de Estadística con base en los patrones de consumo que se derivan la Encuesta Nacional de Ingresos y Gastos de los Hogares de 2018. Para ser incluidos, los bienes y servicios debían cumplir dos criterios: (i) haber sido consumidos por al menos un 7 % de los hogares urbanos, independientemente de su nivel de ingreso, y (ii) representar, en promedio, al menos un 0,05 % del gasto total de dichos hogares.

Este IPC se construye utilizando un índice de Laspeyres, en el cual las cantidades (ponderaciones) permanecen constantes, cuyo período base es diciembre de 2020. Esta característica metodológica facilita el pronóstico, ya que las variaciones en el índice dependen exclusivamente de los cambios en los precios de los productos.

Para esta investigación se contó con series de precios mensuales para los 289 bienes y servicios del IPC desde enero de 2009. Dado que no todos los artículos actuales estaban presentes en versiones anteriores del índice, la División de Análisis de Datos y Estadísticas del Banco Central realizó una imputación de los precios faltantes en los periodos previos.[3]

En términos de la ponderación actual, la división de alimentos y bebidas no alcohólicas representa la mayor proporción de la canasta (24,36 %), seguida por transporte (14,82 %). Entre los bienes y servicios individuales con mayor peso destacan: alquiler de vivienda (5,55 %), automóviles nuevos (4,24 %), gasolina (3,60 %), telefonía móvil (3,48 %), electricidad (3,28 %), educación universitaria (3,14 %), servicio doméstico (2,50 %) y transporte en autobús (2,20 %).

En cuanto a la variabilidad de precios, se observa una alta volatilidad en algunos productos agrícolas. Por ejemplo, la desviación estándar de la variación mensual del precio del tomate es 27,18 %; la de la vainica, 20,54 %; la de la cebolla, 18,97 %; y la de la papaya, 14,56 %. Esta

[3] Aproximadamente el 80 % de la canasta actual, en términos de ponderación, corresponde a bienes que ya estaban presentes en la versión anterior del IPC (base 2016), y un 14 % adicional corresponde a reclasificaciones de bienes previamente incluidos. Por tanto, la imputación se limitó a un subconjunto reducido de artículos con baja ponderación.

alta variabilidad sugiere que mejorar el pronóstico de estos bienes, ya sea por su peso o por su volatilidad, puede contribuir significativamente a la precisión del pronóstico de la inflación agregada. Como se detallará más adelante, varios de estos bienes fueron seleccionados, bajo criterios adicionales, para la estimación de modelos individuales.

Adicionalmente, en estos modelos individualizados se incorporan variables exógenas que podrían incidir en la formación de dichos precios. En un apartado posterior se explica la selección de las variables que fueron incluidas en cada uno de ellos. Entre estas se incluyen el tipo de cambio promedio del mercado MONEX, un precio agregado de importación de hidrocarburos provisto por RECOPE al BCCR, un índice interno de precios de granos elaborado a partir de información de Bloomberg, y el índice de referencia WTI para el precio del petróleo.

Finalmente, se recopila información sobre los precios sugeridos por el CNP para los productos agrícolas más comunes en las ferias del agricultor. Estos datos son publicados semanalmente desde enero de 2020. Esta información se obtiene mediante una rutina automatizada de extracción de datos ($web\ scraping$) que permite generar una base de datos de dichos precios. Debido a que algunos de los bienes con precios más volátiles que se incluyen en el IPC, el incluir está información resulta crucial para incorporar señales recientes sobre la tendencia de los precios de los productos agrícolas que se producen localmente y que se encuentran dentro de la canasta del IPC.[4]

3. Metodología

La metodología empleada en este estudio se desarrolla en dos etapas. En la primera, se estiman modelos ARIMA para pronosticar individualmente los precios de los bienes y servicios incluidos en el IPC. En la segunda, se identifican aquellos bienes que contribuyen en mayor medida al error de pronóstico agregado, y se desarrollan modelos específicos que capturan las particularidades de dichos productos.

[4] Esta fuente también proporciona información relevante para bienes como los huevos, aunque estos no se clasifiquen estrictamente como productos agrícolas.

3.1. Estimación inicial de modelos ARIMA

En la primera etapa, los bienes se clasifican en tres grupos, según las propiedades de estacionariedad de las series de tiempo de sus precios: (i) precios estacionarios, (ii) variaciones mensuales estacionarias, y (iii) series que requieren una segunda diferenciación para alcanzar la estacionariedad. Esta clasificación se realiza mediante la prueba de Kwiatkowski, Phillips, Schmidt y Shin (KPSS).

Luego, para cada precio, con la transformación estacionaria correspondiente, se estima un modelo ARIMA utilizando la función $auto.arima$ del paquete $forecast$ en el lenguaje de programación R. Este paquete selecciona el modelo ARIMA con componente estacional que minimiza el criterio de información de Akaike corregido (AICc), entre todos los modelos con un máximo de tres parámetros autorregresivos, tres de media móvil, y dos parámetros estacionales (uno autorregresivo y uno de media móvil).

Este procedimiento se repite cinco veces, variando el número máximo de parámetros permitidos en el modelo, desde cero hasta cuatro. De entre estas especificaciones, se selecciona aquella que minimiza el error absoluto medio (EAM) de pronóstico a un mes, para el periodo de selección que comprende entre 2021 y 2023. Para ello, se emplea un esquema de ventanas crecientes: se estima el modelo con datos desde diciembre de 2020 hasta un mes determinado, se pronostica el mes siguiente, y se registra el error de pronóstico. Este proceso se repite hasta obtener un pronóstico para diciembre de 2023, y se calcula el EAM correspondiente.

3.2. Selección de bienes para modelado específico

Una vez obtenidos los pronósticos iniciales, se calcula el error de pronóstico un mes hacia adelante del precio de cada bien para el periodo de selección (2021–2023). Se eligen aquellos productos cuya raíz del error cuadrático medio (RMSE), multiplicada por su ponderación en el IPC, supera el umbral de 0,02; o cuyo EAM ponderado supera 0,015. En el caso de los bienes agrícolas, se utilizan umbrales más bajos (0,01 en ambos casos), dada la disponibilidad de información adicional relevante para estos productos.[5]

[5] Los umbrales fueron definidos con el objetivo de seleccionar un conjunto de productos suficientemente amplio para justificar un modelado individualizado, pero manejable en términos de recursos analíticos. En el caso de los bienes agrícolas, el umbral más bajo responde a la disponibilidad de datos detallados provenientes de las ferias del agricultor, que permiten mejorar sustancialmente los pronósticos, incluso para productos con baja ponderación.

Los bienes seleccionados para desarrollar modelos específicos incluyen: gasolina, diésel, gas licuado, boleto aéreo, paquetes turísticos al extranjero, automóviles nuevos, arroz, huevos, papaya, sandía, tomate, cebolla, papa, culantro, zanahoria, electricidad, suministro de agua, aceite, transporte en autobús, transporte en taxi, teléfono celular y servicios de telecomunicaciones en paquetes.

Para los servicios de transporte en autobús y taxi no fue posible identificar modelos que redujeran significativamente el error de pronóstico, por lo que se mantuvieron los modelos ARIMA iniciales. [6]

3.3. Modelos ARIMA con variables exógenas (ARIMAX)

En todos los casos seleccionados, se estiman modelos ARIMA con variables explicativas adicionales (ARIMAX). La selección de variables exógenas y la especificación del modelo (número de parámetros autorregresivos, de media móvil y estacionales) se realiza con base en la minimización conjunta del RMSE y del EAM. A continuación, se detallan los modelos utilizados para cada grupo de bienes seleccionados.

Gasolina, diésel y gas licuado:

En Costa Rica, la Autoridad Reguladora de los Servicios Públicos (ARESEP) establece los precios de los derivados del petróleo comercializados por la Refinería Costarricense de Petróleo (RECOPE). La metodología de cálculo considera, entre otros, el precio en dólares pagado por RECOPE por los hidrocarburos, el tipo de cambio vigente, y ajustes por costos no previstos asumidos por la refinería en periodos anteriores.

Dado este esquema regulatorio, los modelos desarrollados para pronosticar los precios de los hidrocarburos incorporan como variables explicativas las variaciones recientes del tipo de cambio y del precio de los hidrocarburos.[7]

[6] Estos precios son regulados y, aunque existe alguna estacionalidad en la variación de los precios, se han observado ajustes de las tarifas en diferentes meses del año.

[7] El precio de los hidrocarburos corresponde al promedio pagado por RECOPE por los productos procesados, e incluye tanto el costo del crudo como un margen por refinación y transporte hasta el puerto de Limón. Para los pronósticos fuera de muestra, se descompone este precio en el componente del crudo —medido por el precio del West Texas Intermediate (WTI)— y el margen, los cuales se pronostican por separado.

En todos los casos, la variable dependiente es la variación mensual del precio del hidrocarburo. Para los modelos de gasolina y diésel, se incluyen tres rezagos de la variación mensual del precio de los hidrocarburos y tres rezagos de la variación mensual del tipo de cambio. En el caso del gas licuado, la especificación óptima —en términos de reducción del error de pronóstico fuera de muestra— incluye dos rezagos de cada una de estas variables.

Adicionalmente, se incorporan variables dicotómicas para capturar eventos atípicos no explicados por las variables incluidas. Por ejemplo, durante la pandemia de COVID-19, el gobierno decidió mantener fijo el precio de la gasolina, a pesar de la caída en el precio internacional del petróleo, con el fin de crear un fondo para financiar subsidios a personas afectadas por la pérdida de ingresos, por lo que el precio no responde a las variables incluidas en el modelo.

Finalmente, se permite que los errores del modelo sigan una estructura ARIMA, con un máximo de cero, uno y dos parámetros para los modelos de gasolina, diésel y gas licuado, respectivamente.

Boleto aéreo, paquetes turísticos al extranjero y automóviles nuevos:

En el caso de Costa Rica, es común que estos bienes y servicios cuenten con precios denominados en dólares estadounidenses. Por esta razón, el tipo de cambio se incorpora como una variable explicativa clave en los modelos de pronóstico, ya sea de forma directa o indirecta.

Boleto aéreo

Para el precio del boleto aéreo, la variable dependiente es la variación interanual del precio. Como variables explicativas se incluyen el tipo de cambio contemporáneo y el rezago de dos meses del precio WTI, dado que el combustible representa uno de los principales costos operativos de las aerolíneas y, por tanto, influye directamente en el precio de los boletos. Los errores del modelo se suponen distribuidos según un proceso ARIMA con un máximo de dos parámetros.

Debido al alto grado de volatilidad observado en los precios de los boletos aéreos en los últimos años, se incorpora automáticamente una variable dicotómica idiosincrática en aquellos periodos en los que el error de pronóstico supera, en valor absoluto, seis veces la desviación estándar de los errores del modelo.

Paquetes turísticos al extranjero

Para los paquetes turísticos al extranjero, la variable dependiente es la variación mensual del precio. Se incluye como variable explicativa el rezago de un mes del precio del boleto aéreo, lo cual permite capturar de manera indirecta el efecto del tipo de cambio, en línea con el hecho de que una proporción significativa del costo de estos paquetes corresponde al transporte aéreo. En este caso, se asume que los errores son independientes. Al igual que en el caso anterior, se incorpora una variable dicotómica idiosincrática en aquellos periodos en los que el error de pronóstico supera cuatro veces la desviación estándar de los errores del modelo.

Automóviles nuevos

Para el precio de los automóviles nuevos, se utiliza como variable dependiente la variación interanual del precio, y como variable explicativa la variación interanual contemporánea del tipo de cambio. Además, se incluyen dos variables dicotómicas idiosincráticas correspondientes a periodos específicos en los que los cambios observados en el precio no pueden ser explicados adecuadamente por las variables incluidas en el modelo. En este caso, los errores se modelan mediante un proceso ARIMA con un máximo de tres parámetros.[8]

Alimentos:

Para una mayoría de los productos agrícolas (huevos, papaya, sandía, tomate, cebolla, papa, culantro y zanahoria) se dispone de información complementaria proveniente de los precios observados en las ferias del agricultor. Esta fuente de datos resulta particularmente útil para mejorar la precisión de los pronósticos de corto plazo, dada la alta volatilidad de los precios de estos bienes.

En todos los casos, la variable dependiente es la variación mensual del precio del bien en el IPC. Como variable explicativa se utiliza la variación intermensual del precio observado durante la primera semana de cada mes en las ferias del agricultor, empleando este valor como un proxy del precio promedio mensual.

[8] Implícitamente se asume que las clases, marcas y diseños de automóviles que se incluyen en el cálculo del IPC no varían en el tiempo. Cualquier variación en este sentido forma parte de los errores del modelo, y no se cuenta con información adicional para corregir este posible sesgo de variable omitida.

Con excepción del caso del tomate, para el cual se permite que los errores sigan un modelo ARIMA con hasta dos parámetros, se asume que los errores de los modelos son independientes. En consecuencia, para la mayoría de estos productos se estima una regresión lineal simple entre la variación mensual del precio en el IPC y la variación observada en la feria del agricultor.

Estos modelos están diseñados específicamente para realizar pronósticos a un mes, ya que extender el horizonte de predicción requeriría anticipar también los precios observados en las ferias del agricultor. Esta tarea presenta un nivel de dificultad comparable al de pronosticar directamente los precios del IPC, lo que limita la utilidad de estos modelos para horizontes más largos.

Por esta razón, para pronósticos de dos o más meses se recurre a modelos ARIMA con estacionalidad, bajo el supuesto de que el precio en el periodo $t+1$ es conocido y corresponde al valor pronosticado por los modelos descritos previamente. En la mayoría de los casos, el número máximo de parámetros del modelo ARIMA se selecciona con base en el que minimiza el error de pronóstico a un mes, una vez incorporada la información del periodo $t+1$.

En el caso del aceite, la variable dependiente es también la variación mensual del precio. Como variable explicativa se incluyen tres rezagos del índice de precios de materias primas importadas correspondiente a granos, calculado por el BCCR, dado que la mayoría de los aceites se producen a partir de estos insumos. Se permite que los errores sigan un proceso ARIMA con componente estacional y un máximo de un parámetro.

Para el arroz, se estima un modelo ARIMA sin componente estacional, en el que se permite un máximo de un parámetro. En este caso, no se incorporan variables exógenas, dado que el comportamiento del precio puede explicarse adecuadamente mediante la dinámica propia de la serie.

Otros servicios para el hogar regulados:

En el caso del servicio de electricidad, la Autoridad Reguladora de los Servicios Públicos (ARESEP) realiza ajustes tarifarios de manera ordinaria en los meses de enero, abril, julio y octubre. Con base en esta regularidad, se construye una serie trimestral de precios de la electricidad, sobre la cual se estima un modelo ARIMA con componente estacional. Este

modelo permite pronosticar el ajuste esperado en el precio en el próximo mes en que ARESEP realiza una revisión tarifaria. Para los meses restantes, se asume que la variación mensual del precio es nula, en línea con la práctica regulatoria observada.

En contraste, el comportamiento del precio del servicio de agua presenta una dinámica más irregular. Las variaciones tarifarias han sido poco frecuentes y no se concentran en meses específicos, lo que dificulta anticipar el momento en que ARESEP realizará un nuevo ajuste. Por esta razón, y con base en el desempeño fuera de muestra durante el período de selección (2021–2023), se concluye que la mejor estrategia de pronóstico consiste en asumir una variación mensual igual a cero.[9]

4. Resultados para IPC general

A partir de los pronósticos individuales de precios para cada uno de los artículos incluidos en el IPC, y utilizando sus ponderaciones respectivas, se construye un pronóstico de la inflación agregada. En la Figura 1 se presentan los resultados para el período comprendido entre enero de 2021 y diciembre de 2024. Como es habitual en la literatura, se utiliza h para denotar el horizonte de pronóstico, es decir, el número de meses hacia adelante.

Es importante señalar que el período 2021–2023 fue utilizado para la selección de los modelos, por lo que el año 2024 constituye un ejercicio genuino de evaluación fuera de muestra.

En el gráfico 1a se muestran los pronósticos de inflación a uno y tres meses. En general, los pronósticos a un mes presentan una alta concordancia con la inflación observada. En contraste, los pronósticos a tres meses muestran mayores desviaciones, especialmente hacia finales de 2021 e inicios de 2022, cuando la inflación experimentó un aumento significativo. No obstante, incluso en ese contexto, los modelos anticipaban una trayectoria ascendente, aunque de menor magnitud que la observada.

El gráfico 1b presenta un gráfico tipo spaghetti con los pronósticos de inflación para horizontes de uno a seis meses. Para facilitar la interpretación, se utilizan líneas punteadas de distintos colores. Se observa que, aunque los pronósticos subestimaron la inflación durante el pico inflacionario de 2022, sí capturaron la tendencia ascendente. Asimismo, antes del punto

[9] Este resultado subraya la importancia de que el Banco Central de Costa Rica mantenga un seguimiento sistemático de las resoluciones de precios aprobadas por ARESEP para los bienes y servicios regulados que forman parte del IPC.

Gráfico 1. Pronósticos de variación interanual del IPC. 2021-2024.

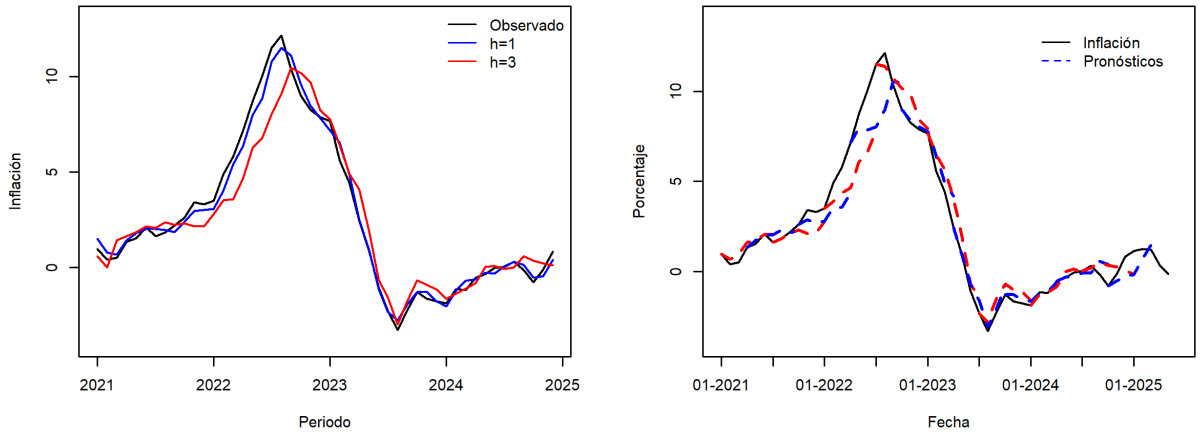

(a) Pronósticos para $h = 1$ y $h = 3$.

(b) Gráfico de *Spaghetti* para pronósticos $h = 1$ a $h = 6$.

Fuente: Elaboración propia.

máximo observado en agosto de 2022, los modelos ya anticipaban una desaceleración en la inflación.

Desde finales de 2022, los pronósticos han mostrado una alta precisión en todos los horizontes, y han sido capaces de anticipar el punto de inflexión que se observó en setiempre de 2023.

Cuadro 1. Medidas de bondad de ajuste para pronósticos a 1 y 3 meses. 2021-2024

	1 mes					3 meses				
	2021	2022	2023	2024	Todos	2021	2022	2023	2024	Todos
RECM	0.31	0.68	0.39	0.26	0.44	0.63	2.14	0.76	0.50	1.21
EAM	0.28	0.62	0.28	0.21	0.35	0.50	1.84	0.66	0.40	0.85
U-Theil	0.67	0.57	0.30	0.51	0.47	0.71	0.70	0.22	0.64	0.50
Sesgo	0.04	-0.36	0.17	-0.03	-0.04	-0.08	-1.33	0.66	0.11	-0.16
Signo	1.00	0.92	0.92	0.92	0.94	0.75	1.00	1.00	0.83	0.90

Fuente: Elaboración propia

Notas: Las siglas corresponden a RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: coeficiente de exactitud de Theil, Sesgo: error medio de pronóstico y signo: porcentaje de meses para los que el signo de la diferencia entre el pronóstico y la última inflación observada coincide con el signo del cambio en la inflación observada.

En el cuadro 1 se presentan diversas métricas de evaluación para los pronósticos a uno y tres meses: raíz del error cuadrático medio (RECM), error absoluto medio (EAM), coeficiente

de Theil (U-Theil), sesgo y precisión del signo[10]. Todas las métricas, excepto la del signo, coinciden en que el año 2022 fue el de menor precisión, lo cual es esperable dada la magnitud y velocidad de los cambios inflacionarios en ese periodo. En contraste, los resultados para 2024, año no utilizado en la selección de los modelos, muestran una mejora sustancial en la precisión de los pronósticos.

Cabe destacar el desempeño del coeficiente U de Theil, que compara el error cuadrático medio del modelo con el de un pronóstico ingenuo (en el que se asume que la inflación futura es igual a la última observada). En todos los casos, la metodología basada en pronósticos por artículo supera ampliamente al enfoque ingenuo.

En el cuadro 2 se presenta los resultados de las métricas de ajuste para los pronósticos a un mes, comparando la metodología basada en artículos individuales con los modelos FAVAR desarrollados por Segura-Rodriguez (2024).[11]

Cuadro 2. Comparación medidas de bondad de ajuste para pronósticos a 1 mes. 2021-2024

	2021			2022			2023			2024		
	Art	Fac	Prom	Art	Fac	Prom	Art	Fac	Prom	Art	Fac	Prom
RECM	0.28	0.30	0.28	0.68	0.70	0.64	0.39	0.32	0.34	0.26	0.37	0.30
EAM	0.26	0.25	0.24	0.62	0.49	0.52	0.28	0.20	0.23	0.21	0.30	0.25
U-Theil	0.58	0.63	0.58	0.57	0.59	0.54	0.30	0.25	0.26	0.51	0.80	0.58
Sesgo	0.00	-0.04	-0.08	-0.36	-0.03	-0.19	0.17	0.07	0.13	-0.03	0.02	-0.05
Signo	1.00	0.82	0.91	0.92	0.92	1.00	0.92	1.00	1.00	0.92	0.83	0.92

Fuente: Elaboración propia a partir de Segura-Rodriguez (2024) e información interna del BCCR.
Notas: Para 2021, las medidas corresponden al periodo de febrero a diciembre. Las siglas corresponden a RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: coeficiente de exacitud de Theil, Sesgo: error medio de pronóstico y signo: porcentaje de meses para los que el signo de la diferencia entre el pronóstico y la última inflación observada coincide con el signo del cambio en la inflación observada.

Los resultados obtenidos al comparar la metodología basada en pronósticos por artículo con los modelos FAVAR desarrollados por Segura-Rodriguez (2024) son mixtos. Las métricas de evaluación son similares en términos generales, aunque varían según el año y la medida

[10] Corresponde al porcentaje de meses en que la diferencia entre el pronóstico y la última inflación observada es igual al signo de la variación en la inflación observada.

[11] El Banco Central de Costa Rica dispone de otros modelos de pronóstico; sin embargo, no se cuenta con una serie histórica de pronósticos generados desde 2021 para todos ellos. Por esta razón, la comparación se limita al modelo FAVAR con promedio bayesiano.

considerada. En particular, la metodología por artículos presenta una menor raíz del error cuadrático medio (RECM) en tres de los cuatro años analizados, mientras que los modelos FAVAR muestran un menor error absoluto medio (EAM).[12]

Estos resultados sugieren que ambos enfoques son complementarios y que su uso conjunto puede mejorar la precisión de los pronósticos. Para ilustrar este punto, se incluye una tercera columna en el cuadro comparativo que presenta las métricas de ajuste para el promedio simple de ambos modelos. En la mayoría de los casos, este promedio genera pronósticos más precisos que los obtenidos por cualquiera de los modelos por separado, o al menos casi tan precisos como el mejor de ellos.[13]

El Cuadro 7, incluido en el Apéndice 7.1, presenta los resultados para pronósticos a tres meses. En este caso, los modelos FAVAR tienden a mostrar un mejor desempeño en un mayor número de ocasiones. Este resultado es coherente con la naturaleza de los modelos: la metodología por artículos, al incorporar información detallada y actualizada sobre precios específicos, es particularmente útil para horizontes de corto plazo, mientras que los modelos FAVAR, al capturar factores comunes, pueden ser más robustos para horizontes más largos.[14]

4.1. Impacto de los modelos ARIMAX

Uno de los objetivos centrales de esta investigación es evaluar si la incorporación de modelos específicos ARIMAX para ciertos artículos mejora la precisión del pronóstico de la inflación agregada.[15]

En el gráfico 2 se muestra el impacto de excluir los modelos específicos y utilizar, en su lugar, el modelo ARIMA general para cada artículo. En el panel izquierdo (2a), correspondiente al período 2021–2023, se observa que para la mayoría de los productos, tanto el EAM como la RECM se reducen significativamente al utilizar modelos específicos. Entre los artículos con

[12] Esta diferencia no es contradictoria: la RECM penaliza más fuertemente los errores extremos, por lo que una menor RECM indica que el modelo por artículos genera menos errores severos, mientras que un menor EAM sugiere que los errores promedio son más pequeños en el modelo FAVAR.

[13] Este resultado se explica por dos factores: (i) en aproximadamente un 23 % de los meses, los errores de ambos modelos tienen signos opuestos, lo que permite que el promedio los compense; y (ii) cuando los errores tienen el mismo signo, el promedio tiende a suavizar su magnitud.

[14] No obstante, según la pruebas de Diebold-Mariano (Diebold y Mariano, 1995) y de permutaciones de Döhrn (2019), en ningún caso se puede afirmar que el modelo FAVAR o el promedio superen estadísticamente al modelo por artículos, o viceversa.

[15] Los artículos seleccionados corresponden a aquellos con mayor RECM ponderado en los modelos ARIMA generales, como se explicó en la sección de metodología.

mayores mejoras se encuentran la gasolina, la electricidad y la cebolla.[16]

Sin embargo, también se identifican casos, como el tomate y la telefonía móvil, en los que el uso de modelos específicos incrementa el error de pronóstico. Esta dicotomía puede explicarse por la interacción entre los errores individuales y su agregación: como se discutió en la introducción, la agregación de errores puede amplificar o atenuar el error total, dependiendo de la correlación entre los errores individuales, y en este análisis la selección del modelo específico se realizó con base en la minimización de los errores individuales.

Gráfico 2. Medidas de bondad de ajuste $h = 1$ al excluir modelo específico para un bien

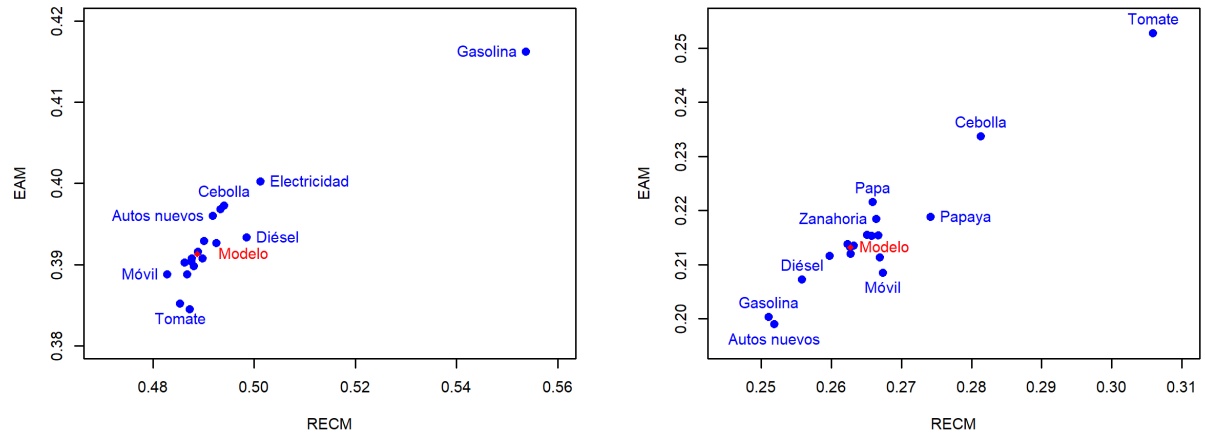

(a) 2021-2023 **(b)** 2024

En el gráfico 2b se presentan los resultados para el año 2024, que no fue utilizado en la selección de los modelos. A pesar de ello, se observa que para un número considerable de productos, la exclusión del modelo específico incrementa los errores de pronóstico. No obstante, los productos para los que se observa una mejora varían entre periodos, lo que sugiere la necesidad de una revisión periódica de los artículos y modelos seleccionados.

Finalmente, en el gráfico 3 se muestra la reducción en las métricas de ajuste para el recio de cada bien al utilizar modelos específicos en lugar de los modelos generales. En el panel izquierdo (3a), correspondiente al período 2021–2023, destacan productos como el servicio de agua, la cebolla, la gasolina, el tomate y la zanahoria. De los 19 productos seleccionados, en 12 casos la prueba de Diebold-Mariano concluye, al 10 %, que los modelos ARIMAX son estadísticamente superiores.[17]

En el gráfico 3b se presenta la reducción en las medidas de bondad de ajuste para el año

[16] La prueba de Diebold-Mariano indica que, al 5 %, los modelos específicos generan pronósticos significativamente más precisos para la gasolina, el arroz y los paquetes turísticos al extranjero; y al 10 %, para los huevos y el diésel. En sentido

Gráfico 3. Reducción de medidas de bondad de ajuste con modelos específicos

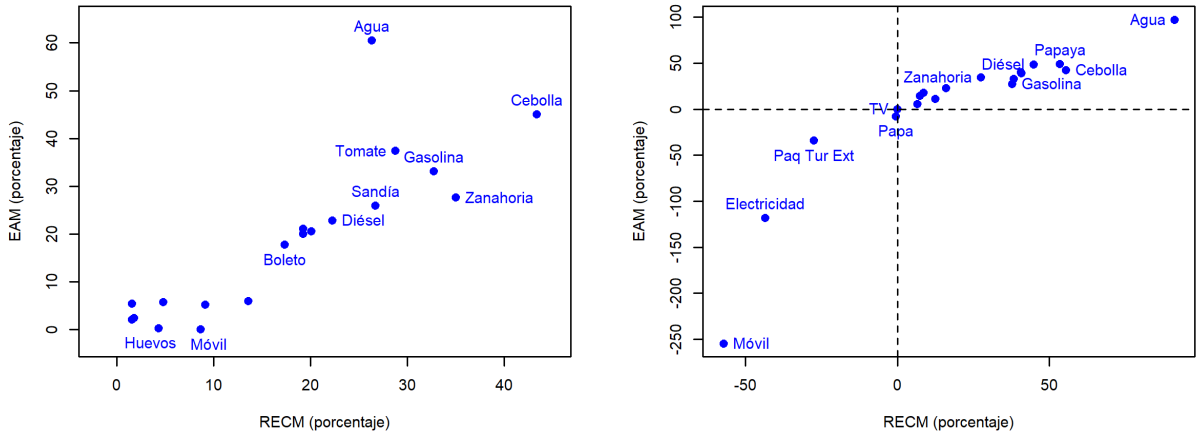

(a) 2021-2023 **(b)** 2024

2024, al utilizar modelos específicos ARIMA-X en lugar de los modelos ARIMA generales. A pesar de que los modelos específicos fueron seleccionados con base en el desempeño durante el período 2021–2023, se observa que para la mayoría de los productos se mantiene una mejora en la precisión del pronóstico. Solo en tres casos —electricidad, telefonía móvil y paquetes turísticos al extranjero— el modelo ARIMA-X genera errores mayores. En los dos últimos casos, la alta volatilidad de los precios dificulta su predicción. En el caso de la electricidad, factores climáticos no incluidos en el modelo provocaron un aumento inesperado en los costos de generación, lo que derivó en precios más altos.

Debido a que estas métricas no capturan todos los cambios en la distribución de los errores de pronóstico, el gráfico 4 complementa este análisis al presentar la distribución de los errores de pronóstico a un mes para los modelos ARIMA y ARIMAX, en el caso de cuatro productos representativos: gasolina, boleto aéreo, tomate y cebolla. En todos los casos, se observa que los errores del modelo ARIMAX están más concentrados alrededor de cero y presentan colas menos pronunciadas, lo que indica una reducción en la frecuencia de errores extremos.

Estos resultados refuerzan la utilidad de incorporar información adicional y modelos individualizados para mejorar la precisión del pronóstico de inflación. Al mismo tiempo, resaltan la necesidad de realizar una revisión constante de los modelos que se utilizan para cada uno de los artículos.

contrario, solo para la zanahoria se encuentra evidencia (al 10 %) de que el modelo general es superior.

[17] Los siete productos para los que no se encuentra evidencia estadística de superioridad del modelo ARIMAX son: arroz, huevos, aceite, culantro, electricidad, automóviles nuevos y telefonía móvil. En ninguno de estos casos se concluye que el modelo general sea superior.

Gráfico 4. Distribución de errores de pronóstico $h = 1$ con modelos ARIMA y ARIMA-X para algunos bienes. 2021-2024.

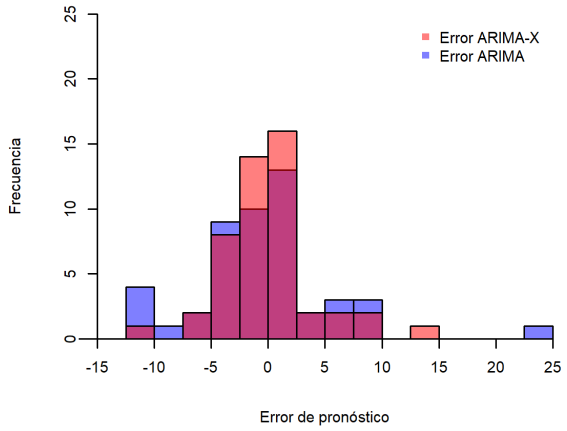

(a) Gasolina

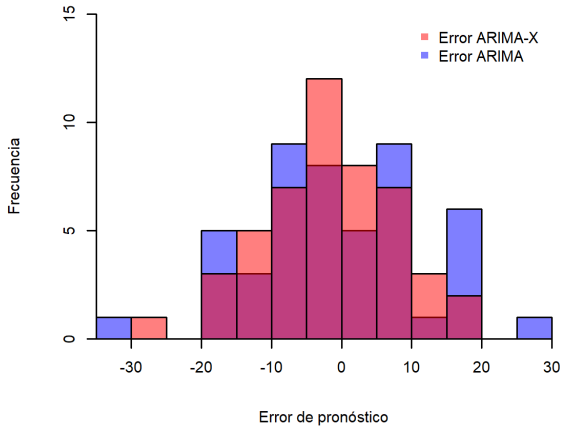

(b) Boleto aéreo

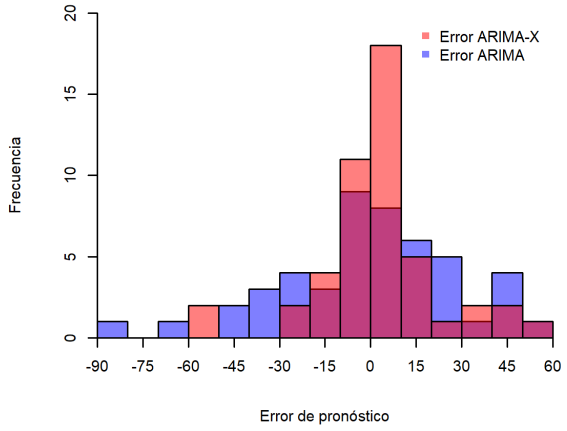

(c) Tomate

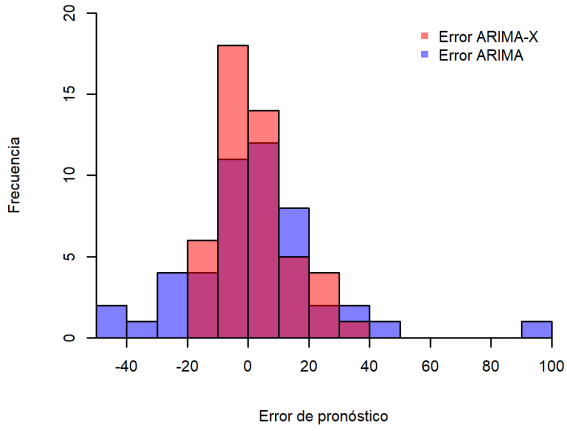

(d) Cebolla

4.2. Modelos alternativos

Como se discutió en la revisión de literatura, no existe consenso en cuanto a la superioridad de los modelos desagregados frente a los modelos agregados para el pronóstico de la inflación. Con el fin de evaluar la utilidad de la metodología propuesta en este estudio, se desarrollaron cinco modelos alternativos para el caso de Costa Rica. Estos modelos permiten comparar el desempeño de la metodología por artículos con enfoques más agregados:

- **ARIMA agregado:** Modelo ARIMA de la variación mensual del IPC, sin variables exógenas.
- **ARIMAX agregado:** Modelo ARIMA de la variación mensual del IPC, con variables exógenas como el tipo de cambio, el precio de los hidrocarburos, el precio del crudo WTI, el precio de importación de granos y un índice ponderado de precios de ferias del agricultor.[18]
- **ARIMA por divisiones:** Modelos ARIMA para la variación mensual del índice de cada una de las 13 divisiones del IPC, sin variables exógenas. Los pronósticos se agregan para obtener la inflación total.
- **ARIMAX por divisiones:** Igual al modelo anterior, pero incorporando variables exógenas relevantes para cada división.
- **ARIMA por artículos:** Modelos ARIMA para la variación mensual del precio de cada uno de los 289 artículos del IPC, sin variables exógenas.

En todos los casos, el modelo ARIMA se seleccionan utilizando la función auto.arima, y el número máximo de parámetros que se permite en dicha selección se determina con base en la minimización del error absoluto medio durante el período 2021–2023.

El Cuadro 3 presenta las medidas de bondad de ajuste para los pronósticos a uno y tres meses generados por los cinco modelos alternativos descritos anteriormente, así como por el modelo principal desarrollado en este estudio, denominado ARIMAX por artículos. En todos los casos, este último modelo presenta los menores valores en las métricas de error, lo que constituye un primer indicio de que la metodología propuesta aporta información adicional

[18] El índice de precios de ferias se construye ponderando los precios por su participación relativa en el IPC, con base en diciembre de 2020.

relevante para el pronóstico de la inflación.

Cuadro 3. Estadísticos de bondad de ajuste para pronósticos a 1 y 3 meses. 2021-2024

		RECM	EAM	U-Theil	Sesgo	Signo
1 mes	ARIMA agregado	0.54	0.38	0.57	-0.02	0.85
	ARIMAX agregado	0.45	0.39	0.48	-0.09	0.85
	ARIMA por divisiones	0.88	0.70	0.92	-0.63	0.52
	ARIMAX por divisiones	0.76	0.65	0.80	-0.64	0.65
	ARIMA por artículos	0.55	0.40	0.58	0.00	0.90
	ARIMAX por artículos	0.44	0.35	0.47	-0.04	0.94
3 meses	ARIMA agregado	1.47	1.08	0.61	0.00	0.83
	ARIMAX agregado	1.53	1.07	0.64	-0.28	0.81
	ARIMA por divisiones	1.66	1.11	0.69	-0.59	0.63
	ARIMAX por divisiones	1.44	0.99	0.60	-0.69	0.71
	ARIMA por artículos	1.42	1.02	0.59	-0.01	0.85
	ARIMAX por artículos	1.21	0.85	0.50	-0.16	0.90

Fuente: Elaboración propia

Notas: Las siglas corresponden a RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: coeficiente de exactitud de Theil, Sesgo: error medio de pronóstico y signo: porcentaje de meses para los que el signo de la diferencia entre el pronóstico y la última inflación observada coincide con el signo del cambio en la inflación observada.

Además, del análisis del cuadro se desprenden tres conclusiones adicionales. Primero, para el horizonte de un mes, el modelo ARIMAX agregado, que modela directamente la inflación agregada e incorpora variables exógenas, muestra un desempeño muy similar al del modelo ARIMAX por artículos. Este resultado es relevante, ya que se trata de una especificación más sencilla que aprovecha la misma información disponible. Sin embargo, esta ventaja desaparece al considerar horizontes de tres meses, donde el modelo por artículos mantiene un mejor desempeño.

Segundo, el modelo ARIMA por artículos, que pronostica los precios desagregados sin incluir variables exógenas, presenta un desempeño comparable al del modelo ARIMA agregado. Este hallazgo es consistente con la literatura, que ha documentado que los modelos desagregados no necesariamente superan a los modelos agregados cuando no se incorpora información adicional relevante (véase Benalal et al. (2004); Hubrich (2005); Harvey y Cushing (2014)). Esto subraya la importancia de los modelos ARIMAX por artículos, que permiten capturar dinámicas específicas de ciertos productos.

Tercero, los modelos estimados a nivel de división del IPC, tanto con como sin variables exógenas, son los que presentan menor precisión en los pronósticos. Este resultado coincide con lo reportado por Bermingham y D'Agostino (2014) y Duarte y Rua (2005), quienes concluyen que la precisión de los pronósticos mejora a medida que se utiliza información más desagregada.

El Cuadro 4 presenta los valores-p de dos pruebas estadísticas utilizadas para comparar la precisión de los pronósticos generados por los distintos modelos. La primera corresponde a la prueba de Diebold-Mariano (Diebold y Mariano, 1995), con el ajuste propuesto por Harvey, Leybourne y Newbold (1997) para muestras pequeñas. La segunda es una prueba de permutación de errores desarrollada por Döhrn (2019). En ambos casos, se emplean pruebas unilaterales, donde la hipótesis alternativa plantea que el modelo ARIMA-X por artículos genera pronósticos más precisos que los modelos alternativos.

Cuadro 4. Valores-p para pruebas de comparación de certeza de los pronósticos. 2021-2024.

	Diebold-Mariano		Prueba de permutaciones	
	1 mes	3 meses	1 mes	3 meses
ARIMA agregado	0.09	0.02	0.09	0.01
ARIMAX agregado	0.39	0.07	0.40	0.08
ARIMA por divisiones	0.00	0.07	0.00	0.00
ARIMAX por divisiones	0.00	0.09	0.00	0.01
ARIMA por artículos	0.01	0.03	0.01	0.00

Notas: Valores-p corresponden a la prueba de una cola, en la que la hipótesis alternativa es que el modelo ARIMAX por artículos genera pronósticos más precisos que el modelo alternativo, con base en el error cuadrático medio.

Los resultados muestran que, con un nivel de significancia de al menos el 10 % (y en muchos casos menor), se rechaza la hipótesis nula de igualdad de precisión en favor del modelo propuesto en este estudio, en todos los casos excepto uno: el pronóstico a un mes generado por el modelo ARIMA-X agregado. Este resultado refuerza la conclusión de que la metodología basada en precios desagregados con variables exógenas específicas proporciona una mejora estadísticamente significativa en la precisión de los pronósticos de inflación.

5. Extensiones

En esta sección se presentan los resultados obtenidos al aplicar la metodología propuesta en dos contextos adicionales: (i) el pronóstico de inflación por divisiones del IPC, y (ii) el pronóstico de indicadores de inflación subyacente.

5.1. Resultados para inflación por grupos

El Cuadro 5 muestra la raíz del error cuadrático medio (RECM) de los pronósticos de la variación interanual de precios para las siete divisiones con mayor peso dentro de la canasta del IPC, las cuales en conjunto representan más del 78 % de la ponderación total. Como se ha documentado en la literatura (Hubrich, 2005; Benalal et al., 2004; Ramírez y Ramírez, 2019), existen grupos de artículos que presentan mayores dificultades de pronóstico que otros.

Cuadro 5. RECM para pronósticos a 1 y 3 meses para algunas divisiones. 2021-2024

	1 mes					3 meses				
	2021	2022	2023	2024	Todos	2021	2022	2023	2024	Todos
IPC	0.31	0.68	0.39	0.26	0.44	0.63	2.14	0.76	0.50	1.21
Alimentos y bebidas no alcohólicas	0.91	1.38	0.84	0.59	0.97	2.05	4.42	1.97	1.05	2.68
Transporte	0.51	2.68	1.10	0.80	1.52	1.59	7.14	2.37	2.15	3.99
Alquiler y servicios de la vivienda	0.76	1.35	1.14	0.93	1.07	1.29	2.53	1.92	1.60	1.89
Información y comunicación	1.23	1.52	1.52	1.31	1.40	1.70	2.56	1.62	2.21	2.06
Bienes y servicios diversos	0.35	0.60	0.35	0.41	0.44	0.68	1.29	0.68	0.92	0.93
Salud	0.26	0.22	0.28	0.21	0.25	0.51	0.49	0.60	0.45	0.52
Comidas fuera del hogar y alojamiento	0.33	0.32	0.26	0.18	0.28	0.50	1.18	0.77	0.22	0.77

Fuente: Elaboración propia

Notas: Las siglas corresponden a RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: coeficiente de exactitud de Theil, Sesgo: error medio de pronóstico y signo: porcentaje de meses para los que el signo de la diferencia entre el pronóstico y la última inflación observada coincide con el signo del cambio en la inflación observada.

Los resultados indican que, para el horizonte de un mes, las divisiones más difíciles de pronosticar son transporte, información y comunicación, y alquiler y servicios de la vivienda. Por el contrario, las divisiones con mayor precisión en los pronósticos son salud y comidas fuera del hogar y servicios de alojamiento. Esta clasificación se mantiene en gran medida para el horizonte de tres meses.

Cabe destacar el caso de la división de alimentos y bebidas no alcohólicas: aunque ocupa el cuarto lugar en términos de RECM a un mes, se convierte en la segunda división con mayor error a tres meses. Esta diferencia se explica por la utilidad de la información proveniente de las ferias del agricultor, que mejora significativamente los pronósticos de corto plazo, pero cuya efectividad disminuye en horizontes más largos. Estos hallazgos son consistentes con la literatura, que identifica a los precios de alimentos y transporte —especialmente aquellos vinculados al petróleo— como los más difíciles de anticipar.

5.2. Pronósticos de inflación subyacente

En línea con la literatura, también se analiza si los indicadores de inflación subyacente son más fáciles de pronosticar que la inflación general. El Cuadro 6 presenta los resultados para tres indicadores de inflación subyacente calculados por el Banco Central de Costa Rica:

- Índice de Exclusión Fija (IEF): excluye artículos con alta volatilidad o estacionalidad (alimentos, combustibles y bienes regulados).
- Índice de Exclusión por Volatilidad (IEV): excluye los bienes con mayor variabilidad histórica.
- Índice de Reponderación por Persistencia (IRP): asigna mayor peso a los artículos con mayor persistencia en sus variaciones de precio.

Para el horizonte de un mes, las diferencias entre los indicadores son reducidas. El IRP muestra los menores errores (RECM y EAM), mientras que el IEF y el IEV presentan resultados similares a los del IPC general. Sin embargo, el coeficiente U de Theil es considerablemente menor para la inflación general, lo que sugiere que los modelos específicos logran reducir de forma significativa los errores de pronóstico para productos volátiles incluidos en el IPC, pero excluidos de los indicadores subyacentes.

Cuadro 6. Estadísticos de bondad de ajuste para pronósticos a 1 y 3 meses. 2024

	1 mes				3 meses			
	IPC	IEF	IEV	IRP	IPC	IEF	IEV	IRP
RECM	0.26	0.29	0.23	0.16	0.50	0.49	0.27	0.32
EAM	0.21	0.26	0.20	0.12	0.40	0.26	0.24	0.28
U-Theil	0.51	0.84	0.62	0.90	0.64	0.92	0.47	0.76
Sesgo	-0.03	-0.03	-0.09	0.05	0.11	0.15	-0.08	0.27
Signo	0.92	0.66	0.92	0.83	0.83	0.66	1.00	0.83

Fuente: Elaboración propia

Notas: Las siglas corresponden a RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: coeficiente de exactitud de Theil, Sesgo: error medio de pronóstico y signo: porcentaje de meses para los que el signo de la diferencia entre el pronóstico y la última inflación observada coincide con el signo del cambio en la inflación observada. El indicador IEF corresponde al Índice de Exclusión Fija, el IEV al Índice de Exclusión por Volatilidad y el IRP al Índices de Reponderación por Persistencia, que son tres de los índices de inflación subyacente que publica el BCCR.

En contraste, para el horizonte de tres meses, los indicadores de inflación subyacente presentan errores de pronóstico notablemente menores que la inflación general. En particular, el IEV muestra un coeficiente U de Theil inferior al del IPC, lo que indica una mayor precisión relativa frente a un pronóstico ingenuo. Este resultado refleja que la información coyuntural utilizada en los modelos específicos es muy útil para pronósticos de corto plazo, pero pierde efectividad en horizontes más largos, especialmente para productos como alimentos y combustibles.

6. Conclusiones

Este estudio propone una metodología para el pronóstico de la inflación en Costa Rica basada en la desagregación de los precios de los artículos que componen el Índice de Precios al Consumidor (IPC), utilizando modelos ARIMA y ARIMAX con variables exógenas específicas para ciertos productos. A partir de la estimación de modelos individuales para cada artículo y la posterior agregación de los pronósticos, se construye una estimación de la inflación general. Los resultados obtenidos permiten extraer varias conclusiones relevantes, tanto desde el punto de vista metodológico como empírico.

En primer lugar, se demuestra que la incorporación de información específica —como el tipo de cambio, los precios internacionales de materias primas y los precios observados en las

ferias del agricultor— mejora significativamente la precisión de los pronósticos, especialmente en horizontes de corto plazo. Esta mejora es particularmente evidente en productos con alta volatilidad o fuerte dependencia de factores externos, como los hidrocarburos, los alimentos frescos y los bienes importados.

Uno de los principales aportes de este trabajo es el uso de los precios semanales publicados por el Consejo Nacional de Producción (CNP) para productos agrícolas. Esta fuente permite anticipar el comportamiento de precios que, por su naturaleza, son difíciles de pronosticar. Asimismo, para productos regulados, se aprovechan las características institucionales de la fijación de precios, como la estacionalidad en los ajustes de tarifas, lo que mejora la capacidad predictiva de los modelos.

En segundo lugar, se encuentra que el enfoque desagregado con variables exógenas (ARIMAX por artículos) supera sistemáticamente a modelos alternativos más agregados, tanto en métricas de error como en pruebas estadísticas de comparación de precisión. Aunque el modelo ARIMAX agregado ofrece resultados similares a un mes, su desempeño se deteriora en horizontes más largos, donde el modelo por artículos mantiene una ventaja clara. Esta ventaja es fundamental en términos de política monetaria debido a que el Banco Central tiene interés en anticipar la senda futura de la inflación más allá del horizonte de un mes.

En tercer lugar, se evidencia que los modelos específicos ARIMAX permiten reducir los errores extremos y mejorar la distribución de los errores de pronóstico. No obstante, su efectividad varía entre periodos, lo que sugiere la necesidad de una revisión periódica de los artículos seleccionados y de los modelos utilizados.

Además, se confirma que los pronósticos de inflación subyacente —especialmente aquellos basados en exclusión por volatilidad o reponderación por persistencia— presentan menor error en horizontes de mediano plazo. Sin embargo, gracias a la inclusión de información específica, la metodología propuesta logra conseguir medidas de bondad de ajuste para la inflación general similares o incluso mejores a la que se obtiene para estos indicadores en horizontes de un mes, lo que resalta su utilidad para el seguimiento coyuntural de la inflación.

Los resultados también permiten extraer tres implicaciones metodológicas adicionales:

- La inclusión de información adicional mejora la precisión de los pronósticos, especialmente en productos con alta volatilidad o precios regulados.

- Los pronósticos son más certeros cuando se utiliza el mayor nivel de desagregación posible, en línea con lo señalado por Bermingham y D'Agostino (2014), mientras que los niveles intermedios de agregación (por divisiones) tienden a ser menos precisos, inclusive que los más agregados.
- El uso de pronósticos indirectos a partir de componentes desagregados no garantiza una mejora en la precisión, a menos que se incorporen variables exógenas relevantes.

Finalmente, la metodología propuesta tiene un valor práctico significativo para el Banco Central de Costa Rica, ya que puede complementar los modelos actuales de pronóstico de inflación de corto plazo. En particular, permite aprovechar que el BCCR recopila regularmente los precios fijados para los bienes regulados, lo que posibilita considerar estos precios como conocidos para horizontes de corto plazo. Esta información contribuiría a mejorar aún más la precisión de los pronósticos y a fortalecer la base informativa para la toma de decisiones de política monetaria en el marco de un régimen de metas de inflación.

Referencias

Barker, T. S. y Pesaran, M. H. (2014). Disaggregation in econometric modelling—an introduction. In *Disaggregation in Econometric Modelling (Routledge Revivals)* (pp. 1–14). Routledge.

Benalal, N., Diaz del Hoyo, J. L., Landau, B., Roma, M., y Skudelny, F. (2004). To aggregate or not to aggregate? Euro area inflation forecasting. *Euro Area Inflation Forecasting (July 2004)*.

Bermingham, C. y D'Agostino, A. (2014). Understanding and forecasting aggregate and disaggregate price dynamics. *Empirical Economics*, *46*(2), 765–788.

Boaretto, G. y Medeiros, M. C. (2023). Forecasting inflation using disaggregates and machine learning. *arXiv preprint arXiv:2308.11173*.

Carlo, T. C. y Marçal, E. F. (2016). Forecasting Brazilian inflation by its aggregate and disaggregated data: a test of predictive power by forecast horizon. *Applied Economics*, *48*(50), 4846–4860.

Chavarría Mejía, J. D. y Chaverri Morales, C. (2015). Pronósticos de inflación mediante técnicas bayesianas. *Economía y Sociedad*, *20*(48), 1–27.

Cobb, M. (2009). Forecasting Chilean inflation from disaggregate components. *Documentos de Trabajo (Banco Central de Chile)*, (545), 1.

Demers, F. y De Champlain, A. (2005). Forecasting core inflation in canada: should we forecast the aggregate or the components? Technical report, Bank of Canada.

Diebold, F. X. y Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business & economic statistics*, *20*(1), 134–144.

Döhrn, R. (2019). *Comparing forecast accuracy in small samples*. Número 833. Ruhr Economic Papers.

Duarte, C. y Rua, A. (2005). *Forecasting inflation through a bottom-up approach: the Portuguese case*. Economics Research Department, Banco de Portugal.

Grunfeld, Y. y Griliches, Z. (1960). Is aggregation necessarily bad? *The review of economics and statistics*, 1–13.

Harvey, D., Leybourne, S., y Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of forecasting*, *13*(2), 281–291.

Harvey, S. K. y Cushing, M. J. (2014). Does Using Disaggregate Components Help in Producing Better Forecasts for Aggregate Inflation? *Journal of Economics and Development Studies*, *2*(2), 527–546.

Hubrich, K. (2005). Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy? *International Journal of Forecasting*, *21*(1), 119–136.

Martínez-Rivera, W., González-Molano, E. R., y Caicedo-García, E. (2023). Forecasting Inflation from Disaggregated Data: The Colombian case. *Borradores de Economía; No. 1251*.

Muñoz, T. y Quiñónez, J. (2025). Evaluación de pronóstico de inflación: una comparación de enfoques agregados y desagregados. *Documento de Trabajo SECMCA-03-2025. Secretaría Ejecutiva del Consejo Monetario Centroamericano*.

Ramírez, F. A. y Ramírez, N. F. (2019). Pronóstico de la inflación de corto plazo a partir de un modelo de inflación por artículos (MIPA) en la República Dominicana. *Documentos de trabajo. Banco Central de República Dominicana*.

Segura-Rodriguez, C. (2024). Modelos FAVAR con factores estáticos y dinámicos para pronosticar la inflación en Costa Rica. *DT-03-2024. Departamento de Investigación Económica. Banco Central de Costa Rica*.

Taylor, J. B. (1993). Discretion versus policy rules in practice. In *Carnegie-Rochester conference series on public policy*, volumen 39, (pp. 195–214). Elsevier.

Theil, H. y Theil, H. (1954). Linear aggregation of economic relations.

Timmermann, A. (2006). Forecast combinations. *Handbook of economic forecasting*, *1*, 135–196.

Vindas Quesada, A., Brenes Soto, C., Jiménez Montero, S., Jiménez Morales, A., y Sandí Esquivel, A. (2024). Pronósticos univariados de inflación en Costa Rica: evaluación y selección de modelos. *NT-05-2024. Departamento de Investigación Económica. Banco Central de Costa Rica*.

7. Apéndice

7.1. Medidas de bondad de ajuste para modelos de artículos y factores

Cuadro 7. Comparación medidas de bondad de ajuste para pronósticos a 3 meses. 2021-2024

	2021			2022			2023			2024		
	Art	Fac	Prom	Art	Fac	Prom	Art	Fac	Prom	Art	Fac	Prom
RECM	0.64	0.71	0.64	2.14	2.16	2.01	0.76	0.75	0.71	0.50	0.38	0.40
EAM	0.48	0.53	0.45	1.88	1.87	1.83	0.66	0.55	0.56	0.40	0.31	0.31
U-Theil	0.65	0.74	0.65	0.70	0.70	0.65	0.22	0.21	0.20	0.64	0.48	0.51
Sesgo	-0.12	-0.42	-0.34	-1.33	-0.10	-0.69	0.66	0.33	0.51	0.11	0.10	0.11
Signo	0.80	0.80	0.80	1.00	0.83	1.00	1.00	1.00	1.00	0.83	0.83	0.92

Fuente: Elaboración propia a partir de Segura-Rodriguez (2024) e información interna del BCCR.

Notas: Para 2021, las medidas corresponden al periodo de abril a diciembre. Las siglas corresponden a RECM: raíz del error cuadrático medio, EAM: error absoluto medio, U-Theil: coeficiente de exacitud de Theil, Sesgo: error medio de pronóstico y signo: porcentaje de meses para los que el signo de la diferencia entre el pronóstico y la última inflación observada coincide con el signo del cambio en la inflación observada.