

Gálvez-Soriano, Oscar de Jesús

Working Paper

Nowcasting del PIB de México usando modelos de factores y ecuaciones puente

Working Papers, No. 2018-06

Provided in Cooperation with:

Bank of Mexico, Mexico City

Suggested Citation: Gálvez-Soriano, Oscar de Jesús (2018) : Nowcasting del PIB de México usando modelos de factores y ecuaciones puente, Working Papers, No. 2018-06, Banco de México, Ciudad de México

This Version is available at:

<https://hdl.handle.net/10419/202472>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

Banco de México
Documentos de Investigación

Banco de México
Working Papers

N° 2018-06

Nowcasting del PIB de México usando Modelos de
Factores y Ecuaciones Puente

Oscar de Jesús Gálvez-Soriano
Banco de México

Junio 2018

La serie de Documentos de Investigación del Banco de México divulga resultados preliminares de trabajos de investigación económica realizados en el Banco de México con la finalidad de propiciar el intercambio y debate de ideas. El contenido de los Documentos de Investigación, así como las conclusiones que de ellos se derivan, son responsabilidad exclusiva de los autores y no reflejan necesariamente las del Banco de México.

The Working Papers series of Banco de México disseminates preliminary results of economic research conducted at Banco de México in order to promote the exchange and debate of ideas. The views and conclusions presented in the Working Papers are exclusively the responsibility of the authors and do not necessarily reflect those of Banco de México.

Nowcasting del PIB de México usando Modelos de Factores y Ecuaciones Puente*

Oscar de Jesús Gálvez-Soriano[†]
Banco de México

Resumen: En este documento se evalúan cinco modelos de Nowcasting que pronostican el PIB trimestral de México: un Modelo de Factores Dinámicos (MFD), dos Modelos de Ecuaciones Puente (Bridge Equations; BE) y dos Modelos de Componentes Principales (PCA). Los resultados indican que el promedio de los pronósticos de las BE es estadísticamente mejor que el del resto de los modelos considerados, de acuerdo con la prueba de precisión de pronósticos de Diebold-Mariano (1995). Además, utilizando información en tiempo real, se encuentra que el promedio de las BE es más preciso que la mediana de los pronósticos de los analistas encuestados por Bloomberg y que la mediana de los especialistas que responden la Encuesta de Expectativas del Banco de México.

Palabras Clave: Nowcasting, Modelo de Factores Dinámicos, Ecuaciones Puente, Análisis de Componentes Principales, PIB trimestral, prueba de Diebold-Mariano.

Abstract: This paper evaluates five Nowcasting models that forecast Mexico's quarterly GDP: a Dynamic Factor Model (MFD), two Bridge Equation Models (BE) and two Principal Components Models (PCA). The results indicate that the average of the BE forecasts is statistically better than the rest of the models under consideration, according to the Diebold-Mariano (1995) accuracy test. In addition, using real-time information, the BE average is found to be more accurate than the median of the forecasts provided by the analysts surveyed by Bloomberg and the median of the experts who answer Banco de México's Survey of Professional Forecasters.

Keywords: Nowcasting, Dynamic Factor Model, Bridge Equations, Principal Component Analysis, Quarterly GDP, Diebold-Mariano test.

JEL Classification: C32, C38, C53, E52.

*Agradezco los valiosos comentarios de Alejandrina Salcedo, Aldo Heffner, Rodolfo Ostolaza y dos dictaminadores anónimos del Banco de México, así como los proporcionados por los participantes en los seminarios del Banco de México, el ITAM y la Facultad de Ciencias de la UNAM.

[†] Dirección General de Investigación Económica. Correo electrónico: oscar.galvez@banxico.org.mx.

1 Introducción

La información acerca del estado actual de la economía es un aspecto crucial para la toma de decisiones de los hacedores de política económica. Sin embargo, las estadísticas clave sobre la evolución de la economía están disponibles con cierto retraso. Este es el caso de las series que se calculan con frecuencia trimestral, como el Producto Interno Bruto (PIB). En efecto, el INEGI publica su estimación oportuna del PIB de México y su estimación de Cuentas Nacionales cuatro y siete semanas después de terminado el trimestre de referencia, respectivamente. Con la finalidad de contar con información en tiempo real sobre la actividad económica, en esta investigación propongo utilizar un conjunto de modelos de Nowcasting que estiman con un pequeño margen de error el crecimiento del PIB de Cuentas Nacionales para el trimestre de referencia más reciente desde cinco semanas antes de su publicación oficial.

Para la elaboración del Nowcasting propongo cinco modelos econométricos basados en investigaciones motivadas en pronosticar el PIB trimestral con base en datos mensuales (Rünstler y Sédillot, 2003; Baffigi, Golinelli, y Parigi, 2004; Giannone, Reichlin y Small, 2008). Entre los modelos considerados, desarrollo un Modelo de Factores Dinámicos (MFD), dos modelos de Ecuaciones Puente (*Bridge Equations*, BE) y dos modelos de Componentes Principales (PCA). Todos ellos utilizan variables de alta frecuencia (indicadores mensuales) para pronosticar una variable de menor frecuencia (el PIB trimestral). Las variables de alta frecuencia consisten en datos de la actividad económica que se divulgan mensualmente como, por ejemplo, indicadores de ventas, producción, empleo, comercio exterior y financieros.

Investigaciones previas han propuesto modelos de Nowcasting con el fin de pronosticar el PIB de México (Caruso, 2018; y Dahlhaus et al., 2017). No obstante, ninguno de estos trabajos ha incluido en su análisis a las BE ni a los PCA, sino que se limitan a comparar sus pronósticos con los de la Encuesta sobre las Expectativas de los Especialistas en Economía del Sector Privado del Banco de México (EEBM). De hecho, mis resultados sugieren que las BE producen pronósticos del PIB trimestral de México más precisos que los MFD y que los reportados en la EEBM.

Las investigaciones antes citadas sólo han logrado evaluar sus modelos dentro de muestra, lo que resta robustez para su aplicación práctica debido a que tanto el PIB como las series mensuales se revisan constantemente. Recientemente, Delajara et al. (2016) recuperaron las series originalmente publicadas para las cinco variables de su MFD con las cuales lograron realizar un análisis en *pseudo* tiempo real; sin embargo, ellos tampoco consideran a las BE en su análisis. En mi investigación evalué los pronósticos de las BE en tiempo real, lo cual no se había hecho anteriormente. Esto ha sido posible debido a que llevé un registro de los pronósticos de todos los modelos propuestos durante 12 trimestres consecutivos (desde 2014-II hasta 2017-I, periodo que coincide con la implementación práctica de los mismos). Con base en estos registros y utilizando la prueba de Diebold-Mariano, encuentro que los modelos de BE generan predicciones más precisas que la mediana de los pronósticos de los analistas encuestados por Bloomberg y que la mediana de los pronósticos de los especialistas que responden la EEBM.

El análisis de los errores de pronóstico de las BE sugiere que su varianza disminuye consistentemente con la inclusión de mayor información conforme se dispone de nuevos datos observados. En efecto, para el periodo que comprende del 2014-II al 2017-I, los errores de pronóstico presentan una importante reducción en su varianza desde un mes antes de que el INEGI publique el crecimiento del PIB, por lo que el 75 por ciento de las veces el margen de error de las BE es, en términos absolutos, menor a 0.1 puntos porcentuales de la variación trimestral del PIB observado.

La estructura de este documento de investigación es la siguiente: en la Sección 1 se presenta una revisión de la literatura que ha propuesto modelos de Nowcasting; en la Sección 2 se describen teóricamente las BE, el MFD y el modelo de PCA; en la Sección 3 se exponen los datos que serán utilizados para aplicar los modelos de la Sección 2 al caso de México, mientras que en la Sección 4 se exhiben los principales resultados y en la Sección 5 se presentan las conclusiones.

2 Revisión de Literatura

Las primeras investigaciones que utilizaron variables de alta frecuencia para pronosticar el PIB trimestral se apoyaron en modelos de BE (Rünstler y Sédillot, 2003; Baffigi, Golinelli,

y Parigi, 2004). El método de BE consiste en el uso de ecuaciones dinámicas y lineales donde las variables explicativas se forman con los agregados trimestrales de series diarias o mensuales. Sin embargo, las BE implican modelos poco parsimoniosos por el gran número de variables explicativas incluidas. Con el fin de reducir el número de variables independientes, Klein y Sojo (1989) utilizan la técnica de PCA y, años más tarde, Stock y Watson (2002a,b) confirman la eficiencia de los pronósticos obtenidos con este método.

Recientemente, Giannone, Reichlin y Small (2008) desarrollaron un método para obtener pronósticos de las tasas de crecimiento del PIB usando los factores de una representación de Estado-Espacio cuyos coeficientes son estimados con el Filtro de Kalman. Este método se conoce en la literatura como MFD y ha sido ampliamente utilizado para pronosticar el PIB de países desarrollados (Rünstler et al., 2009; Banbura y Modugno, 2014; Angelini et al., 2011; Yiu y Chow, 2011; y de Winter, 2011, son algunos ejemplos). Sin embargo, la mayoría de las investigaciones que utilizan MFD se basan en conjuntos de información grandes que, de acuerdo con Álvarez, Camacho y Perez-Quiros (2012), implican un supuesto fuerte sobre la ortogonalidad de los factores obtenidos, el cual no necesariamente se cumple por el gran número de series que están correlacionadas.¹ Los hallazgos empíricos de Álvarez et al. (2012) indican que, aunque ninguno de los dos modelos (con conjuntos grandes y con conjuntos pequeños de información) tuvo resultados sistemáticamente superiores sobre el otro, la precisión de los pronósticos generados por el modelo con el conjunto pequeño fue igual o superior a la del modelo con el conjunto grande. Recientemente, otros autores (Camacho y Doménech, 2012; Barnett et al., 2014; Delajara et al., 2016; Dahlhaus et al., 2017; y Caruso, 2018) han optado por usar modelos de pequeña escala. Así, con base en la literatura descrita, en este documento sólo considero conjuntos de información pequeños en los modelos propuestos.

La primera investigación que propuso un modelo de Nowcasting para México fue elaborada por Liu, Matheson y Romeu (2012), quienes evalúan el *nowcast* y el pronóstico de la tasa de crecimiento del PIB usando cinco modelos: Modelo Autorregresivo (AR), BE, VAR

¹ Por ejemplo, Giannone et al. (2008) usan 200 indicadores mensuales de la actividad económica de los Estados Unidos Americanos (EUA), mientras que Álvarez et al. (2012) prueban la conveniencia de usar conjuntos grandes contra conjuntos pequeños; 146 indicadores de EUA como conjunto grande y 13 indicadores representativos como conjunto pequeño.

bivariado, VAR Bayesiano y MFD, para diez países de América Latina.² Sus resultados indican que, para la mayoría de los países considerados, el flujo de datos mensuales ayuda a mejorar la precisión de las estimaciones y que el MFD produce, en general, *nowcasts* y pronósticos más precisos relativos a otras especificaciones de modelos. Sin embargo, una de las excepciones se obtuvo para el caso de México, donde se lograron mejores resultados con el VAR Bayesiano.

Asimismo, el primer antecedente de la estimación oportuna que publica el INEGI fue propuesto por Guerrero, García y Sainz (2013), quienes sugieren un procedimiento para hacer estimaciones oportunas del PIB trimestral de México usando Vectores Autorregresivos (VAR). Guerrero et al. (2013) estructuran el pronóstico por sectores económicos y luego por actividad, de forma análoga a como el INEGI elabora el dato oficial. Sus resultados sugieren que las estimaciones tienen errores relativamente pequeños, por lo que recomiendan utilizar su modelo para posteriores estimaciones del PIB trimestral de México. Sin embargo, Caruso (2018) no considera esta propuesta como un *nowcast*, sino que lo cataloga como un *backcast* ya que, con el modelo de Guerrero et al. (2013), no es posible contar con una estimación durante el trimestre de referencia hasta que hayan transcurrido 15 días después de que éste ha concluido para poder ofrecer la primera estimación del PIB.

Por lo anterior, Caruso (2018) se inclina por el uso de un MFD basado en Doz, Giannone y Reichlin (2012), y Banbura y Modugno (2014). Con este modelo el autor pronostica el PIB de México utilizando series mensuales de México y de Estados Unidos. Sus resultados indican que el MFD genera pronósticos más precisos que los ofrecidos por el Fondo Monetario Internacional, la OCDE, los pronósticos de la EEBM y que los pronósticos de los analistas encuestados por Bloomberg. Sin embargo, las comparaciones que hace Caruso (2018) entre los pronósticos de su MFD y los de los especialistas no son necesariamente las más adecuadas, ya que estos últimos se publican en tiempo real, mientras que los del MFD que estima incluyen las revisiones de las series.

Dahlhaus et al. (2017) utilizan un MFD basado en Giannone et al. (2008) con el fin de modelar y pronosticar el PIB de Brasil, India, Rusia, China y México (BRIC-M). El MFD

² Argentina, Brasil, Chile, Colombia, República Dominicana, Ecuador, México, Perú, Uruguay y Venezuela.

que los autores usan para México utiliza variables parecidas a las del MFD que propongo en esta investigación, salvo los indicadores de precios que no considero y el Indicador Global de la Actividad Económica³ (IGAE), que no es incluido por los autores. Dahlhaus et al. (2017) comparan los pronósticos de su MFD con los generados por un AR(2) y un MA(4); sus resultados sugieren que el MFD produce mejores pronósticos que los modelos de referencia.

En otra investigación semejante a la de Caruso (2018), Delajara et al. (2016) usan un MFD para pronosticar el PIB de México, pero, a diferencia del primero, los autores hacen pruebas de su modelo en *pseudo* tiempo real. Delajara et al. (2016) usan cinco variables de la actividad económica de México y comparan los pronósticos de su modelo con los ofrecidos por la EEBM. Sus resultados muestran que su MFD produce pronósticos más precisos que los de la EEBM. Sin embargo, salvo Lui et al. (2012), ninguna de las investigaciones antes citadas considera a las BE en sus comparaciones. En este sentido, la presente investigación provee nueva evidencia acerca de la conveniencia en el uso de BE para hacer Nowcasting del PIB de México.

3 Nowcasting

El Nowcasting puede definirse como la previsión de la actividad económica en el pasado reciente, el presente y el futuro cercano. Estas previsiones son calculadas como la proyección lineal del PIB trimestral (contemporáneo) dado un conjunto de datos de mayor frecuencia. Intuitivamente, se estiman especificaciones a través de Mínimos Cuadrados Ordinarios en las que el PIB es una función de sus propios rezagos, así como de los valores contemporáneos y rezagados de las variables independientes que se construyen a partir de un conjunto de indicadores mensuales.

Formalmente, denotemos al crecimiento del PIB trimestral como y_t^Q , y al conjunto de información mensual como X_t , donde el superíndice Q se refiere a variables trimestrales y el subíndice t se refiere al tiempo (meses o trimestres). Deseamos estimar el PIB trimestral

³ El IGAE es un indicador de frecuencia mensual que publica el INEGI aproximadamente ocho semanas después de terminado el mes de referencia y el cual representa el 93.9% del PIB en el año base, 2008=100.

contemporáneo, por lo que calculamos la proyección lineal del PIB dado el conjunto de información X_t^Q :

$$\text{Proy}[y_t^Q | X_t^Q]$$

Partimos del hecho de que nuestro conjunto de información está compuesto por n variables, $X_{it|v_j}^Q$, donde $i = 1, \dots, n$ identifica las series individuales y $t = 1, \dots, T_{v_j}$ denota el tiempo, el cual varía entre series v_j de acuerdo a su calendario de publicación, este problema es conocido en la literatura como *jagged edges* o *ragged edges*. En este sentido, los primeros pronósticos que ofrece el Nowcasting (al principio del trimestre de referencia) se realizan con observaciones faltantes al final de las series.

El *nowcast* es calculado como el valor esperado del PIB condicionado en la información disponible y el modelo subyacente, \mathcal{M} , bajo el cual se calcula la esperanza condicional:

$$\hat{y}_t^Q = E \left[y_t^Q | X_{v_j}^Q; \mathcal{M} \right]$$

Regularmente, se utiliza un modelo lineal en donde los regresores son las variables del conjunto de información (o los factores principales) y la variable dependiente es el crecimiento del PIB trimestral. La incertidumbre (varianza) asociada a esta proyección es:

$$V_{y_{t|v_j}^Q} = E \left[\left(\hat{y}_{t|v_j}^Q - y_t^Q \right)^2 | X_{v_j}^Q; \mathcal{M} \right]$$

Debido a que el número de datos observados va creciendo con el tiempo, la varianza del error va disminuyendo, es decir:

$$V_{y_{t|v_j}^Q} \leq V_{y_{t|v_{j-1}}^Q}$$

3.1 Ecuaciones Puente

En las Ecuaciones Puente no se calculan factores, sino que son los mismos indicadores mensuales los que se utilizan como variables explicativas. Denotemos al vector de n indicadores mensuales como $X_t = (X_{1,t}, \dots, X_{n,t})$, para $t = 1, \dots, T$. La ecuación puente es estimada con agregados trimestrales, $X_{i,t}^Q$, de los tres datos mensuales correspondientes.

$$X_{i,t}^Q = \frac{1}{3}(X_{i,1} + X_{i,2} + X_{i,3})$$

Estos agregados trimestrales se utilizan como regresores en la ecuación puente para obtener un pronóstico del crecimiento del PIB trimestral:

$$y_t^Q = \mu + \psi(L)X_t^Q + \varepsilon_t^Q$$

donde μ es el coeficiente de la constante, $\psi(L) = \psi_0 + \psi_1 L^1 + \dots + \psi_p L^p$ denota el polinomio de rezago, y ε_t^Q es el término de error, que se asume ruido blanco con distribución Normal.

3.2 Modelos de Factores Dinámicos

Los MFD fueron desarrollados y aplicados por primera vez por Giannone, Reichlin y Small (2008) para pronosticar el PIB trimestral de Estados Unidos. Sin embargo, la idea original de utilizar Modelos de Estado Espacio (SSM) con el fin de obtener indicadores coincidentes de Estados Unidos ya había sido propuesta y estudiada por Stock y Watson (1988, 1989), basados en la propuesta original de Geweke (1977).

Consideremos el vector de n series mensuales $X_t = (X_{1,t}, \dots, X_{n,t})'$, para $t = 1, \dots, T$. La dinámica de los factores considerada por Giannone et al. (2008) está dada por la siguiente representación de estado espacio:

$$X_t = \Lambda f_t + \xi_t, \quad \xi_t \sim \mathbb{N}(0, \Sigma_\xi) \quad (1)$$

$$f_t = \sum_{i=1}^p A_i f_{t-i} + \zeta_t \quad (2)$$

$$\zeta_t = B\eta_t, \quad \eta_t \sim \mathbb{N}(0, \mathbb{I}_q) \quad (3)$$

donde Λ es una matriz $n \times r$ de ponderadores, lo que implica que la ecuación (1) relaciona las series mensuales X_t a un vector $r \times 1$ de factores latentes $f_t = (f_{1,t}, \dots, f_{r,t})'$ más un componente idiosincrático $\xi_t = (\xi_{1,t}, \dots, \xi_{n,t})'$. Se asume que este último es ruido blanco con una matriz de covarianzas diagonal Σ_ξ . La ecuación (2) describe la ley de movimiento de los factores latentes f_t , los cuales son conducidos por un proceso autorregresivo de orden p , más

un ruido blanco q -dimensional, donde B es una matriz $n \times q$, y donde $q \leq r$. Es decir, el número de shocks comunes, q , es menor o igual al número de factores comunes, r . En consecuencia $\zeta_t \sim \mathcal{N}(0, BB')$. Finalmente, A_1, \dots, A_p son matrices $r \times r$ de coeficientes y además se asume que el proceso estocástico de f_t es estacionario.⁴

3.3 Modelos de Análisis de Componentes Principales

El método de PCA es una técnica estadística que normalmente se utiliza para la reducción de datos. Ello implica que de un conjunto grande de información se obtienen vectores principales a partir de la descomposición de la matriz de covarianzas de las series originales. Estos vectores describen una serie de combinaciones lineales no correlacionadas de las variables que contienen la mayor parte de la varianza de todo el conjunto de información. En mi investigación utilizo esta técnica para hacer pronósticos con dichos vectores, lo que genera modelos más parsimoniosos.

Partiendo del conjunto de información X_t de n series mensuales, definamos como Σ_{X_t} a la matriz $n \times n$ de covarianzas del conjunto de información. Existe una matriz $n \times n$ ortogonal, Φ , cuyas columnas son los c_t vectores principales de Σ_{X_t} , y una matriz diagonal, Ψ , donde los elementos de su diagonal principal son los eigenvalores de Σ_{X_t} , tales que,

$$\Phi' \Sigma_{X_t} \Phi = \Psi$$

Los n vectores c_t son ortogonales y están ordenados de acuerdo a la proporción de la varianza que representan del conjunto X_t .

4 Datos

En esta investigación, utilizo la serie trimestral del PIB de México, para el periodo que comprende del primer trimestre de 1993 (1993-I) al primer trimestre de 2017 (2017-I). Considero tres conjuntos de información para las variables explicativas. El primero (CI-1) incluye 25 indicadores mensuales que, al trimestralizarlos, presentan una correlación con el PIB superior a 0.30 (la correlación se calcula sobre las variaciones trimestrales de las series

⁴ El desarrollo completo del SSM empleado por Giannone et al. (2008) se encuentra en Forni, Giannone, Lippi y Reichlin (2009).

desestacionalizadas). Sin embargo, si el indicador se publica en la primera semana después del mes de referencia, lo conservo en el conjunto de información, incluso si la correlación es menor a 0.30. Como criterio adicional, sólo utilizo series mensuales que estén disponibles desde 1993, con el fin de contar con variables explicativas cuyo periodo de observación corresponde con el del PIB.

El segundo conjunto de información (CI-2) está formado por ocho variables, algunas de las cuales están incluidas en el CI-1 pero con una correlación con el PIB más estricta de al menos 0.40. Además dejé de considerar como criterio la fecha inicial de disponibilidad de datos, por lo que ahora hay indicadores que no estaban incluidos en el CI-1. El tercer conjunto (CI-3) es exclusivo para la estimación del MFD y en él utilizo 11 variables que elegí arbitrariamente del CI-1 y el CI-2 por representar sectores distintos de la economía.⁵

Podemos decir que los tres conjuntos de información están formados por variables “duras” y variables “suaves”. Las primeras ofrecen información oportuna y coincidente de la actividad económica, mientras que las segundas, aunque son más oportunas y se adelantan a la actividad económica, provienen de encuestas de percepción, por lo que pudieran ser imprecisas. En efecto, los indicadores duros son muy importantes para la estimación de PIB trimestral, pues tienen un mayor peso en los factores principales, mientras que los indicadores suaves tienen un menor impacto, lo que refleja el hecho de que la mayor parte de su contribución se debe principalmente a su oportunidad.

Más aún, en la literatura se ha mostrado que las variables que proporcionan la información más oportuna contribuyen a una mejora de la estimación sólo al principio del trimestre y que una vez que se incluyen los datos actualizados (publicados) de los indicadores duros su contribución se desvanece (Banbura et al., 2013).

Respecto a la utilización de los datos, desestacionalizo todas las variables que integran el conjunto de información con el programa X12 ARIMA,⁶ excepto las que ya publica el INEGI

⁵ La necesidad de tener un conjunto de información especial para el MFD se deriva de su estimación, y del hecho de que el incluir variables con pocas observaciones (como la Encuesta Mensual sobre Empresas Comerciales que inicia en 2008) dificulta la solución recursiva del modelo.

⁶ Todos los modelos de ajuste estacional se sustentaron en el documento “Procedimiento Para Obtener Modelos de Ajuste Estacional con el Programa X12ARIMA” del Grupo Especializado en Desestacionalización (GED) del Comité Especializado de Estadísticas Macroeconómicas y Cuentas Nacionales.

con ajuste estacional y aquellas que provienen de las encuestas de percepción (porque no presentan un patrón estacional). Además, sólo trabajo con series estacionarias; para ello, transformo algunas de las series mediante una diferencia logarítmica, con base en pruebas de raíz unitaria (véase el Anexo 1, Tabla A.2). Finalmente, como es convención en la literatura, estandarizo todas las series antes de aplicar las metodologías de Nowcasting.

5 Resultados

Para lidiar con los conjuntos de información incompletos (*jagged edges*), elaboré modelos ARIMA para cada variable mensual, con el fin de pronosticar las observaciones faltantes. De esta manera, para generar el pronóstico del crecimiento del PIB trimestral,⁷ tanto las BE como los MFD y los PCA fueron estimados a partir de conjuntos de información previamente completados con ecuaciones ARIMA. Lo anterior me permite comparar el poder predictivo de cada modelo independientemente de cómo lidia con los conjuntos de información incompletos. Esto a pesar de que tanto los modelos de PCA como el MFD podrían hacer los pronósticos de sus propios factores.

5.1 Estimación de las BE

Realicé la estimación de las BE usando el CI-1 y el CI-2, por lo que obtengo los modelos BE1 y BE2, respectivamente. Teóricamente, una BE utiliza para su estimación un método de MCO con rezagos de las variables incluidas en el modelo; sin embargo, la mayoría de las investigaciones antes citadas proponen modelos ARIMA con variables exógenas, los cuales mejoran la precisión de las estimaciones. En consecuencia, estimo la siguiente ecuación:

$$\phi(L)y_t^Q = \theta(L)\varepsilon_t + \psi(L)X_t^Q \quad (4)$$

donde todas las variables se trataron con una diferencia logarítmica para aproximar una tasa de crecimiento. Se tiene que $\phi(L)$, $\theta(L)$ y $\psi(L)$ son polinomios de rezago cuyo orden fue determinado con base en la función de auto-correlación de los errores, el estadístico Q de Ljung-Box, con pruebas de significancia estadística de los coeficientes estimados y con base en los criterios de información convencionales. Finalmente, ε_t se asume ruido blanco con

⁷ Entendiéndose por crecimiento a la tasa de variación del PIB de un trimestre respecto al inmediato anterior, utilizando series desestacionalizadas.

distribución Normal. La estimación de la ecuación anterior permite hacer pronósticos de la tasa de crecimiento del PIB (Figura 1).

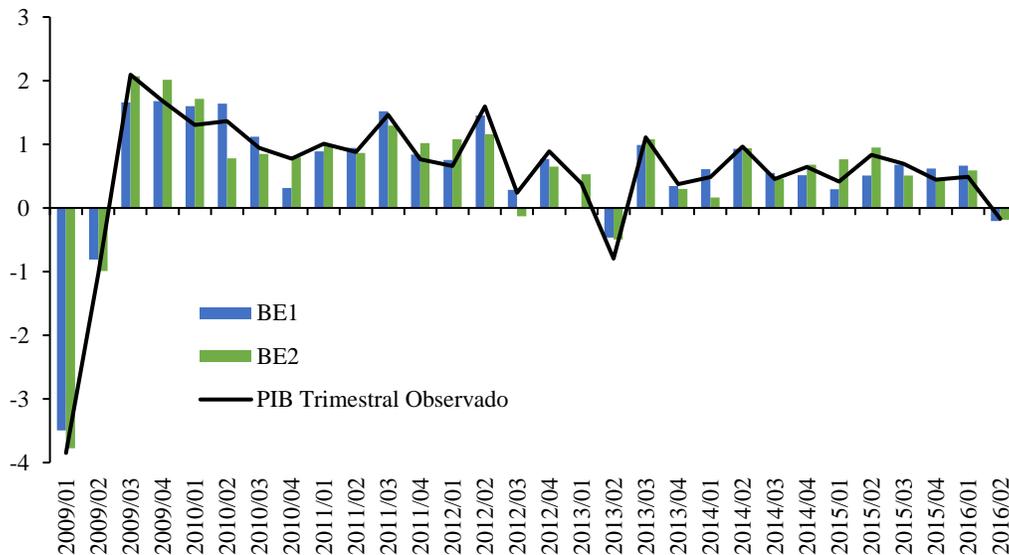


Figura 1. Pronósticos del crecimiento del PIB usando BE.

5.2 Estimación del MFD

En el caso del MFD sólo utilizo las 11 variables del CI-3. Para estimar los coeficientes del modelo utilizo el Método de Máxima Verosimilitud (MMV). A su vez, los parámetros de la función de verosimilitud son estimados con el Filtro de Kalman.⁸ Este requiere de valores iniciales para las variables de estado, así como de una matriz de covarianzas para comenzar con el proceso recursivo. Para ello, utilicé el método sugerido en Hamilton (1994b).⁹

El modelo de Estado Espacio estimado tiene la siguiente ecuación de estado:

⁸ Para profundizar en los SSM y el Filtro de Kalman véase Hamilton (1994a, 1994b), Harvey (1989), y Brockwell and Davis (1991).

⁹ Es decir, los valores iniciales se obtienen con los coeficientes estimados con una regresión lineal de X_t sobre f_t , dado que este último sigue una estructura autorregresiva.

$$\begin{pmatrix} f_t \\ \xi_{1,t} \\ \xi_{2,t} \\ \xi_{3,t} \\ \xi_{4,t} \\ \xi_{5,t} \\ \xi_{6,t} \\ \xi_{7,t} \\ \xi_{8,t} \\ \xi_{9,t} \\ \xi_{10,t} \\ \xi_{11,t} \end{pmatrix} = \begin{pmatrix} \varphi & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \delta_1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \delta_2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \delta_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \delta_4 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \delta_5 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \delta_6 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \delta_7 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \delta_8 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \delta_9 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \delta_{10} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \delta_{11} \end{pmatrix} \begin{pmatrix} f_{t-1} \\ \xi_{1,t-1} \\ \xi_{2,t-1} \\ \xi_{3,t-1} \\ \xi_{4,t-1} \\ \xi_{5,t-1} \\ \xi_{6,t-1} \\ \xi_{7,t-1} \\ \xi_{8,t-1} \\ \xi_{9,t-1} \\ \xi_{10,t-1} \\ \xi_{11,t-1} \end{pmatrix} + \begin{pmatrix} \eta_t \\ \varsigma_{1,t} \\ \varsigma_{2,t} \\ \varsigma_{3,t} \\ \varsigma_{4,t} \\ \varsigma_{5,t} \\ \varsigma_{6,t} \\ \varsigma_{7,t} \\ \varsigma_{8,t} \\ \varsigma_{9,t} \\ \varsigma_{10,t} \\ \varsigma_{11,t} \end{pmatrix}$$

Con $\eta_t \sim \mathcal{N}(0,1)$ y $\varsigma_{i,t} \sim \mathcal{N}(0, \sigma_i^2)$.

Mientras que la ecuación de observación es:

$$\begin{pmatrix} IGAE_t \\ Consumo_t \\ IMAI_t \\ M_t \\ ANTAD_t \\ Cemento_t \\ M4_t \\ EMEC_t \\ X_t \\ CFE_t \\ PEMEX_t \end{pmatrix} = \begin{pmatrix} \lambda_1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \lambda_2 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \lambda_3 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \lambda_4 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \lambda_5 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ \lambda_6 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ \lambda_7 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ \lambda_8 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ \lambda_9 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ \lambda_{10} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ \lambda_{11} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} f_t \\ \xi_{1,t} \\ \xi_{2,t} \\ \xi_{3,t} \\ \xi_{4,t} \\ \xi_{5,t} \\ \xi_{6,t} \\ \xi_{7,t} \\ \xi_{8,t} \\ \xi_{9,t} \\ \xi_{10,t} \\ \xi_{11,t} \end{pmatrix}$$

Para utilizar el factor que se obtiene a partir de la estimación del MFD (Figura 2) es necesario hacer una trimestralización del mismo. Esta se obtiene con el promedio de las tres observaciones mensuales correspondientes a cada trimestre $f_t^Q = \frac{1}{3}(f_1 + f_2 + f_3)$. De esta forma, el crecimiento del PIB se estima con la siguiente ecuación:

$$y_t^Q = \alpha + \beta f_t^Q + \varepsilon_t^Q \quad (5)$$

Es decir, el *Nowcast* del PIB trimestral es una función lineal del factor. El procedimiento de estimación de esta regresión lineal de la ecuación (5) emplea el método de Cochrane-Orcutt (1949) para obtener estimadores robustos ante la presencia de autocorrelación residual.

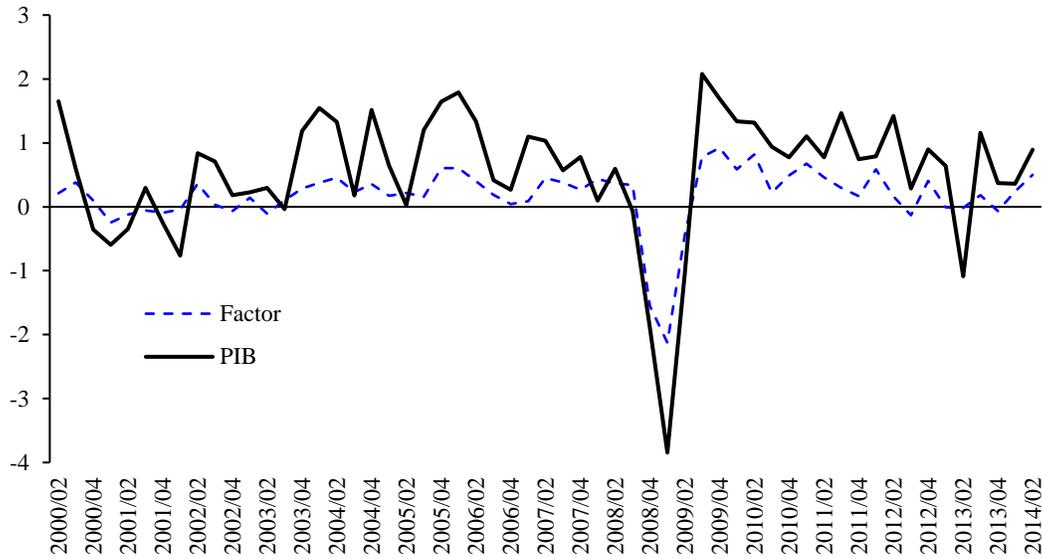


Figura 2. Crecimiento del PIB trimestral vs. Factor del MFD.

5.3 Estimación del PCA

Finalmente, estimé los modelos de PCA utilizando el CI-1 y el CI-2, obteniendo los modelos PCA1 y PCA2, respectivamente. En el análisis obtengo todos los componentes (vectores) principales, c_t , que surgen de cada conjunto de información. Sin embargo, sólo considero los k componentes ($k < n$) cuyo eigenvalor sea mayor o igual a la unidad, de acuerdo al criterio de Kaiser (1958). Después de obtener estos componentes los roto con el fin de distribuir la varianza explicada por cada uno de ellos, por lo que utilizo el método varimax, lo que también me permite mantener la propiedad de ortogonalidad entre los componentes aún después de haber distribuido su varianza. A su vez, el mantener la propiedad de ortogonalidad implica una reducción importante en el número de componentes obtenidos debido a la alta correlación entre las variables consideradas. Esto ayuda a mantener la parsimonia en el modelo que pronostica el PIB.

En consecuencia, de forma análoga a los métodos anteriormente expuestos, en el PCA utilizo los k componentes principales trimestralizados (Figuras 3 y 4) como regresores en la siguiente ecuación lineal para pronosticar el crecimiento del PIB trimestral:

$$y_t^Q = \gamma + \delta c_t^Q + \varepsilon_t^Q \quad (6)$$

donde δ es una matriz $n \times k$ de coeficientes, c_t^Q es el vector de los k componentes principales trimestralizados, y ε_t^Q es el término de error, que se asume ruido blanco con distribución Normal. La estimación de la ecuación (6) se apoya de la técnica de Mínimos Cuadrados Generalizados (MCG) mediante el método de Cochrane-Orcutt.

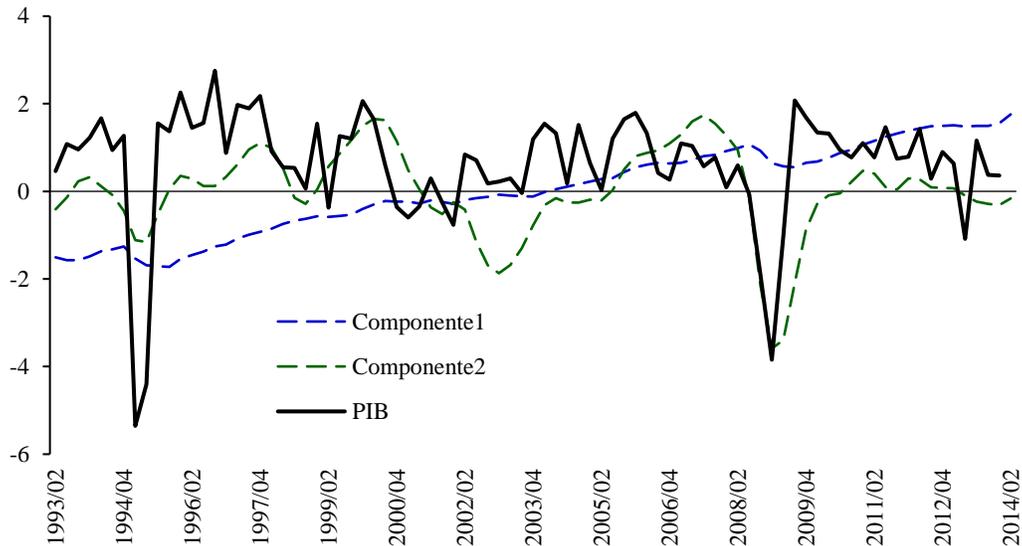


Figura 3: Crecimiento del PIB trimestral vs. Componentes del PCA1.

5.4 Pruebas de Diebold-Mariano para las Series Dentro de Muestra

Bajo la hipótesis de que los pronósticos mejorarán tomando el promedio o la mediana de los cinco modelos, considero ambos estadísticos como pronósticos adicionales. También considero el promedio de los pronósticos de las BE, así como un modelo univariado, AR(1), el cual se incluye como modelo de referencia. Este modelo AR utiliza la serie del PIB trimestral como insumo, tratándola con una diferencia logarítmica para inducir la estacionariedad y para aproximarse a la tasa de crecimiento del PIB.

Con el fin de evaluar el poder predictivo de cada modelo y así discernir cuál es más apropiado para realizar Nowcasting, utilizo la prueba de Diebold-Mariano (DM).¹⁰ En la Tabla 1 se resumen dicha prueba comparando cada modelo con el resto. En la diagonal principal se indica el Error Cuadrático Medio (ECM) de cada modelo y en las columnas se indica qué modelo resulta más preciso, de acuerdo con esta prueba. Asimismo, señalo con asteriscos la

¹⁰ En el Anexo 2 se presentan los detalles de esta prueba.

significancia estadística de la diferencia de los errores en cada pareja de modelos comparados. La prueba considera los trimestres que van de 2009-I a 2016-II.

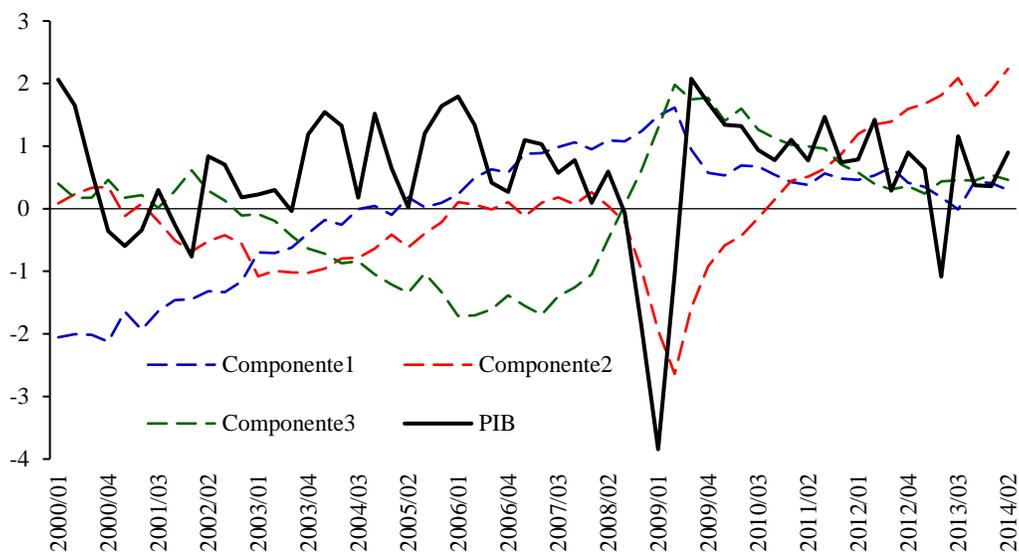


Figura 4: Crecimiento del PIB trimestral vs. Componentes del PCA2.

Tabla 1. Prueba de Diebold-Mariano (criterio de pérdida ECM)

Modelos	AR	PCA1	PCA2	MFD	BE1	BE2	Promedio	Mediana	Prom(BE)
AR	0.808								
PCA1	PCA1	0.665							
PCA2	PCA2	PCA2	0.542						
MFD	MFD*	MFD*	MFD**	0.120					
BE1	BE1*	BE1**	BE1***	BE1	0.045				
BE2	BE2*	BE2*	BE2***	BE2	BE1*	0.056			
Promedio (Todos los Modelos)	Promedio*	Promedio*	Promedio***	MFD	BE1***	BE2*	0.124		
Mediana (Todos los Modelos)	Mediana*	Mediana*	Mediana***	Mediana	BE1*	BE2	Mediana*	0.058	
Promedio(BE)	Prom(BE)**	Prom(BE)**	Prom(BE)***	Prom(BE)**	Prom(BE)*	Prom(BE)***	Prom(BE)***	Prom(BE)***	0.026

p-value para la significancia de la diferencia del ECM entre los modelos comparados ***p<0.01, **p<0.05, *p<0.1

La muestra incluye los pronósticos de 2009-I a 2016-II. Se emplea el Error Cuadrático Medio (ECM) como criterio de pérdida y se usa el Kernel de una distribución Uniforme para calcular la varianza de largo plazo. En la diagonal principal se encuentran los ECM de cada modelo, estimados con base en la variación trimestral desestacionalizada del PIB.

Los resultados de la prueba de DM sugieren que los pronósticos generados con el MFD y con las BE superan estadísticamente (en términos de precisión) a los obtenidos con el AR, el PCA1 y el PCA2. Si bien no se encontraron diferencias estadísticamente significativas entre los errores de pronóstico de las BE y los del MFD, sí las hubo entre los errores promedio de las BE y los del MFD. Más aún, encuentro que los pronósticos que ofrece este promedio de BE son más precisos que los obtenidos con la media o la mediana de todos los modelos. En efecto, el promedio de los pronósticos de las Ecuaciones Puente obtuvo el ECM más pequeño ($ECM = 0.026$), el cual implica que, en términos generales, se obtiene un error de 14 centésimas de la variación trimestral desestacionalizada observada (Tabla 2). Con base en estos resultados, concluyo que el promedio de las BE es el mejor predictor del PIB trimestral entre los modelos estimados.

Tabla 2. Errores de Pronóstico (2009-I a 2016-II)

Criterio	AR	PCA1	PCA2	MFD	BE1	BE2	Promedio	Mediana	Promedio BE
BIAS	0.001	0.295	-0.146	0.035	-0.003	0.000	0.036	0.015	-0.001
MAE	0.550	0.546	0.555	0.243	0.168	0.174	0.248	0.165	0.136
MSE	0.808	0.665	0.542	0.120	0.045	0.056	0.124	0.058	0.026
RMSE	0.899	0.816	0.736	0.346	0.212	0.237	0.353	0.241	0.162

Nota: Los errores de pronóstico se obtienen como la diferencia entre el valor observado y el pronosticado. Los criterios que se muestran en esta tabla se detallan en la Sección 5.5.

Con el fin de corroborar la robustez de mis resultados, realicé la prueba de DM bajo un criterio de pérdida distinto. Para ello utilicé el Error Absoluto Medio del Pronóstico (EAM) como criterio de pérdida y un Bartlett Kernel para calcular la varianza de largo plazo de la serie de diferencias. Los resultados siguen mostrando que la precisión de los pronósticos generados con el MFD es mayor que la del modelo univariado y que la de los modelos de PCA, con diferencias estadísticamente significativas. Este resultado es consistente con los hallazgos de Giannone et al. (2008), Rünstler et al. (2009) y Banbura y Modugno (2014), quienes han propuesto el uso de MFD para hacer Nowcasting. Sin embargo, esta nueva prueba sugiere que los pronósticos generados por todos los modelos (incluidos el MFD) son superados por las BE, así como por el promedio de éstas, con diferencias significativas al 95% de confianza (véase Tabla A.3. del Anexo 3).

Asimismo, realicé pruebas de DM en una muestra más reducida, para no considerar el periodo de la crisis financiera de 2008-2009. De esta forma, evalué los pronósticos desde 2011-I hasta el final de la muestra (véase Tabla A.4. del Anexo 3). Los resultados favorecen el uso del promedio de BE sobre cualquier otro modelo, con diferencias significativas de al menos el 90% de confianza (excepto cuando se compara con el modelo BE1, donde no hay diferencias significativas). Nuevamente, el MFD ofrece pronósticos más precisos que el AR y que los modelos de PCA, pero se muestra que las BE producen pronósticos más precisos que éste.

5.5 Pronósticos Dentro de Muestra de las BE

Para evaluar la eficiencia de las BE realicé un análisis de los errores de pronóstico utilizando los siguientes criterios, para los cuales k se refiere al número de periodos pronosticados.

Sesgo de Pronóstico (BIAS).

$$BIAS = \frac{1}{k} \sum_{i=1}^k (\hat{y}_i - y_i)$$

Error Promedio del Pronóstico al Cuadrado (MSE).

$$MSE = \frac{1}{k} \sum_{i=1}^k (\hat{y}_i - y_i)^2$$

Raíz del Error Cuadrático Promedio del Pronóstico (RMSE).

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (\hat{y}_i - y_i)^2}$$

Realicé la evaluación de los tres criterios previamente descritos utilizando dos enfoques, uno de ventana móvil (*rolling window*) y otro de ventana expandida (*expanding window*). En el primero estimo la ecuación (6) con datos desde 1993-I hasta 2006-IV (X_1^{56} , el subíndice 1 se refiere al primer dato observado [1993-I] y el 56 al 2006-IV, es decir 56 trimestres desde el primer dato observado). Con dicha estimación pronostico cuatro trimestres ($k = 4$) hacia

adelante. Análogamente, reestimo la ecuación (4) con datos desde 1993-II hasta 2007-I (X_2^{57}), y así sucesivamente de la siguiente forma,

$$\hat{y}_{j,T+i+j}^Q = E[y_{j,T+j}^Q | X_j^{T+j}] \quad \forall i = (1,4), j = (1,28)$$

Donde $\hat{y}_{j,T+i+j}^Q$ se refiere al pronóstico i trimestres después de la estimación hecha desde j hasta $(T + j)$ trimestres después; X_j^{T+j} se refiere al conjunto de información que comienza j trimestres después de la primera observación y termina $(T + j)$ después de esta. Ello implica que la ventana de estimación tiene siempre la misma longitud, es decir $T = 56$ trimestres. Las ventanas de estimación se rotaron 28 veces, hasta 2013-IV con el fin de que en la última rotación se pronosticara hasta 2014-IV.

En el segundo enfoque estimo la ecuación (4) con X_1^{56} y pronóstico cuatro trimestres ($k = 4$) hacia adelante. A continuación reestimo la ecuación (4) con X_1^{57} , es decir, con un trimestre adicional, y así sucesivamente de la siguiente forma,

$$\hat{y}_{T+i+j}^Q = E[y_{T+j}^Q | X^{T+j}] \quad \forall i = 1, \dots, 4 \wedge j = 1, \dots, 28$$

Esto implica que en la última ventana hice una estimación desde 1993-I hasta 2013-IV, con la cual pronóstico cuatro trimestres (hasta 2014-IV).

Tabla 3. Análisis de los errores de pronóstico en *pseudo* tiempo real

Estadístico	Rolling window				Expanding window			
	Horizonte de pronóstico							
	$k=1$	$k=2$	$k=3$	$k=4$	$k=1$	$k=2$	$k=3$	$k=4$
BE1								
BIAS	0.004	-0.059	-0.053	-0.029	0.017	-0.042	-0.040	-0.022
MSE	0.118	0.133	0.149	0.159	0.117	0.115	0.138	0.159
RMSE	0.344	0.365	0.386	0.399	0.342	0.339	0.372	0.399
BE2								
BIAS	0.021	0.033	0.013	0.048	0.076	0.074	0.026	0.077
MSE	0.275	0.229	0.183	0.353	0.220	0.185	0.134	0.229
RMSE	0.524	0.479	0.428	0.594	0.469	0.430	0.366	0.478

Nota: Se muestran los estadísticos promedio que se obtienen de una estimación con una ventana móvil y una expandida. El tamaño de la primera ventana es de 56 trimestres en BE1 y 28 trimestres en BE2; de 1993-I a 2006-IV y de 2000-I a 2006-IV, respectivamente.

Los resultados de la ventana móvil muestran que los errores de pronóstico generados con BE1 presentan un comportamiento ascendente a medida que k crece. Es decir, los errores se hacen más grandes cuando el horizonte de pronóstico es más largo. Sin embargo, esto no es cierto para el modelo de BE2, donde el error más pequeño se obtuvo al pronosticar tres periodos hacia adelante. En el caso de la ventana expandida tampoco se observa un incremento en el error de pronóstico en ninguno de los modelos (Tabla 3).

El sesgo del modelo BE1 muestra una subestimación del crecimiento del PIB a medida que el horizonte de pronóstico crece (excepto en $k = 4$, donde el sesgo se reduce). Por otro lado, en el modelo BE2 con una ventana expandida, el sesgo se mantiene relativamente constante e incluso se reduce en $k = 3$. Estos resultados son consistentes con los hallazgos de Giannone et al. (2008), quienes sugieren utilizar el Nowcasting para pronosticar únicamente el trimestre del cual no se cuenta con información (*forecast one step ahead*) y no para trimestres futuros.

5.6 Pronósticos en Tiempo Real (Fuera de Muestra)

Debido a que el promedio de las BE provee pronósticos más precisos del PIB que el resto de los modelos considerados, realizo pruebas en tiempo real con el fin de analizar la evolución y sensibilidad del pronóstico ante la publicación de información nueva correspondiente a cada serie que forma parte del conjunto de información.

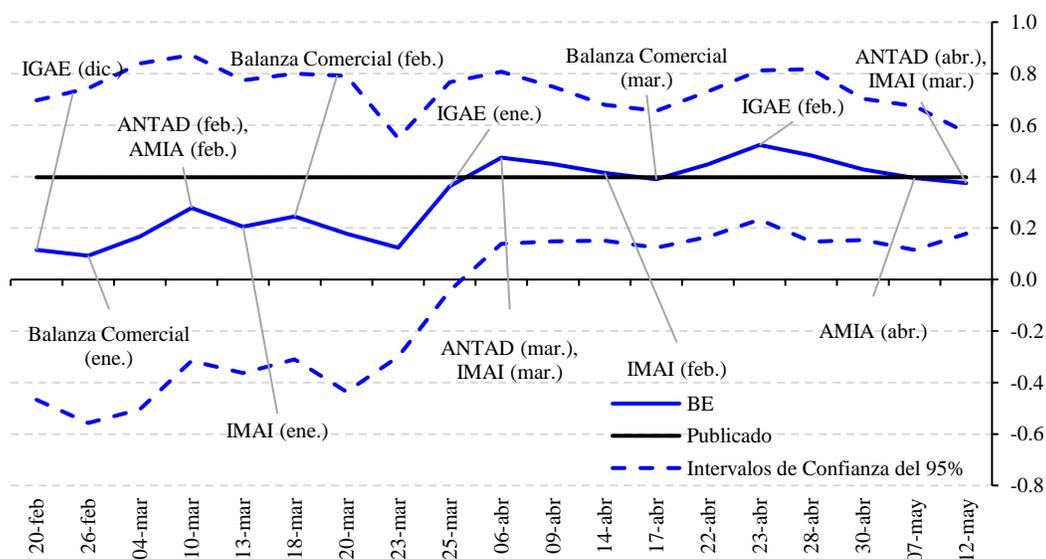


Figura 5. Evolución del Nowcasting en tiempo real vs. variación trimestral del PIB (2015-I)

El periodo de estudio comprende del 2014-II al 2017-I, y el análisis consiste en observar la evolución del pronóstico, actualizándolo con base en la publicación mensual de variables que “completan” al conjunto de información. Esto permite evaluar ante qué variables es más sensible el pronóstico y en qué momento mejora su precisión hasta obtener una estimación confiable del PIB. La Figura 5 muestra un ejemplo de cómo se comporta la actualización del Nowcasting a medida que se publican cada uno de los indicadores que componen al conjunto de información. El pronóstico empieza con la publicación del IGAE del tercer mes del trimestre previo al de referencia, es decir, comienza durante el trimestre en curso.

Con el registro de este análisis, para los doce trimestres evaluados obtuve el error de pronóstico, el cual fue agrupado por cortes. Identifiqué 12 cortes de particular relevancia que componen la evolución del pronóstico del PIB en tiempo real para cualquier trimestre Q . Estos cortes incluyen indicadores de interés que tienen efectos importantes sobre el Nowcasting:

INICIAL. Publicación del IGAE del último mes del trimestre anterior.

1. Publicación de la Balanza Comercial del primer mes del trimestre de referencia.
2. Publicación de las ventas de autos (AMIA) del segundo mes del trimestre de referencia.
3. Publicación de la Actividad Industrial (IMAI) del primer mes del trimestre de referencia.
4. Publicación de la Balanza Comercial del segundo mes del trimestre de referencia.
5. Publicación del IGAE del primer mes del trimestre de referencia.
6. Publicación de las ventas de autos (AMIA) del tercer mes del trimestre de referencia.
7. Publicación de la Actividad Industrial (IMAI) del segundo mes del trimestre de referencia.
8. Publicación de la Balanza Comercial del tercer mes del trimestre de referencia.
9. Publicación del IGAE del segundo mes del trimestre de referencia.
10. Publicación de las ventas de autos (AMIA) del primer mes del siguiente trimestre.

FINAL. Publicación de la Actividad Industrial del tercer mes del trimestre de referencia.

Con esta información construí un diagrama de cajas y brazos para evaluar la rapidez y eficiencia del Nowcasting para mejorar su precisión hasta obtener una estimación confiable del PIB. En la Figura 6 grafico el promedio de los errores de pronóstico en el periodo t (representado por un punto sólido) y la mediana de los errores (línea horizontal negra). Las cajas del diagrama representan los límites de dispersión de los errores de pronóstico en los cuartiles centrales y los brazos muestran los errores de pronóstico en el primero y último cuartiles (los círculos vacíos representan valores extremos). La figura muestra que la información que incorpora la Balanza Comercial del segundo mes del trimestre de referencia

(corte 4) al conjunto de datos mejora la precisión del pronóstico respecto al obtenido con la información acumulada hasta la publicación del Indicador Mensual de la Actividad Industrial (IMAI) del primer mes del trimestre de referencia.

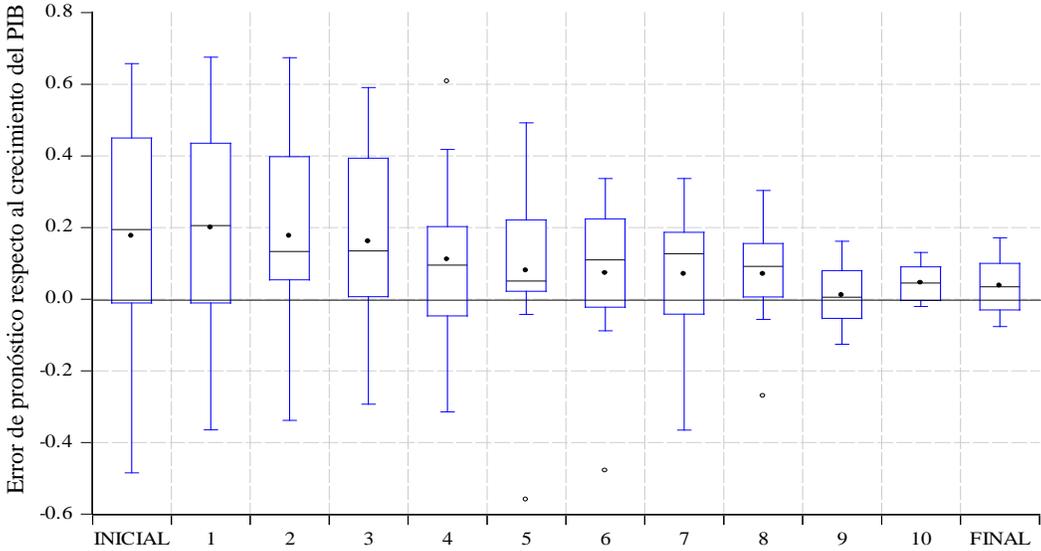


Figura 6. Errores de pronóstico del Nowcasting en puntos porcentuales sobre la variación trimestral del PIB (2014-II a 2017-I).

Con la publicación del IGAE del segundo mes del trimestre de referencia (corte 9), el pronóstico no sólo se aproxima al valor verdadero del PIB, sino que además se reduce aún más la varianza del error. Ello implica que el modelo que propongo puede ofrecer un pronóstico preciso del PIB de México un mes antes de que el INEGI publique el dato oficial del PIB. Una vez que se incluyen al conjunto de información los datos del IGAE del segundo mes del trimestre de referencia, el pronóstico es, en promedio, igual a la variación trimestral observada del PIB, y el 75 por ciento de las veces el margen de error es, en términos absolutos, menor a 0.1 puntos porcentuales de dicha variación trimestral.

5.7 Ecuaciones Puente vs. Especialistas

Como en el caso de Caruso (2018), en esta investigación pongo a competir los pronósticos del modelo “preferido” de BE con los pronósticos de los analistas encuestados por Bloomberg, así como los de la EEBM.¹¹ No obstante, los pronósticos introducidos en el

¹¹ Los pronósticos de los analistas encuestados por Bloomberg se obtienen del repositorio disponible en su plataforma, mientras que los de la EEBM se obtienen de la base de datos que publica el Banco de México en su sitio web.

análisis de Caruso (2018) no son comparables debido a que los estimados con su MFD no se realizaron en tiempo real, mientras que los de los especialistas sí. Para enfrentar este problema, Delajara, et al. (2016) recuperan las series históricas del PIB y de los cinco indicadores de su MFD para simular la generación de pronósticos en tiempo real y así mejorar la comparabilidad entre éstos y los ofrecidos por los especialistas.

Tabla 4. Prueba de Diebold-Mariano

Modelos	Prom(BE)	Bloom	EEBM
Promedio (BE)	0.004		
Bloomberg	Prom(BE)**	0.019	
EEBM	Prom(BE)***	Bloom*	0.051

p-value para la significancia de la diferencia del ECM entre los modelos comparados ***p<0.01, **p<0.05, *p<0.1

La muestra incluye los pronósticos de 2014-II a 2017-I. Se emplea el Error Cuadrático Medio (ECM) como criterio de pérdida. En la diagonal principal se encuentran los ECM de cada modelo, estimados con base en la variación trimestral desestacionalizada del PIB.

En mi caso, cuento con un registro desde 2014-II hasta 2017-I de pronósticos generados en tiempo real con los cinco modelos que propongo en esta investigación. Así que utilizo los registros del promedio de las BE para compararlos con los de la mediana de los analistas encuestados por Bloomberg y los de la mediana de los registrados en la EEBM.¹²

Tabla 5. Errores de Pronóstico en Tiempo Real (2014-II a 2017-I)

Criterio	Promedio BE	Bloomberg	EEBM
BIAS	0.022	0.023	0.052
MAE	0.051	0.117	0.197
MSE	0.004	0.019	0.051
RMSE	0.065	0.138	0.227

Nota: Los errores de pronóstico se obtienen como la diferencia entre el valor observado y el pronosticado.

¹² En los resultados de la EEBM que publica el Banco de México sólo se reporta el pronóstico para el crecimiento anual del PIB con series originales, por lo que traduje estas tasas anuales a sus correspondientes variaciones trimestrales con series desestacionalizadas. Para ello, desestacionalizo las respectivas series históricas del PIB con la variación anual pronosticada por los analistas y con los modelos oficiales del INEGI.

Para llevar a cabo la comparación utilicé la prueba de DM. Los resultados de la prueba muestran que el ECM del promedio de las BE es menor al de los pronósticos de Bloomberg, con diferencias estadísticamente significativas. Análogamente, el ECM de las Ecuaciones Puentes es estadísticamente menor al de la EEBM. El ECM de las BE, 0.004, implica que durante el análisis en tiempo real, el pronóstico del PIB ha diferido, en promedio, 5 centésimas de la variación trimestral desestacionalizada observada (Tabla 5).

6 Conclusiones

En esta investigación propongo un conjunto de modelos para hacer Nowcasting de las variaciones trimestrales desestacionalizadas del PIB de México actualizando los pronósticos a medida que se publica información nueva correspondiente al trimestre de referencia. Los modelos de pronóstico que considero son un MFD, dos BE y dos modelos de PCA. Utilizo pruebas de Diebold-Mariano con el fin de evaluar los errores de pronóstico de cada modelo. La evaluación se realiza dentro de muestra, durante el periodo 2009-I a 2016-II. Como referencia incluí en el análisis los pronósticos de un modelo univariado (AR).

Los resultados de las pruebas de DM sugieren que el promedio de las BE son mejores predictores del PIB trimestral de México en comparación con el modelo AR, el MFD y los modelos de PCA. Aun comparando con la media y la mediana de los pronósticos de todos los modelos (sin considerar el AR), se prefiere el promedio de las BE. Estos resultados fueron consistentes bajo pruebas de robustez en las que cambié el criterio de pérdida y el periodo de análisis. Mis hallazgos contrastan con los de Liu et al. (2012), quienes sugieren el uso de MFD para pronosticar el PIB de economías emergentes. No obstante, Liu et al. (2012) tampoco se inclinan por el uso de los MFD para los datos de México, sino que optan por un modelo VAR Bayesiano; además el conjunto de información que ellos utilizan es sustancialmente distinto al que propongo en esta investigación.

Adicionalmente, proveo un análisis de los pronósticos en tiempo real. Esto fue posible debido a que registré el comportamiento del Nowcasting durante doce trimestres consecutivos (desde 2014-II hasta 2017-I) a medida que se incorporaba información nueva en cada modelo. De este registro obtuve los errores de pronóstico del promedio de las BE. Mis resultados muestran que la varianza de los errores se reduce a medida que se cuenta con más

información observada del trimestre de referencia. Asimismo, encuentro que el modelo que propongo en esta investigación puede ofrecer un buen pronóstico del PIB un mes antes de que el INEGI publique el dato oficial y una semana antes de que publique su estimación oportuna del PIB. En efecto, una vez que se incluyen al conjunto de información los datos del IGAE del segundo mes del trimestre de referencia, el pronóstico es, en promedio, igual a la variación trimestral observada del PIB, y el 75 por ciento de las veces el margen de error es, en términos absolutos, menor a 0.1 puntos porcentuales de dicha variación trimestral.

Finalmente, utilicé los registros del Nowcasting en tiempo real para compararlos con la mediana de los pronósticos de los analistas de Bloomberg y con la mediana de los especialistas de la EEBM, usando la prueba de DM. Los resultados de la prueba muestran que el ECM del promedio de las BE es menor a la media de los pronósticos provistos por los analistas encuestados por Bloomberg, con diferencias estadísticamente significativas. Análogamente, el ECM de las BE es estadísticamente menor al de la EEBM.

Referencias

1. Álvarez, R., Camacho, M. and Perez-Quiros, G. (2012). *Finite Sample Performance of Small versus Large Scale Dynamic Factor Models*. Documentos de Trabajo N° 1204. Banco de España.
2. Angelini, E., Camba-Mendez, G., Giannone, D., Reichlin, L., and Rünstler, G. (2011). *Short-Term Forecasts of Euro Area GDP Growth*. The Econometrics Journal, 14(1), C25-C44.
3. Baffigi, A., Golinelli, R., Parigi, G. (2004). *Bridge Models to Forecast the Euro Area GDP*. International Journal of Forecasting 20(3), pp. 447-460.
4. Banbura, M., Giannone, D., Modugno, M., & Reichlin, L. (2013). *Now-casting and the real-time data flow*. Working Paper Series 1564, European Central Bank.
5. Banbura, M. and Modugno, M. (2014). *Maximum likelihood estimation of factor models on datasets with arbitrary pattern of missing data*. Journal of Applied Econometrics 29(1), pp. 133-160.
6. Barnett, W., Chauvet, M., and Leiva-Leon, D. (2014). *Realtime nowcasting of nominal GDP under structural breaks*. Bank of Canada Working Paper, No. 2014-39.
7. Brockwell, P. J., and R. A. Davis (1991). *Time Series: Theory and Methods*. 2nd ed. New York: Springer.
8. Camacho, M. and Doménech, R. (2012). *MICA-BBVA: a factor model of economic and financial indicators for short-term GDP forecasting*. Journal of the Spanish Economic Association, 3(4), pp. 475-497.
9. Caruso, Alberto (2018). *Nowcasting with the help of foreign indicators: The case of Mexico*. Economic Modelling, Elsevier, 69(C), pp. 160-168.
10. Cochrane, D., and G. H. Orcutt (1949). *Application of least squares regression to relationships containing autocorrelated error terms*. Journal of the American Statistical Association 44(245): pp. 32-61.
11. de Winter, J. (2011). *Forecasting GDP growth in times of crisis: private sector forecasts versus statistical models*. DNB Working Paper No. 320.

12. Dahlhaus, T., J.-D. Guénette, and G. Vasishta (2017). *Nowcasting BRIC+ M in real time*. *International Journal of Forecasting*, 33, 915-935.
13. Delajara, Hernández-Álvarez and Rodríguez-Tirado (2016). *Nowcasting Mexico's short-term GDP growth in real-time: A factor model versus professional forecasters*. *Economía*, 17(1), pp. 167-182.
14. Diebold, F. and Mariano, R. (1995). *Comparing Predictive Accuracy*. *Journal of Business and Economic Statistics*, 13:3, pp. 253-263.
15. Doz, C., Giannone, D. and Reichlin, L. (2012). *A quasi-maximum likelihood approach for large, approximate dynamic factor models*. *Review of economics and statistics* 94(4), 1014–1024.
16. Forni, M., D. Giannone, M. Lippi, and L. Reichlin (2009): *Opening The Black Box: Structural Factor Models With Large Cross Sections*. *Econometric Theory*, 25(05), pp. 1319-1347.
17. Gómez-Zamudio, L. and Ibarra, R. (2017) *Are daily financial data useful for forecasting GDP? Evidence from Mexico*. Working Paper 2017-17. Banco de México.
18. Guerrero, V., García, A. and Sainz E. (2013). *Rapid Estimates of Mexico's Quarterly GDP*. *Journal of Official Statistics*, 29(3), pp. 397–423.
19. Geweke, J. (1977). *The Dynamic Factor Analysis of Economic Time Series*. [In:] Aigner DJ, Goldberger AS (ed.), *Latent Variables in Socio-Economic Models*.
20. Giannone, D., Reichlin, L., and Small, D. (2008). *Nowcasting: The Real-time Informational Content of Macroeconomic Data*. *Journal of Monetary Economics*, pp. 665-676.
21. Hamilton, J. D. (1994a). *State Space Models*. [In:] *Handbook of Econometrics*, ed. R. F. Engel and D. L. McFadden, pp. 3039-3080. Amsterdam: Elsevier.
22. _____. (1994b). *Time series analysis*. Princeton University Press.
23. Harvey, A. C. (1989). *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge: Cambridge University Press.
24. Kaiser, H. F. (1958). *The varimax criterion for analytic rotation in factor analysis*. *Psychometrika* 23(3), pp. 187-200.

25. Kalman, R. E. (1960). *A New Approach to Linear Filtering and Prediction Problems*. Journal of Basic Engineering, 82(1), pp. 35-45.
26. Klein, L.R. and Sojo, E. (1989). *Combinations of High and Low Frequency Data in Macroeconometric Models*. [In:] *Economics in Theory and Practice: An Eclectic Approach* (pp. 3–16), edited by L.R. Klein and J. Marquez. Norwell, MA: Kluwer Academic Publishers.
27. Liu, P., Matheson, T., and Romeu, R. (2012). *Real-time forecasts of economic activity for Latin American economies*. *Economic Modelling*, 29(4), pp. 1090-1098.
28. Maddala, G. S. and Kim, I-M., (1998). *Unit Roots, Cointegration, and Structural Change*. Cambridge University Press, Cambridge.
29. Rünstler, G. and Sédillot, F. (2003). *Short-Term Estimates of Euro Area Real GDG by Means of Monthly Data*. Working Paper Series 276, European Central Bank.
30. Rünstler, Barhoumi, Benk, Cristadoro, Den Reijer, Jakaitiene, Jelonk, Rua, Ruth, and van Nieuwenhuyze, (2009). *Short-term forecasting of GDP using large datasets: a real-time forecast evaluation exercise*. *Journal of Forecasting*, 28, pp. 595–611.
31. Sánchez, I. and Peña, D. (2001). *Properties of Predictors in Overdifferenced Nearly Nonstationary Autoregression*. *Journal of Time Series Analysis*, 22(1), pp. 45–66.
32. Stock, J. H., and Watson, M. W. (1988). *A probability model of the coincident economic indicators*. NBER Working Paper No. 2772.
33. _____. (1989). *New indexes of coincident and leading economic indicators*. [In:] *NBER Macroeconomics Annual 1989*, ed. O. J. Blanchard and S. Fischer, vol. 4, pp. 351-394. Cambridge, MA: MIT Press.
34. _____. (2002a). *Macroeconomic forecasting using diffusion indices*. *Journal of Business and Economics Statistics*, 20(2), pp. 147–162.
35. _____. (2002b). *Forecasting Using Principal Components from a Large Number of Predictors*. *Journal of the American Statistical Association*, 97(460), pp. 1167-1179.
36. Yiu, M. S., and Chow, K. K. (2011). *Nowcasting Chinese GDP: information content of economic and financial data*. *China Economic Journal*, 3(3), pp. 223-240.

Anexo 1. Bases de Datos

Variables de los conjuntos de información

Tabla A.1. Variables de los Conjuntos de Información

Nombre del Indicador	Fuente	Coefficiente de correlación con el PIB (1993-I a 2016-I)	CI-1	CI-2	CI-3
IGAE	INEGI	0.958	✓	✓	✓
Consumo Privado	INEGI	0.850	✓		✓
Actividad Industrial	INEGI	0.849	✓	✓	✓
Industria manufacturera	INEGI	0.811	✓		
Importaciones Mexicanas	Banco de México	0.802	✓		✓
Producción Industrial en EUA	Federal Reserve System	0.746		✓	
Construcción	INEGI	0.699	✓		
Ventas de la ANTAD	ANTAD	0.626	✓	✓	✓
Exportaciones no petroleras manufactureras	Banco de México	0.617	✓	✓	
Indicador adelantado	INEGI	0.559	✓		
Bolsa Mexicana de Valores	INEGI	0.533	✓		
Producción de cemento	Banco de México	0.478	✓	✓	✓
Producción de vehículos de AMIA	AMIA	0.470	✓	✓	
Agregado monetario M4	Banco de México	0.443	✓		✓
Ventas al por mayor (EMEC)*	INEGI	0.439		✓	✓
Refacciones para automóviles	Banco de México	0.387	✓		
Producción de aluminio	Banco de México	0.373	✓		
Exportaciones Mexicanas	Banco de México	0.348	✓		✓
Cuartos ocupados (Hoteles)	SECTUR	0.348	✓		
Ventas de electricidad	CFE	0.322	✓		✓
Gases industriales	Banco de México	0.319	✓		
Transporte en ferrocarril	Banco de México	0.288	✓		
Producción de llantas	Banco de México	0.249	✓		
Asistencia a cines	Banco de México	0.181	✓		
Venta de gasolinhas	PEMEX	0.176	✓		✓
THIE	INEGI	-0.341	✓		
Tipo de cambio real	Banco de México	-0.544	✓		

Nota: Las correlaciones de los indicadores con (*) se presentan para periodos más cortos porque las series no comienzan en 1993.

*El coeficiente de correlación se obtuvo respecto a las variaciones trimestrales desestacionalizadas del PIB y las del indicador seleccionado.

Variables con diferencias logarítmicas y ajuste estacional

En la Tabla A.2 enlisto todas las variables que forman parte de los tres conjuntos de información.

Asimismo presento los resultados de las pruebas de raíz unitaria. Por último, indico qué variables

presentan ajuste estacional del INEGI (marcadas con ✓). Las variables que no presentan ajuste estacional (marcadas con X) fueron desestacionalizadas con el programa X12 ARIMA.

Realicé un análisis de correlación entre el PIB trimestral y cada una de las variables trimestralizadas en el periodo 1993-2016. Finalmente realicé pruebas de raíz unitaria para todas las variables, de donde concluyo que cuatro de las 27 variables son estacionarias por lo que no las transformé con diferencias logarítmicas.

Es importante mencionar que hice las pruebas de raíz unitaria sobre las series desestacionalizadas, aun sabiendo que estas pruebas podrían estar sesgadas. En efecto, de acuerdo con Maddala y Kim (1998, pp. 364-365), en muestras finitas, los estadísticos de las pruebas de raíz unitaria ADF y Phillips-Perron podrían estar sesgados a no rechazar la hipótesis nula cuando los datos están desestacionalizados. Si este fuera el caso para las pruebas previamente hechas, habría algunas variables sobre-diferenciadas, lo cual no representa un problema de acuerdo a Sánchez y Peña (2001), quienes sostienen que es mejor sobre-diferenciar a sub-diferenciar cuando se usan modelos autorregresivos para generar pronósticos.

Tabla A.2. Pruebas de raíz unitaria

Nombre del Indicador	Ho: La serie tiene una raíz unitaria						Ho: La serie es estacionaria		Diferencia Logarítmica	Ajuste Estacional del INEGI
	Prueba de Dickey-Fuller Aumentada			Prueba de Phillips-Perron			Prueba de Kwiatkowski-Phillips-Schmidt-Shin			
	Ninguno	Intercepto	Intercepto y Tendencia	Ninguno	Intercepto	Intercepto y Tendencia	Intercepto	Intercepto y Tendencia		
Indicador Global de la Actividad Económica	1.000 [0.000]	0.948 [0.000]	0.395 [0.000]	1.000 [0.000]	0.935 [0.000]	0.159 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	✓
Consumo Privado	1.000 [0.000]	0.965 [0.000]	0.107 [0.000]	1.000 [0.000]	0.955 [0.000]	0.213 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	✓
Actividad Industrial	0.995 [0.000]	0.664 [0.000]	0.620 [0.000]	0.991 [0.000]	0.659 [0.000]	0.460 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	✓
Industria Manufacturera	0.997 [0.000]	0.773 [0.000]	0.693 [0.000]	0.990 [0.000]	0.742 [0.000]	0.500 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	✓
Importaciones Mexicanas	0.968 [0.000]	0.912 [0.000]	0.021 [0.000]	0.991 [0.000]	0.939 [0.000]	0.124 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	✓
Producción Industrial en EUA	0.664 [0.001]	0.096 [0.010]	0.209 [0.044]	0.759 [0.000]	0.364 [0.000]	0.644 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	✓
Construcción	0.946 [0.000]	0.718 [0.000]	0.497 [0.000]	0.939 [0.000]	0.709 [0.000]	0.332 [0.000]	p<0.01 [p>0.10]	0.05<p<0.10 [p>0.10]	✓	✓
Ventas de la ANTAD	1.000 [0.000]	1.000 [0.000]	0.611 [0.000]	1.000 [0.000]	0.999 [0.000]	0.615 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Exportaciones no petroleras manufactureras	0.990 [0.000]	0.952 [0.000]	0.503 [0.000]	0.985 [0.000]	0.941 [0.000]	0.364 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	✓
Indicador adelantado	0.657 [0.000]	0.000 [0.000]	0.001 [0.000]	0.678 [0.000]	0.012 [0.001]	0.047 [0.003]	p>0.10 [p>0.10]	p>0.10 [p>0.10]	X	X
Bolsa Mexicana de Valores	0.651 [0.000]	0.000 [0.000]	0.000 [0.000]	0.652 [0.000]	0.015 [0.000]	0.066 [0.003]	p>0.10 [p>0.10]	p>0.10 [p>0.10]	X	X
Producción de cemento	0.855 [0.000]	0.747 [0.000]	0.057 [0.000]	0.879 [0.000]	0.421 [0.000]	0.007 [0.000]	p<0.01 [p>0.10]	0.05<p<0.10 [p>0.10]	✓	X
Producción de Vehículos de AMIA	0.944 [0.000]	0.895 [0.000]	0.430 [0.000]	0.918 [0.000]	0.801 [0.000]	0.066 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	X
Agregado monetario M4	1.000 [0.000]	1.000 [0.000]	0.994 [0.000]	1.000 [0.000]	1.000 [0.000]	0.997 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X

Tabla A.2. Pruebas de raíz unitaria (continuación)

Nombre del Indicador	Ho: La serie tiene una raíz unitaria						Ho: La serie es estacionaria		Diferencia Logarítmica	Ajuste Estacional del INEGI
	Prueba de Dickey-Fuller Aumentada			Prueba de Phillips-Perron			Prueba de Kwiatkowski-Phillips-Schmidt-Shin			
	Ninguno	Intercepto	Intercepto y Tendencia	Ninguno	Intercepto	Intercepto y Tendencia	Intercepto	Intercepto y Tendencia		
Ventas al por mayor (EMEC)	0.967 [0.000]	0.239 [0.000]	0.474 [0.000]	0.954 [0.000]	0.252 [0.000]	0.342 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	✓
Refacciones para automóviles	0.943 [0.000]	0.975 [0.000]	0.887 [0.000]	0.658 [0.000]	0.775 [0.000]	0.155 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Producción de aluminio	0.988 [0.000]	0.991 [0.000]	0.338 [0.000]	0.933 [0.000]	0.906 [0.000]	0.001 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Exportaciones Mexicanas	0.964 [0.000]	0.885 [0.000]	0.031 [0.000]	0.991 [0.000]	0.923 [0.000]	0.161 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	✓
Cuartos ocupados (Hoteles)	0.951 [0.000]	0.696 [0.000]	0.004 [0.000]	0.972 [0.000]	0.574 [0.000]	0.008 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Ventas de electricidad	1.000 [0.000]	0.799 [0.000]	0.181 [0.000]	1.000 [0.000]	0.780 [0.000]	0.037 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Gases industriales	0.582 [0.000]	0.001 [0.000]	0.000 [0.000]	0.551 [0.000]	0.004 [0.000]	0.000 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	X
Transporte en ferrocarril	0.958 [0.000]	0.730 [0.000]	0.382 [0.000]	0.957 [0.000]	0.576 [0.000]	0.022 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Producción de llantas	0.353 [0.001]	0.438 [0.010]	0.148 [0.046]	0.080 [0.000]	0.000 [0.000]	0.000 [0.000]	p<0.01 [p>0.10]	0.01<p<0.05 [p>0.10]	✓	X
Asistencia a cines	0.942 [0.000]	0.899 [0.000]	0.297 [0.000]	0.789 [0.000]	0.048 [0.000]	0.000 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Venta de gasolinas	1.000 [0.000]	0.951 [0.000]	0.899 [0.000]	0.999 [0.000]	0.818 [0.000]	0.955 [0.000]	p<0.01 [p>0.10]	p<0.01 [p>0.10]	✓	X
Tasa de interés interbancaria de equilibrio	0.737 [0.000]	0.002 [0.000]	0.012 [0.000]	0.668 [0.000]	0.012 [0.000]	0.053 [0.002]	p>0.10 [p>0.10]	p>0.10 [p>0.10]	X	X
Tipo de cambio real	0.736 [0.000]	0.000 [0.000]	0.001 [0.000]	0.718 [0.000]	0.029 [0.000]	0.118 [0.001]	p>0.10 [p>0.10]	p>0.10 [p>0.10]	X	X

Nota: las pruebas de raíz unitaria se hicieron para el periodo 1993-2013. Se muestran los p-values para rechazar la Ho. En azul se resaltan las pruebas en las que se considera que la serie tiene una raíz unitaria. El p-value entre corchetes se refiere a las pruebas de raíz unitaria con las diferencias de la serie original.

Anexo 2. La Prueba de Diebold-Mariano

Definamos a los errores de pronóstico como:

$$\varepsilon_{it} = \hat{y}_{it} - y_t, \quad i = 1, 2$$

Se asume que la función de pérdida asociada con el pronóstico i es función del error de pronóstico, ε_{it} , y se denota por $g(\varepsilon_{it})$. La función $g(\cdot)$ es una función de pérdida, tal que; toma el valor de cero cuando no se comete error, nunca es negativa y es creciente a medida que los errores se hacen más grandes en magnitud. Típicamente, $g(\varepsilon_{it})$ es el cuadrado (*squared-error loss*) o el valor absoluto (*absolute error loss*) de ε_{it} .

$$g(\varepsilon_{it}) = \varepsilon_{it}^2$$

$$g(\varepsilon_{it}) = |\varepsilon_{it}|$$

Un problema con estas funciones de pérdida es que son simétricas. De hecho, en algunos casos, la simetría entre errores de pronóstico, positivos y negativos, podría ser inapropiada.

Definimos la diferencia de pérdida entre dos pronósticos como:

$$d_t = g(\varepsilon_{1t}) - g(\varepsilon_{2t})$$

Decimos que los dos pronósticos tienen igual precisión si y sólo si la diferencia de pérdida tiene una esperanza de cero para todo t . De tal manera que nos gustaría probar la hipótesis nula,

$$H_0: E(d_t) = 0 \quad \forall t$$

contra la hipótesis alternativa,

$$H_1: E(d_t) \neq 0$$

La hipótesis nula es que los dos pronósticos tienen la misma precisión. La hipótesis alternativa es que los dos pronósticos tienen diferentes niveles de precisión. Considere la cantidad:

$$\sqrt{T}(\bar{d} - \mu)$$

Donde $\bar{d} = \sum_{t=1}^T d_t$ es la media muestral de la diferencia entre funciones de pérdida, $\mu = E(d_t)$ es la media poblacional de la diferencia entre funciones de pérdida $f_d(0) = \frac{1}{2\pi} (\sum_{k=-\infty}^{\infty} \gamma_d(k))$ es la

densidad espectral de la diferencia de pérdida a la frecuencia 0, $\gamma_d(k)$ es la autocovarianza de la diferencia de pérdida al rezago k .

Es posible mostrar que si la serie generada por la diferencia entre funciones de pérdida $\{d_t; t = 1, \dots, T\}$ es covarianza estacionaria y de memoria corta, entonces $\sqrt{T}(\bar{d} - \mu) \rightarrow_d N(0, 2\pi f_d(0))$. En lo sucesivo asumiremos que la serie generada por la diferencia de pérdida es covarianza estacionaria y de memoria corta. Suponga que los pronósticos son $h(> 1)$ -periodos hacia adelante. Para probar la hipótesis nula de que los dos pronósticos tienen la misma precisión, Diebold-Mariano (1995) utilizan el siguiente estadístico

$$DM = \frac{\bar{d}}{\sqrt{\frac{2\pi \hat{f}_d(0)}{T}}}$$

Donde $\hat{f}_d(0)$ es un estimador consistente de $f_d(0)$ definido por

$$\hat{f}_d(0) = \frac{1}{2\pi} \sum_{k=-(T-1)}^{T-1} I\left(\frac{k}{h-1}\right) \hat{\gamma}_d(k)$$

Donde $\hat{\gamma}_d(k) = \frac{1}{T} \sum_{t=|k|+1}^T (d_t - \bar{d})(d_{t-|k|} - \bar{d})$, e $I\left(\frac{k}{h-1}\right) = \begin{cases} 1 & \text{para } \left|\frac{k}{h-1}\right| \leq 1 \\ 0 & \text{de otra forma} \end{cases}$

Anexo 3. Análisis de Robustez, Prueba de DM

Como análisis de robustez realicé la prueba de DM con un criterio de pérdida distinto al del ECM, por lo que utilicé el Error Absoluto Medio (EAM). Para calcular la varianza de largo plazo utilicé un Bartlett Kernel (Tabla A.3). Asimismo, analicé un periodo distinto con el fin de determinar si el promedio de las BE es consistentemente mejor al resto de los modelos (Tabla A.4).

**Tabla A.3. Prueba de Diebold-Mariano (criterio de pérdida EAM)
Pronósticos de 2009-I a 2016-II**

Modelos	AR	PCA1	PCA2	MFD	BE1	BE2	Promedio	Mediana	Prom(BE)
AR	0.550								
PCA1	PCA1	0.546							
PCA2	AR	PCA1	0.555						
MFD	MFD**	MFD*	MFD***	0.243					
BE1	BE1***	BE1***	BE1***	BE1**	0.168				
BE2	BE2**	BE2**	BE2***	BE2**	BE1	0.174			
Promedio (Todos los Modelos)	Promedio***	Promedio*	Promedio***	MFD	BE1*	BE2*	0.248		
Mediana (Todos los Modelos)	Mediana***	Mediana*	Mediana***	Mediana**	Mediana	Mediana	Mediana***	0.165	
Promedio(BE)	Prom(BE)***	Prom(BE)**	Prom(BE)***	Prom(BE)**	Prom(BE)*	Prom(BE)**	Prom(BE)***	Prom(BE)*	0.136

p-value para la significancia de la diferencia del EAM entre los modelos comparados ***p<0.01, **p<0.05, *p<0.1

La muestra incluye los pronósticos de 2009-I a 2016-II. Se emplea el Error Absoluto Medio del Pronóstico (EAM) como criterio de pérdida. Se usa el estimador Bartlett Kernel para calcular la varianza de largo plazo. En la diagonal principal se encuentran los EAM de cada modelo, estimados con base en la variación trimestral desestacionalizada del PIB.

La primera prueba de robustez es consistente con los hallazgos previos, a saber, el MFD es más preciso que el modelo AR, que el PCA1 y que el PCA2, sin embargo no es más preciso que las BE. Por otro lado, concluyo que en todos los casos, el promedio de las BE provee de pronósticos más precisos respecto al resto de los modelos, en el periodo analizado, con diferencias estadísticamente significativas de al menos el 95% de confianza (Tabla A.3).

Adicionalmente realicé la prueba de DM para un periodo distinto de tiempo. Como la prueba original incluye el periodo de la crisis financiera de 2008-2009, en esta prueba adicional omito dicho periodo, de tal forma que el análisis se realiza del 2011-I al 2016-II. En esta prueba utilicé

el ECM como criterio de pérdida y uso el Kernel de una distribución uniforme para calcular la varianza de largo plazo.

De acuerdo con las pruebas de DM calculadas en el periodo considerado, confirmo que los pronósticos de las BE son más precisos que el resto de los modelos, sin embargo, también destaca el hecho de que el MFD tuvo un buen desempeño, con relación a los modelos de PCA y al AR. En conclusión, los pronósticos del promedio de los dos modelos de BE son más precisos que el resto de los modelos de referencia con al menos un 95% de confianza, aunque la diferencia de los ECM no resultó estadísticamente significativa cuando se compara con el modelo BE1 (Tabla A.4).

**Tabla A.4. Prueba de Diebold-Mariano (criterio de pérdida ECM)
Pronósticos de 2011-I a 2016-II**

Modelos	AR	PCA1	PCA2	MDF	BE1	BE2	Promedio	Mediana	Prom(BE)
AR	0.293								
PCA1	PCA1***	0.234							
PCA2	AR***	PCA1**	0.378						
MDF	MDF**	MDF*	MDF**	0.143					
BE1	BE1***	BE1***	BE1***	BE1**	0.026				
BE2	BE2**	BE2***	BE2***	BE2**	BE1*	0.048			
Promedio (Todos los Modelos)	Promedio***	Promedio***	Promedio***	Promedio	BE1**	BE2**	0.082		
Mediana (Todos los Modelos)	Mediana***	Mediana***	Mediana***	Mediana*	BE1*	BE2	Mediana***	0.059	
Promedio(BE)	Prom(BE)***	Prom(BE)***	Prom(BE)***	Prom(BE)**	Prom(BE)	Prom(BE)**	Prom(BE)***	Prom(BE)**	0.020

p-value para la significancia de la diferencia del ECM entre los modelos comparados ***p<0.01, **p<0.05, *p<0.1

La muestra incluye los pronósticos de 2011-I a 2016-II. Se emplea el Error Cuadrático Medio (ECM) como criterio de pérdida. Se usa el Kernel de una distribución Uniforme para calcular la varianza de largo plazo. En la diagonal principal se encuentran los ECM de cada modelo, estimados con base en la variación trimestral desestacionalizada del PIB.