

Pronósticos de inflación mediante técnicas bayesianas

Juan Diego Chavarría Mejía
Carlos Chaverri Morales

Documento de Investigación DI-05-2015
Departamento de Investigación Económica
Marzo, 2015

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

La serie Documentos del Departamento de Investigación Económica del Banco Central de Costa Rica en versión PDF puede encontrarse en www.bccr.fi.cr

Pronósticos de inflación mediante técnicas bayesianas.

Juan Diego Chavarría
Carlos Chaverri Morales¹

Resumen

La efectividad de la política monetaria bajo un esquema de metas de inflación como el propuesto por el Banco Central de Costa Rica se basa en buena medida en el correcto y oportuno pronóstico de la inflación de corto y mediano plazo con el fin de diseñar de mejor forma las acciones de política monetaria. Así el propósito de este trabajo es desarrollar una herramienta complementaria para elaborar pronósticos de inflación mediante un enfoque bayesiano. Para lo anterior se propone la utilización de la metodología “Bayesian Model Averaging” y de “Weighted Average Least Squares”. Los modelos de proyección especificados permitirían ampliar y complementar el análisis que se realiza actualmente con el Modelo Macroeconómico de Proyección Trimestral (MMPT) del Banco Central de Costa Rica. Como resultado esta investigación muestra que, para datos de periodicidad mensual y a horizontes de pronóstico de 1 a 12 meses, es posible encontrar proyecciones mediante un proceso bayesiano que poseen una mayor capacidad predictiva en relación con aquellas producidas por un modelo autorregresivo.

Palabras clave: Modelos de series temporales, números índice y agregación, predicción y simulación. Análisis bayesiano.

Clasificación JEL.: C22, C43, E27, C11.

¹ Departamento de Investigación Económica.

chavarriamj@bccr.fi.cr

chaverrimc@bccr.fi.cr

Forecasting Inflation by Bayesian techniques.

Abstract

The effectiveness of monetary policy under inflation targeting scheme proposed by the Central Bank of Costa Rica is based in the correct and timely forecast of inflation in order to design the best monetary policy actions. The purpose of this study is to develop a complementary tool to forecast inflation using a Bayesian approach. To that end, we estimate the methodologies of "Bayesian Model Averaging" and "Weighted Average Least Squares". This forecast allows expanding and complementing the analysis actually estimated with the Macroeconomic Quarterly Projection Model (MQPM) of the Central Bank of Costa Rica. From the results of this evaluation, we show that for monthly data and forecast horizons from 1 to 12 months, you may find forecast by a Bayesian process that have greater predictive performance than the autoregressive model.

Key words: Time-Series Models, Index Numbers and Aggregation, Forecasting and Simulation. Bayesian analysis.

JEL classification: C22, C43, E27,C11.

Pronósticos de inflación mediante técnicas bayesianas

Contenido

1.	Introducción	6
2.	Metodología	7
	2.1 <i>Bayesian model averaging</i>	10
	2.2 Weighted Average Least Squares	13
	2.3 Factores dinámicos	15
3.	Selección de variables y datos utilizados	16
4.	Datos utilizados	17
5.	Resultados obtenidos	22
6.	Conclusiones	31
7.	Bibliografía	32
8.	Anexo 1	34

Pronósticos de inflación mediante técnicas bayesianas.

1. Introducción

La política monetaria en Costa Rica se encuentra en un proceso de ajuste ante la migración gradual de un régimen monetario basado en el control de los agregados monetarios hacia un sistema de Meta Explícita de Inflación². Es reconocido en la literatura sobre el tema que en este tipo de régimen, la efectividad de la política monetaria se puede cuantificar, entre otras cosas, contrastando la evolución de la inflación observada en el corto y mediano plazo con la meta anunciada.

De manera prospectiva y haciendo uso de herramientas cuantitativas, dicha evaluación es posible mediante la construcción de pronósticos de inflación, los cuales constituyen un marco de análisis básico de la programación macroeconómica. Adicionalmente, la elaboración de indicadores que aíslan la volatilidad, que ciertos precios registran, complementa la información sobre la cual las autoridades toman las decisiones sobre la política monetaria.

En línea con lo anterior y con el fin de ampliar la gama de instrumentos con que cuenta el Banco Central de Costa Rica (BCCR), el Departamento de Investigación Económica ha desarrollado investigación tendiente a elaborar una serie de modelos que le permiten contar con pronósticos de la inflación. La construcción de dichos modelos ha seguido principalmente dos líneas de investigación: i) especificaciones univariadas de series de tiempo y ii) construcción de modelos semiestructurales.

En lo que corresponde a las especificaciones univariadas, se han propuesto modelos autoregresivos con media móvil (ARMA); entre ellos se encuentran los trabajos de Hoffmaister et. al. (2000), Muñoz (2008), Rodríguez (2009) y Vindas (2011). En relación con la segunda línea de trabajo, se cuenta con distintos modelos entre ellos: Modelo Univariable de Inflación, Modelo de Vector Autorregresivo Lineal de Mecanismos de Transmisión de la Política Monetaria, Modelo Impacto de los Precios del Petróleo en Costa Rica, Modelo de Títulos

² Este proyecto fue aprobado como parte del Plan Estratégico Maestro del BCCR para el periodo 2005-2009, mediante artículo 11 de la sesión de Junta Directiva No. 5229-2005 del 5 de enero del 2005.

Fiscales, Modelo de *Pass Through* del Tipo de Cambio en Costa Rica y proyecciones basadas en un modelo “ingenuo”³.

Adicionalmente Álvarez y Torres (2011) estimaron modelos de proyección de inflación de corto plazo basándose en una especificación de Curva de Phillips para las series trimestrales y mensuales de inflación general (derivada del IPC) y sus desagregaciones en bienes y servicios transables y no transables. El resultado de esta investigación muestra que, para datos de periodicidad trimestral y a horizontes de pronóstico de entre 2 y 4 trimestres, es posible encontrar combinaciones de proyecciones ponderadas que poseen una mayor capacidad predictiva en relación con aquellas que se estiman de forma agregada para la tasa de inflación.

El presente trabajo tiene como objetivo desarrollar herramientas complementarias para elaborar pronósticos de inflación a partir de la teoría bayesiana. Para lo anterior se propone utilizar la metodología “*Bayesian Model Averaging*” (BMA, por sus siglas en inglés) y la “*Weighted Average Least Squares*” (WALS, por sus siglas en inglés). Los modelos especificados permitirían no solamente ampliar el análisis y las proyecciones que se realizan actualmente con el Modelo Macroeconómico de Proyección Trimestral (MMPT), sino que además constituyen una fuente de información adicional para la formulación de proyecciones basadas en juicio de experto.

Luego de esta introducción, en la segunda sección se presenta una breve reseña de la metodología empleada. En la tercera sección se explicará los criterios para seleccionar las variables que componen la base de datos y el indicador de inflación de referencia. En la cuarta se mencionan los principales resultados. Finalmente, la quinta sección contiene las principales conclusiones de la investigación y las recomendaciones del caso.

2. Metodología

Esta sección contiene una descripción de las metodologías utilizadas para la construcción de las proyecciones de inflación mediante técnicas bayesianas.

Un problema que hasta el momento ha sido poco abordado en la literatura y al cual todos los investigadores se enfrentan a la hora de realizar cualquier estudio empírico, es el referente a

³ El modelo ingenuo proyecta la inflación asumiendo que no varía con respecto al último dato observado.

la incertidumbre⁴. Este problema surge al momento de seleccionar una especificación que se considera apropiada para predecir una variable de interés (Steel, [2014](#)). Dentro de las posibles soluciones a este problema, sobresalen los métodos que aprovechan al máximo toda la información disponible, como pueden ser los modelos basados en métodos bayesianos y de factores dinámicos.

Además del problema sobre cuál es la especificación correcta, existe otro relacionado con las variables que deben ser incluidas. Precisamente, en los años recientes esta dificultad ha tomado cierta relevancia dado el aumento en la cantidad de información estadística a disposición del público y de los investigadores, lo que hace cada vez más difícil determinar qué variables utilizar aun respetando los criterios teóricos que respaldan la validación empírica.

Los modelos para generar pronósticos de inflación no son ajenos a dichos problemas. Por lo tanto, para solucionar estas dificultades en este trabajo se propone la utilización de dos métodos bayesianos, con los cuales se busca primordialmente reducir la incertidumbre sobre la especificación del modelo. El primero de ellos es llamado “*Bayesian Model Averaging*” (BMA) que es un método usual para la generación de pronósticos en modelos multivariados cuando existe incertidumbre sobre la correcta especificación por utilizar, esta técnica ha sido descrita por Magnus et al. ([2010](#)). Mientras el segundo método de estimación que se utiliza es el propuesto por Magnus y Durbin ([1999](#)) y Danilov y Magnus ([2004](#)) llamado “*Weighted Average Least Squares*”(WALS).

En ambos enfoques metodológicos la preocupación no se centra en la elección óptima de un modelo, sino buscan las mejores estimaciones de todos los n modelos posibles, para luego ponderar estos resultados mediante su respectiva probabilidad condicional a los datos muestrales. Esto para brindar una medida ponderada tanto de los parámetros como de los pronósticos de la variable dependiente.

Por otro lado, con el objetivo de utilizar la mayor cantidad de información disponible, el ejercicio de estimación que proponemos utiliza el enfoque de factores dinámicos. Esta técnica se basa en el uso de las componentes principales como variables sintéticas; para que esto sea posible se busca utilizar aquella información que esté lo más correlacionada posible con las variables independientes. Por lo tanto, es un método de reducción de información el cual intenta maximizar la variabilidad explicada por las variables sintéticas reduciendo la distancia entre las observaciones originales y los puntos proyectados sobre estas variables.

⁴ Falta de conocimiento seguro y claro de que la elección de las variables es la adecuada.

Con esta técnica se facilita el manejo de una gran cantidad de información contenida en un número reducido de variables, disminuyendo la incertidumbre sobre cuáles variables incorporar en las estimaciones definitivas y adicionalmente se logra simplificar los requerimientos computacionales para realizar las estimaciones.

La estimación del pronóstico de inflación mediante el enfoque BMA y WALS parte del siguiente modelo lineal normal:

$$y = X_1\hat{\beta}_1 + X_2\hat{\beta}_2 + \varepsilon; \text{ con } \varepsilon \sim N(0, \sigma^2) \quad (1)$$

Donde y es un vector de $n \times 1$ de observaciones de la variable de interés. Además, se consideran dos conjuntos de variables, el primero representado en la matriz X_1 de tamaño $n \times k_1$ llamado variables “*focus*”⁵, constituido por las variables sobre las cuales se tiene certeza que deben estar en el modelo⁶, ya sea por aspectos teóricos o por algún interés empírico particular del investigador.

Adicionalmente, se tiene otro grupo de variables sobre las que no se tiene certeza si deben tomarse en consideración dentro de la especificación del modelo, estas son llamadas variables auxiliares. Este grupo son las que se representan en la matriz X_2 de tamaño $n \times k_2$.

Por último, β_1 representa al vector de parámetros de tamaño $k_1 \times 1$ de las variables *focus* y β_2 es el vector de parámetros de tamaño $k_2 \times 1$ de las variables auxiliares.

Así, del análisis previo resulta relevante preguntarse, ¿cuáles variables auxiliares es conveniente utilizar? En la literatura sobre el tema no existe una regla definida para dar respuesta a dicha interrogante. Una alternativa que resulta intuitiva es probar con diferentes modelos que tomen en cuenta todas las posibles combinaciones de estas variables auxiliares. Donde para cada variable auxiliar se tienen dos modelos posibles, uno llamado modelo restrictivo donde se supone que el coeficiente correspondiente a la variable auxiliar es cero y otro sin restricción donde no se hace dicho supuesto. Si se repite el proceso para todas las k_2 variables auxiliares, se tendrán un total de 2^{k_2} modelos posibles, donde a cada uno de estos modelos se podrá llamar como M_i , $i = 1, 2, \dots, 2^{k_2}$. Y se representa de la siguiente forma:

⁵ Manteniendo la nomenclatura original de Luca & Magnus (2011).

⁶ Este grupo de variables se supone que tienen probabilidad 1 de encontrarse en la especificación final.

$$y = X_1\hat{\beta}_1 + X_{2_i}\hat{\beta}_{2_i} + \varepsilon; \text{ con } \varepsilon \sim N(0, \sigma^2) \quad (2)$$

Ahora, para estimar los parámetros de cada modelo ($\hat{\beta}_1$ y $\hat{\beta}_{2_i}$), se plantean dos métodos diferentes. Los cuales se detallan a continuación.

2.1 Bayesian model averaging

El primero de ellos es un método propuesto por Magnus et al. (2010), el cual parte de las siguientes regresiones particionadas utilizadas para estimar los parámetros sin restricción de cada modelo M_i :

$$\hat{\beta}_{1u} = \hat{\beta}_{1r} - Q\hat{\beta}_{2u} \quad (3)$$

$$\hat{\beta}_{2u} = (X_2' M_1 X_2)^{-1} X_2' M_1 y \quad (4)$$

Donde:

$$\hat{\beta}_{1r} = (X_1' X_1)^{-1} X_1' y \quad (5)$$

$$Q = (X_1' X_1)^{-1} X_1' X_2 \quad (6)$$

$$M_1 = I_n - X_1 (X_1' X_1)^{-1} X_1' \quad (7)$$

La variable $\hat{\beta}_{1r}$ representa el vector de parámetros (modelo restringido) de tamaño $k_1 \times 1$ de una regresión usando el criterio de mínimos cuadrados ordinarios (MCO) explicada sólo por las variables consideradas *focus*. Además, Q es el vector de parámetros de tamaño $k_1 \times 1$ de una regresión MCO de X_2 explicada por las variables *focus* y M_1 es una matriz de tamaño $n \times n$ (idempotente y simétrica) que representa la proyección en el espacio nulo (ortogonal) de las variables *focus*.

Mediante este procedimiento los parámetros del modelo sin restricciones (ecuaciones (3) y (4)) pueden obtenerse de manera sencilla para cada modelo M_i . Pero al realizar esto obtenemos un conjunto de parámetros y modelos, sobre los cuales no se tiene certeza si deben o no estar en la especificación definitiva, cada uno de ellos ofrece información importante que se puede aprovechar. Por esto, se plantea una estrategia para calcular la probabilidad de que un modelo determinado sea el correcto sobre el total de modelos considerados.

Para esto como primer paso, se define una distribución de probabilidad inicial (*prior*) sobre el conjunto de modelos, donde su función de probabilidad mide la probabilidad de que el modelo sea correcto. Esta distribución tiene como una de sus principales características que se define de forma previa a contrastar con los datos muestrales, por eso es llamada distribución *prior* y se representa como $p(M_i)$.

Luego de esto, parece coherente utilizar toda la información disponible sobre la variable de interés para calcular la probabilidad que un determinado modelo M_i sea el correcto. Por lo tanto, se plantea una distribución de probabilidad condicional a la información disponible, la cual es llamada distribución *posterior* y se representa como $p(M_i|y)$.

Para obtener esta distribución *posterior* se parte de la siguiente definición de probabilidad condicional:

$$p(M_i|y) = \frac{p(M_i, y)}{p(y)} \quad (8)$$

Como $p(M_i, y) = p(y, M_i)$, y usando nuevamente la definición de probabilidad condicional se puede sustituir el numerador de la ecuación (8) por $p(M_i, y) = p(y|M_i)p(M_i)$.

Además, por el teorema de probabilidad total es posible sustituir el denominador por:

$$p(y) = p(y|M_1)p(M_1) + p(y|M_2)p(M_2) + \dots + p(y|M_{2^{k_2}})p(M_{2^{k_2}}) = \sum_{j=1}^{2^{k_2}} p(y|M_j)p(M_j).$$

Con lo que la distribución posterior, se representa como:

$$\lambda_i = P(M_i|y) = \frac{p(y|M_i)p(M_i)}{\sum_{j=1}^{2^{k_2}} p(y|M_j)p(M_j)} \quad (9)$$

Como se puede apreciar esta distribución depende tanto de la distribución *prior* como de la probabilidad condicional $P(y|M_i)$, también llamada función de verosimilitud marginal. Respecto a la distribución *prior*, si no se cuenta con información de otras investigaciones o algún criterio de experto sobre el conjunto de modelos, usualmente se asume que todos los modelos tienen la misma probabilidad de ser el modelo correcto, representado por $P(M_i) = 2^{-k_2}$. Asimismo al definir la distribución *prior* de esta manera, se observa que no depende de i , por lo que la distribución posterior únicamente dependería de la función de verosimilitud marginal, $\lambda_i \propto p(y|M_i)$.

Para obtenerla se puede suponer que un determinado modelo M_i es el correcto. Realizando un proceso similar al anterior se puede hacer algún supuesto sobre la distribución *prior* de los parámetros.

Por ejemplo, si se asume una *prior* no informativa sobre β_1 y σ^2 , y una *prior* Gaussiana para β_{2i} , se obtiene que para un modelo en particular se tiene la probabilidad condicional prior, que es una probabilidad tipo Zellner's *g-prior* (Zellner, [1986](#)), la cual es una distribución normal que depende del hiperparámetro g , el que está relacionado con la importancia que se le quiera brindar a la información contenida en la *prior*. En este trabajo se sigue lo propuesto por Fernández, Ley y Steel ([2001](#)) donde se utiliza una regla expresada en la ecuación (12) para determinar este hiperparámetro. Generando la siguiente probabilidad condicional *prior*:

$$p(\beta_1, \beta_2, \sigma^2 | M_i) \propto (\sigma^2)^{(k_{2i}+2)/2} \exp\left(-\frac{\beta_{2i}' V_{0i}^{-1} \beta_{2i}}{2\sigma^2}\right) \quad (10)$$

Donde:

$$V_{0i}^{-1} = g_i X_{2i}' M_1 X_{2i} \quad (11)$$

$$g_i = \frac{1}{\max(n, k_2^2)} \quad (12)$$

Como resultado del supuesto de normalidad, se obtiene la siguiente distribución de verosimilitud gamma inversa para los parámetros:

$$p(y | \beta_1, \beta_{2i}, \sigma^2, M_i) \propto (\sigma^2)^{-n/2} \exp\left(-\frac{\varepsilon_i' \varepsilon_i}{2\sigma^2}\right) \quad (13)$$

Ahora si se combina (10) y (13), y el resultado se usa en (9), la distribución posterior del conjunto de modelos toma la siguiente forma:

$$\lambda_i \propto \left(\frac{g_i}{1 + g_i}\right)^{k_{2i}/2} (y' M_1 A_i M_1 y)^{-(n-k_1)/2} \quad (14)$$

Donde:

$$A_i = \frac{g_i}{1 + g_i} M_1 + \frac{g_i}{1 + g_i} [M_1 - M_1 X_{2i} (X'_{2i} M_1 X_{2i})^{-1} X'_{2i} M_1] \quad (15)$$

Consecuentemente, de las ecuaciones (14) y (15) se observa que la probabilidad *posterior* de cada modelo depende básicamente de la matriz X_{2i} de variables auxiliares y del hiperparámetro g_i , e indirectamente de la matriz X_1 , las que modifican el valor de A_i y con esto la probabilidad posterior.

Dado que ahora se cuenta con un valor para la probabilidad de cada modelo, se puede agregar para cada parámetro estimado sobre el total de modelos posibles calculados utilizando un promedio ponderado, donde el ponderador utilizado es la probabilidad posterior de cada modelo, como se muestra a continuación:

$$E(\beta_j|y) = \sum_{i=1}^{2^{k_2}} \lambda_i E(\beta_j|y, M_i) \quad (16)$$

Estas agregaciones de modelos han mostrado buenas propiedades predictivas como se ha demostrado en diversos estudios. Por otro lado, estos modelos cuentan con algunas limitaciones principalmente relacionadas con el número de variables auxiliares, dado que si se cuenta con un número considerable de variables auxiliares el proceso de estimación puede resultar lento, al igual el hecho de que no se utiliza ningún criterio de optimización en la elección de la prior sobre β_2 puede ser objeto de críticas.

2.2 Weighted Average Least Squares

Otra estrategia que puede ser utilizada para encontrar la probabilidad de cada modelo, es el propuesto por De Luca y Magnus (2011), esta técnica se basa en una ortogonalización de la matriz de variables auxiliares, la que permite reducir de manera considerable la cantidad de modelos por estimar. Pasando a estimar únicamente k_2 modelos, reduciendo significativamente el tiempo de estimación.

Los autores proponen que se siga la siguiente ortogonalización:

$$\Lambda = P' X'_2 M_1 X_2 P \quad (17)$$

$$X_2^* = X'_2 P \Lambda^{-1/2} \quad (18)$$

$$\beta_2^* = \Lambda^{1/2} P' \beta_2 \quad (19)$$

Donde P es una matriz de $k_2 \times k_2$ formada por los vectores propios de la matriz $X_2' M_1 X_2$ (matriz de la proyección de X_2 ortogonal a X_1), Λ es una matriz diagonal de $k_2 \times k_2$, donde en la diagonal se encuentran los valores propios de la matriz $X_2' M_1 X_2$.

Además se puede probar de (18) que $X_2'^* M_1 X_2^* = I_{k_2}$ y obtener los parámetros originales de β_2 de (19), como $\beta_2 = P \Lambda^{-1/2} \beta_2^*$.

Así, luego de realizar esta ortogonalización se estima el modelo no restringido mediante MCO como sigue:

$$\hat{\beta}_{1u} = \hat{\beta}_{1r} - R \hat{\beta}_{2u} \quad (20)$$

$$\hat{\beta}_{2u} = X_2'^* M_1 y \quad (21)$$

Donde:

$$\hat{\beta}_{1r} = (X_1' X_1)^{-1} X_1' y \quad (22)$$

$$R = (X_1' X_1)^{-1} X_1' X_2^* \quad (23)$$

Se desprende que (22) es el vector de parámetros de tamaño $k_1 \times 1$ de una regresión por MCO de y explicada por las variables *focus*. Además, la ecuación (23) representa el vector de parámetros de tamaño $k_1 \times 1$ de una regresión MCO de X_2^* explicada por las variables *focus*.

Ahora si se define una matriz $S_i = (I_{k_2 - k_{2i}}, 0)$ de tamaño $k_2 \times (k_2 - k_{2i})$, que busca capturar las restricciones que se imponen a cada modelo M_i sobre los parámetros de las variables auxiliares. Se puede cambiar las ecuaciones (20) y (21) por:

$$\hat{\beta}_{1i} = \hat{\beta}_{1r} - R W_i \hat{\beta}_{2u} \quad (24)$$

$$\hat{\beta}_{2u} = W_i X_2'^* M_1 y \quad (25)$$

Donde:

$$W_i = I_{k_2} - S_i S_i' \quad (26)$$

Así W_i es una matriz diagonal de unos y ceros de tamaño $k_2 \times k_2$, donde si un elemento en particular es igual a cero se considera que la restricción está activa y por lo tanto en este modelo la variable auxiliar respectiva tiene una restricción y su parámetro se supone igual a cero, lo opuesto en el caso donde se encuentre un uno.

Esta matriz diagonal genera que las k_2 variables auxiliares sean independientes, lo que admite que todos los modelos que contienen un $X_{2_i}^*$ en particular, tengan el mismo $\beta_{2_i}^*$ independiente de cuales otras variables auxiliares sean consideradas, lo que reduce de manera significativa los cálculos.

Por otro lado, este método de estimación permite utilizar como prior sobre las variables auxiliares otro tipo de distribuciones como la de Laplace o Subotin, las cuales han demostrado propiedades importantes de equivalencia en las estimaciones⁷.

2.3 Factores dinámicos

Además de preocuparse por la incertidumbre propia sobre la especificación del modelo, interesa reducir la indecisión sobre cuáles variables utilizar a la hora de la estimación. Así, al disponer de una gran cantidad de información que puede llegar a utilizarse como variables *focus* o auxiliares en la ecuación (2), puede resultar relevante utilizar alguna técnica que permita disminuir este número de variables buscando tener una pérdida mínima de información.

De esta manera, para dar solución a lo anterior se propone utilizar la técnica de estimaciones con factores dinámicos, que no es otra cosa que regresiones donde las variables explicativas son los componentes principales⁸ obtenidos de un análisis de componentes principales (ACP). Dichos componentes son variables sintéticas que se caracterizan por ser combinaciones lineales de las variables originales pero con la ventaja que en un número reducido de variables se logra explicar un alto porcentaje de la variabilidad del conjunto de variables originales.

⁷ Para mayor detalle consultar De Luca y Magnus, [2011](#).

⁸ Los componentes principales se obtienen como el producto matricial de la matriz de datos X por cada uno de los vectores propios u_i , provenientes de una diagonalización de la matriz de correlaciones de los datos originales.

De esta forma si se parte de un modelo como (2), se pueden sustituir las variables *focus* y auxiliares por un número limitado de componentes principales, como se propone a continuación.

$$y = F_1 \hat{\beta}_1 + F_{2i} \hat{\beta}_{2i} + \epsilon; \text{ con } \epsilon \sim N(0, \sigma^2) \quad (27)$$

Donde F_1 es una matriz que está formada por los componentes principales que se consideran *focus* y F_{2i} es la matriz formada por los componentes principales considerados auxiliares.

3. Selección de variables y datos utilizados

Dada la importancia que tiene la adecuada medición de la inflación a la hora de tomar decisiones de política monetaria, y en especial para el BCCR poder predecir sus valores futuros de manera precisa y oportuna, resulta fundamental escoger cuál es la medida de precios que se debe seguir y determinar las variables que expliquen su comportamiento.

Por lo tanto, dado el rezago con que puede afectar la política monetaria las variables reales de la economía y con esto la estructura de precios, se vuelve fundamental que la medida de inflación utilizada permita seguir los movimientos de más mediano plazo de los precios, intentando evitar algunos desequilibrios de muy corto plazo.

Por esto, las medidas que se proponen son la inflación general medida por el Índice de precios al consumidor (IPC), indicador elaborado por el Instituto Nacional de Estadística y Censos (INEC), además de la inflación de media troncada, indicador elaborado por el BCCR, el cual se basa en el IPC pero elimina de su cálculo aquellos productos que presenten variaciones de precios más atípicas (Esquivel, Rodríguez y Vásquez, [2011](#)).

Para lograr lo anterior se analizan los 292 productos que componen la canasta actual del IPC y se eliminan de su cálculo el 30% de los productos que presentan las menores variaciones intermensuales y el 10% de los productos con mayores variaciones respecto a un truncamiento centrado en el percentil 60 de los datos. Esto es realizado cada mes permitiendo disponer una serie de precios pero sin estas variaciones atípicas⁹.

⁹ Para mayor información sobre la metodología ver: Monge, Rodríguez y Vásquez (2011). “*Medias truncadas del IPC como indicadores de inflación subyacente en Costa Rica*”. Serie Documentos de Investigación No. 01-2011. San José: Departamento de Investigación Económica, Banco Central de Costa Rica. Disponible [aquí](#).

4. Datos utilizados

Los datos utilizados para la aplicación empírica de las técnicas bayesianas consisten en 52 variables mensuales de la economía costarricense todas disponibles desde el mes de Enero del año 1999 al mes de Noviembre 2014. En todos los casos se utilizan datos no desestacionalizados, en términos reales, centradas y estandarizadas¹⁰.

Dentro de las variables utilizadas se encuentran once¹¹ de los grupos de productos que componen el IPC, además de agregaciones particulares de bienes y servicios, transables o no transables, regulados y no regulados, entre otros. Conjuntamente, se utilizaron otros índices de precios como el Índice de precios al productor industrial (IPPI), Índice de bienes pecuarios e Índice de granos básicos.

Por otra parte, para capturar algunas presiones internacionales sobre la inflación doméstica se incluyeron variables como la inflación de los socios comerciales, inflación de los Estados Unidos de América (EUA), crecimiento de Estados Unidos, tipo de cambio real, tipo de cambio nominal entre el dólar y el colón, precios del petróleo crudo tipo West Texas Intermediate (WTI, por sus siglas en inglés), así como un cóctel de precios de hidrocarburos de referencia para la economía costarricense y la tasa de interés del London Interbank Offered Rate (LIBOR por sus siglas en inglés) a seis meses.

Además, se incluyen algunas variables macroeconómicas relacionadas con la curva de Phillips¹² como lo son la brecha del producto, Índice mensual de actividad económica (IMAE), datos de empleo¹³, entre otras. Así como, variables utilizadas en las teorías monetarias de inflación como la base monetaria, emisión monetaria, M1 y el medio circulante.

¹⁰ Se hizo el ejercicio con datos desestacionalizados pero no cambiaron los resultados, por lo que se tomó la decisión de utilizar los datos sin quitar el componente estacional para no perder detalle en la información.

¹¹ No se utilizó el grupo de comunicaciones dado que tiene un comportamiento donde presenta fuertes variabilidades de un mes a otro, para luego no tener variaciones por largos periodos de tiempo lo cual afecta las estimaciones.

¹² Para mayor detalle: "[Inflation Forecast and the New Keynesian Phillips Curve](#)", Brissimis et. al.(2008)

¹³ El empleo utilizado es el registrado en la base de Patronos a la Caja Costarricense del Seguro Social (CCSS), sin contar a los trabajadores por cuenta propia.

Más aún, se agregaron algunas variables relacionadas con el crédito al sector privado (separado en actividades empresariales y para consumo) y la tasa de política monetaria como medidas indirectas de las restricciones monetarias. Aparte de algunos indicadores del sector real como exportaciones y actividad manufacturera.

En el Anexo 1, se presentan en detalle todas las variables incluidas en las estimaciones como las transformaciones efectuadas para que estas fueran estacionarias. Las pruebas de estacionariedad no se presentan por razones de espacio, pero están disponibles mediante solicitud a los autores.

Ahora dada la gran variedad y número de variables con las que se cuenta, tal y como se mencionó previamente se utiliza el método de componentes principales para reducir el número de variables aprovechando la correlación que existe entre ellas. Luego de generar los componentes principales para toda la muestra se genera una matriz de correlaciones (ver Cuadro 1) de las variables originales (normalizadas y estandarizadas) exceptuando IPC, y la inflación de media truncada, respecto a los primeros 5 componentes principales. Con el objetivo de poder apreciar con qué variables se encuentra más correlacionada cada componente principal.

En este cuadro 1 se puede apreciar una fuerte correlación entre la primera componente principal con algunos grupos del IPC como lo son los Artículos de la vivienda y servicios domésticos, Comidas y bebidas fuera del hogar; y Alimentos y bebidas no alcohólicas, todos con correlaciones positivas. Al igual, este primer componente está fuertemente correlacionado con otros índices como IPC sin combustible, bienes no regulados; así como no regulados sin café; bienes no transables, bienes transables sin combustible e índice de precios de los servicios. Todas ellas con correlaciones positivas y mayores al 60%.

El segundo componente se encuentra correlacionado principalmente con variables relacionadas con agregados monetarios como la emisión monetaria, base monetaria y medio circulante, al igual que el crédito al sector privado.

El tercer componente se encuentra correlacionado con el transporte, bienes transables y bienes regulados; además de la inflación internacional de socios comerciales y el Índice de precios al productor industrial (IPPI). Mientras el cuarto componente está correlacionado

negativamente con los bienes regulados sin combustible, los bienes regulados, servicios regulados; y el alquiler y servicios de la vivienda. Mientras el último componente se encuentra correlacionado con la inflación internacional, inflación de Estados Unidos, variación del WTI y tipo de cambio real.

Es importante destacar que al realizar la descomposición de los datos mediante el análisis expuesto, los componentes resultantes además de estar correlacionados con las variables originales, cuentan con ciertas características que se detallan a continuación:

- i) Tienen media cero, como resultado de la normalización de los datos.
- ii) La variancia de cada componente principal es igual al valor propio correspondiente al vector propio de donde se obtuvo. Por lo tanto, el primer componente principal será el que le corresponda al valor propio mayor y con esto, será el componente que explique la mayor cantidad de variancia del conjunto de datos.
- iii) Los componentes principales tienen cero correlaciones entre ellos. Por lo tanto, estas nuevas variables sintéticas no tendrán el problema de multicolinealidad a la hora de realizar las estimaciones, a diferencia del caso donde se utilicen las variables originales.
- iv)

Ahora dado que el interés es buscar la mejor representación posible de los datos, entendiéndose esto como buscar la manera de recoger la mayor cantidad de la variabilidad de los datos originales en una nueva representación. Por lo tanto, se presenta en el Cuadro 2 la varianza que acumula cada componente principal respecto a la varianza total de los datos.

Cuadro 1 : Matriz de correlaciones de Pearson
Variables originales y componentes principales

Grupo IPC de alimentos y bebidas no alcohólicas	0,560	0,617
Grupo IPC de bebidas alcohólicas y cigarrillos		
Grupo IPC de comidas y bebidas fuera del hogar	0,609	
Grupo IPC de prendas de vestir y calzado		
Grupo IPC de alquiler y servicios de la vivienda		-0,542
Grupo IPC de artículos de la vivienda y servicios domésticos	0,588	

Grupo IPC de salud			
Grupo IPC de transporte		0,734	
Grupo IPC de entretenimiento y cultura			
Grupo IPC de educación			
Grupo IPC de bienes y servicios diversos			
Agregación IPC bienes regulados		0,543	-0,576
Agregación IPC bienes no regulados	0,856		
Agregación IPC servicios	0,756		
Agregación IPC bienes	0,708		
Agregación IPC bienes no transables	0,824		
Agregación IPC bienes transables		0,718	
Agregación IPC servicios regulados			-0,569
Agregación IPC servicios no regulados	0,625		
Agregación IPC bienes agrícolas		0,602	
Agregación IPC bienes otros bienes no regulados	0,615		
Agregación IPC bienes regulados sin combustible			-0,603
Agregación IPC sin agropecuarios	0,854		
Agregación IPC sin combustible	0,929		
Agregación IPC bienes no regulados sin café	0,808		
Agregación IPC bienes transables sin combustible	0,655		
Agregación IPC bienes pecuarios			
Agregación IPC otros agropecuarios			
Agregación IPC granos básicos			
Tasa de variación índice de precios de servicios	0,600		
Tasa de variación índice de salarios mínimos nominales			
Brecha del producto			
Empleo sin cuenta propia			
Índice mensual de actividad económica			
Bienes exportables			
Precio promedio del cóctel de hidrocarburos, relevantes para Costa Rica			
Inflación de socios comerciales		0,512	0,533
Inflación de EUA			0,558
Índice de actividad económica de Estados Unidos			
Base monetaria	0,635		
Emisión monetaria	0,745		
M1	0,624		
Crédito al sector privado para consumo			

Crédito al sector privado para actividades empresariales		
Crédito al sector privado	0,531	
Tipo de cambio nominal dólar/colón		
Indicador de tasa de política monetaria		
Libor a 6 meses		
Tasa de variación del IPPI	0,639	
Tasa de variación interanual Índice Mensual Actividad Manufacturera		
Tasa básica pasiva real		
Tasa de variación del barril WTI		0,544
Tipo de cambio real		0,516

Fuente: elaboración propia.

Es relevante indicar que en el Cuadro 2, únicamente se presentan los componentes principales cuya variación sea mayor a uno, ya que con este criterio de selección asegura que la incorporación de cada componente esté contribuyendo a la explicación del conjunto de variables.

Se puede apreciar en el mismo cuadro que con únicamente once componentes principales se acumula cerca del 70% de la variabilidad total del conjunto de datos. Por lo tanto, con este método de reducción de la información se puede garantizar que con este pequeño número de variables sintéticas se está representando el conjunto de 52 variables, dejando sin explicar solamente un 30% de la variabilidad de ellas.

Por otro lado, en el cuadro se observa que cada componente explica un porcentaje cada vez menor de la variabilidad total de los datos, siendo el componente 1 el que tiene la mayor proporción de la variabilidad explicada con alrededor de un 20%. Como se analizó anteriormente, este componente se caracteriza por estar altamente correlacionado con algunos grupos del IPC y otras agregaciones, se puede estar seguro que estas variables van a encontrarse bien representadas por medio de este componente. El mismo análisis se puede hacer con los demás componentes principales y con su respectiva relación con las variables originales.

**Cuadro 2:
Variación explicada y acumulada ACP**

Componente	Variación explicada	% de variancia	% de variancia acumulada
Comp1	10,24	19,32%	19,32%
Comp2	5,11	9,64%	28,96%
Comp3	4,34	8,19%	37,15%
Comp4	3,67	6,93%	44,07%
Comp5	2,91	5,49%	49,56%
Comp6	2,63	4,97%	54,53%
Comp7	2,15	4,05%	58,58%
Comp8	1,72	3,24%	61,82%
Comp9	1,53	2,88%	64,71%
Comp10	1,47	2,77%	67,47%
Comp11	1,35	2,56%	70,03%
Comp12	1,20	2,27%	72,30%
Comp13	1,18	2,22%	74,52%
Comp14	1,06	2,00%	76,52%

Fuente: elaboración propia.

5. Resultados obtenidos

Para analizar la capacidad predictiva de estos modelos, se realiza un ejercicio dentro de muestra cuyo objetivo es evaluar la calidad de los pronósticos provenientes tanto de las técnicas bayesianas como de los modelos de factores dinámicos en comparación con otro tipo de modelos comúnmente utilizados para estos fines, como lo son los modelos autorregresivos. Para esto se utilizará una medida de la calidad de los pronósticos como el error cuadrático medio.

Para realizar esto se dividirá la muestra en dos ventanas, una llamada ventana de estimación, que se extiende desde el mes de enero de 1999 a enero del año 2011, y otra ventana llamada ventana de prueba, la que se extiende del mes de febrero del año 2011 al mes de noviembre del 2014.

Asimismo la ventana de estimación es una ventana rodante, esto quiere decir que dentro de ella se calcularán tanto los componentes principales de todas las variables, con los parámetros de las regresiones utilizadas. Esta ventana se moverá un periodo a la vez, donde

en cada paso se incluirá una nueva observación y se dejará la última observación utilizada en el paso previo, hasta llegar al último mes en consideración (noviembre 2014).

En cada uno de las iteraciones se utilizarán los componentes principales para estimar las variables de interés utilizando las técnicas de BMA, WALs, factores dinámicos y un modelo autorregresivo; y con estas estimaciones se realizarán pronósticos de 1,2, 3,..., 6 y 12 meses hacia adelante a partir de la última información disponible.

Es importante recordar que para cada ventana de estimación se contará con una importante cantidad de posibilidades, dado que cada periodo cuenta con un conjunto diferente de componentes principales, de los que se deben definir cuales utilizar, además de cuáles tratar como variables *focus* y cuáles como variables auxiliares; asimismo definir si se utilizan rezagos. Por ello, se probarán diferentes especificaciones tomando en cuenta diferentes número de rezagos para los primeros tres componentes principales, así como diferente número de rezagos de la variable dependiente.

Este procedimiento se realiza con el objetivo de simular un experimento en tiempo real, que consta en intentar replicar las condiciones que tendría un individuo a la hora de pronosticar la inflación si se ubicara en el último periodo de la ventana de estimación y su interés fuera proyectar la inflación para $h = 1, \dots, 6$ y 12 meses hacia adelante.

Así para cada periodo y para cada modelo se podrá proyectar los valores de inflación para diferentes horizontes en la ventana de prueba, lo cual se puede representar como:

$$\hat{y}_{T_1+h} = \hat{\alpha}(L)y_{T_1+h-1} + \hat{\beta}(L)F_{T_1+h-1} \quad (28)$$

Donde $\hat{\alpha}(L)$ es el polinomio de rezagos de la variable dependiente y $\hat{\beta}(L)$ es el polinomio de rezagos de los componentes principales. Así para efectos de la estimación de este trabajo se considera el primer polinomio de rezagos las variables que formarán el vector de variables consideradas *focus* con un máximo de 4 rezagos de la variable dependiente mientras el segundo polinomio representa el vector de variables auxiliares formado por los primeros tres componentes principales con un máximo de 4 rezagos.

Para evaluar la calidad de los pronósticos se debe establecer un indicador que permita comparar el resultado de los diferentes modelos propuestos. Para esto, se utilizará el error cuadrático medio (ECM), que se define como el promedio del error de pronóstico en la ventana de prueba para cada horizonte de proyección ($h = 1, \dots, 6$ y 12) y cada tipo de modelo.

$$ECM_{T_1} = \frac{1}{T - T_1} \sum_{h=1}^{T-T_1} (\hat{y}_{T_1+h} - y_{T_1+h})^2 \quad (29)$$

Donde T_1 representa la última observación de la ventana de estimación, \hat{y}_{T_1+h} son los valores pronosticados h pasos hacia adelante desde T_1 , y y_{T_1+h} son los valores observados de la variable de interés.

Para poder proyectar tanto la inflación de media truncada como la inflación que se obtiene del Índice de precios al consumidor, e intentando simular un ejercicio en tiempo real los individuos tendrían que tomar una decisión sobre si proyectar estas series ya sea de manera directa o mediante un proceso iterativo, el cual requiere realizar algún supuesto sobre el comportamiento futuro de los predictores.

Por lo tanto, si se usa el segundo método y se realizan dos tipos de supuestos sobre las variables originales, buscando que estos supuestos sean fácilmente replicables en futuras ocasiones, se podrán utilizar los valores proyectados de las variables originales como individuos suplementarios en el ACP¹⁴ y con esto tener las proyecciones de las variables predictoras.

Así el primer supuesto utilizado es hacer crecer a las variables originales a la tasa de crecimiento promedio de los últimos 8 meses para todo el periodo restante (creci), mientras que el segundo supuesto es que las variables originales se van a quedar fijas en su último valor observado (fija).

Los resultados obtenidos de las proyecciones de 1, 2, ..., 6 y 12 meses se presentan en el Cuadro 3. Donde para una presentación más intuitiva se reescalan los ECM respecto a un modelo univariado (AR1), el cual es usado como referencia. De esta manera cualquier valor menor que 1 se interpreta como un método de estimación que presenta un ECM menor que el generado por este modelo autorregresivo. Por ejemplo, en el cuadro 3 se observa para el

¹⁴ Estos individuos suplementarios se caracterizan por no ser utilizados a la hora de calcular los vectores propios del ACP, pero son proyectados en el espacio que generan estos vectores.

resultado ubicado en la primera fila y la primera columna, resultado correspondiente al método de estimación de BMA con predictores fijos y con un rezago ($k = 1$), presenta errores de pronóstico 3,9% menores a los que produce un modelo autorregresivo un periodo hacia adelante.

Se puede apreciar en el Cuadro 3, que para la mayoría de los horizontes de proyección así como para los métodos de estimación propuestos, presentan resultados que superan los producidos por un modelo autorregresivo. Presentando resultados mejores de hasta un 30%, siendo los horizontes de 2, 3, 4 y 12 meses los que presentaron un mejor desempeño en el caso de la inflación, y los de 1 y 2 meses en el caso de la inflación de media truncada.

Cuadro 3:
Simulación de predicciones dentro de muestra: Inflación Media truncada e Inflación¹⁵
- Ventana de estimación de 72 observaciones -

Método de Predicción	Inflación de Media truncada				Inflación			
	K=1	K=2	K=3	K=4	K=1	K=2	K=3	K=4
Horizonte = 1 mes								
BMA (fijas)	0.9610	0.9267	0.8786*	0.8411**	0.8641	0.8764	0.8571	0.8357
BMA (creci)	0.9610	0.9267	0.8786*	0.8411**	0.8641	0.8764	0.8571	0.8357
WALS (fijas)	0.9547	0.9432	0.8829*	0.8089**	0.8423	0.8505	0.8674	0.8361
WALS (creci)	0.9547	0.9432	0.8829*	0.8089**	0.8423	0.8505	0.8674	0.8361
Factores dinámicos (fijas)	0.9592	0.9806	0.9249	0.8148**	0.8686	0.8922	0.941	0.9179
Factores dinámicos (creci)	0.9592	0.9806	0.9249	0.8148**	0.8686	0.8922	0.941	0.9179
Horizonte = 2 mes								
BMA (fijas)	0.9304	0.9037	0.8513***	0.8094***	0.8024***	0.8161***	0.8051**	0.8028**
BMA (creci)	0.9420	0.9110	0.8570***	0.8145***	0.8050***	0.8187**	0.8187**	0.8053**
WALS (fijas)	0.9102	0.8990**	0.8339***	0.7429***	0.7471***	0.7674*	0.7969	0.7919
WALS (creci)	0.9215	0.9060**	0.8393	0.7471***	0.7495***	0.7696*	0.7989	0.7942
Factores dinámicos (fijas)	0.9039	0.9328	0.8679*	0.7469**	0.7482**	0.8033	0.8757	0.8856
Factores dinámicos (creci)	0.9149	0.9396	0.8729*	0.7502*	0.7504**	0.8055	0.8777	0.8879
Horizonte = 3 mes								
BMA (fijas)	0.9821	0.9622	0.9518	0.9250	0.8439	0.8654	0.8790	0.8493
BMA (creci)	1.0063	0.9813	0.9663	0.9383	0.8498	0.8713	0.8838	0.8545
WALS (fijas)	0.9775	0.9887	0.9470	0.8857	0.8177	0.8620	0.8834	0.8360
WALS (creci)	1.0010	1.0071	0.9608	0.8976	0.8230	0.8671	0.8878	0.8413
Factores dinámicos (fijas)	0.9912	1.0515	0.9756	0.9131	0.8503	0.9392	0.9995	0.9680
Factores dinámicos (creci)	1.0141	1.0691	0.9888	0.9235	0.8555	0.9442	1.0041	0.9734
Horizonte = 4 mes								
BMA (fijas)	0.8747	0.8899	0.9041	0.9064	0.7947***	0.8278*	0.8480**	0.7943**
BMA (creci)	0.9002	0.9118	0.9226	0.9236	0.8018***	0.8351	0.8545*	0.8019**
WALS (fijas)	0.8602	0.8816	0.8957	0.9003	0.7559*	0.7826	0.8127	0.8927
WALS (creci)	0.8851	0.9027	0.9135	0.9166	0.7624*	0.7890	0.8188	0.9008
Factores dinámicos (fijas)	0.8498	0.8891	0.8963	0.9103	0.7636	0.8182	0.8856	1.0651
Factores dinámicos (creci)	0.8741	0.9095	0.9134	0.9252	0.7699	0.8246	0.8917	1.0734
Horizonte = 5 mes								
BMA (fijas)	0.8439	0.8484**	0.8689**	0.8817*	0.8461*	0.8792	0.8909	0.8457
BMA (creci)	0.8756	0.8766*	0.8936***	0.9049*	0.8562	0.8897	0.9006	0.8561
WALS (fijas)	0.8212	0.8099*	0.8369**	0.8606*	0.8326	0.8691	0.9303	1.0752
WALS (creci)	0.8522	0.8374*	0.8609**	0.8829*	0.8420	0.8786	0.9396	1.0865
Factores dinámicos (fijas)	0.7943	0.7821	0.8053*	0.8427	0.8493	0.9232	1.0411	1.3141
Factores dinámicos (creci)	0.8248	0.8089	0.8288	0.8636	0.8586	0.9327	1.0506	1.3259
Horizonte = 6 mes								
BMA (fijas)	0.8822	0.8909	0.9087	0.9097	0.8049	0.8360	0.8355	0.7542
BMA (creci)	0.9222	0.9274	0.9415	0.9407	0.8148	0.8461	0.8452	0.7641
WALS (fijas)	0.8688	0.8657	0.8822	0.8758	0.7562	0.7790	0.7936	0.8455
WALS (creci)	0.9081	0.9014	0.9141	0.9061	0.7651	0.7878	0.8018	0.8554
Factores dinámicos (fijas)	0.8511	0.8543	0.8587	0.8501	0.7543	0.7975	0.8348	0.9740
Factores dinámicos (creci)	0.8899	0.8895	0.8902	0.8793	0.7629	0.8060	0.8429	0.9841
Horizonte = 12 mes								
BMA (fijas)	1.0059	0.9438	0.9231	0.9540	0.7791**	0.7788**	0.7847**	0.7949*
BMA (creci)	1.1648	1.0881	1.0527	1.0819	0.8015*	0.8017*	0.8069*	0.8179
WALS (fijas)	0.9867	0.9362	0.9019	0.9282	0.7234***	0.7189***	0.7002***	0.7918**
WALS (creci)	1.1422	1.0774	1.0289	1.0599	0.7445**	0.7402**	0.7190***	0.8151**
Factores dinámicos (fijas)	0.9803	0.9877	0.9214	0.9450	0.7171***	0.7390***	0.7449***	0.9378
Factores dinámicos (creci)	1.1333	1.1279	1.0475	1.0812***	0.7387***	0.7620**	0.7663***	0.9644

¹⁵ Para probar la significancia estadística de los pronósticos, se utilizó la prueba de Diebold y Mariano. Se presentan con asteriscos la significancia estadística de cada modelo y horizonte de estimación (***) 1%, ** 5% y * 10%

Es destacable el buen desempeño que tiene todos los métodos en el caso de la inflación para los pronósticos a 12 meses. Se observa que para muchos modelos y rezagos utilizados presentan un desempeño estadísticamente superior al de un modelo autorregresivo. Esto es de especial relevancia dado el interés que tiene el BCCR en obtener pronósticos oportunos y confiables de esta variable en este horizonte en específico, con el fin de definir adecuadamente la política monetaria.

La calidad de los pronósticos a 12 meses que estos modelos pueden ofrecer se evalúa con la información que contiene el cuadro 4. Las proyecciones de la inflación general se elaboran utilizando datos actualizados al mes de noviembre del año 2014 y se generan proyecciones de lo que se espera sería la inflación interanual para horizontes de 1, 2 y hasta 12 meses a partir del último dato disponible, esto permite comparar la proyección con el dato observado a diciembre 2014 y los valores para enero y febrero 2015.

Cuadro 4:
Inflación observada y proyecciones de inflación a 12 meses¹⁶

Mes	Inflación observada	Rango Meta		Pronósticos bayesianos			
		Lim. superior	Lim. inferior	BMA	WALS	Factores dinámicos	Modelo autorregresivo
Dic-14	5,13%	5,00%	3,00%	4,59%	4,23%	4,08%	5,92%
Ene-15	4,39%	5,00%	3,00%	4,59%	4,22%	4,06%	5,78%
Feb-15	3,53%	5,00%	3,00%	4,59%	4,05%	3,81%	5,78%
Mar-15		5,00%	3,00%	4,58%	3,97%	3,69%	5,85%
Abr-15		5,00%	3,00%	4,57%	3,78%	3,40%	5,38%
May-15		5,00%	3,00%	4,55%	3,60%	3,13%	5,55%
Jun-15		5,00%	3,00%	4,57%	3,74%	3,35%	5,88%
Jul-15		5,00%	3,00%	4,59%	3,97%	3,70%	5,65%
Ago-15		5,00%	3,00%	4,59%	4,16%	4,00%	6,03%
Sep-15		5,00%	3,00%	4,60%	4,29%	4,18%	6,91%
Oct-15		5,00%	3,00%	4,60%	4,27%	4,15%	7,97%
Nov-15		5,00%	3,00%	4,61%	4,40%	4,34%	8,35%
Dic-15		5,00%	3,00%	4,60%	4,27%	4,13%	8,52%

Trimestre	MMPT ^{2/}	Inflación observada	Rango Meta		BMA	WALS	Factores dinámicos	Modelo autorregresivo
			Lim. superior	Lim. inferior				
I-2015	3,88%	3,96%	5,00%	3,00%	4,59%	4,08%	3,85%	5,80%
II	4,75%		5,00%	3,00%	4,56%	3,71%	3,29%	5,60%
III	4,53%		5,00%	3,00%	4,59%	4,14%	3,96%	6,20%
IV	4,40%		5,00%	3,00%	4,60%	4,31%	4,21%	8,28%

1/ Con información a noviembre 2014.

2/ De acuerdo con las estimaciones generadas al 30/01/2015 para el Programa Macroeconómico 2015-2016.

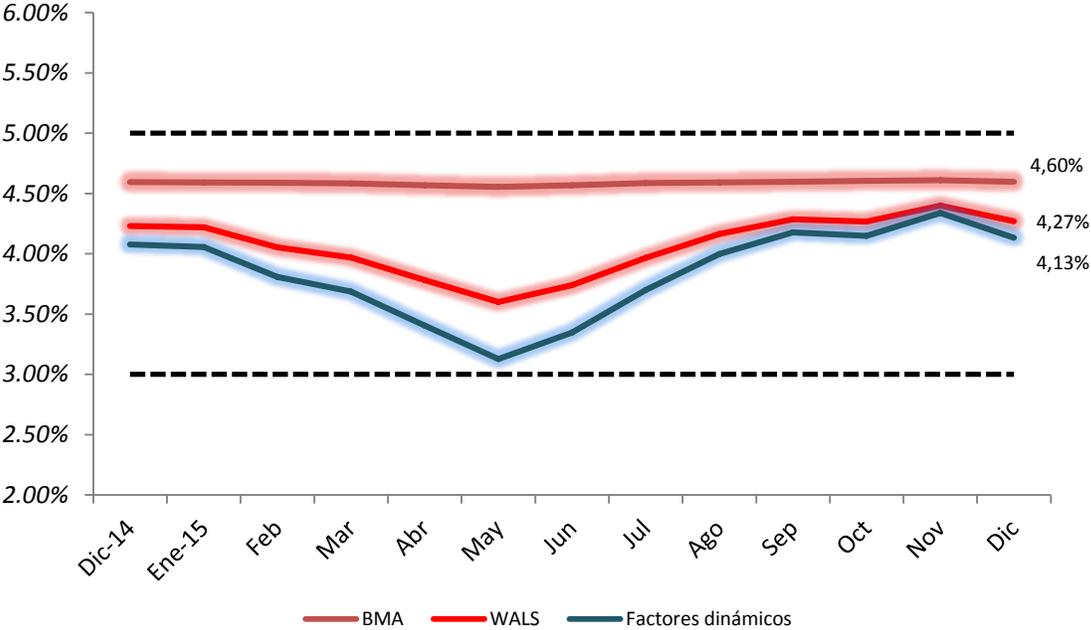
¹⁶ Estos resultados no constituyen una proyección oficial del BCCR.

Como se puede apreciar la proyección de variación interanual de la inflación general que se obtiene a partir de los modelos no se aleja mucho de la inflación observada, siendo la proyección de inflación obtenida mediante la técnica WALs y de factores dinámicos las que desvían menos en relación con lo observado. A pesar de este buen resultado, es necesario destacar que estas estimaciones no representan un ejercicio de proyección en tiempo real sino la validación del uso de técnicas bayesianas para generar pronósticos.

Resulta importante mencionar que el conjunto de información utilizada no incorpora los efectos de las reducciones en el precio de los combustibles que se registraron durante los primeros meses de 2015 y que modificaron el patrón de comportamiento de las 51 variables utilizadas para la construcción de las componentes principales.

Otro resultado interesante y que se revalida con la proyección central del MMPT para el Programa Macroeconómico 2015-2016 es que para todo el periodo de estimación, la inflación proyectada está dentro del rango meta definido por el BCCR.

Gráfico 1 : Proyecciones de inflación



Fuente: elaboración propia.

Para probar la coherencia de los resultados se realizaron diversas pruebas variando tanto el tamaño de la ventana de estimación como el punto de inicio de la ventana de pruebas, encontrando que los resultados se mantienen.

Un ejemplo de estas pruebas se presenta en el Cuadro 5, donde se realiza el mismo ejercicio de estimación anterior pero ahora cambiando la ventana de estimación a una de 48 observaciones. En el cuadro se aprecia que los resultados son coherentes respecto a los encontrados anteriormente. Se puede apreciar una importante bondad de ajuste en las proyecciones por ejemplo de la inflación de media truncada para los horizontes de 1, 2 y 5 meses, mientras en el caso de la inflación general los métodos son superiores en los horizontes de 2, 4 y 12 meses.

Por otro lado, y de acuerdo con la información contenida en los Cuadros 3 y 5, que las proyecciones de los modelos bayesianos presentan para horizontes más extensos de estimación mejores resultados que los propios modelos de factores dinámicos. Además se observa que no existe una ventaja absoluta de ninguno de los dos métodos bayesianos propuestos respecto a los otros. Un resultado importante es que para el caso de muchos horizontes de estimación es superior el método de BMA mientras que para otros el método de WALs realiza una mejor estimación.

Finalmente, se puede anotar que para algunos rezagos los métodos de factores dinámicos tienden a perder su buen desempeño, generando que los resultados sean dependientes del número de rezagos utilizados en las especificaciones (por ejemplo, el desempeño de los factores dinámicos en el Cuadro 3 con un horizonte de predicción de 5 meses).

Cuadro 5
Simulación de predicciones dentro de muestra: Inflación Media truncada e Inflación
- Ventana de estimación de 48 observaciones¹⁷ -

Método de Predicción	Inflación de Media truncada				Inflación			
	K=1	K=2	K=3	K=4	K=1	K=2	K=3	K=4
Horizonte = 1 mes								
BMA (fijas)	0.8340*	0.8109***	0.8043***	0.7251***	0.8256**	0.8720***	0.8896***	0.9431
BMA (creci)	0.8340*	0.8109***	0.8043***	0.7251***	0.8256**	0.8720***	0.8896***	0.9431
WALS (fijas)	0.8457*	0.8179**	0.8051**	0.7649**	0.8457*	0.8838	0.9224	1.0692
WALS (creci)	0.8457*	0.8179**	0.8051**	0.7649**	0.8457*	0.8838	0.9224	1.0692
Factores dinámicos (fijas)	0.8496	0.8140*	0.8235	0.8599	0.8508	0.9183	1.0140	1.3212
Factores dinámicos (creci)	0.8496	0.8140*	0.8235	0.8599	0.8508	0.9183	1.0140	1.3212
Horizonte = 2 mes								
BMA (fijas)	0.8417**	0.8224***	0.7993***	0.7672***	0.7920***	0.8225***	0.8325***	0.8724**
BMA (creci)	0.8505*	0.8295***	0.8054***	0.7728***	0.7939***	0.8244***	0.8341***	0.8741*
WALS (fijas)	0.8308**	0.8126***	0.7874***	0.7380***	0.7623***	0.8025***	0.8601	1.0380
WALS (creci)	0.8398**	0.8201***	0.7936***	0.7425***	0.7644***	0.8046***	0.8622	1.0404
Factores dinámicos (fijas)	0.8393**	0.8390***	0.8051**	0.7952*	0.7538***	0.8177*	0.9491	1.3220
Factores dinámicos (creci)	0.8488**	0.8471***	0.8114**	0.7993*	0.7560***	0.8199	0.9515	1.3248
Horizonte = 3 mes								
BMA (fijas)	0.9045	0.8838	0.8804	0.8712	0.8575	0.8879	0.9126***	0.9642
BMA (creci)	0.9228	0.8995	0.8946	0.8840	0.8617	0.8919	0.9159***	0.9674
WALS (fijas)	0.8821	0.8760	0.8432	0.8541	0.8528	0.9197	0.9559	1.1751
WALS (creci)	0.9009	0.8927	0.8580	0.8647	0.8574	0.9240	0.9600	1.1793
Factores dinámicos (fijas)	0.9057	0.9301	0.8871	0.9440	0.8823	0.9925	1.0814	1.5310
Factores dinámicos (creci)	0.9253	0.9481	0.9027	0.9537	0.8872	0.9972	1.0859	1.5358
Horizonte = 4 mes								
BMA (fijas)	0.7845*	0.7683*	0.7749*	0.7474	0.7580***	0.7423***	0.7272***	0.8285
BMA (creci)	0.8038	0.7854*	0.7908*	0.7629	0.7628***	0.7465***	0.7306***	0.8325
WALS (fijas)	0.7574*	0.7498*	0.7475*	0.7090	0.7567***	0.7682**	0.8041	1.0886
WALS (creci)	0.7775	0.7683*	0.7647*	0.7233	0.7621***	0.7729**	0.8088	1.0939
Factores dinámicos (fijas)	0.7714	0.7791	0.7760	0.7508	0.7769**	0.8258	0.9349	1.4968
Factores dinámicos (creci)	0.7925	0.7989	0.7945	0.7649	0.7826**	0.8309	0.9405	1.5034
Horizonte = 5 mes								
BMA (fijas)	0.7814*	0.7670*	0.7791*	0.7318	0.8016**	0.8077**	0.7946	0.9416
BMA (creci)	0.8055	0.7891*	0.7996	0.7509	0.8082**	0.8133**	0.7990	0.9457
WALS (fijas)	0.7384**	0.7332**	0.7318**	0.7116	0.8375	0.8706	0.9436	1.3662
WALS (creci)	0.7634*	0.7571**	0.7541**	0.7300	0.8451	0.8772	0.9503	1.3730
Factores dinámicos (fijas)	0.7438**	0.7521**	0.7467**	0.7629	0.8741	0.9465	1.1369	1.8951
Factores dinámicos (creci)	0.7702*	0.7778**	0.7707*	0.7815	0.8824	0.9539	1.1453	1.9043
Horizonte = 6 mes								
BMA (fijas)	0.7953	0.7825	0.7910	0.7445	0.7620	0.7163	0.6749	0.7710
BMA (creci)	0.8250	0.8101	0.8167	0.7686	0.7682	0.7214	0.6788	0.7740
WALS (fijas)	0.7560*	0.7626*	0.7495*	0.6728	0.8028	0.7999	0.8217	1.1000
WALS (creci)	0.7860	0.7917	0.7761	0.6953	0.8099	0.8062	0.8280	1.1063
Factores dinámicos (fijas)	0.7584*	0.7810*	0.7646*	0.6880	0.8420	0.8775	0.9843	1.5328
Factores dinámicos (creci)	0.7898	0.8120	0.7926	0.7105	0.8498	0.8847	0.9922	1.5415
Horizonte = 12 mes								
BMA (fijas)	0.9013	0.8780	0.8745	0.8856**	0.7791**	0.7788**	0.7847**	0.7949*
BMA (creci)	1.0083	0.9841	0.9742	0.9887	0.8015*	0.8017*	0.8069*	0.8179
WALS (fijas)	0.8923	0.8745	0.8524	0.9643	0.7234***	0.7189***	0.7002***	0.7918**
WALS (creci)	0.9925	0.9787	0.9450	1.0584	0.7445**	0.7402**	0.7190**	0.8151**
Factores dinámicos (fijas)	0.9123	0.9054	0.8637	1.0717	0.7171***	0.7390***	0.7449***	0.9378
Factores dinámicos (creci)	1.0111	1.0090	0.9557	1.1661	0.7387***	0.7620**	0.7663***	0.9644

¹⁷Para probar la significancia estadística de los pronósticos, se utilizó la prueba de Diebold y Mariano. Se presentan con asteriscos la significancia estadística de cada modelo y horizonte de estimación (***) 1%, ** 5% y * 10%)

6. Conclusiones

En línea con las necesidades de información precisa y oportuna que requiere el BCCR para la toma de decisiones de política que le permitan mantener una inflación baja y estable, el presente trabajo busca proponer herramientas complementarias para elaborar pronósticos de inflación de corto y mediano plazo, a partir de un conjunto de variables cuyo rezago en relación con el periodo t es de entre 60 y 90 días.

Así, se propone la utilización de dos técnicas bayesianas, como lo son el “*Bayesian Model Averaging*” y “*Weighted Average Least Squares*”, así como de un modelo de factores dinámicos, con el objetivo de proponer modelos alternativos que vengan a enriquecer las estimaciones que realiza el Banco.

Estas técnicas buscan reducir la incertidumbre sobre cuál debe ser la especificación definitiva a la hora de buscar predecir ya sea la inflación de media truncada, como la inflación, mientras que la utilización de la técnica de componentes principales busca reducir la incertidumbre sobre cuáles variables utilizar y abrir la posibilidad de utilizar un conjunto amplio de información.

De esta manera se realiza un ejercicio dentro de muestra probando que estas técnicas brindan pronósticos estadísticamente superiores a las que pueden entregar un modelo univariado. Estos resultados son especialmente significativos para el caso de la inflación a un horizonte de 12 meses, lo cual es relevante en términos de su utilidad en las decisiones de política monetaria.

Además de esto, estos pronósticos son robustos ante cambios en la longitud de ventana de estimación y ante cambios en el periodo de inicio de la estimación.

Como trabajos futuros, los resultados de esta investigación pueden ser complementados y ampliados con la construcción de gráficos de abanico para la inflación a partir de estimaciones generadas por cada modelo; una línea de investigación importante a desarrollar se puede centrar en el análisis de la función de probabilidad *posterior* de cada modelo. Lo anterior permitirá identificar en cada momento del tiempo cuales son las variables que tienen la mayor probabilidad de explicar el fenómeno inflacionario en el corto plazo.

A la luz de los resultados obtenidos se recomienda que las proyecciones de inflación mediante técnicas bayesianas sean incorporadas como insumo relevante para el seguimiento de la programación macroeconómica que realiza el BCCR.

7. Bibliografía

- Álvarez, C. & Torres, C. (2011) "Modelos de Inflación de Corto Plazo para los Sectores Transable y No Transable de la Economía Costarricense". Documento de Investigación 04-2011. San José: Departamento de Investigación Económica, Banco Central de Costa Rica.
- Brissimis, S. & Magginas, N. (2008). "Inflation Forecast and the New Keynesian Phillips Curve". International Journal of Central Banking, Vol. 4, No. 2.
- Danilov, D. & Magnus, J. (2004). "Forecast Accuracy After Pretesting with an Application to the Stock Market". Journal of Forecasting 23, 251-274.
- De Luca, G & Magnus, J (2011). "Bayesian Model Averaging and Weighted Average Least Squares: Equivariance, Stability, and Numerical Issues". CentER Discussin Paper; Vol. 2011-082. Tilburg: Econometrics.
- Diebold, F. & Mariano, R. (1995). "Comparing predictive accuracy". Journal of Business and Economic Statistics 13, 253-265.
- Esquivel, M., Rodríguez, A. & Vásquez, J. (2011). "Medias truncadas del IPC como indicadores de inflación subyacente en Costa Rica". Documento de investigación 01-2011. San José: Departamento de Investigación Económica, Banco Central de Costa Rica.
- Fernández, C., Ley, E. & Steel, M. (2001). "Benchmarks priors for Bayesian model averaging". Journal of Econometrics 100, 381-427
- Ibarra, R. (2010). "Forecasting Inflation in Mexico Using Factor Models: Do Disaggregated CPI Data Improve Forecast Accuracy?". Documento de trabajo, núm. 01, Banco de México.
- González, E. (2010). "Bayesian model averaging. An application to forecast inflation in Colombia". Borradores de Economía núm. 7013, Banco de la República.
- Hoeting, J., Madigan, D., Raftery, A. & Volinsky, C. (1997). "Bayesian Model Averaging for Linear Regression Models", Journal of the American Statistics Association, Vol. 92, pp. 179-191.
- Hoeting, J., Madigan, D., Raftery, A. & Volinsky, C. (1999). "Bayesian Model Averaging: A Tutorial", Statistical Science, 14, pp. 382-417.

- Hoffmaister, A. Saborío, G. & Vindas, K. (2000). "Proyecciones de Inflación: Innovaciones en los Precios Agrícolas y Regulados, y Ajustes". Nota de Investigación 7. San José: Departamento de Investigación Económica, Banco Central de Costa Rica.
- Magnus, J., Powell, O. & Prüfer, P. (2010). "A comparison of two model averaging techniques with an application to growth empirics". *Journal of econometrics*, 154, 139-153.
- Magnus, J. & Durbin, J. (1999). "Estimation of regression coefficients of interest when other regression coefficients are of no interest". *Econometrica*, Vol. 67, 639-643.
- Muñoz, E. (2008). "Validación del Modelo Univariable de Inflación empleado en la Combinación de Pronósticos". Informe técnico 08-2008. San José: División Económica, Banco Central de Costa Rica.
- Poghosyan, K & Magnus, J. (2012). "WALS estimation and forecasting in factor-based dynamic models with an application to Armenia". *International Econometric Review*, 4, 40-58.
- Rodríguez, A. (2009). "Evaluación del modelo lineal pass-through para la proyección de inflación dentro del régimen de banda cambiaria". Documento de Investigación 07-2009. San José: Departamento de Investigación Económica, Banco Central de Costa Rica.
- Steel, M. (2014) Bayesian model averaging and forecasting. University of Warwick: Typescript.
- Stock. J. & Watson, M. (1999). "Forecasting Inflation". *Journal of Monetary Economics* 44, 293-335.
- Stock. J & Watson, M. (2002). "Macroeconomic Forecastin Using Diffusion Indexes". *American Statistical Association Journal of Business & Economic Statistics*, Vol. 20, No. 2.
- Vindas, A. (2011). "Validación del modelo ARMA para la proyección de la inflación en Costa Rica". Documento de trabajo 03-2011. San José: Departamento de Investigación Económica, Banco Central de Costa Rica.
- Wright, J. (2003). "Forecasting U.S. Inflation by Bayesian Averaging", *International Finance Discussion Papers*, Board of Governors of the Federal Reserve System.
- Zellner, A. (1986). "On Assessing Prior Distributions and Bayesian Regression Analysis with g-Prior Distributions", in *Bayesian Inference and Decision Techniques: Essays in Honour of Bruno de Finetti*, ed. By Goel, and A. Zellner, pp. 233-243. Elsevier

8. Anexo 1

Variables	Descripción	Transformación ^{1/}
IPC_truncado	Índice de inflación media truncada	2
IPC	Índice de precios al consumidor	2
abna	Grupo IPC de alimentos y bebidas no alcohólicas	2
bacig	Grupo IPC de bebidas alcohólicas y cigarrillos	2
cbfh	Grupo IPC de comidas y bebidas fuera del hogar	2
pvc	Grupo IPC de prendas de vestir y calzado	2
alqserviv	Grupo IPC de alquiler y servicios de la vivienda	2
artviserdom	Grupo IPC de artículos de la vivienda y servicios domésticos	2
sal	Grupo IPC de salud	2
trans	Grupo IPC de transporte	2
entcul	Grupo IPC de entretenimiento y cultura	2
edu	Grupo IPC de educación	2
bsdiv	Grupo IPC de bienes y servicios diversos	2
reg	Agregación IPC bienes regulados	2
noreg	Agregación IPC bienes no regulados	2
ser	Agregación IPC servicios	2
bienes	Agregación IPC bienes	2
notran	Agregación IPC bienes no transables	2
tran	Agregación IPC bienes transables	2
serreg	Agregación IPC servicios regulados	2
sernoreg	Agregación IPC servicios no regulados	2
bieagro	Agregación IPC bienes agrícolas	2
otrosnoreg	Agregación IPC bienes otros bienes no regulados	2
regsincom	Agregación IPC bienes regulados sin combustible	2
ipcsinagro	Agregación IPC sin agropecuarios	2
ipcsincom	Agregación IPC sin combustible	2
noregsincaf	Agregación IPC bienes no regulados sin café	2
transincom	Agregación IPC bienes transables sin combustible	2
pec	Agregación IPC bienes pecuarios	2
oa	Agregación IPC otros agropecuarios	2
gb	Agregación IPC granos básicos	2
ips	Tasa de variación índice de precios de servicios	2
ismn	Tasa de variación índice de salarios mínimos nominales	1
brecha_men	Brecha del producto	1
empleo_scp	Empleo sin cuenta propia	2
imae	Índice mensual de actividad económica	2

expor	Bienes exportables	2
p_hid	Precio promedio del cóctel de hidrocarburos, relevantes para Costa Rica	2
phi_int	Inflación de socios comerciales	1
phi_us	Inflación de EUA	1
IPI_usa	Índice de actividad económica de Estados Unidos	2
bm	Base monetaria	2
emi	Emisión monetaria	2
m1	Medio circulante	2
cred_sp_sb_con	Crédito al sector privado para consumo	2
cred_sp_sb_ae	Crédito al sector privado para actividades empresariales	2
cred_sp_sb	Crédito al sector privado	2
e	Tipo de cambio nominal dólar/colón	1
itpm	Indicador de tasa de política monetaria	1
libor6	Tasa Libor a seis meses	2
IPPI	Tasa de variación del IPPI	2
imam	Tasa de variación interanual Índice Mensual Actividad Manufacturera	2
tbp_real	Tasa básica pasiva real	1
wti	Tasa de variación del WTI	1
tcr	Tipo de cambio real	2

^{1/} **1:** Variable en diferencia, **2:** Variable en diferencia logarítmica.