



GOBIERNO DE LA  
REPÚBLICA DOMINICANA

HACIENDA

SISTEMA DE PRONÓSTICOS  
MACROECONÓMICOS DE  
CORTO PLAZO:

# Estimación y evaluación de modelos de series de tiempo

---

**José A. Vargas**

Ministerio de Hacienda de  
la República Dominicana

Julio 2022

**Ministerio de Hacienda de la República Dominicana**

Dirección General de Análisis y Política Fiscal

**Sistema de Pronósticos Macroeconómicos de Corto Plazo: estimación y evaluación de modelos de series de tiempo**

José A. Vargas

Serie de Documentos de Investigación No. 2022-01

Julio 2022

# Sistema de Pronósticos Macroeconómicos de Corto Plazo: estimación y evaluación de modelos de series de tiempo

Ministerio de Hacienda de la República Dominicana

José A. Vargas\*

julio 2022

## Resumen<sup>†</sup>

El presente documento de trabajo expone los resultados de las evaluaciones de una serie de modelos y estrategias utilizadas por la Dirección de Análisis de Política Fiscal del Ministerio de Hacienda para la realización de pronósticos macroeconómicos de corto plazo. La batería de modelos considerados comprende modelos univariantes (AR(1) y SARIMA) y multivariantes (SARIMAX, VAR, VECM, modelos de Factores Dinámicos y FAVAR). Los resultados indican que la primera clase de modelos pueden exhibir desempeño superiores a los enfoques multivariantes, especialmente cuando se sigue una especificación basada en los fundamentos económicos, para el caso del Índice de Precios al Consumidor (IPC) y el tipo de cambio nominal (TCN). Contrario a esto, para el Índice Mensual de Actividad Económica (IMAE) estas últimas estrategias presentan menores errores. En adición, los citados modelos tienden a predecir correctamente el signo de los cambios en las variables de interés en más del 90%. Respecto a la distribución de las proyecciones, el TCN y el IPC presentan una dispersión sustancialmente menor, en comparación con el IMAE, lo cual indica un mayor riesgo relativo en el caso de las previsiones del crecimiento de la economía que sobre la inflación o depreciación/apreciación nominal.

## Abstract

This working paper presents the results of evaluations of a series of economic models and strategies used by the Fiscal Policy Analysis Department of the Ministry of Finance of the Dominican Republic for short-term macroeconomic forecasts. The compendium of considered models includes univariate models (AR(1) and SARIMA) and multivariate models (SARIMAX, VAR, VECM, Dynamic-factor models and FAVAR). The results indicate that the first class of models may exhibit superior performance to multivariate approaches, especially when following a specification based on economic fundamentals, for the case of the Consumer Price Index (CPI) and the nominal exchange rate (TCN). Contrary to this, for the Monthly Index of Economic Activity (IMAE) these last strategies present fewer errors. In addition, the aforementioned models tend to correctly predict the sign of changes in the variables of interest by more than 90%. Regarding the distribution of the projections, the TCN and the CPI present a substantially smaller dispersion, compared to the IMAE, which indicates a greater relative risk in the case of forecasts of economic growth than on inflation or nominal depreciation/appreciation.

**Palabras clave:** Modelos de series temporales, pronósticos, evaluación, precisión.

**Clasificación JEL:** C15, C32, C52, C53.

---

\*jvargas@hacienda.gov.do. Los errores u omisiones que pudieran subsistir son de exclusiva responsabilidad del autor. Asimismo, las opiniones vertidas en este documento corresponden al autor y no comprometen la posición del Ministerio de Hacienda de la República Dominicana.

<sup>†</sup>El autor agradece las valiosas observaciones realizadas al documento por Camila Goris y Oliver Gonzáles.

## Contenido

<b>1. Introducción</b>	<b>1</b>
<b>2. Uso de modelos de series temporales en la práctica</b>	<b>2</b>
<b>3. Gestión y preparación de datos</b>	<b>3</b>
<b>4. Modelos de series de tiempo para pronósticos de corto plazo</b>	<b>4</b>
4.1. Modelos univariantes . . . . .	4
4.2. Modelos multivariantes . . . . .	6
<b>5. Evaluación de pronósticos</b>	<b>12</b>
<b>6. Elección de modelos</b>	<b>13</b>
<b>7. Incertidumbre de los pronósticos</b>	<b>14</b>
<b>8. Resultados</b>	<b>16</b>
Validación de los modelos estimados . . . . .	16
Análisis de desempeño . . . . .	17
Análisis de desempeño con estrategia de ventana móvil . . . . .	20
Pronósticos de las variables objetivo . . . . .	21
<b>9. Comentarios finales</b>	<b>26</b>
<b>Referencias</b>	<b>27</b>
<b>Anexos</b>	<b>29</b>

## 1. Introducción

Los hacedores de políticas económicas toman decisiones basadas en el comportamiento esperado de los fundamentales macroeconómicos (comportamiento del producto y el nivel precios, por ejemplo). De esta manera, la implementación de un sistema de pronósticos, o el uso de modelos individuales para la proyección de variables particulares, es una tarea conocida entre las autoridades rectoras de las políticas económicas, tanto de bancos centrales (política monetaria) como ministerios de hacienda (política fiscal)<sup>3</sup>.

En tal sentido, para el Ministerio de Hacienda es relevante contar con previsiones de corto y mediano plazo sobre indicadores como el crecimiento económico, la depreciación del tipo de cambio y la inflación. Atendiendo a estos requerimientos la Dirección General de Análisis y Política Fiscal (DGAPF) ha implementado una serie de modelos econométricos para pronósticos macroeconómicos en los horizontes citados. Como paso siguiente, el Departamento de Estudios Fiscales (DEF) de esta Dirección ha realizado una integración de estos modelos, con la finalidad de constituir un sistema integrado de proyecciones, Sistema de Pronósticos Macroeconómicos de Corto y Mediano Plazo (SIPMACOMP).

En coherencia con lo expuesto con anterioridad, el presente documento tiene por objetivo presentar los resultados de la estimación y evaluación de una batería de modelos para pronósticos de corto plazo implementados por el DEF y los procesos auxiliares realizados con tal finalidad. Las estrategias utilizadas integran tanto modelos univariantes como multivariantes e incluyen enfoques de estimación que permiten lidiar con valores ausentes en las series de interés, lo cual permite realizar proyecciones de tipo nowcasting (proyectar variables dentro del periodo de estimación). Esto último permite explotar toda la data disponibles para anticipar el crecimiento del Índice Mensual de Actividad Económica (IMAE), previo a su publicación, por el Banco Central de la República Dominicana (BCRD).

Los resultados de los ejercicios de pronósticos y sus evaluaciones de desempeño muestran que existen estrategias de estimación y de proyecciones claramente superiores sobre sus alternativas consideradas, aunque estas pueden variar en función del indicador o variable de interés. Específicamente, los modelos univariantes suelen tener una mayor precisión para los casos inflación y tipo de cambio, mientras que el Crecimiento del IMAE se predice mejor utilizando modelos multivariantes como VAR, especialmente cuando la especificación se basa en fundamentos macroeconómicos, o Modelos de Factores Dinámicos (MFD). En adición, los citados modelos tienden a predecir correctamente el signo de los cambios en las variables de interés en más del 90%. Respecto a la distribución de las proyecciones, el TCN y el IPC presentan una dispersión sustancialmente menor, en comparación con el IMAE, lo cual indica un mayor riesgo relativo en el caso de las previsiones del crecimiento de la economía que sobre la inflación o depreciación/apreciación nominal.

El resto de documento está compuesto por la segunda sección que expone de manera breve una revisión de literatura sobre el uso de modelos de series de tiempo por las autoridades rectoras de la política económica. A esta le siga una tercera, que trata sobre la gestión y el procesamiento de la data utilizada y una cuarta con las especificaciones y estrategia de estimación de los modelos econométricos empleados. En adición, de las secciones quinta a la séptima se tratan tópicos particulares relacionado al pronóstico en sí, puntualmente: (i) estrategia de evaluación de pronósticos, (ii) elección de modelo a ser empleados y (iii) se discute brevemente

---

<sup>3</sup>Si bien entre los modelos utilizados por las autoridades que dirigen las políticas económicas suelen adoptar un enfoque más estructural, la razones principales para utilizar estos modelos en lugar de los de series temporales se fundamenta en la utilidad de aquellos para el análisis de proyectos de políticas y su consistencia macroeconómica que en su desempeño.

sobre la moderación de la incertidumbre en torno a las previsiones de los modelos estimados, en ese orden. Finalmente, en las secciones octava y novena se presentan los principales resultados, tanto en términos de previsiones para las variables de interés como las evaluaciones de estos, y algunas consideraciones del autor.

## 2. Uso de modelos de series temporales en la práctica

Los modelos de series de tiempo tienen fundamentalmente dos finalidades prácticas que son evaluar la relación entre dos o más variables de interés (en ocasiones con el fin último de realizar simulaciones a partir de los parámetros estimados) y proyectar series particulares. Esta última ha sido de vital importancia para las autoridades rectoras de las políticas económicas, tanto desde la perspectiva monetaria y financiera (bancos centrales) como desde la óptica fiscal (ministerios de hacienda).

Los modelos utilizados para proyecciones de variables macroeconómicas suelen seguir, grosso modo, dos estrategias: (i) modelos de series de tiempo, utilizados generalmente para pronósticos de corto plazo; (ii) modelos estructurales o semiestructurales, empleados para obtener previsiones a horizontes de mediano y largo plazo. Estos últimos tienden a combinarse o alimentarse del primer enfoque, siendo el caso de instituciones como el Banco de Reservas de Nueva Zelanda, que ha publicado tanto su método de combinación de modelos de series de tiempo para el pronóstico de la inflación (Drought & McDonald, 2011) y modelos de factores dinámicos para el pronóstico de las principales variables macroeconómicas (Matheson, 2005) como el uso de modelos estructurales ((Neroli & Reid, 2017), (Delbrück, Dunstan, Lienert, Pepper, & Sleeman, 2008)), que constituye su principal herramienta para tales fines.

En esta misma línea, en la Reserva Federal de los Estados Unidos las discusiones sobre el uso de modelos macroeconómicos tanto para el análisis de política como la realización pronósticos suelen girar entorno a modelos estructurales. En este sentido, la principal herramienta de la institución para las proyecciones de interés es la estimación de una combinación de modelos de equilibrio general dinámico estocástico <sup>4</sup> (DSGE, por sus siglas en inglés), (Chung, Kiley, & Laforte, 2010) (Edge, Kiley, & Laforte, 2008). No obstante, las evaluaciones realizadas sugieren que la supremacía de este enfoque sobre modelos de series de tiempo responde principalmente a su utilidad para el análisis de políticas económicas, siendo estos últimos competitivos en lo concerniente a las proyecciones (Edge, Kiley, & Laforte, 2010).

En el caso de los países de América Latina se identifica el uso de estas estrategias por las autoridades encargadas de las políticas económicas. De esta manera, tanto el Departamento de Planeación como el Banco [Central] de la República de Colombia exhiben publicaciones que muestran su utilización en la formación de previsiones sobre el estado futuro de la economía. Puntualmente, sus publicaciones al respecto sugieren el uso de Modelos Factoriales (Jaramillo & Javier, 2017) (Critiano, Hernández, & Paulino, 2012), modelos de redes neuronales (Jalil & Misas, 2006) (Salazar, 2009), modelos VAR, VEC y ARX, verificándose un mejor desempeño de los primeros para el caso de la inflación de alimentos (González, 2008). Para los modelos ARIMA se considera transformaciones Box-Cox para evaluar el rendimiento de los modelos bajo incertidumbre, encontrando resultados variados dependiendo del periodo y la serie considerada (Cajiao, Melo, & Parra, 2014).

<sup>4</sup>Siendo su principal enfoque un modelo basado en un enfoque nuevo keynesiano de equilibrio general estocástico dinámico (DSGE) de mediana escala, estimado en base a optimización dinámica.

El uso de estas herramientas también se verifica para las autoridades directoras y ejecutoras de la política económica de Chile. De manera específica, la Dirección de Presupuestos ha publicado su documento sobre el uso de modelos de series de tiempo para las proyecciones de ingresos fiscales (Cerdeira, Gamboni, Beyzaga, & Gallardo, 2019). En adición, el Ministerio de Hacienda del país utiliza modelos econométricos para obtener previsiones de las variables macroeconómicas, aunque siguiendo un enfoque más estructural (Bravo, Cerdeira, Larraín, & Riveras, 2014).

Para el caso de la República Dominicana se verifica el uso combinado de las estrategias antes citadas por parte del Banco Central, mientras que el Ministerio de Hacienda ha evolucionado en la incorporación de modelos de estos tipos a sus herramientas para las previsiones de variables macroeconómicas. Desde la perspectiva de las autoridades monetarias, las publicaciones sugieren una amplia tradición en el uso de técnicas econométricas, tanto modelos de series de tiempo como modelos semiestructurales, orientados a un horizonte de proyecciones de mediano plazo. En ese sentido, la institución cuenta con un sistema estructurado que combina diversos enfoques y estrategias en el proceso de formación de sus proyecciones sobre los fundamentales macroeconómicos (BCRD, 2017).

Por su lado, el Ministerio de Hacienda ha publicado algunos de modelos para las proyecciones macroeconómicas de corto plazo de manera separada, a saber, modelos vectores autorregresivos aumentados por factores (FAVAR) (Pérez & Caffaro, 2018) y modelos de factores dinámicos (Pérez & Brens, 2018). Paralelamente, la entidad cuenta con modelos de enfoques más estructurales y económicamente consistentes, utilizados para la formación de proyecciones de mediano plazo.

Continuando con estos esfuerzos, el presente documento presenta los ejercicios y resultados del proceso de consolidación de los dos primeros y otros modelos de series temporales, para constituir un sistema de pronósticos macroeconómicos de corto plazo, como un paso inicial a la integración de los modelos de la institución en un sistema de proyecciones macrofiscales de corto y mediano plazo.

De acuerdo con lo anterior, se verifica que el uso de modelos econométricos para proyectar el estado futuro de la economía es una práctica generalizada entre las autoridades y hacedores de políticas económicas. Sin embargo, estas herramientas son parte de un conjunto mayor de estrategia que se complementan en la formación de las expectativas sobre la dinámica esperada de la economía y las tomas de decisiones subsiguientes.

### 3. Gestión y preparación de datos

Para las estimaciones de los modelos utilizados para proyectar las variables objetivo, se utilizan tanto informaciones públicas disponibles en portales oficiales de instituciones nacionales e internacionales como informaciones internas y suministradas por otras entidades gubernamentales, ver **Tabla A2**. Dada la diversidad tanto de fuentes como de estructuras y formatos de la data requerida, para su gestión y tratamiento se utilizan técnicas de extracción de datos disponibles con el auxilio del paquete estadístico RStudio.

El uso de estas herramientas, permite que la gestión de datos se puede realizar de manera simultánea y automatizada, lo cual permite eficientizar dicha actividad. Adicionalmente, permite programar su actualización. En este caso, la misma se realiza los días 16 (cuando se ha publicado una pequeña parte de los datos), 20 (para actualizar los pronóstico con mayor disponibilidad de datos a la fecha) y el último día del mes (revisando las previsiones con la data completa, incluyendo el último dato del IMAE). De esta manera, se aprovecha

toda la data a la que se puede acceder en distintos momentos del tiempo para actualizar las proyecciones nowcasting del IMAE y a fin de mes, cuando se cuente con toda la data del periodo actualizada, se realizan las proyecciones forecasting para todo el Sistema, utilizando todas las estrategias consideradas.

El conjunto de datos e indicadores actualizado a partir de la citada herramienta integra 53 variables (o indicadores), donde para cada periodo de estimación se selecciona una pequeña cantidad de estas a partir de varios criterios: (1) ejercicios de minería de datos (proceso estadístico) y (2) basado en fundamentos macroeconómicos.

El proceso estadístico, a su vez, utiliza los criterios siguientes: (i) que las variables estén correlacionadas con las variables objetivo, (ii) que estén actualizadas a no más de un periodo anterior al mes corriente (con excepción de los Modelos de Factores Dinámico, para los cuales no se requiere de información completa) y (iii) que no estén altamente correlacionadas con otra variables diferentes a las de interés. Siguiendo a Caffaro & Pérez (2018), se considera correlación alta cuando el coeficiente de correlación excede el 95%<sup>5</sup>. En el caso de la selección de variables en base a fundamentos macroeconómicos, las variables relevantes son tomadas de la literatura doméstica relevante.

Las variables e indicadores considerados en las estimaciones de los modelos presentados en el documento, se transforman y ajustan según lo requiera su propia característica y los supuestos asumidos por los modelos que las caracterizan. En tal sentido, para los modelos que no pueden lidiar con valores ausentes el proceso inicia con la eliminación de observaciones incompletas (para la cual al menos una variable no se encuentra actualizada). Hecho esto, se toma la tasa de crecimiento de las variables y posteriormente se transforman en estacionarias, de ser necesario.

Una vez se cuenta con un conjunto de series estacionarias, se ajustan para una relativa estabilización de la varianza, empleando la transformación Box-Cox. Esta solo se aplica cuando es requerido en base a una prueba de normalidad sobre la serie.

## 4. Modelos de series de tiempo para pronósticos de corto plazo

En la presente sección se realiza una exposición de los modelos utilizados para proyectar las variables de interés. A grandes rasgos, estos se pueden clasificar tanto en modelos univariantes y multivariantes, en función de que utilicen o no información adicional al propio pasado de la variable objetivo, como en modelos con información completa e incompleta, de acuerdo a si la estrategia de estimación admita o no valores de ausentes.

### 4.1. Modelos univariantes

Un modelo univariante de serie de tiempo es un modelo econométrico que describe el comportamiento de una variable con base en su propio pasado. En este sentido, se puede realizar una estimación de la serie en cuestión sin informaciones adicionales a ella misma (Greene, 2003).

El caso más sencillo es el proceso autorregresivo de orden  $p$ ,  $AR(p)$ , definido como:

<sup>5</sup>Este último criterio se aplica con la finalidad de evitar ruidos en las estimaciones, pues cualquiera de estas variables debe contener la información relevante para el pronóstico de interés.



$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + \epsilon_t \quad (1)$$

Donde  $y_t$  es el valor de la variable analizada (IMAE, por ejemplo) y  $\epsilon_t$  sigue un proceso ruido blanco (white noise), no observado, distribuido como una normal con media cero y varianza constante, e independiente del tiempo (Novales, 2000).

$p$  es el orden del proceso, número de rezagos de la variable en cuestión incluidos en el modelo. En tal sentido, el valor de la serie en cuestión en cualquier momento del tiempo se expresa como una función lineal de los valores observados de esta hasta ( $p$ ) periodos anteriores. En adición, se debe cumplir que  $y_t$  sea un proceso estacionario, sus características no deben cambiar en el tiempo. En sentido práctico, para que  $y_t$  sea débilmente estacionaria, se debe cumplir que, sus primeros dos momentos (media y varianza) permanezcan invariables en el tiempo.

Una variación del caso anterior, es el proceso de media móvil (MA), el cual se define como:

$$y_t = \alpha_0 + \alpha_1 \epsilon_{t-1} + \alpha_2 \epsilon_{t-2} + \dots + \alpha_q \epsilon_{t-q} + \epsilon_t \quad (2)$$

Donde  $y_t$  se explica en función del error pasado estimado a partir del modelo (1). En este caso, los valores actuales de la variable en cuestión son explicados a partir de sus innovaciones, su valor medio y una variable aleatoria (que sigue un proceso ruido blanco).

Otra forma de definir el proceso generador una serie de temporal (el modelo que mejor describe las características y comportamiento de esta), es como una combinación de los procesos antes definidos, AR( $p$ ) y MA( $q$ ). A esta se le conoce como proceso autorregresivo de media móvil (ARMA ( $p,q$ )). Esto se puede expresar como:

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + \epsilon_t + \alpha_1 \epsilon_{t-1} + \alpha_2 \epsilon_{t-2} + \dots + \alpha_q \epsilon_{t-q} \quad (3)$$

Notar que en este caso, el valor actual de la serie objetivo es explicado tanto por su propio pasado como por el de sus innovaciones (hasta  $q$  periodos previos).

### Procesos integrados y estacionales

Las series económicas se suelen caracterizar por presentar tendencias marcadas (al alza o la baja), por lo cual al momento de identificar el proceso generador de cada serie, se considera que la misma podría seguir un proceso integrado de orden  $d$ ,  $I(d)$ . En tal caso, se toman  $d$  diferencias de la serie, para caracterizar de manera adecuada el proceso autorregresivo integrado de media móvil, ARIMA( $p,d,q$ ). Formalmente,

$$\Delta y_t = (1 - L)y_t = y_t - y_{t-1} \quad (4)$$

Donde  $\Delta$  es el operador de diferencia y  $L$  es el operador de rezagos.

Una vez la serie es diferenciada se puede aplicar el modelo AMRA( $p,q$ ) más adecuado, determinado a partir de los criterios de información.

Finalmente, se considera la posibilidad de que el proceso generador de la serie en cuestión contenga elementos estacionales en su estructura. En este sentido, algunos modelos se pudieran extender (en caso de que corresponda) presentando una estructura SARIMA(p,d,q)X(P,D,Q)s. Donde P, D y Q son versiones estacionales de p, d y q, mientras que s se refiere a la frecuencia de la serie.

La elección del modelo que mejor caracteriza el proceso generador de cada serie se realiza de un conjunto de alternativas de no más de 100 especificaciones distintas, en base a los criterios de información y considerando todos elementos antes expuestos.

## 4.2. Modelos multivariantes

Los modelos antes expuestos son limitados para capturar la dinámica de las variables macroeconómicas, dado que las mismas suelen estar interrelacionadas entre sí.

En este sentido, estos se toman como puntos de partida para la construcción de modelos más elaborados, esperando encontrar alternativas más adecuadas para estimar el comportamiento futuro de la economía, una vez considerada la trayectoria posible u observada de factores relacionados.

### Modelos SARIMAX

El primer caso de modelos que consideran información diferente al pasado de la serie en cuestión, son los ARMAX (SARIMAX, si la serie es integrada y presenta componentes estacionales).

Este consiste en incluir regresores exógenos al modelo univariante determinado, como:

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + \epsilon_t + \alpha_1 \epsilon_{t-1} + \alpha_2 \epsilon_{t-2} + \dots + \alpha_q \epsilon_{t-q} + \beta X \quad (5)$$

De tal manera, se aprovecha toda la información contenida en el pasado de la serie en cuestión más el aporte de factores exógenos relacionados. Esta estrategia permite considerar el aporte de indicadores relacionados a la variable objetivo sin perder las características propias de esta. Para estos modelos se toman las variables utilizadas en los modelos VAR, lo cual permite utilizar los pronósticos de estos últimos para la realización de proyecciones fuera de muestra.

### Vectores autorregresivos (VAR)

Un vector autorregresivo (VAR) se puede entender como un sistema de ecuaciones de regresión, en el cual cada variable es explicada por su propio pasado (rezagos de esta) y el de las demás variables en el sistema. En adición, la estructura de rezagos es la misma para todas las series en las ecuaciones a estimar (Martin, Hun & Harris, 2011). Este se puede representar como:

$$Y_t = C + A_1 Y_{t-1} + A_{t-2} Y_2 + \dots + A_{t-p} Y_p + U_t \quad (6)$$

Donde  $U$  es un vector de errores, que se asume sigue un proceso ruido blanco multivariado. De forma análoga,  $Y$  es un vector de variables y  $A$  una matriz de coeficientes. Finalmente,  $C$  es vector de constantes. Para un VAR(1) bivariado, esta representación se puede detallar como,

$$y_t = \alpha_1 + \beta_{1,1}y_{1,t-1} + \beta_{1,2}y_{2,t-1} + u_{1,t} \quad (7)$$

$$y_t = \alpha_2 + \beta_{1,2}y_{1,t-1} + \beta_{1,1}y_{2,t-1} + u_{2,t} \quad (8)$$

En este punto es relevante destacar que todas las variables del sistema deben ser estacionarias, por lo cual deben ser transformadas en caso de no serlo.

En otro orden, la elección del número de retardos adecuados se basa en los criterios de información, de Akaike (AIC), Hannan (HIC) y Scharz (SIC). Estos criterios buscan una medida equilibrada, óptima, entre la mejora de la función de máxima verosimilitud y la pérdida de grados de libertad cuando se incluyen retardos al modelo. Estos se definen como,

$$AIC = -2\ln L_T(\hat{\theta}) + \frac{2k}{T} \quad (9)$$

$$HIC = -2\ln L_T(\hat{\theta}) + \frac{2k\ln(\ln(T))}{T} \quad (10)$$

$$SIC = -2\ln L_T(\hat{\theta}) + \frac{k\ln(T)}{T} \quad (11)$$

Donde  $k$ , es el número de parámetros estimados y  $T$  es el total de observaciones en la muestra. La especificación óptima será aquella que produzca los mínimos valores de los criterios de información.

Cabe destacar que en la determinación del orden del VAR se considera la posible presencia de autocorrelación serial, con lo cual el orden efecto del modelo puede variar sustancialmente del sugerido por estos indicadores. Combinando estos criterios de selección, los VAR para el IMAE y el IPC resultaron VAR(4), mientras que para el tipo de cambio este correspondió a un VAR(3).

Para la selección de variables a ser incluidas en estos modelos se siguieron dos estrategias distintas. En un primer enfoque, se siguió un proceso estadístico, consistente en inclusión/exclusión de variables según aporten o no a reducir los errores de pronósticos. Como punto de partida se toma cada una de variables objetivos (por separado) y la del conjunto de datos con la cual presente la mayor correlación.

El segundo proceso de selección de variables consistió en adoptar un enfoque basado en fundamentos económicos y se construyó un modelo que intenta sintetizar la dinámica de la economía doméstica (tomando variables representativas de los diversos sectores de esta). A tales fines, se construye un VAR siguiendo Jiménez & Ramírez (2015) y Ramírez (2012). Las variables relevantes, de acuerdo con los citados autores, incluye tasa de interés, tipo de cambio, IMAE, IPC, reservas internacionales netas, precios del petróleo, IPC e índice de actividad industrial de Estados Unidos.

### Modelos multivariantes de series no estacionarias

Al diferenciar una serie temporal para transformarla en estacionaria se puede perder información útil sobre la dinámica de interacción entre ellas. En este caso, previo a su transformación se podría probar la existencia de cointegración entre estas. El análisis implica determinar el número de relaciones de cointegración que puedan existir en el sistema, estableciendo así si hay una o más tendencias estocásticas. Si se identifican  $r$  relaciones de cointegración en un sistema de  $q$  series, entonces existen  $q-r$  tendencias estocásticas comunes en el sistema (Zipitría 2010).

### Metodología de Engle y Granger: caso bivariado

Para el caso uniecuacional, un proceso bivariado, la estimación de un modelo de cointegración es como sigue:

1. Analizar en orden de integración de las variables,
2. Estimar la relación de largo plazo, si los elementos del proceso son  $I(1)$ .

Si las variables en cuestión son  $y_t$  y  $z_t$  sería regresar a  $y_t$  sobre  $z_t$  en niveles, es decir,

$$y_t = \beta_0 + \beta_1 z_t + u_t \quad (12)$$

3. Si  $u$  sigue un proceso ruido blanco, estimar el modelo de corrección de errores. En este sentido, lo que se evalúa es si la combinación lineal de las dos variables no estacionarias sí resulta serlo (Martin, Hun & Harris, 2011).

El modelo de corrección de errores se plantea como,

$$\Delta y_t = \alpha_1 + \alpha_y [y_{t-1} - \beta_1 z_{t-1}] + \sum_{i=1} \alpha_{11}(i) \Delta y_{t-i} + \sum_{i=1} \alpha_{12}(i) \Delta z_{t-i} + \epsilon_{yt} \quad (13)$$

$$\Delta z_t = \alpha_1 + \alpha_z [y_{t-1} - \beta_1 z_{t-1}] + \sum_{i=1} \alpha_{21}(i) \Delta y_{t-i} + \sum_{i=1} \alpha_{22}(i) \Delta z_{t-i} + \epsilon_{zt} \quad (14)$$

o,

$$\Delta y_t = \alpha_1 + \alpha_y \hat{u}_{t-1} + \sum_{i=1} \alpha_{11}(i) \Delta y_{t-i} + \sum_{i=1} \alpha_{12}(i) \Delta z_{t-i} + \epsilon_{yt} \quad (15)$$

$$\Delta z_t = \alpha_1 + \alpha_z \hat{u}_{t-1} + \sum_{i=1} \alpha_{21}(i) \Delta y_{t-i} + \sum_{i=1} \alpha_{22}(i) \Delta z_{t-i} + \epsilon_{zt} \quad (16)$$

Si uno de estos coeficientes es cero (p.e.  $\alpha_y$ ), entonces  $z$  hace toda la corrección para eliminar todas las desviaciones del equilibrio de largo plazo. Dado que  $y$  no se ve afectada por el mecanismo de corrección se dice que  $y$  es débilmente exógena.

### Metodología de Johansen: caso multivariado

Partiendo de un vector de variables  $Y_t$ , donde al menos dos de ellas son I(1), pudiendo ser el resto I(0), y un VAR(p) asociado como,

$$Y_t = A_1 Y_{t-1} + A_{t-2} Y_2 + \dots + A_{t-p} Y_p + U_t \quad (17)$$

Donde se establece la existencia de cointegración si  $U_t \text{ iid}(0, \Sigma)$ . La propuesta de Johansen (1988) es escribir el VAR como un Vector de Corrección de Errores (VECM). Limitando el modelo anterior a  $p=2$ ,

$$Y_t = \beta_1 Y_{t-1} + \beta_{t-2} Y_2 + U_t \quad (18)$$

Restando  $Y_{t-1}$ ,

$$\Delta Y_t = (\beta_1 - I_n) Y_{t-1} + \beta_2 Y_{t-2} + U_t \quad (19)$$

Donde  $Y_{t-2} = \Delta Y_{t-1} + Y_{t-1}$ .

### Modelos multivariantes con factores

En los modelos antes descritos se asume que toda la información relevante para el pronóstico de las series objetivo se encuentra en el pasado de cada serie y un grupo reducido de otras variables. No obstante, puede existir un conjunto más amplio de variables con poder explicativo sobre su dinámica temporal. Existen técnicas que permiten reducir la dimensionalidad de este conjunto de datos, y de esta manera aprovechar las ventajas de las estrategias antes vistas, como el VAR, junto a toda la data disponibles. En la presente sección se describe una selección de estos modelos.

### Modelos de factores dinámicos

Para estos modelos se asume que el conjunto de datos en cuestión, digamos  $X_t$ , con N variables observables, se puede expresar como un vector de factores de longitud N x k, donde k es un número pequeño. Siguiendo a Stock & Watson (2016), esto se representa como,

$$X_t = \lambda(L) f_t + e_t \quad (20)$$

Donde  $f_t$ , es un conjunto de k factores no observables, elemento común a todas las variables, y  $e_t$  es un vector de perturbaciones idiosincrática, componente particular de i-ésima serie.

Estos factores pueden evolucionar como,

$$f_t = \Psi(L) f_{t-1} + \eta_t \quad (21)$$

Donde  $\lambda(L)$  y  $\Psi(L)$  son matrices polinomiales (N x q) y (q x q), respectivamente. Siendo  $f_t$  un número reducido de factores no observables (q).

En este sentido, la evolución de los datos se puede representar en función de un número reducido de factores (no observados) y un vector de perturbaciones (componente idiosincrático) de cada serie individual,  $e_t$ , el cual podría estar correlacionado. En adición, la  $i$ -ésima fila de la matriz  $\lambda(L)$  ( $\lambda_i(L)$ ) se denomina factor de carga dinámico de la variable  $i$ , mientras que el  $\lambda_i(L)f_t$  es el componente común de la  $i$ -ésima serie.

En adición, se puede asumir que el componente idiosincrático sigue un proceso autorregresivo de la forma,

$$e_{it} = \delta e_{it-1} + \nu_{it} \quad (22)$$

En general, este elemento puede seguir cualquier estructura de un modelo ARMA, a determinar con base en los criterios de información. Con la finalidad de realizar comparaciones entre alternativas, se podría asumir distintos procesos generadores para  $e_{it}$  y luego comparar la precisión de cada una de estas.

Para la estimación de estos modelos se sigue dos estrategia distintas:

### 1. Análisis de Componentes Principales

Los métodos utilizados en los modelos de factores suelen ser multietápicos. Entre los más populares se encuentra el Análisis de Componentes Principales (ACP), que en una primera etapa se utiliza para estimar los factores de carga ligados a cada variable y los factores no observados. Para esto se normaliza el conjunto de datos con el objetivo de transformar las variables en estacionarias. En adición, la técnica requiere de data completa (sin valores ausentes) y la inexistencia de valores atípicos.

Este proceso se corresponde al enfoque estático de modelos de factores, y se recomienda su uso cuando el conjunto de regresores ( $X_t$ ) es grande, verificándose que se puede obtener estimaciones consistentes incluso en presencia de errores idiosincráticos correlacionados (serial y transversalmente) (Stock & Watson, 2002).

Una vez estimados los factores no observados, se puede proyectar la variable de interés, por Mínimos Cuadrados Ordinarios (MCO). De esta manera,

$$y_{t+h} = \beta'_f f + \beta'_w w_t + \epsilon_{t+h} \quad (23)$$

siendo  $w_t$  un vector de variables observadas, con cierto poder explicativo sobre la variable objetivo y  $h$  es el horizonte de pronóstico. Finalmente,  $\epsilon_{t+h}$  es el error de pronóstico resultante. En caso de que  $N$  sea pequeña, se puede proceder a estimar la versión dinámica <sup>6</sup>.

### 2. Otros métodos de estimación

La estrategia de estimación anterior (ACP) presenta sus ventajas en varios contextos, especialmente cuando se tiene un conjunto de datos con una dimensionalidad considerable o se tiene interés en variables con distintas frecuencias, caso en el cual se pudiera realizar estimaciones tipo nowcasting (utilizar data mensuales para proyectar la serie trimestral del PIB, por ejemplo). Sin embargo, el pronóstico obtenido siguiendo este camino podría exhibir un rendimiento inferior a los de sus alternativas más cercanas, con el agravante adicional de que no puede lidiar con datos ausentes o atípicos.

<sup>6</sup>más detalles en (Stock & Watson, 2002).

En vista de lo anterior, se sigue la estrategia de estimación de factores dinámicos a partir de un proceso de estimación iterativo, específicamente por maximización de expectativas (ME). Esto permite realizar estimaciones nowcasting de la actividad económica (adelantando el indicador a su publicación por el BCRD), con lo cual se aprovecha toda la información disponible hasta el periodo  $t$  (para cuando se cuenta con la publicación de un amplio conjunto de indicadores relacionados a esta) y adelantar el dato del crecimiento en base a un conjunto reducido de variables para las cuales se cuenta con el dato efectivo.

### Modelos VARs Aumentados por Factores (FAVAR)

Los modelos VAR antes expuestos pueden presentar problemas en relación con la dimensionalidad de los datos utilizados, los cuales podrían ir en dos direcciones. Por un lado, el crecimiento del número de variables en el sistema puede generar una pérdida relevante de grados de libertad, por la rápida parametrización del modelo, y, por otro, utilizando una cantidad pequeña de estas se puede omitir factores relevantes para explicar las variables de interés o no identificar adecuadamente los shocks estudiados (en el caso de análisis estructural), (Bai, Li, & Lina, 2015). A la luz de estas consideraciones, una de las estrategias empíricas utilizadas en el Sistema es el enfoque de Vectores Autorregresivos Aumentados por Factores (FAVAR). este tipo de modelos permite combinar las ventajas de los VAR con las técnicas de reducción de dimensiones para emplear toda la data relevante disponible.

Siguiendo a Bernanke, Boivin, J. & Piotr (2003) el modelo FAVAR se puede plantear como

$$\begin{bmatrix} F_t \\ Y_t \end{bmatrix} = \Phi(L) \begin{bmatrix} F_{t-1} \\ Y_{t-1} \end{bmatrix} + \nu \quad (24)$$

Donde  $Y_t$  es un vector ( $M \times 1$ ) de variables observables (las variables objetivo del Sistema) y  $F_t$  es un vector ( $K \times 1$ ) de factores no observables, siendo  $k$  un número pequeño, como se ha establecido con anterioridad. Los factores para este tipo de análisis se pueden extraer empleando las técnicas antes citadas, predominando el ACP.

Para la determinación de los factores se parte de un conjunto de datos de 53 variables e indicadores sobre los diversos sectores de la economía dominicana (real, monetario, financiero, precios, fiscal, cambiario y externo). Para la realización de pronóstico a partir de estos modelos se sigue un proceso de 4 pasos, de acuerdo con (Pérez & Caffaro, 2018), los cuales se enumeran a continuación:

1. Se eliminan las variables con correlaciones muy altas y muy bajas con las demás del conjunto de datos,
2. Estandarización de las variables a utilizar en la extracción de factores,
3. Estimación de modelos de referencia (VAR y FAVAR básicos),
4. Estimación FAVAR óptimo, eligiendo las variables que minimizan error cuadrático medio.

Para esto último se utiliza un proceso recursivo de eliminación de variables, eliminando aquellas que siendo excluidas reducen los errores de predicción del modelo.

Con relación a la implementación de los autores citados, en esta ocasión se parte por seleccionar un conjunto de variables relacionadas a las series objetivo y luego aplicar el proceso anterior. Esto con la finalidad de obtener factores que contengan información relevante para los pronósticos de interés.

## 5. Evaluación de pronósticos

Dado el objetivo de cualquier sistema de pronóstico de estimar con la mayor precisión posible el estado futuro de un fenómeno particular, la economía dominicana en el caso que nos ocupa, es necesario evaluar de manera oportuna el desempeño del mismo. En este sentido, el Sistema de Pronósticos de Corto Plazo se compone de tres módulos distintos: (i) gestión y actualización de datos, (ii) evaluación de desempeño y (iii) estimación y comunicación de pronósticos.

Para evaluación de los pronósticos, se inicia por elegir la estrategia de estimación de los parámetros ligados a los modelos empleados. En este sentido, se identifican varias estrategias:

**Recurso:** se expande la muestra en un periodo y se pronostica  $t+h$  pasos hacia adelante. Esto es, se estima el modelo hasta el periodo  $t$  para proyectar la variable objetivo a  $t+h$ , luego se expande la muestra en una observación para el pronóstico de  $t+h+1$ , repitiendo el proceso hasta el periodo  $T$  (muestra completa).

**Ventana Móvil:** se desplaza la muestra un paso adelante, manteniendo fijo su tamaño. En este caso, se estiman los parámetros de interés con la muestra inicial hasta el periodo  $t$  y dichas estimaciones se utilizan para pronosticar  $t+h$ , mientras que en el paso siguiente se estima hasta  $t+1$  (manteniendo el tamaño de la muestra) y se proyecta  $t+1+h$ , hasta llegar a  $T$ .

**Estimaciones Fijas:** Se estiman los parámetros del modelo solo una vez y estos se utilizan para proyectar de uno hasta  $p$  pasos hacia adelante. En este caso, la evaluación no se realiza a un horizonte puntual, sino para un periodo específico, de  $t+h$  a  $t+p$ .

Para agotar estos procesos se divide la muestra en subconjuntos de datos, uno de entrenamiento y otro de prueba. Siguiendo a Ramírez y Ramírez (2019), la ventana de información reservada para la prueba de los modelos asciende al 25% de los valores de la muestra.

Una vez seleccionada la estrategia de estimación de parámetros, lo primero que se debe tomar en consideración al realizar la evaluación de pronósticos es el sesgo. Este se entiende como una tendencia sistemática a subestimar/sobrestimar el valor real de la serie de interés dado un horizonte temporal (Clements, 2005). Es decir, el pronóstico será insesgado si:

$$E(y_{t+h} - f_{t+h|t}) = 0$$

Donde  $y_{t+h}$  es el valor observado  $h$  pasos adelante y  $f_{t+h|t}$  es el valor predicho, dado el periodo  $t$  (pronóstico puntual). Finalmente,  $E$  es la esperanza matemática. La condición de insesgamiento se ha asociado a la condición de optimalidad del pronóstico, es decir, se entiende que bajo tal condición el modelo evaluado predice correctamente la variable de interés (Capistrán & López-Moctezuma, 2008).

La evaluación de los modelos en términos de magnitud se realiza utilizando indicadores basados en los errores de pronóstico de las distintas estrategias, en adición a la evaluación del sesgo antes expuesta. Los indicadores más utilizados son:

1. La raíz del error cuadrático medio,



$$RMSE = \sqrt{n^{-1} \sum_{t=T}^n e_{t+h}^2}$$

Donde  $e_{t+h} = x_{t+h} - f_{t+h|t}$ ,  $x$  es el valor observado y  $f$  es el pronóstico. Este indicador suele ser utilizado cuando los modelos evaluados requieren la misma transformación de la variable de interés (objetivo). Sin embargo, para varios de los modelos antes presentados este indicador no es adecuado, pues no siempre resulta ser comparable. Un ejemplo, es el caso de los modelos VECM, en los cuales se utilizan las variables en nivel, a diferencia de los modelos VARs, para los cuales es necesario que estas sean estacionarias para ser incluidas en el sistema, lo cual por lo general requiere de transformaciones.

## 2. Error porcentual absoluto medio,

En caso de que los modelos a ser evaluados requieran diversas transformaciones se requiere un indicador que relativice la precisión de los métodos de estimación evaluados. Uno de los más utilizados en la literatura al respecto es el error porcentual absoluto medio (MAPE, por sus siglas en inglés) y se define como:

$$MAPE_h = n^{-1} \sum_{t=T}^n \frac{|x_{t+h} - f_{t+h|t}|}{|x_{t+h}|}$$

Finalmente, siguiendo a Ramírez y Ramírez (2019) se evalúa la capacidad de los modelos para identificar la dirección del cambio en la variable objetivo con relación a su valor actual. Para dicha evaluación se crea una variable indicador (dummy) que toma el valor de uno (1) cuando el sentido (signo) del cambio estimado en el nivel de la serie coincide con el observado y cero (0) en caso contrario. En este sentido, se construye la variable  $\hat{d}_{t+h}$ , como sigue:

$$\hat{d}_{t+h} = 1, \text{ si } sig(f_{t+h} - f_t) = sig(x_{t+h} - x_t) 0, \text{ en caso contrario}$$

En este sentido, no solo se observa la capacidad de los modelos para aproximar adecuadamente el nivel de las variables de interés, sino que, en adición, se evalúa su desempeño en términos de predecir el signo de las variaciones de estas.

## 6. Elección de modelos

El objetivo de todo pronosticador es obtener predicciones de la variable de interés que minimice el error promedio de los pronósticos producidos. En este sentido, la literatura sobre modelos de series temporales ha mostrado interés en la determinación de proyecciones óptimas. Dentro de las estrategias de selección de modelos para tales fines se destacan *el mejor pronóstico* y los *pronósticos combinados*, siendo estos últimos los que han mostrado mejor desempeño, hecho que se ha verificado tanto en el caso de combinar mediante promedios simples (Barnard, 1963) como con técnicas más elaboradas para tales actividades (Bates & Granger, 1969).

La necesidad de realizar dichas combinaciones surge por una serie de hechos, como son: (i) a pesar de que se haya seguido un procedimiento correcto para las estimaciones de los modelos de interés estos no están

exentos de otras dificultades como la selección de variables, especificación y método de estimación (Castaño & Melo, s.f.); (ii) las estrategias particulares pueden ser superiores a sus alternativas en ciertos aspectos e inferiores en otros (Ramírez & Ramírez, 2019). Esto hace que las previsiones de modelos combinados superen incluso a la mejor alternativa individual.

Una manera simple de combinación de pronósticos es asignando la misma ponderación ( $w$ ) a todas las ( $k$ ) estrategias de estimación empleadas (Raviv, 2016). De esta manera, se puede combinar los resultados de los distintos modelos como:

$$f_c = \frac{1}{k} \sum_{i=1}^k f_i$$

Una estrategia más elaborada de combinación de pronósticos es utilizar ponderaciones distintas de acuerdo con la capacidad predictiva de los modelos estimados. Una forma de lograr este objetivo es utilizando como ponderador el inverso de la medida de precisión por medio de la cual se evalúan los distintos métodos de proyección de las variables objetivo. Formalmente, esto se puede expresar como:

$$f_c = \frac{\frac{1}{MAPE_i}}{\sum_{i=1}^k \frac{1}{MAPE_i}} f_i$$

La idea de esta estrategia de combinación es asignar un mayor peso a los modelos con errores de pronósticos menores.

Un aspecto relevante en este punto es la determinación óptima del número ( $k$ ) de estrategias a ser combinada. Dado el objetivo de llegar a una estrategia que permita minimizar el error medio de pronóstico se utiliza como punto de partida el modelo con menor MAPE y luego se combina de manera iterativa con el resto hasta encontrar una combinación que minimice el MAPE de las proyecciones combinadas.

## 7. Incertidumbre de los pronósticos

Los pronósticos sobre los fundamentales macroeconómicos representan aseveraciones sobre el estado de la economía “h” periodos hacia adelante. Por su propia naturaleza existe cierto riesgo en torno de estos valores, pues no se puede saber con precisión los valores puntuales de las variables de interés para el futuro, una vez utilizada toda la información disponible al respecto. En este sentido, es importante conocer (estimar) y comunicar dicho riesgo en forma de probabilidades (Julio, 2006). En este sentido, en la etapa de reporte de proyecciones realizadas se elaboran una serie de “Fan Charts” o función de probabilidad de los valores futuros de cada variable objetivo, dada la información disponible sobre esta.

Para tales fines, se realizan ejercicios de bootstrapping en base a las distribuciones de los residuos observados para el periodo de estimación. De manera precisa, siguiendo a Pérez & Brens (2018), el ejercicio consistió en simular  $N$  muestras de los errores para  $T$  periodo de cada modelo estimado y basado en ello, generar  $N$  sendas de posibles valores de cada variable objetivo para el horizonte  $T$ . Para todos los casos presentados más adelante  $N=1000$  y  $T=12$ , dada la característica de corto plazo de los modelos presentados.

A partir de tales tareas se obtienen las densidades de los pronósticos en lugar de presentar estimaciones puntuales. En este sentido, se exponen de manera explícita los riesgos asociados a dichas predicciones, a fin de que estos sean adecuadamente comunicados en los reportes de proyecciones.

## 8. Resultados

### Validación de los modelos estimados

Como primer paso en el proceso de evaluación de los modelos estimados en la presente sección se evalúa el comportamiento de los residuos de estos. En este sentido, en la determinación de las especificaciones se consideró tanto los criterios de información como la presencia de autocorrelación.

De acuerdo con lo anterior, en el **gráfico 1** se presentan los resultados pertinentes para la evaluación de la bondad del ajuste de los modelos utilizados para pronosticar el IMAE. En este se destaca que los errores tienden a presentar una dinámica que sugiere especificaciones adecuadas, sin valores atípicos al final del periodo de evaluación, lo cual sugiere que los modelos estimados están representando de manera correcta el comportamiento reciente de las series de interés.

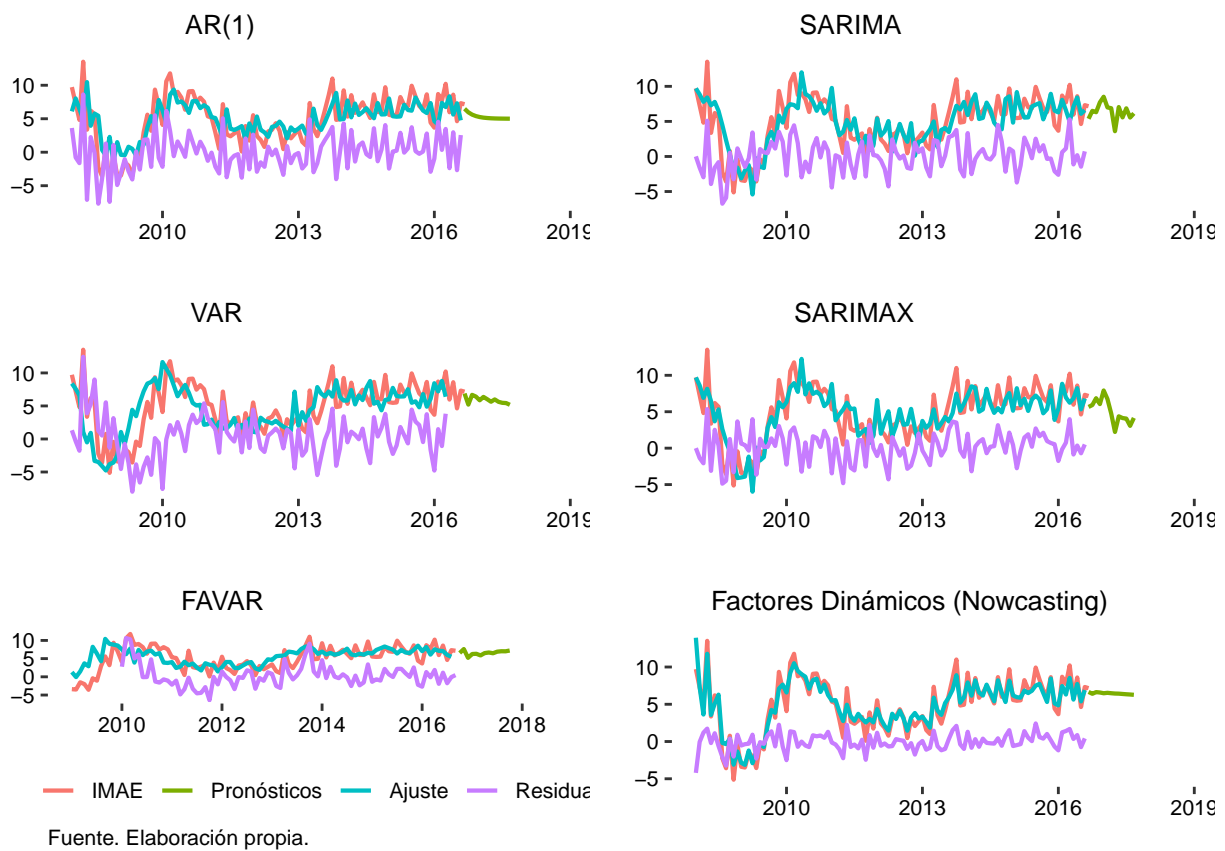


Gráfico : Bondad del ajuste según modelos de pronósticos para el IMAE

Este análisis se complementó con la realización de prueba de autocorrelación en el proceso de determinación de variables y especificaciones, en el caso de los modelos puramente estadísticos para los cuales no se parte de la teoría económica en la determinación de regresores y estructura de rezagos.

Finalmente, una apreciación relevante en términos de la bondad del ajuste es que los modelos menos elaborados respecto a la estructura de rezagos (AR(1) y factores dinámicos) son los que mejor se ajustan a los valores observados del IMAE. Sin embargo, estos son más limitados representando la dinámica de la serie proyectada

más de un paso hacia adelante, tendiendo rápidamente a la media, lo cual puede favorecer una estrategia de pronósticos combinados.

De forma análoga, tanto para el caso del tipo de cambio nominal como del IPC, las estrategias univariantes (y SARIMAX en el caso de la primera serie), presentan los mejores ajustes, y consecuentemente residuales menores y más estables. Adicionalmente, se observan errores relativamente pequeños al final de muestra utilizada, ver **Gráfico A1** y **Gráfico A2**.

## Análisis de desempeño

Dado el propósito del sistema de proyecciones de anticipar el comportamiento de la economía doméstica en el futuro próximo o el periodo actual (en el caso del crecimiento económico que presenta rezagos en su publicación) para aportar evidencia empírica en el proceso de formación de expectativas al respecto, la evaluación del desempeño de los modelos empleados es un punto neurálgico de este. En este sentido, en la **Tabla 1** se presenta la raíz del error cuadrático medio (RMSE)<sup>7</sup> de pronósticos de los modelos empleados para distintas estrategias de estimación para cada variable objetivo.

Lo primero que cabe destacar, es que los modelos SARIMA, SARIMAX y VAR suelen generar errores menores a sus alternativas, consideradas para las series de TCN e IPC. Para el caso de la actividad económica, los enfoques VAR, SARIMAX y factores dinámicos generan divergencias más reducidas entre los pronósticos y sus valores observados. En tal sentido, para el caso de este último indicador, los modelos multivariantes presentan un mejor desempeño, en comparación con aquellos que solo utilizan información pasada de la misma variable.

En cuanto a los enfoques de estimación y selección de variables, una especificación basada en fundamentos y teorías económicas (VAR Economía) es superior a aquella puramente estadística, incluyendo/excluyendo regresores de manera recursiva según reduzcan o no el RMSE, para el caso del IMAE. No obstante, esta última estrategia exhibe peor desempeño en los pronósticos de la inflación y el tipo de cambio nominal. En adición, estimar estos modelos mediante técnicas bayesianas genera menores errores en las proyecciones de las variables de interés.

---

<sup>7</sup>Debido a la presencia de valores atípicos en las series de residuos (ligadas a los efectos de la pandemia ocasionada por la COVID-19), para este indicador se utiliza la mediana en lugar de la media.

Tabla 1: RMSE mediano de modelos empleados por variable objetivo con estrategia recursiva, hasta  $h = 12$

Modelo	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	t+11	t+12
<b>IMAE</b>												
AR(1)	1.34	0.9	1.57	1.67	1.68	1.67	1.69	1.77	1.78	1.79	1.82	1.84
SARIMA optimo	1.43	1.41	1.48	1.4	1.37	1.65	1.82	1.58	1.53	2.15	1.54	2.23
VAR	1.31	1.34	1.65	1.53	1.86	1.89	2.23	2.52	3.25	3.34	3.29	3.68
VAR bayesiano	1.09	1.37	1.42	1.41	1.44	1.69	1.55	1.91	2	2.08	2.25	2.08
SARIMAX	1.10	1.2	1.27	1.33	1.59	1.81	1.73	1.55	2.08	1.98	1.76	1.59
VECM	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06
FAVAR	5.80	5.8	6.06	6.42	6.42	7.16	6.62	6.65	6.53	6.73	6.93	7.09
VAR Economía	1.28	1.63	1.61	1.77	1.95	2.49	2.19	2.67	2.07	2.4	1.86	2.19
VAR Economía bayesiano	0.86	1.07	1.41	0.74	1.05	1.41	1.85	2.1	1.92	2.18	1.69	2.15
Nowcasting	1.16	0.7	1.28	0.75	1.42	2.17	1.45	2.02	1.67	2.1	2.17	1.98
Combinado	1.34											
<b>Tipo de cambio</b>												
AR(1)	0.40	0.9	1.06	1.62	1.96	2.21	2.27	2.18	1.67	1.49	1.34	1.38
SARIMA optimo	0.23	0.64	0.79	1.12	1.24	1.14	2.11	2.35	2.15	1.98	1.85	1.66
VAR	0.37	0.81	1.37	1.45	1.49	1.85	1.92	2.23	2.15	2.33	2.05	2.13
VAR bayesiano	0.43	0.78	0.98	1.16	1.46	1.54	1.46	1.47	1.59	1.49	1.51	1.51
SARIMAX	0.31	0.68	0.88	1.13	1.3	1.76	2.14	2.23	2.12	1.77	1.62	1.6
VECM	8.04	8.04	8.04	8.04	8.04	8.04	8.04	8.04	8.04	8.04	8.04	8.04
FAVAR	5.52	5.65	6.1	5.75	5.81	5.95	5.22	5.39	5.25	5.5	5.49	5.43
VAR Economía	2.77	2.41	2.3	2.47	2.36	2.67	2.87	2.58	2.29	2.28	2.18	2.35
VAR Economía bayesiano	1.82	2.07	1.67	1.88	2.04	2.25	2.34	2.02	1.97	1.8	1.69	1.89
Combinado	0.96											
<b>IPC</b>												
AR(1)	0.44	0.83	1.17	1.27	1.45	1.81	1.6	1.69	1.32	1.48	1.71	1.83
SARIMA optimo	0.32	0.75	0.83	0.97	1.2	1.29	1.43	1.23	1.19	1.34	1.71	1.56
VAR	0.62	1.01	1.36	1.7	1.48	1.46	1.53	1.33	1.52	1.84	1.77	1.97
VAR bayesiano	0.52	0.69	1.16	1.3	1.19	1.2	1.28	1.24	1.55	1.75	1.95	2.01
SARIMAX	0.39	0.62	0.76	0.87	0.84	0.87	0.97	1.19	0.99	0.91	0.93	0.84
VECM	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.03	8.03	8.03
FAVAR	7.72	7.72	7.12	7.48	7.2	7.31	5.62	5.74	4.61	4.77	4.82	4.81
VAR Economía	4.21	3.74	4.11	4.37	4.44	4.4	3.99	3.98	3.91	3.27	3.54	3.6
VAR Economía bayesiano	3.38	3.61	3.37	3.76	3.62	3.65	3.5	3.41	3.26	2.55	2.8	2.71
Combinado	1.69											

**Fuente:**

Elaboración propia.

En términos de la estrategia de selección de pronóstico, las predicciones individuales suelen superar a las combinaciones de ellas, lo cual no es coherente con lo observado en la literatura al respecto. Sin embargo, las adicciones ponderadas de modelos (agregando del mejor a peor) presenta RMSE decreciente en la cantidad modelos dentro de batería de estimadores evaluados, lo cual sugiere que la combinación optima pudiera exceder la colección de enfoques o especificaciones consideradas, ver **Gráfico A3**.

Con relación horizonte temporal, si bien los errores de pronósticos crecen con su ampliación (naturalmente) en la mayoría de los casos dichos errores se incrementan de manera suave manteniéndose similares en los

primeros pasos hacia adelante.

Desde la perspectiva de la capacidad de los modelos considerados para predecir correctamente el signo del cambio en la variable, en la **tabla 2** se muestra el porcentaje en los cuales los modelos puede predecir de manera acertada la dirección del cambio interanual en el IPC, IMEA y el TCN. Es decir, es una media relativa que indicada la proporción en la que si los pronósticos indican una expansión de la actividad económica la economía efectivamente crece (independientemente de la magnitud en la que lo haga), por ejemplo.

Tabla 2: Capacidad predicción de signo modelos empleados por variable objetivo con estrategia recursiva, hasta  $h = 12$

Modelo	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	t+11	t+12
<b>IMEA</b>												
AR(1)	0.91	0.91	0.79	0.7	0.7	0.7	0.7	0.7	0.7	0.64	0.67	0.67
SARIMA optimo	0.88	0.88	0.79	0.73	0.76	0.73	0.73	0.76	0.7	0.64	0.67	0.67
VAR	0.91	0.91	0.88	0.85	0.82	0.79	0.76	0.73	0.67	0.64	0.61	0.64
VAR bayesiano	0.97	0.94	0.88	0.76	0.73	0.7	0.7	0.7	0.7	0.64	0.64	0.67
SARIMAX	0.91	0.91	0.88	0.85	0.82	0.76	0.7	0.67	0.67	0.64	0.64	0.67
VECM	0.95	0.95	0.9	0.86	0.81	0.81	0.81	0.81	0.81	0.86	0.86	0.85
FAVAR	0.39	0.33	0.36	0.39	0.45	0.45	0.45	0.42	0.39	0.33	0.3	0.24
VAR Economía	0.88	0.82	0.79	0.76	0.73	0.7	0.73	0.7	0.64	0.61	0.64	0.67
VAR Economía bayesiano	0.96	0.88	0.85	0.81	0.79	0.76	0.73	0.71	0.66	0.61	0.64	0.67
Nowcasting	0.94	0.94	0.91	0.82	0.76	0.73	0.73	0.7	0.7	0.64	0.64	0.67
Combinado	0.73											
<b>Tipo de cambio</b>												
AR(1)	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMA optimo	1.00	1	1	1	1	1	1	1	1	1	1	1
VAR	1.00	1	1	1	1	1	1	1	1	1	1	1
VAR bayesiano	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMAX	1.00	1	1	1	1	1	1	1	1	1	1	1
VECM	1.00	1	1	1	1	1	1	1	1	1	1	1
FAVAR	0.12	0.18	0.18	0.18	0.27	0.3	0.33	0.39	0.33	0.42	0.42	0.52
VAR Economía	0.67	0.73	0.76	0.79	0.82	0.85	0.88	0.91	0.91	0.94	0.97	1
VAR Economía bayesiano	0.88	0.92	0.92	0.93	0.93	0.93	0.93	0.94	0.94	0.94	0.97	1
Combinado	1.00											
<b>IPC</b>												
AR(1)	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMA optimo	1.00	0.97	0.97	0.94	0.94	0.91	0.91	1	1	1	1	1
VAR	1.00	0.97	0.97	0.97	1	1	1	1	1	1	1	1
VAR bayesiano	1.00	0.96	0.96	0.96	0.96	1	1	1	1	1	1	1
SARIMAX	1.00	0.97	0.97	0.97	0.94	0.94	1	0.97	0.97	0.97	0.97	0.97
VECM	0.90	0.9	0.9	0.9	0.86	0.81	0.86	0.86	0.81	0.76	0.76	0.75
FAVAR	0.12	0.18	0.21	0.24	0.3	0.3	0.3	0.33	0.3	0.36	0.33	0.33
VAR Economía	0.67	0.73	0.76	0.79	0.82	0.85	0.88	0.91	0.91	0.94	0.97	1
VAR Economía bayesiano	0.88	0.92	0.92	0.93	0.93	0.93	0.93	0.94	0.94	0.94	0.97	1
Combinado	1.00											

**Fuente:**

Elaboración propia.

De acuerdo con este indicador, las estrategias utilizadas pueden predecir la dirección del cambio en las variables de interés de manera correcta en más del 90% de las veces en la mayoría de los modelos. Sin embargo, para los pronósticos de la actividad económica, la capacidad de predicción del signo se reduce sustancialmente en el horizonte de pronóstico, llegando a ser inferior al 70%.

## **Análisis de desempeño con estrategia de ventana móvil**

Los resultados expuestos con anterioridad se basan en una estrategia de estimación recurvisa, en la cual se expande la muestra en una observación para pronosticar el valor del periodo siguiente. En la presente sección se presenta el desempeño de los modelos evaluados adoptando un enfoque de ventanas móviles, donde en lugar de expandir la muestra en una unidad la misma se desplaza un paso hacia adelante, manteniendo su tamaño invariante.

En general, los resultados obtenidos sugieren que adoptar una estrategia de ventanas móviles mejora el desempeño de los modelos evaluados, reduciendo los RMSE en casi la totalidad de los casos.

Para los modelos VAR, cuyo desempeño no siempre mejora para los pronósticos un paso hacia adelante, la estrategia de ventanas móviles es superior en la medida en que se amplía el horizonte, llegando a generar errores sustancialmente menores al final del horizonte de proyecciones.

Las conclusiones anteriores suelen mantenerse en términos de la evaluación de la capacidad para predecir el signo de los cambios en las variables de interés. Es decir, adoptar una estrategia de ventanas móviles potencia el desempeño de los modelos con respecto a las predicciones de la dirección de las variaciones del IPC, y IMAE y el TCN, al menos para horizontes temporales mayores a  $t+1$ .



Tabla 3: RMSE mediano de modelos empleados por variable objetivo mediante ventanas móviles, hasta  $h = 12$

Modelo	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	t+11	t+12
<b>IMAE</b>												
AR(1)	1.24	0.78	1.26	1.42	1.38	1.37	1.78	2.4	2.39	2.48	2.37	2.38
SARIMA optimo	1.09	1.21	1.24	1.42	1.4	1.59	1.5	2.29	2.06	2.6	2.09	2.52
VAR	1.31	1.45	1.3	1.19	1.38	1.62	2.31	2.29	2.97	2.49	3.17	3.94
VAR bayesiano	0.85	1.06	0.99	1.18	1.44	1.9	1.86	1.67	1.68	1.87	1.73	1.87
SARIMAX	0.82	1.05	1.2	1.29	1.35	1.26	1.17	1.99	2.14	1.95	2.17	1.86
VECM	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06	8.06
FAVAR	5.80	5.92	6.4	6.42	6.49	7.26	7.02	6.91	7.09	6.97	6.72	6.7
VAR Economía	1.13	1.19	1.24	2.64	2.12	2.41	3.32	3.49	3.51	3.91	3.4	4.17
VAR Economía bayesiano	0.71	0.67	0.76	0.66	0.81	1.03	1.34	1.52	1.49	1.6	1.58	2.68
Nowcasting	1.79	1.76	2.04	1.87	1.96	2.21	2.18	1.95	2.25	2.09	2.24	2.54
Combinado	1.30											
<b>Tipo de cambio</b>												
AR(1)	0.42	0.93	1.28	1.68	1.85	2.12	2.17	2.11	1.77	1.57	1.37	1.49
SARIMA optimo	0.27	0.59	0.93	1.25	1.32	1.37	1.87	2.19	2.02	1.86	1.86	1.64
VAR	0.37	0.94	1.26	1.52	1.71	1.78	2	2.21	2.57	2.11	1.73	1.22
VAR bayesiano	0.30	0.56	0.83	0.84	1.23	1.52	1.6	1.59	1.38	1.31	1.32	1.47
SARIMAX	0.24	0.5	0.91	1.21	1.18	1.54	2.11	2.26	1.6	2.3	1.74	1.77
VECM	8.03	8.04	8.03	8.03	8.04	8.04	8.04	8.04	8.04	8.04	8.04	8.04
FAVAR	5.53	5.64	5.87	5.83	5.77	5.99	6.04	5.46	5.97	5.99	5.86	5.87
VAR Economía	3.10	2.64	2.86	2.92	2.87	3.28	3.36	3.4	3.25	3.27	2.94	3.15
VAR Economía bayesiano	1.74	1.68	1.58	1.68	2	2.19	2.29	2.18	2.42	2.38	2.58	2.69
Combinado	0.96											
<b>IPC</b>												
AR(1)	0.46	0.81	1.26	1.29	1.71	1.64	1.74	1.37	1.45	1.82	1.9	1.88
SARIMA optimo	0.41	0.63	0.92	0.93	1.29	1.38	1.73	1.91	1.67	1.37	1.64	1.67
VAR	0.45	1.09	1.36	1.57	1.47	1.48	1.64	1.53	1.79	1.88	1.76	2.16
VAR bayesiano	0.42	0.87	1.1	1.3	1.38	1.51	1.43	1.52	1.82	1.9	2.19	2.03
SARIMAX	0.35	0.54	0.85	0.98	1.16	0.93	1.19	1.14	1.2	0.98	0.94	0.88
VECM	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02	8.02
FAVAR	7.72	7.72	7.88	7.9	7.72	7.48	5.76	5.83	5.24	5.17	5.33	5.31
VAR Economía	4.39	4.59	4.61	5.12	5.47	5.59	5.1	4.7	4.81	4.58	3.81	4.25
VAR Economía bayesiano	3.24	3.44	3.44	3.64	3.57	3.77	3.49	3.7	3.85	3.48	3.18	2.82
Combinado	1.64											

**Fuente:**

Elaboración propia.

## Pronósticos de las variables objetivo

Finalmente, en el presente apartado se presentan los resultados de los principales pronósticos de las variables objetivos, con la finalidad de discutir respecto de la distribución de estos, su nivel de incertidumbre alrededor de los pronósticos centrales. A tales fines se han realizado ejercicios de bootstrap para simular la densidad de las predicciones en base a las propiedades estadísticas de los residuos de cada modelo.

En coherencia con lo anterior, se han tomado los percentiles 10, 25, 50, 75 y 90, lo cual permite estudiar toda la distribución de estos. En la **Tabla 4** se presentan los resultados para el caso del crecimiento de la actividad económica, verificándose que para marzo 2022 la media del pronóstico alcanza el 1.80% para el 10% más bajo de los valores más probables y asciende a 10.67% para el 90% más elevados. El pronóstico central (percentil 50) se ubica en 6.10%, para una diferencia de 0.30 puntos porcentuales respecto del valor efectivo del indicador para el citado mes.

Tabla 4: Distribución pronósticos crecimiento IMAE de principales modelos, marzo 2022 / junio 2022 (h = 1:4)

Distribución/modelo	Mar-2022	Abr-2022	May-2022	Jun-2022
<b>AR</b>				
Percentil 10	1.67	1.46	1.31	1.22
Percentil 25	3.41	3.20	3.05	2.95
Percentil 50	5.57	5.36	5.22	5.12
Percentil 75	7.49	7.28	7.14	7.04
Percentil 90	9.26	9.05	8.91	8.81
<b>SARIMA</b>				
Percentil 10	5.49	1.42	0.80	3.58
Percentil 25	7.11	3.04	2.42	5.20
Percentil 50	8.59	4.53	3.91	6.68
Percentil 75	10.48	6.41	5.79	8.57
Percentil 90	11.98	7.92	7.30	10.07
<b>VAR</b>				
Percentil 10	-0.47	0.00	-1.25	-1.65
Percentil 25	2.21	2.38	1.13	0.64
Percentil 50	4.67	5.17	3.94	3.56
Percentil 75	7.78	7.90	6.85	6.38
Percentil 90	10.27	10.59	9.39	8.71
<b>SARIMAX</b>				
Percentil 10	1.13	1.30	0.69	0.52
Percentil 25	3.54	3.44	2.83	2.58
Percentil 50	5.76	5.96	5.36	5.21
Percentil 75	8.56	8.41	7.98	7.75
Percentil 90	10.80	10.84	10.27	9.85
<b>Factores Dinámicos</b>				
Percentil 10	1.18	1.44	0.35	-0.23
Percentil 25	3.64	3.62	2.55	1.87
Percentil 50	5.90	6.20	5.13	4.56
Percentil 75	8.76	8.70	7.80	7.15
Percentil 90	11.05	11.18	10.14	9.30
<b>Promedio</b>				
Percentil 10	1.80	1.12	0.38	0.68
Percentil 25	3.98	3.13	2.40	2.65
Percentil 50	6.10	5.44	4.71	5.03
Percentil 75	8.61	7.74	7.11	7.38
Percentil 90	10.67	9.92	9.20	9.35
Observado	6.40	4.70	NA	NA

**Fuente:**

Elaboración propia.

Para los meses siguientes las divergencias entre los valores altos y bajos se mantienen notablemente similares, observándose una diferencia de 0.74 puntos porcentuales entre el pronóstico central y el valor efectivo para el mes de abril.

Desde la perspectiva de los pronósticos individuales, el modelo SARIMA es el que presenta la menor divergencia entre los valores más altos y los más bajos de la distribución, siendo estos notablemente similares para el

resto de los casos.

Tabla 5: Distribución pronósticos depreciación/apreciación TCN de principales modelos, marzo 2022 / junio 2022 (h = 1:4)

Distribución/modelo	Mar-2022	Abr-2022	May-2022	Jun-2022
<b>AR(1)</b>				
Percentil 10	-3.18	-3.36	-3.36	-3.36
Percentil 25	-2.72	-2.90	-2.90	-2.90
Percentil 50	-2.16	-2.33	-2.33	-2.33
Percentil 75	-1.65	-1.83	-1.83	-1.83
Percentil 90	-1.19	-1.37	-1.37	-1.37
<b>SARIMA</b>				
Percentil 10	-2.72	-2.32	-1.91	-1.33
Percentil 25	-2.38	-1.98	-1.57	-0.99
Percentil 50	-2.07	-1.67	-1.26	-0.68
Percentil 75	-1.67	-1.28	-0.87	-0.29
Percentil 90	-1.36	-0.96	-0.55	0.03
<b>VAR</b>				
Percentil 10	-4.12	-4.29	-3.38	-0.89
Percentil 25	-3.94	-4.13	-3.22	-0.74
Percentil 50	-3.77	-3.94	-3.02	-0.54
Percentil 75	-3.56	-3.75	-2.83	-0.34
Percentil 90	-3.39	-3.57	-2.65	-0.18
<b>SARIMAX</b>				
Percentil 10	-3.64	-3.20	-3.02	-2.70
Percentil 25	-3.10	-2.73	-2.54	-2.24
Percentil 50	-2.61	-2.16	-1.98	-1.65
Percentil 75	-1.98	-1.62	-1.40	-1.08
Percentil 90	-1.48	-1.08	-0.88	-0.62
<b>FAVAR</b>				
Percentil 10	-2.60	-2.32	-2.56	-2.23
Percentil 25	-2.29	-2.05	-2.28	-1.97
Percentil 50	-2.01	-1.72	-1.96	-1.63
Percentil 75	-1.65	-1.41	-1.63	-1.31
Percentil 90	-1.37	-1.10	-1.34	-1.04
<b>Promedio</b>				
Percentil 10	-3.15	-2.97	-2.92	-2.58
Percentil 25	-2.74	-2.59	-2.54	-2.21
Percentil 50	-2.34	-2.16	-2.11	-1.77
Percentil 75	-1.88	-1.73	-1.67	-1.33
Percentil 90	-1.50	-1.33	-1.28	-0.97
Observado	-4.00	-3.39	-3.08	NA

**Fuente:**

Elaboración propia.

De forma análoga, los pronósticos de la variación interanual del TCN presentan una divergencia relativamente más cerrada entre los niveles más altos y bajos de los valores de su distribución. De manera puntual, la diferencia promedio entre el percentil 90 y el 10 oscila entre 1.61 y 1.65 puntos porcentuales para el intervalo marzo-junio del 2022. Este margen es más estrecho para el caso del modelo VAR empleado, moviéndose entre 0.71 y 0.73 puntos porcentuales, siendo mayor para el modelo SARIMAX.

Sin embargo, una parte relevante de los modelos no es capaz de recoger adecuadamente la dinámica de apreciación reciente, evento extraño dentro de la muestra empleada para la estimación, siendo el modelo VAR macroeconómicamente consistente el único con la capacidad de recoger este cambio en la tendencia de la tasa de cambio de manera correcta, aproximándose bastante a las magnitudes de los valores efectivos. En consecuencia es el único modelo para el cual los valores efectivos de las variaciones del TCN están

consistentemente contenidos en la densidad de los pronósticos, con disparidad no mayor a los a los 0.55 puntos porcentuales, en términos absolutos, entre los pronósticos centrales y los valores observados entre marzo y mayo 2022.

Por último, en la **Tabla 6** se presentan los pronósticos para las variaciones porcentuales interanuales del IPC. Similar a lo observado con anterioridad, la dispersión entre los valores de la parte alta y baja de la distribución es sustancialmente más estrecha que la de los pronósticos del crecimiento, lo cual supone un menor riesgo asociado.

De manera específica, la divergencia promedio entre los percentiles 90 y 10 oscila entre 1.40 y 1.42 puntos porcentuales, siendo estas diferencias menores en el caso del modelo SARIMAX y mayores para el AR(1) utilizado como punto de referencia (benchmark).

Respecto a las divergencias entre los valores observados y los pronósticos centrales promedio, estos muestran diferencias que oscilan entre 0.06 y 0.36 puntos porcentuales durante el periodo marzo mayo 2022.

Tabla 6: Distribución pronósticos inflación IPC de principales modelos, marzo 2022 / junio 2022 (h = 1:4)

Distribución/modelo	Mar-2022	Abr-2022	May-2022	Jun-2022
<b>AR(1)</b>				
Percentil 10	7.84	8.01	8.00	8.00
Percentil 25	8.29	8.46	8.45	8.45
Percentil 50	8.85	9.02	9.01	9.01
Percentil 75	9.35	9.51	9.51	9.50
Percentil 90	9.81	9.97	9.97	9.96
<b>SARIMA</b>				
Percentil 10	8.19	7.96	7.34	7.14
Percentil 25	8.55	8.33	7.70	7.50
Percentil 50	8.88	8.66	8.03	7.84
Percentil 75	9.30	9.08	8.45	8.26
Percentil 90	9.64	9.42	8.79	8.59
<b>VAR</b>				
Percentil 10	8.53	9.12	9.49	9.71
Percentil 25	8.81	9.37	9.74	9.95
Percentil 50	9.06	9.66	10.03	10.26
Percentil 75	9.39	9.95	10.34	10.55
Percentil 90	9.65	10.23	10.60	10.80
<b>SARIMAX</b>				
Percentil 10	8.91	9.54	9.83	10.08
Percentil 25	9.15	9.75	10.05	10.29
Percentil 50	9.37	10.00	10.29	10.55
Percentil 75	9.65	10.25	10.55	10.80
Percentil 90	9.87	10.49	10.78	11.00
<b>FAVAR</b>				
Percentil 10	8.03	8.25	8.03	7.76
Percentil 25	8.43	8.61	8.39	8.11
Percentil 50	8.80	9.04	8.82	8.55
Percentil 75	9.27	9.45	9.26	8.98
Percentil 90	9.65	9.85	9.64	9.33
<b>Promedio</b>				
Percentil 10	8.30	8.58	8.54	8.54
Percentil 25	8.65	8.90	8.86	8.86
Percentil 50	8.99	9.28	9.24	9.24
Percentil 75	9.39	9.65	9.62	9.62
Percentil 90	9.72	9.99	9.96	9.94
Observado	9.05	9.64	9.47	NA

**Fuente:**

Elaboración propia.

## 9. Comentarios finales

En el presente documento se presenta tanto la estimación como evaluación de desempeño de una batería de modelos de series de tiempo utilizados por el Departamento de Estudios Fiscales de Ministerio de Hacienda de la República Dominicana para la elaboración de pronósticos de corto plazo. Los resultados sugieren que los modelos puramente estadísticos, en los cuales las variables explicativas y especificaciones se seleccionan siguiendo procesos recursivos, al margen de los fundamentos y las teorías económicas, exhiben mejor desempeño en los pronósticos del IPC y el TCN, mientras que el IMAE es proyectado con mayor precisión utilizando un modelo macroeconómicamente más consistente. Sin embargo, la baja capacidad del primer enfoque para predecir cambios de tendencia observados al final de la muestra para el TCN indica que es relevante el uso de modelos con información sobre la dinámica económica a partir de diversas fuentes (distintos sectores de la economía), siendo capaces de capturar señales tempranas sobre posibles cambios en el comportamiento de los indicadores de interés.

En adición, cabe destacar que los modelos presentados deberían concertarse en la proyecciones a muy corto plazo (especialmente en los pronósticos mes a mes), en vista de que los modelos que presentan mejor ajuste suelen ser los menos elaborados (desde el punto de vista de la consistencia macroeconómica) y que tienden rápidamente al promedio. Esto indica que para horizontes mayores se recomienda el uso de modelos equipados para proyecciones de mediano plazo y macroeconómicamente más fundamentados.

En coherencia con lo anterior, la integración de los modelos de corto plazo en un sistema, supone una etapa inicial a la consolidación de los modelos de mediano plazo para las proyecciones macroeconómicas.

## Referencias


- Aiolfi, M., & Timmermann, A. (2003). Persistence in Forecasting Performance.
- Bai, J., Li, K., & Lina, L. (2015). Estimation and inference of FAVAR models. *Journal of Business & Economic Statistics*.
- BCRD. (2017). Sistema de Proyecciones Macroeconómicas del Banco Central de la República Dominicana. Santo Domingo, D.N.: BCRD.
- Bernanke, B., Boivin, J., & Piotr, E. (2003). Measuring the Effects of Monetary Policy: A Factor-Augmented Vector Autoregressive (FAVAR) Approach.
- Bravo, J., Cerda, R., Larraín, F., & Riveras, W. V. (2014). Un Modelo Macroeconómico de Proyección para Chile.
- Cajiao, S., Melo, L., & Parra, D. (2014). Pronósticos para una Economía menos Volátil: el caso Colombiano. Borradores de Economía.
- Castaño, E., & Melo, L. (n.d.). MÉTODOS DE COMBINACIÓN DE PRONÓSTICOS : Una aplicación a la inflación colombiana. Banco de la República de Colombia.
- Cerda, R., Gamboni, C., Beyzaga, C., & Gallardo, I. (2019). Modelos de series de tiempo para la proyección de ingresos fiscales en Chile. Dirección de Presupuestos.
- Critiano, D., Hernández, M., & Paulino, J. (2012). Pronósticos de corto plazo en tiempo real para la actividad económica colombiana. Borradores de Economía.
- Delbrück, F., Dunstan, A. H., Lienert, A., Pepper, H., & Sleeman, C. (2008). The evolution of the Forecasting and Policy System (FPS) at the Reserve Bank of New Zealand. Reserve Bank of New Zealand.
- Drought, S., & McDonald, C. (2011). Forecasting house price inflation: a model combination approach. Reserve Bank of New Zealand.
- González, E. (2008). Pronósticos de agregados a partir de desagregados Caso empírico: Inflación de alimentos en Colombia.
- Jalil, M., & Misas, M. (2006). Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétricas. Banco de la República de Colombia.
- Jaramillo, M., & Javier, a. (2017). Modelos Factoriales y Pronósticos Macroeconómicos: El caso del Crecimiento Colombiano.
- Matheson, T. (2005). Factor model forecasts for New Zealand. Reserve Bank of New Zealand.
- Michael, C. (2005). Evaluating Econometric Forecasts of Economic and Financial Variables.
- Neroli, A., & Reid, G. (2017). NZSIM: A model of the New Zealand economy for forecasting and policy analysis. RESERVE BANK OF NEW ZEALAND.
- Pérez, J., & Brens, P. (2018). Modelo de Factores Dinámicos para Pronósticos de la Actividad Económica en Tiempo Real. Ministerio de Hacienda de la República Dominicana.

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

Salazar, J. (2009). Evaluación de una red neuronal sobre el PIB. Borradores de Economía.

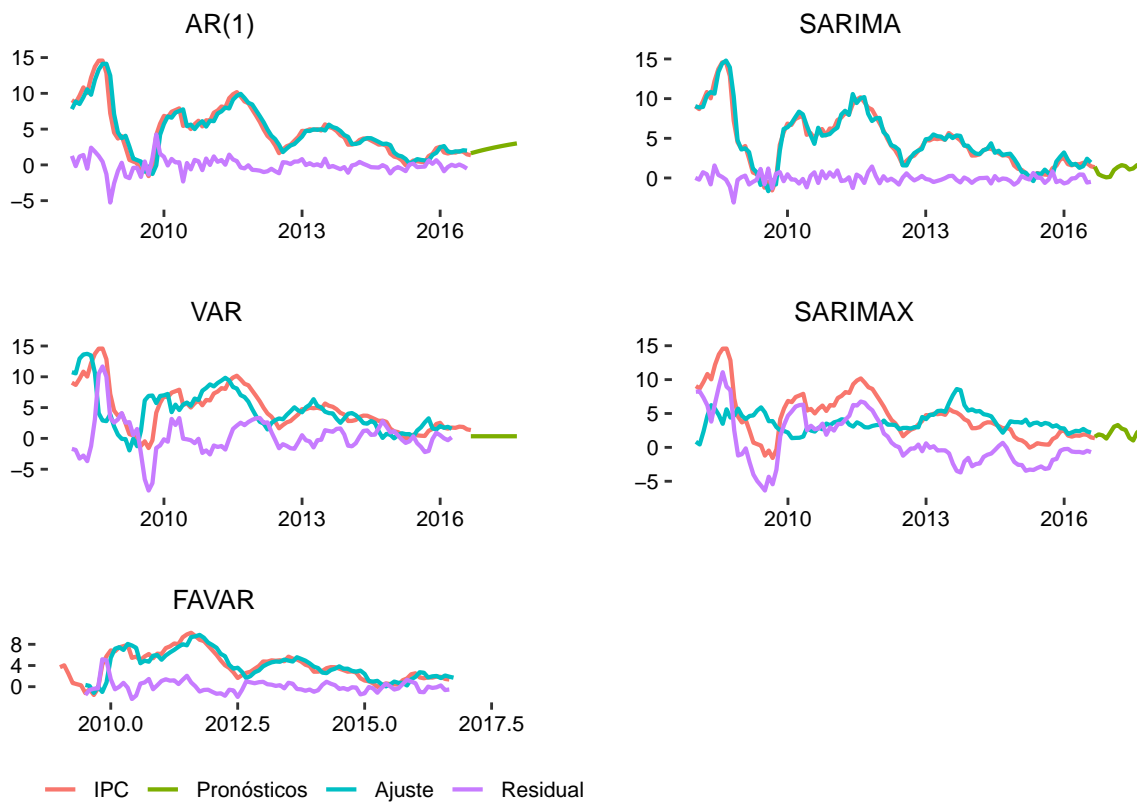


## Anexos



Fuente. Elaboración propia.

Gráfico A1: Bondad del ajuste según modelos de pronósticos para el TCN



Fuente. Elaboración propia.


Gráfico A2: Bondad del ajuste según modelos de pronósticos para el IPC

Tabla A1: Capacidad predicción de signo modelos empleados por variable objetivo mediante ventanas móviles, hasta  $h = 12$

Modelo	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	t+11	t+12
<b>IMAE</b>												
AR(1)	0.91	0.91	0.79	0.73	0.7	0.7	0.7	0.7	0.7	0.64	0.64	0.67
SARIMA optimo	0.88	0.85	0.79	0.73	0.67	0.64	0.67	0.7	0.7	0.64	0.64	0.67
VAR	0.88	0.88	0.85	0.82	0.79	0.79	0.76	0.7	0.67	0.64	0.61	0.64
VAR bayesiano	0.94	0.94	0.88	0.79	0.73	0.7	0.67	0.67	0.7	0.64	0.64	0.67
SARIMAX	0.91	0.88	0.85	0.82	0.76	0.76	0.7	0.67	0.67	0.64	0.61	0.67
VECM	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.86	0.81	0.86	0.81	0.85
FAVAR	0.36	0.36	0.42	0.39	0.39	0.36	0.33	0.33	0.33	0.33	0.3	0.36
VAR Economía	0.97	0.91	0.85	0.82	0.79	0.76	0.73	0.7	0.67	0.64	0.61	0.64
VAR Economía bayesiano	0.95	0.91	0.88	0.84	0.77	0.74	0.71	0.69	0.67	0.65	0.66	0.67
Nowcasting	0.67	0.67	0.67	0.67	0.67	0.67	0.67	0.67	0.67	0.67	0.67	0.67
Combinado	0.73											
<b>Tipo de cambio</b>												
AR(1)	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMA optimo	1.00	1	1	1	1	1	1	1	1	1	1	1
VAR	1.00	1	1	1	1	1	1	1	1	1	1	1
VAR bayesiano	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMAX	1.00	1	1	1	1	1	1	1	1	1	1	1
VECM	1.00	1	1	1	1	1	1	1	1	1	1	1
FAVAR	0.09	0.15	0.12	0.12	0.09	0.15	0.15	0.18	0.21	0.24	0.3	0.33
VAR Economía	0.70	0.7	0.7	0.73	0.76	0.79	0.82	0.85	0.88	0.91	0.94	0.97
VAR Economía bayesiano	0.95	0.96	0.96	0.96	1	1	1	1	1	1	1	1
Combinado	1.00											
<b>IPC</b>												
AR(1)	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMA optimo	1.00	1	0.94	0.94	0.88	0.88	0.82	0.82	0.85	0.88	0.82	0.94
VAR	1.00	1	0.97	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94
VAR bayesiano	1.00	1	1	1	1	1	1	1	1	1	1	1
SARIMAX	1.00	1	1	0.94	0.94	0.94	0.91	0.94	0.97	1	1	1
VECM	1.00	1	1	0.9	0.9	0.86	0.9	0.9	0.95	1	0.86	0.85
FAVAR	0.09	0.15	0.15	0.18	0.12	0.15	0.12	0.12	0.12	0.12	0.15	0.15
VAR Economía	0.70	0.7	0.7	0.73	0.76	0.79	0.82	0.85	0.88	0.91	0.94	0.97
VAR Economía bayesiano	0.95	0.96	0.96	0.96	1	1	1	1	1	1	1	1
Combinado	1.00											

**Fuente:**

Elaboración propia.



Fuente. Elaboración propia.

Gráfico A3: RMSE de modelos combinados por cantidad de modelos




Gráfico A4: Proyecciones del Índice Mensual de Actividad Económica (IMAE)




Gráfico A5: Proyecciones del Tipo de Cambio Nominal




Gráfico A6: Proyecciones del Índice de Precios al Consumidor (IPC)



Avenida México 45 Gascue Santo Domingo República Dominicana  
TELÉFONO 809 687 5131 [HACIENDA.GOB.DO](http://HACIENDA.GOB.DO)