Banco de México
Documentos de Investigación

Banco de México
Working Papers

N° 2017-17

**¿Son útiles los datos financieros diarios para predecir
el PIB? Evidencia para México**

Luis M. Gomez-Zamudio
Banco Central de Chile

Raul Ibarra
Banco de México

Septiembre 2017

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.

Are daily financial data useful for forecasting GDP? Evidence from Mexico*

Luis M. Gomez-Zamudio[†]
Banco Central de Chile

Raul Ibarra[‡]
Banco de México

Abstract: This article evaluates the use of financial data sampled at high frequencies to improve short-term forecasts of quarterly GDP for Mexico. In particular, the mixed data sampling (MIDAS) regression model is employed to incorporate both quarterly and daily frequencies while remaining parsimonious. To preserve parsimony, factor analysis and forecast combination techniques are used to summarize the information contained in a dataset containing 392 daily financial series. Our findings suggest that the MIDAS model that incorporates daily financial data lead to improvements for quarterly forecasts of GDP growth over traditional models that either rely only on quarterly macroeconomic data or average daily financial data. Furthermore, we explore the ability of the MIDAS model to provide forecast updates for GDP growth (nowcasting).

Keywords: GDP Forecasting, Mixed Frequency Data, Daily Financial Data, Nowcasting.

JEL Classification: C22, C53, E37.

Resumen: Este artículo evalúa el uso de datos financieros muestreados en altas frecuencias para mejorar los pronósticos de corto plazo del PIB trimestral para México. En particular, se emplea un modelo de regresión con muestreo de datos mixto (MIDAS, por sus siglas en inglés) para incorporar frecuencias tanto trimestrales como diarias mientras permanece parsimonioso. Para preservar parsimonia, se utilizan técnicas de análisis de factores y combinaciones de pronósticos para resumir la información contenida en una base de datos que contiene 392 series financieras diarias. Nuestros resultados sugieren que el modelo MIDAS que incorpora información financiera diaria conduce a mejoras en los pronósticos trimestrales del crecimiento del PIB sobre los modelos tradicionales que se basan únicamente en datos trimestrales macroeconómicos o que promedian datos financieros diarios. Además, exploramos la habilidad del modelo MIDAS de proporcionar actualizaciones de los pronósticos de crecimiento del PIB (nowcasting).

Palabras Clave: Pronósticos del PIB, Datos con Frecuencias Mixtas, Datos Financieros Diarios, Nowcasting.

*We thank Nicolás Amoroso, Santiago Bazdresch, Julio A. Carrillo, Yoosoon Chang, Bernardo Guimaraes, Juan R. Hernandez, Jorge Herrera, José Gonzalo Rangel, Abel Rodríguez, five anonymous referees and seminar participants at Banco de México, El Colegio de México and the 2016 Asian Meeting of the Econometric Society for valuable comments. Jose A. Jurado and Andrea Miranda provided excellent research assistance. Support provided by CONACYT is gratefully acknowledged. Luis M. Gómez-Zamudio contributed to this paper when he was working at Banco de México. The views on this paper correspond to the authors and do not necessarily reflect those of Banco de México.

[†] Banco Central de Chile. Email: lgomezz@bcentral.cl.

[‡] Dirección General de Investigación Económica. Email: ribarra@banxico.org.mx.

1. Introducción

Predecir el crecimiento del PIB es importante para los hacedores de política, empresas e inversionistas en su proceso de toma de decisiones. La crisis financiera global de 2008-2009, junto con el acontecimiento de la Gran Recesión han contribuido a la necesidad de reevaluar la importancia de los mercados financieros para anticipar ciclos económicos (Espinoza et al., 2012). Las variables financieras están frecuentemente asociadas con expectativas de futuros eventos económicos. Por ejemplo, los precios de las acciones pueden ser interpretados como valores esperados descontados de pagos de dividendos futuros, capturando así la rentabilidad futura de las empresas y las tasas de descuento a futuro, que a su vez están vinculadas a las tasas de crecimiento futuras de la economía. Similarmente, las tasas de interés se pueden interpretar como indicadores de la postura de la política monetaria, la cual puede tener efectos sobre la economía real en el corto plazo (Friedman y Schwartz, 2008). De la misma manera, los precios de las materias primas están asociados con los costos de producción y afectan el crecimiento futuro, y las depreciaciones del tipo de cambio tienden a fomentar las exportaciones y por lo tanto el crecimiento del producto. No obstante, la evidencia empírica acerca del papel de las variables financieras mensuales o trimestrales para pronosticar el crecimiento del PIB no es concluyente (Stock y Watson, 2003; Forni et al., 2003).

Los datos financieros son potencialmente útiles para hacer predicciones, no solo por su naturaleza como indicadores adelantados, sino también porque hay una gran cantidad de series que están disponibles de forma continua sin rezago informativo, en comparación a los datos de la actividad real que se publican con un retraso significativo. No obstante, existen dos principales retos que deben abordarse para aprovechar este tipo de datos. El primero es el hecho de que la información financiera se muestrea con una mayor frecuencia que las variables macroeconómicas (por ejemplo, el PIB). Estas variables macro generalmente están disponibles trimestralmente, mientras que muchas variables financieras se muestrean diariamente. La estrategia estándar para usar esta información para hacer pronósticos es promediar los datos financieros de periodicidad alta de forma trimestral, es decir, un esquema de ponderación simple, para poder estimar una regresión con datos

trimestrales. Este método, sin embargo, podría no ser óptimo, por ejemplo, si los datos más recientes son más informativos. En este caso, los datos recientes deberían recibir un mayor peso que los datos previos. Una regresión lineal simple usando cada valor diario de la variable predictora como un regresor individual requeriría estimar una gran cantidad de parámetros, conduciendo así a una alta incertidumbre de la estimación. Una posible forma de superar esta dificultad es utilizar el modelo de regresión con frecuencias mixtas (MIDAS, acrónimo en inglés de *mixed data sampling*) propuesto por Ghysels et al. (2007). El enfoque MIDAS consiste en regresiones que permiten que las variables a pronosticar y los regresores tengan una diferente periodicidad, utilizando polinomios de rezagos distribuidos para lograr parsimonia. Este tipo de modelos se ha utilizado en la literatura reciente, como en Clements y Galvão (2008) y Marcellino y Schumacher (2010), para mejorar la precisión de las predicciones del PIB trimestral con indicadores mensuales para los Estados Unidos y Alemania, respectivamente. Más recientemente, el uso específico de los datos financieros junto con el modelo MIDAS para predecir el crecimiento del PIB de EE.UU. ha sido explorado en Andreou et al. (2013). En resumen, estos artículos han llegado a la conclusión de que el uso de datos de frecuencia mixta mejora la precisión del pronóstico.

Un segundo desafío es cómo incorporar toda la información disponible de tal manera que el modelo se mantenga parsimonioso. En este sentido, algunos métodos son potencialmente útiles para tratar con grandes conjuntos de datos de variables financieras, tal como los modelos de factores y las combinaciones de pronósticos, así como una amplia variedad de opciones de parametrización de modelos que reducen considerablemente el número de coeficientes estimados. Los modelos de factores son útiles para resumir el contenido informativo de bases de datos amplias con pocos factores comunes (Stock y Watson, 2002a). La idea detrás de esta estrategia es extraer el componente común de un conjunto de variables, filtrando las variaciones idiosincrásicas que no están correlacionadas. Por ejemplo, Stock y Watson (2002b) utilizan una base de datos que contiene 215 series económicas tales como actividad real, precios y variables financieras para extraer un pequeño conjunto de factores. Estos factores a su vez se utilizan para construir pronósticos

para variables macroeconómicas, como el producto y la inflación, los cuales superan a los modelos alternativos univariados y multivariados. En estudios empíricos se ha encontrado que las combinaciones de pronósticos mejoran la precisión sobre pronósticos individuales al aprovechar la información de un conjunto de modelos en lugar de depender de un solo modelo (Timmermann, 2006). Stock y Watson (2003) han sugerido que, al combinar pronósticos de modelos de bajo desempeño basados en variables financieras individuales, se rescata el papel predictivo de la información financiera. En este trabajo, se emplean modelos de factores y combinaciones de pronósticos como enfoques complementarios. Es decir, se usan combinaciones de pronósticos de modelos MIDAS estimados con un solo factor financiero diario en el espíritu del trabajo de Andreou et al. (2013).

En este documento se sigue el enfoque de pronóstico propuesto por Andreou et al. (2013) para investigar si el uso de las variables financieras y un modelo de regresión MIDAS conducen a mejoras en el pronóstico de corto plazo de la tasa de crecimiento del PIB mexicano. Para este propósito, un conjunto amplio de 392 variables financieras fue obtenido de Bloomberg. Estas variables se pueden agrupar en las siguientes categorías: materias primas, acciones, riesgo corporativo, tipo de cambio y renta fija. El período de estudio es 1999 a 2013. Esta base de datos será usada como la principal fuente de información. Las variables financieras que se seleccionan son monitoreadas frecuentemente por los hacedores de políticas y pronosticadores profesionales y han sido propuestas en la literatura como buenos predictores de la actividad económica. Debido a la gran cantidad de variables, el análisis de factores se utiliza para resumir toda la información. El modelo MIDAS se estima haciendo uso de estos factores y se obtienen pronósticos de diferentes especificaciones en horizontes de uno y cuatro trimestres adelante. El desempeño de los modelos MIDAS con variables financieras se compara posteriormente con el de los modelos de factores tradicionales que solo utilizan datos macroeconómicos trimestrales, los cuales a su vez han tenido éxito en la literatura para predecir el crecimiento del PIB (Stock y Watson, 2002b). Para fines de comparación, también se proporcionan modelos de referencia que incluyen modelos de caminata aleatoria, autorregresivos, de vectores autorregresivos y bayesianos de vectores autorregresivos, así como pronósticos de la

encuesta a pronosticadores profesionales.¹ Adicionalmente, se realizan combinaciones de pronósticos para mejorar aún más la precisión. También se presentan los pronósticos del PIB a partir de un modelo de regresión MIDAS utilizando una base de datos mensuales de variables macroeconómicas, como en Marcellino y Schumacher (2010). Por lo tanto, se puede evaluar el papel de las variables financieras diarias en comparación con el enfoque de usar solo variables mensuales.

Este artículo contribuye a la literatura en por lo menos dos importantes maneras. Primero, según nuestro conocimiento, este es el primer documento que aplica el enfoque MIDAS para pronosticar el PIB en una economía en desarrollo. De esta manera, se proporciona evidencia adicional sobre los potenciales beneficios de esta reciente metodología. Este ejercicio de predicción es relevante porque la volatilidad de las variables económicas y financieras en estos países tiende a ser mayor, lo cual afecta la precisión del pronóstico. Aunque esto podría implicar mayor ruido, también podría tener contenido predictivo relevante. Además, ya que las economías en desarrollo presentan niveles más bajos de desarrollo en los mercados financieros, las variables financieras no necesariamente tendrán el mismo papel predictivo que en las economías avanzadas. Segundo, este es el primer artículo que investiga si las variables financieras tienen un papel importante en la predicción del crecimiento del PIB en México.

Nuestro artículo examina tres principales preguntas acerca del desempeño predictivo del modelo MIDAS. Primero, se investiga si el modelo MIDAS que incorpora datos financieros diarios conduce a mejoras en los pronósticos trimestrales de crecimiento del PIB sobre los modelos alternativos que se basan solo en datos macroeconómicos trimestrales. Segundo, nos gustaría descubrir cómo se compara el modelo MIDAS con un

¹ Existen métodos alternativos para usar datos de alta frecuencia para predecir el crecimiento trimestral de GPD, tales como modelos de puente (Baffigi et al. 2004), modelos de espacio de estado (Mariano y Murasawa, 2003) y modelos factoriales (Giannone et al., 2008). Mientras que los modelos de puente y los modelos de espacio de estado se basan en pequeños conjuntos de variables, los modelos de factores permiten aprovechar grandes conjuntos de datos al resumir la información en algunos factores comunes. Nuestro trabajo se centra exclusivamente en los modelos MIDAS, aunque las comparaciones de pronósticos de los modelos MIDAS con algunos de estos métodos serían claramente de interés para futuras investigaciones.

esquema de ponderación simple. Tercero, se explora la capacidad del modelo MIDAS para proporcionar actualizaciones de pronósticos del crecimiento del PIB utilizando información reciente (nowcasting).²

El resultado más importante es que la inclusión de datos financieros diarios y el uso del modelo de regresión MIDAS contribuyen a mejorar el pronóstico del PIB en México. En particular, se encuentra que el modelo con datos financieros y datos macroeconómicos trimestrales supera a un modelo que solo emplea variables macroeconómicas trimestrales. Además, se muestra que el modelo MIDAS supera el esquema de ponderación simple en términos de precisión. El modelo MIDAS es útil para proporcionar actualizaciones del crecimiento del PIB, aunque los pronósticos con adelantos parecen tener una precisión predictiva similar en comparación con los pronósticos a corto plazo sin adelantos. Además, en línea con la literatura existente, se encuentra que las combinaciones de pronósticos son efectivas para mejorar la capacidad predictiva de un conjunto de modelos. Se concluye que las metodologías descritas en este documento tienen éxito al incorporar información adicional mientras se preserva la parsimonia.

El resto del artículo está organizado de la siguiente manera. La sección 2 presenta el modelo de regresión MIDAS, el análisis de factores y la combinación de pronósticos. Una descripción general de la base de datos se muestra en la Sección 3. La sección 4 presenta los resultados. La sección 5 concluye el artículo. Por último, el Apéndice proporciona una descripción detallada de la base de datos y resultados complementarios.

2. Metodología

2.1. El Modelo MIDAS

Nuestra metodología se basa en el modelo MIDAS y sigue de cerca el enfoque de pronóstico de Andreou et al. (2013). Para ilustrar el modelo MIDAS, considere dos de las

² Nowcasting se refiere al proceso de actualización de los pronósticos del crecimiento del PIB del trimestre actual a medida que se dispone de nueva información. Por ejemplo, si estamos a un mes del trimestre actual, es decir, a fines de enero, abril, julio u octubre, tendremos un mes de datos diarios para pronosticar el crecimiento económico trimestral.

variables utilizadas en este artículo, el crecimiento trimestral del PIB mexicano como la variable dependiente y el rendimiento diario del índice de precios de las acciones mexicanas como la variable independiente. El crecimiento del PIB se muestrea trimestralmente, mientras que el índice GSCI se muestrea diariamente.

Defina ahora Y_t^Q como el crecimiento trimestral del PIB, y $X_{m,t}^D$ como el rendimiento diario del índice de precios de las acciones mexicanas, donde Q significa frecuencia trimestral, D diaria y m es el número de días hábiles bursátiles en un trimestre. Usando esta notación, una predicción del crecimiento del PIB h períodos en el futuro con el modelo propuesto por Ghysels et al. (2007) tiene la siguiente forma:

$$Y_{t+h}^{Q,h} = \mu^h + \sum_{j=0}^{p_Y^Q-1} \rho_{j+1}^h Y_{t-j}^Q + \beta^h \sum_{j=0}^{q_X^D-1} \sum_{i=0}^{m-1} w_{i+j*m}^{\theta^h} X_{m-i,t-j}^D + u_{t+h}^h.$$

Este modelo tiene una constante, los términos AR tradicionales con p_Y^Q rezagos trimestrales de la variable dependiente Y_t^Q , y un término que incorpora q_X^D veces m rezagos diarios para la variable independiente. El término que multiplica la variable diaria $w_{i+j*m}^{\theta^h}$ merece especial atención. Este término es el esquema de ponderación que reducirá el número de parámetros a estimar y conducirá a un modelo más parsimonioso en lugar de tener que estimar un coeficiente para cada rezago de alta frecuencia. Los pesos se normalizan para que sumen la unidad con la finalidad de permitir la identificación de β^h . Note que este modelo se puede utilizar para generar pronósticos directos (en lugar de iterados) de múltiples períodos adelante.

Como se explica en Ghysels et al. (2007), existen varios esquemas de ponderación que son útiles para reducir el número de parámetros a estimar. Estos incluyen el MIDAS no restringido, la función de probabilidad Beta normalizada, el polinomio exponencial “Almon lag” normalizado, el polinomio “Almon lag” y las funciones escalonadas. Excluyendo el MIDAS no restringido, U-MIDAS, y el polinomio “Almon lag”, esos métodos se estiman por mínimos cuadrados no lineales.

La función de densidad de probabilidad Beta y el polinomio exponencial “Almon lag” normalizado se describen a continuación debido a la importancia que han tenido en la literatura para propósitos de pronóstico debido a su representación parsimoniosa y formas flexibles (Andreou et al., 2013). La función de probabilidad Beta normalizada tiene la siguiente forma que consta de tres parámetros,

$$w_i(\theta_1, \theta_2, \theta_3) = \frac{a_i^{\theta_1-1}(1-a_i)^{\theta_2-1}}{\sum_{i=1}^N a_i^{\theta_1-1}(1-a_i)^{\theta_2-1}} + \theta_3,$$

donde $a_i = \frac{(i-1)}{(N-1)}$, con $i = 1, 2, \dots, N$. Este método puede hacerse más parsimonioso restringiendo el primer parámetro para que sea uno y/o el tercer parámetro para que sea cero.³ Si todos estos parámetros no están restringidos, este esquema de ponderación se llama Beta distinto de Zero. N denota el número total de rezagos de alta frecuencia utilizados en la regresión. Para $\theta_1=\theta_2=1$, $\theta_3=0$, tenemos pesos iguales.

El polinomio exponencial “Almon lag” normalizado consta de dos parámetros representados como,

$$w_i(\theta_1, \theta_2) = \frac{\exp(\theta_1 i + \theta_2 i^2)}{\sum_{i=1}^m \exp(\theta_1 i + \theta_2 i^2)},$$

donde $i = 1, 2, \dots, N$. Como con el esquema de ponderación anterior, el segundo parámetro puede restringirse para ser cero.

Como se describe en Ghysels et al. (2007), el polinomio exponencial “Almon lag” y la función de probabilidad Beta son lo suficientemente flexibles como para adaptarse a varias formas, como los patrones de decrecimiento lento, decrecimiento rápido o forma de joroba. Una forma decreciente implica que la información reciente recibe mayor peso que la información precedente. En contraste, el MIDAS sin restricciones y los esquemas de función escalonada imponen menos estructura a la función. Estos esquemas pueden ser

³ La función beta descrita anteriormente se deriva de Ghysels (2015) y se aproxima a la función beta descrita en Galvão (2013) como $\text{Beta}(\theta_1, \theta_2) = \frac{a_i^{\theta_1-1}(1-a_i)^{\theta_2-1}\Gamma(\theta_1+\theta_2)}{\Gamma(\theta_1)\Gamma(\theta_2)}$, donde Γ es la función gamma.

Figura 1: Función de parametrización Beta

Nota: La figura muestra los pesos para los primeros 63 rezagos de la función de probabilidad Beta para diferentes valores de los parámetros.

estimados convenientemente a través de OLS, pero requieren una mayor cantidad de parámetros a ser estimados. En la mayoría de los casos se encuentra que la función beta se desempeña mejor en términos de precisión de pronóstico. La Figura 1 muestra varias formas de la función Beta para diferentes valores de los parámetros, donde el tercer parámetro es restringido a 0. Como puede observarse, la tasa de decaimiento depende de los valores de los parámetros. Como comparación, la forma más tradicional de usar datos de alta frecuencia es hacer un promedio, lo cual se llama un esquema de ponderación simple. En nuestro caso, eso significaría promediar el índice diario GSCI para cada trimestre, es decir, asignar el mismo peso a todos los rezagos en un trimestre. Aunque este esquema ha sido ampliamente utilizado en la literatura, puede no ser óptimo para series de tiempo que presentan deterioro de memoria. Por lo tanto, la regresión MIDAS nos permite elegir la forma óptima de los pesos.

2.2. Modelos de Factores

Siguiendo a Stock y Watson (2002a), se usa el modelo de factores para condensar la información de una gran cantidad de variables en unos pocos factores. Stock y Watson

(2002b) han encontrado que los modelos de factores son útiles para mejorar los pronósticos de importantes variables macroeconómicas, como el producto y la inflación. El objetivo es obtener un pequeño conjunto de factores que explique una parte importante de la variación en el conjunto entero de variables. Formalmente, suponga que existe un amplio conjunto de variables X que será utilizado para pronosticar. Este conjunto contiene N variables con T observaciones cada una. Es posible que $N > T$. El objetivo es encontrar un conjunto de factores F y un conjunto de parámetros Λ que mejor expliquen X .

El modelo de factores puede ser escrito como:

$$X_t = \Lambda F_t + e_t,$$

donde e_t son perturbaciones idiosincráticas con dependencia transversal y temporal limitada. Otra forma de analizar un factor es considerarlo como una variable no observable que explica una parte importante de la variación de las variables observadas.

Para estimar los factores, Stock y Watson (2002a) proponen el uso del método de componentes principales, el cual consiste en minimizar la siguiente expresión:

$$V(\tilde{F}, \tilde{\Lambda}) = (NT)^{-1} \sum_i \sum_t (X_{it} - \tilde{\lambda}_i \tilde{F}_t)^2,$$

sujeto a la normalización que $\frac{\tilde{F}' \tilde{F}}{T} = I_T$, donde $\tilde{F} = (\tilde{F}_1 \tilde{F}_2 \cdots \tilde{F}_T)'$, $\tilde{\lambda}_i$ es la i -ésima fila de $\tilde{\Lambda}$ e I_T es la matriz identidad. La matriz de factores estimada es $\sqrt{T}$ multiplicada por los eigenvectores correspondientes a los r eigenvalores más grandes de la matriz XX' de dimensión $T \times T$. Este método produce un conjunto de factores ortogonales que pueden ser ordenados de acuerdo con su contribución a la varianza general de todo el conjunto de variables.

La mayor parte de la literatura se ha centrado en extraer factores a bajas frecuencias, como datos trimestrales o mensuales. Siguiendo este enfoque, se extraerán factores de un gran conjunto de variables financieras diarias. Una vez que los factores son estimados, estos son incorporados en la regresión MIDAS como una variable de alta frecuencia. Por ejemplo, si se usa el factor que explica la mayor variación de todo el conjunto de variables financieras,

denotado como F^1 , como el regresor de alta frecuencia, nuestro modelo de regresión MIDAS puede ser escrito como:

$$Y_{t+h}^{Q,h} = \mu^h + \sum_{j=0}^{p_Y^Q-1} \rho_{j+1}^h Y_{t-j}^Q + \beta^h \sum_{j=0}^{q_X^D-1} \sum_{i=0}^{m-1} w_{i+j*m}^{\theta^h} F_{m-i,t-j}^1 + u_{t+h}^h.$$

En nuestro caso, el primer factor representa el 23% de la variabilidad de las 392 series de tiempo diarias utilizadas. Los primeros 5 factores explican el 42.7% de la variación subyacente. La Sección 4 presenta más detalles sobre el conjunto de datos. Para preservar la parsimonia, se consideran modelos de pronóstico que incluyen los factores financieros diarios uno a la vez, y se sigue el método de Andreou et al. (2013) mediante el uso de combinaciones de pronósticos de estos modelos que incluyen un solo factor.

Siguiendo a Marcellino et al. (2003), las series son estandarizadas antes de que los factores sean obtenidos, restando sus medias y dividiendo por sus desviaciones estándar. Esto es necesario ya que se emplea una amplia variedad de series y estas difieren en sus unidades de medida. Adicionalmente, de ser necesario, las series se transforman para lograr estacionariedad. Siguiendo a Stock y Watson (2002a, 2008), el método de componentes principales que se usa para estimar los factores es al mismo tiempo parsimonioso y robusto a tener inestabilidad temporal en el modelo, siempre que la inestabilidad sea relativamente pequeña e idiosincrásica. Es decir, los factores y pronósticos estimados son consistentes incluso en presencia de variación temporal en el modelo (Stock y Watson, 2002a). Un método alternativo propuesto por Forni et al. (2000) consiste en extraer los componentes principales del dominio de frecuencia utilizando métodos espectrales. Sin embargo, Boivin y Ng (2005) encuentran que el método de Stock y Watson tiene errores de pronóstico más pequeños en las simulaciones, así como en aplicaciones empíricas. Al imponer menos restricciones y tener que estimar un número menor de parámetros auxiliares, este enfoque parece ser menos vulnerable a la identificación errónea y produce mejores pronósticos que el método de Forni et al. (2000).

Una cuestión importante es la determinación del número de factores a incluir en el modelo. Para este propósito, se evalúa la contribución marginal de cada componente principal para

explicar la variación total de las series. Como resultado, se utilizan 3 factores macro trimestrales, que explican casi el 76% de la variación total de las 20 series macroeconómicas.⁴ Del mismo modo, se usan 5 factores financieros diarios, los cuales explican un porcentaje lo suficientemente grande de la variación total de las 392 series financieras (43%).

2.3. Combinaciones de Pronósticos

Para emplear la información contenida en varios de los factores estimados, sin aumentar el número de parámetros en el modelo, se utilizan métodos de combinación de pronósticos. Al preservar la parsimonia se logra una menor incertidumbre en los parámetros, mejorando así la precisión del pronóstico. Por lo tanto, las combinaciones de pronóstico abordan el problema de la incertidumbre del modelo mediante el uso de información de modelos alternativos en lugar de centrarse en un solo modelo. Un estudio sobre los métodos de combinación de pronósticos puede encontrarse en Timmermann (2006).

Como resultado general en la literatura, las combinaciones de pronósticos mejoran la precisión del pronóstico (Timmermann, 2006). Siguiendo a Andreou et al. (2013), se presentan algunas combinaciones que mejoran la precisión del pronóstico de las predicciones individuales. Formalmente,

$$\hat{Y}_{C_M,t+h}^{Q,h} = \sum_{i=1}^M w_{i,t}^h \hat{Y}_{i,t+h}^{Q,h}.$$

Por lo tanto, una combinación de pronóstico $\hat{Y}_{C_M,t+h}$ se puede interpretar como un promedio ponderado de los M pronósticos $\hat{Y}_{i,t+h}$ para el horizonte h de M modelos. Una vez más, una decisión importante es seleccionar el esquema de ponderación. Para este

⁴ Se encuentra que los factores estimados de nuestro conjunto de variables macroeconómicas están altamente relacionados con subconjuntos relevantes de importantes variables macroeconómicas como el producto y la inflación. En particular, el primer factor se encuentra altamente correlacionado con la inflación, mientras que el segundo factor está altamente correlacionado con el crecimiento del producto. Es decir, los factores estimados parecen ser informativos e interpretables desde un punto de vista económico. Con respecto a los factores financieros, el primer factor está altamente correlacionado con las acciones, y el segundo factor está correlacionado con la renta fija y las materias primas.

propósito, se necesita pensar en términos de una función de pérdida. Formalmente, se prefiere una combinación de n pronósticos a un solo pronóstico si,

$$E[\mathcal{L}(\hat{Y}_{i,t+h}^{Q,h}, Y_{t+h})] > \min_{C(\cdot)} E[\mathcal{L}(C(\hat{Y}_{1,t+h}^{Q,h}, \hat{Y}_{2,t+h}^{Q,h}, \dots, \hat{Y}_{M,t+h}^{Q,h}), Y_{t+h})],$$

para $i = \{1, 2, \dots, M\}$.

En la desigualdad anterior: $\mathcal{L}$ es una función de pérdida que relaciona los valores predichos observados. Intuitivamente, se espera que la función de pérdida crezca a medida que el valor predicho se aleja más del valor real. Por otro lado, C es la función de combinación que relaciona los pronósticos individuales. Por lo tanto, se busca seleccionar una función C que minimice la pérdida esperada, y la combinación de pronóstico sería preferible si el valor esperado de la función de pérdida para esa combinación es menor que cada una de las pérdidas esperadas para cada uno de los pronósticos individuales.

Dados los supuestos anteriores, la solución es una combinación lineal de los pronósticos individuales. Para finalizar esta derivación, se denota a $\hat{\mathbf{Y}}_{t+h}^{Q,h}$ como un vector que contiene todos los pronósticos individuales y a $\mathbf{w}_{t+h}^h$ como un vector de parámetros. Por lo tanto, la función de combinación se puede reescribir como $C(\hat{\mathbf{Y}}_{t+h}^{Q,h}; \mathbf{w}_{t+h}^h)$. El último paso requiere definir una función de pérdida. Siguiendo a Andreou et al. (2013), se utiliza el error cuadrático medio de pronóstico (ECMP), ya que se ha encontrado que proporciona una gran mejoría en los pronósticos. Por lo tanto, los pesos del ECMP se seleccionan analizando el desempeño histórico del pronóstico del modelo y asignando a cada uno de ellos un peso inversamente proporcional a su ECMP.

2.4. Predicción con Adelantos (Nowcasting)

Los modelos MIDAS tienen la capacidad de incorporar información reciente para mejorar los pronósticos. Para comprender esto, suponga que el crecimiento trimestral actual del PIB necesita ser pronosticado. Si estamos en el primer mes del trimestre actual, es decir, a fines de enero, abril, julio u octubre, tendremos alrededor de 21 días hábiles bursátiles (1 mes) de datos diarios para predecir el crecimiento económico trimestral. El uso de la información

actualizada para pronosticar el futuro valor de una variable de interés se denomina nowcasting.

Formalmente, el modelo MIDAS se aumenta con adelantos de la siguiente manera:

$$Y_{t+h}^{Q,h} = \mu^h + \sum_{j=0}^{p_Y^Q-1} \rho_{j+1}^h Y_{t-j}^Q + \beta^h \left[\sum_{i=(3-J_X)*\frac{m}{3}}^{m-1} w_{i-m}^{\theta^h} X_{m-i,t+1}^D + \sum_{j=0}^{q_X^D-1} \sum_{i=0}^{m-1} w_{i+j*m}^{\theta^h} X_{m-i,t-j}^D \right] + u_{t+h}^h$$

El nuevo término tiene dos aspectos notables. Primero, el subíndice $t+1$ para la variable financiera X^D implica que la ecuación de pronóstico incluye la información de alta frecuencia generada durante el presente trimestre. Otro aspecto importante a tener en cuenta es el de los valores de i y J_X . Supongamos que $m=63$, eso significa que se cuenta con 63 días hábiles bursátiles en un trimestre. J_X indica el número de meses de información disponible del trimestral actual en una frecuencia diaria. En consecuencia, si el primer mes del trimestre acaba de terminar, se tienen 21 días de datos disponibles, por lo tanto, $J_X=1$ debe seleccionarse para obtener los límites apropiados de la suma.

A diferencia del nowcasting tradicional que involucra modelos de estado-espacio, que potencialmente implican una gran cantidad de parámetros y ecuaciones de medición, el enfoque MIDAS proporciona un marco parsimonioso para lidiar con una gran cantidad de predictores de alta frecuencia. La ventaja de usar datos financieros es que no están sujetos a revisiones como ocurre con muchas variables de la actividad real. Por lo tanto, en nuestro modelo, los datos financieros absorben las noticias en los precios de los activos para proporcionar actualizaciones del pronóstico del crecimiento del PIB.

2.5. Evaluación de Pronósticos

Para comparar la capacidad de pronóstico de modelos alternativos, se utiliza la prueba de Diebold y Mariano (1995). Es decir, se prueba la hipótesis nula de que dos modelos diferentes tienen la misma capacidad de pronóstico. Para ese fin, se define una función de

pérdida de pronóstico cuadrática para el modelo i como $g(u_{i,t}) = u_{i,t}^2$. Bajo la hipótesis nula, ambos modelos tienen la misma capacidad de pronóstico, es decir:

$$H_0: g(u_{1,t}) = g(u_{2,t})$$

Diebold y Mariano (1995) definen primero la diferencia entre las funciones de pérdida para dos modelos alternativos como $d_t = g(u_{1,t}) - g(u_{2,t})$. Por lo tanto, estos autores proponen la siguiente prueba estadística:

$$DM = \frac{\bar{d}}{\sqrt{\text{var}(\bar{d})}},$$

donde $\bar{d}$ es la media muestral de d_t y $\sqrt{\text{var}(\bar{d})}$ se define como $\sqrt{\text{var}(\bar{d})} = \frac{\gamma_0 + 2\gamma_1 + \dots + 2\gamma_q}{H-1}$.

H es el número de períodos por pronosticar y $\gamma_j = \text{cov}(d_t, d_{t-j})$. El estadístico tiene una distribución t-student con $H-1$ grados de libertad. Los valores p que se muestran más adelante en el documento se derivan de una regresión con errores robustos de Huber-White de d_t sobre una constante y probando si la constante es estadísticamente significativa.

2.6. Modelos Alternativos

Para analizar el desempeño relativo del modelo MIDAS, se estiman los siguientes modelos alternativos: un modelo autorregresivo (AR), una caminata aleatoria (RW), un modelo de vectores autorregresivos (VAR) y un modelo bayesiano de vectores autoregresivos (BVAR). También se comparan nuestros resultados con la encuesta a expertos en previsión económica. Los modelos y encuestas antes mencionados han sido ampliamente utilizados tanto por los bancos centrales como por la literatura empírica como puntos de referencia para el pronóstico del PIB (Chauvet y Potter, 2013). El orden del modelo AR se eligió utilizando el Criterio de Información de Akaike (AIC) y el Criterio de Información Bayesiano (BIC), lo que resultó en un rezago autorregresivo. Los modelos AR y RW contienen variables dummy estacionales. Para todos los casos, la variable dependiente es el crecimiento trimestral del PIB.

Los modelos VAR representan una forma sistemática de capturar la dinámica y los comovimientos de un conjunto de series de tiempo sin restringir por una forma funcional específica y han sido particularmente útiles para fines de pronóstico desde el influyente artículo de Sims (1980). El modelo VAR puede ser escrito como:

$$Y_t = A_0 + \sum_{i=1}^p A_i Y_{t-i} + \varepsilon_t,$$

donde Y_t es el vector de variables que se pronostica, A_i son las matrices de coeficientes a estimar y ε_t es un vector de residuales. Las variables incluidas en el modelo VAR son la tasa de crecimiento del PIB, la tasa de inflación trimestral, la tasa de interés y la tasa de crecimiento del PIB estadounidense.⁵ Para determinar el número de rezagos p , se usa el AIC y se establece el número máximo de rezagos a cuatro. El modelo también puede contener variables dummy estacionales que no están incluidas en la ecuación anterior por simplicidad.

Una limitación de los modelos VAR es que a menudo implican estimar una gran cantidad de parámetros, resultando en una pérdida de grados de libertad y conduciendo así a estimaciones ineficientes y un menor desempeño de pronóstico. Para abordar esta limitación, se estima un modelo bayesiano de VAR (BVAR) (Litterman, 1986; Doan et al., 1984). La idea es utilizar información *a priori* para reducir el modelo VAR sin restricciones hacia un punto elemental de referencia parsimonioso, reduciendo así la incertidumbre de los parámetros y mejorando la precisión del pronóstico. Estudios anteriores han encontrado que los modelos BVAR tienen un buen desempeño de pronóstico en comparación con los modelos macroeconómicos convencionales para diferentes países y períodos, incluidos Litterman (1986), McNees (1986), Artis y Zhang (1990), Bańbura et al. (2010), entre otros.

Un modelo BVAR requiere especificar la media y la desviación estándar de la distribución *a priori* de los parámetros. En particular, se sigue el prior de Minnesota, en el que cada variable sigue una caminata aleatoria alrededor de un componente determinístico (Litterman, 1986). Si el modelo se especifica en primeras diferencias, esta especificación

⁵ Herrera-Hernández (2004) y Capistrán y López-Moctezuma (2010) encuentran que el PIB de EE. UU. es útil para mejorar los pronósticos del PIB mexicano en un esquema de VAR.

del prior reduce a cero todos los elementos de A_i del modelo VAR previo. Esto implica que cada variable depende principalmente de su propio primer rezago. Además, el prior de Minnesota incorpora la premisa de que los rezagos más recientes deberían proporcionar información más confiable que los más distantes y que los rezagos propios explican más la variación de una variable dada que los rezagos de otras variables en la ecuación. Las premisas previas se imponen estableciendo los siguientes momentos para la distribución del prior de los parámetros:

$$E[(A_k)_{ij}] = 0, \quad V[(A_k)_{ij}] = \begin{cases} \frac{\lambda^2}{k^{2\tau}}, & j = i \\ \frac{\lambda^2 \gamma^2 \sigma_i^2}{k^{2\tau} \sigma_j^2}, & \text{en otro caso} \end{cases}$$

Por lo tanto, el prior de Minnesota se puede describir mediante tres hiperparámetros, el parámetro de incertidumbre global λ , el parámetro de peso de cada variable en las otras γ y el parámetro de decaimiento τ . Los cambios en estos parámetros implican cambios en la varianza de la distribución del prior. El parámetro de incertidumbre global λ indica la incertidumbre de la restricción de la caminata aleatoria, o el peso relativo de la distribución del prior con respecto a la información contenida en los datos. Para $\lambda = 0$, los datos no afectan las estimaciones. Cuando $\lambda \rightarrow \infty$, las estimaciones posteriores convergen a las estimaciones de OLS. El parámetro $\gamma < 1$ indica el grado en que los rezagos de otras variables son menos informativos que los rezagos propios. El parámetro $\tau \geq 0$ captura el grado en el cual los rezagos más recientes contienen más información que los más distantes. Por lo tanto, el factor $1/k^{2\tau}$ representa la tasa a la cual la varianza del prior disminuye al aumentar la longitud del rezago. σ_i^2/σ_j^2 toma en cuenta la diferente escala y variabilidad de las series. σ_i y σ_j se estiman como los errores estándar de una regresión AR univariada para cada variable. Finalmente, se usa un prior no informativo (difuso) para las variables determinísticas. El modelo BVAR se estima utilizando el método de estimación mixto de Theil (Theil y Goldberger, 1961).

Los hiperparámetros son elegidos en función del desempeño del pronóstico. En particular, se estima el modelo BVAR para las combinaciones que resultan de establecer los siguientes

parámetros: $\lambda = \{0.1, 0.2\}$, $\gamma = \{0.3, 0.5\}$, $\tau=1$, y el número de rezagos $p = \{1, 2, 3, 4\}$.⁶ A partir de estas 16 combinaciones de hiperparámetros, se selecciona la combinación que minimiza la RECMF en un pseudo ejercicio de pronóstico fuera de la muestra.

Para proporcionar evidencia adicional de la precisión predictiva del modelo MIDAS, nuestros pronósticos son también comparados con los de la encuesta a expertos en previsión económica, que es conducida por el Banco de México. Capistrán y Lopez-Moctezuma (2010) encuentran que los pronósticos de esta encuesta superan los pronósticos de los modelos univariados y multivariados tradicionales de series de tiempo. Hay alrededor de 30 participantes en la encuesta, incluidas instituciones financieras, de consultoría y académicas. Capistrán y Lopez-Moctezuma (2010) proporcionan una descripción detallada de esta encuesta. Se usa el pronóstico de consenso para la tasa de crecimiento del PIB, definido como la media entre los pronosticadores. Para el período de pronóstico utilizado en este documento, los datos solo están disponibles para el horizonte de un trimestre por delante.

3. Datos

Tres bases de datos son usadas en nuestro análisis en diferentes frecuencias de muestreo: diaria, mensual y trimestral. La base de datos diarios se divide en 5 diferentes categorías de información financiera: materias primas (166 series), acciones (94 series), tipo de cambio (27 series), riesgo corporativo (53 series) y renta fija (52 series). Como se expuso anteriormente, la variable dependiente es el PIB mexicano. Se ha encontrado en la literatura que estas series financieras diarias son buenos predictores del crecimiento de la producción (Andreou et al., 2013). El período de estudio es de 1999Q1 a 2013Q4. El periodo de estimación inicial es de 1999Q1 a 2009Q4 y el período de pronóstico es de 2009Q4+h a 2013Q4. Aunque la muestra es relativamente pequeña para la estimación de mínimos cuadrados no lineales, Bai et al. (2013) proporcionan evidencia basada en simulaciones de Monte Carlo que muestran que el desempeño de pronóstico de los modelos de regresión MIDAS puede no verse afectado.

⁶ Esos valores para los hiperparámetros se han utilizado previamente en la literatura (por ejemplo, Dua y Ray, 1995; LeSage, 1999; Canova, 2007).

La serie de tiempo del PIB mexicano, aunque no es tan extensa como las de los países desarrollados, está disponible desde 1993. Sin embargo, el período de estimación es efectivamente más corto debido a que un importante número de variables financieras están disponibles desde 1999 en adelante. A pesar de que podría ser un período corto para fines de pronóstico, este permite la inclusión de información diaria relevante. Adicionalmente, se usa un período de muestra durante el cual México ha seguido exclusivamente un régimen cambiario de tipo de cambio flexible y se excluye la crisis económica de 1995 del período de estimación, lo cual podría afectar nuestras estimaciones. La adopción de un tipo de cambio flexible implica una menor volatilidad del producto, ya que la economía se ve menos afectada por choques externos que afectan el crecimiento económico (Levy-Yeyati y Sturzenegger, 2003). Además de la adopción de un tipo de cambio flexible, otras reformas se llevaron a cabo después de la crisis financiera de 1995 que han promovido el desarrollo de los mercados financieros en México, particularmente para mercados de derivados, fondos de pensiones, títulos públicos y el sistema bancario (Sidaoui, 2006). El desarrollo de los mercados financieros está posiblemente asociado con un papel más importante de las variables financieras para predecir el PIB.

La base de datos construida es principalmente un subconjunto de las series de tiempo sugeridas por Andreou et al. (2013), las cuales han mostrado que proporcionan un buen contenido predictivo para el PIB de EE.UU. No obstante, hay algunas observaciones destacadas con respecto a los datos mexicanos. Primero, la tasa diaria de CETES a 28 días es incluida en el grupo de renta fija.⁷ En particular, es importante incluir esta información ya que la tasa de interés es el instrumento de política monetaria en México. A su vez, la tasa diaria de CETES a 28 días simula el comportamiento de la tasa de interés objetivo. En segundo lugar, los tipos de cambio se expresan en términos de pesos mexicanos. Además, por lo que respecta a las acciones, dos índices de la Bolsa Mexicana de Valores son utilizados, IPC e INMEX. Por último, algunas de las variables financieras específicas para México que podrían ser relevantes para el pronóstico del PIB, como bonos corporativos y materias primas, no están disponibles para todo el período de estudio y por lo tanto no

⁷ Los CETES son títulos de la Tesorería de la Federación, es decir, deuda emitida por el gobierno federal a través del Ministerio de Hacienda y el Banco de México (Banco Central de México).

fueron incluidas en nuestro estudio. Para obtener información detallada acerca de las series utilizadas, por favor refiérase al Apéndice. Toda la información financiera fue extraída de Bloomberg.

Siguiendo a Marcellino et al. (2003), algunas de las series empleadas en este estudio fueron transformadas debido a que no eran estacionarias. Para cada variable se prueba la hipótesis de raíz unitaria por medio de una prueba de Dickey Fuller aumentada (ADF) con 12 rezagos. Las series no estacionarias fueron transformadas en primeras diferencias logarítmicas. Posteriormente, para garantizar la estacionariedad, las series transformadas fueron sometidas a pruebas de raíces unitarias utilizando la prueba ADF. En general, los precios de las materias primas, los precios de las acciones y los tipos de cambio son transformados en rendimientos diarios (es decir, en primeras diferencias logarítmicas). Las tasas de interés para los bonos corporativos estadounidenses son transformadas a primeras diferencias. Se encuentra que las tasas de interés internas son estacionarias en niveles. La variable a predecir, es decir, la tasa de crecimiento del PIB, no es ajustada estacionalmente. Por lo tanto, las regresiones son estimadas utilizando variables dummy estacionales. Sin embargo, se encuentra que los resultados son robustos si se utilizan datos ajustados estacionalmente.⁸

Otro conjunto importante de información incluida en nuestras regresiones son los datos macro trimestrales. Este conjunto incluye 20 variables macro cuyo alto poder explicativo y predictivo para el PIB ha sido previamente documentado (Andreou et al., 2013). En particular, este conjunto contiene información como: índices de precios, variables de comercio internacional, tasa de inflación y los índices de actividad económica para México y EE.UU. Parte de este conjunto de variables está disponible mensualmente. Para transformar estas variables en datos trimestrales, los datos mensuales son promediados para cada trimestre. Las variables macroeconómicas también son transformadas si es necesario

⁸ Siguiendo estudios previos sobre pronósticos, incluyendo Stock y Watson (2002) y Marcellino et al. (2003), no se han filtrado las series utilizando el método de Hodrick y Prescott (1997). Como lo muestran Cogley y Nason (1995), cuando el filtro HP se aplica a procesos integrados, este puede generar fluctuaciones en el ciclo económico incluso si no están presentes en las series originales, lo que potencialmente podría inducir al error nuestros pronósticos.

para conseguir estacionariedad, como se indica por una prueba ADF. En general, las variables de la actividad real, los precios y los agregados monetarios se transforman en tasas de crecimiento trimestrales.

Además del conjunto diario de variables financieras y el conjunto trimestral de variables macroeconómicas, se utiliza un conjunto de datos macro mensuales como datos de alta frecuencia para la regresión MIDAS. Este conjunto consta de 18 variables tal como: índices de precios, índices de actividad económica para México y el IPC de EE. UU. Se sigue el mismo procedimiento para preservar la parsimonia, es decir, se estima un conjunto de factores y se combinan diferentes pronósticos usando cada factor para obtener el pronóstico final. Los datos de México se obtienen a partir del Instituto Nacional de Estadística y Geografía (INEGI) y del Banco de México (el banco central de México). Los datos de EE.UU. se obtuvieron de la base de datos del Banco de la Reserva Federal de St. Louis (FRED).

4. Resultados

4.1. Ejercicio de Pronóstico y Selección del Modelo

Antes de presentar los resultados para el ejercicio de pronóstico, algunos puntos que requieren mayor explicación serán discutidos. Primero, se usa una ventana recursiva para todas las especificaciones y horizontes del modelo. Por ejemplo, considere el pronóstico i , con $i = 0, 1, \dots, n - 1$, en donde n es el número de pronósticos un paso adelante. A continuación, la fecha de inicio de la estimación se fija en 1999Q1, mientras que la fecha de finalización cambia con cada valor pronosticado, la cual es 2009Q4+ i . Así, el modelo se estima cada vez que cambia la ventana y los pronósticos se calculan un paso adelante. Esta ventana crece con cada punto pronosticado, ya que incluye el siguiente valor observado. Se espera que la ventana recursiva mejore los pronósticos en comparación con una ventana de estimación fija, ya que cada nueva estimación incluye información más reciente.

El segundo aspecto importante es especificar si el ejercicio es en tiempo real o no. Es decir, ya que el PIB está sujeto a revisiones (así como a otras variables macroeconómicas

utilizadas como regresores), los datos efectivamente disponibles en un trimestre en particular pueden diferir de los valores finales que serán publicados por las oficinas de estadística. Aunque sería interesante realizar un ejercicio de pronóstico en tiempo real empleando los datos que estaban efectivamente disponibles para los pronosticadores, los datos en tiempo real para México no están disponibles. Por lo tanto, se usan datos revisados en nuestras estimaciones. Tenga en cuenta que nuestros modelos siguen siendo comparables en el ejercicio de evaluación de pronósticos, ya que todos utilizan la misma información. Además, esta cuestión es menos relevante en nuestro caso, ya que los datos financieros diarios no están sujetos a revisiones. Por lo tanto, como en Stock y Watson (2003), se sigue la idea de que la mejor manera de evaluar una relación predictiva es usar datos finales en lugar de datos prematuros del PIB.

Como se discutió en la sección introductoria, una interesante función del modelo MIDAS es el nowcasting, la cual permite pronosticar utilizando información reciente. En este trabajo se realiza un ejercicio de pronóstico para el crecimiento del PIB utilizando la información de un mes transcurrido en el trimestre (es decir, 21 días hábiles bursátiles), en horizontes de uno y cuatro trimestres adelante. También se analizan los pronósticos utilizando 2 meses de adelantos de datos financieros. Las conclusiones son similares a las reportadas en este documento.

Dado que hay una amplia variedad de especificaciones disponibles, el AIC y BIC son utilizados para seleccionar el número de rezagos, tanto para los términos autorregresivos como para los términos de alta frecuencia. En nuestro marco de pronóstico preferido se utiliza información de cinco factores. En particular, se sigue un enfoque similar al de Andreou et al. (2013) y se utiliza una combinación de pronósticos de los cinco modelos estimados con cada uno de los cinco factores extraídos del conjunto entero de variables financieras. Es decir, se usan tanto modelos de factores como de combinaciones de pronósticos para tratar con el gran conjunto de datos de variables financieras. Para determinar el número de factores diarios, se considera la contribución marginal de cada factor para explicar la variación total de las series. Se encuentra que cinco factores explican un porcentaje lo suficientemente grande de la variación.

La función beta es usada ya que en la mayoría de los casos presentó la RECMF más baja. Además, la varianza de la RECMF de este esquema de ponderación es menor. Las pruebas para identificar a los mejores modelos se implementan utilizando un máximo de 5 rezagos de la variable dependiente y de 1 a 6 trimestres de la información del factor independiente (q_X^D). Debido a que el número de días de hábiles bursátiles en un trimestre es $m=63$, el número máximo de rezagos diarios es $63 \times 6 = 378$. La selección de los modelos se realizó siguiendo el AIC y el BIC. Como se explicó anteriormente, independientemente de los rezagos de alta frecuencia especificados, el modelo estima solo 2 parámetros para el esquema de ponderación Beta.

4.2. Resultados de Pronóstico para Modelos con Factores Financieros Diarios

La Tabla 1 presenta la RECMF para diferentes especificaciones estimadas para dos horizontes de pronóstico diferentes: 1 trimestre adelante ($h = 1$) y 1 año adelante ($h = 4$). Fuera de los modelos benchmark alternativos, el BVAR y el EEEESP tienen el mejor desempeño de pronóstico. El modelo RW muestra la RECMF más alta. La precisión de pronóstico del modelo BVAR es consistente con estudios previos para diferentes países, incluidos Artis y Zhang (1990) y Bańbura et al. (2010).

La tabla también presenta la RECMF relativa del modelo MIDAS con respecto al modelo AR benchmark. El número óptimo de rezagos según el BIC se muestra entre paréntesis. Como se puede observar, la RECMF del modelo MIDAS que emplea el primer factor es superado por los modelos benchmark. Una posible explicación es que los modelos benchmark contienen variables macroeconómicas que tienen un buen contenido predictivo para pronosticar el PIB, las cuales no están contenidas en el modelo MIDAS. En la última parte de esta subsección será presentado un ejercicio que incorpora variables macroeconómicas en el modelo MIDAS para proporcionar evidencia de la capacidad de pronóstico de esta metodología y el uso de datos de alta frecuencia.

Tabla 1: Comparativo de RECMF para modelos sin adelantos

		h=1	h=4		
	Modelo	RECMF	RECMF	RECMF	RECMF como
			como % del AR		% del AR
Modelos	AR	1.1348	1.0000	1.1136	1.0000
Alternativos	RW	1.2890	1.1359	3.2330	2.9032
	VAR	1.1156	0.9831	1.2112	1.0877
	BVAR	0.9285	0.8182	0.9899	0.8889
	EEEESP	0.9688	0.8537		
Factor 1	Beta (p=2, q=6)	1.6978	1.4961	1.8168	1.6315
Productos primarios F1	Beta (p=1, q=1)	1.5170	1.3368	1.3902	1.2483
Acciones F1	Beta (p=3, q=5)	1.4217	1.2528	1.5319	1.3756
Riesgo Corporativo F1	Beta (p=1, q=2)	1.4375	1.2667	1.5536	1.3951
Tipo de Cambio F1	Beta (p=1, q=1)	1.0367	0.9135	1.0429	0.9365
Renta Fija F1	Beta (p=1, q=5)	1.9653	1.7319	1.9792	1.7773
Combinaciones de Pronósticos					
Factores 1 al 5	Beta AIC/BIC óptimo	1.0453	0.9211	1.1936	1.0718

Nota: Esta tabla muestra la raíz del error cuadrático medio de pronóstico (RECMF) para $h = 1$ y $h = 4$ pasos adelante del PIB para la muestra 1999Q1-2013Q4. El periodo de estudio es 1999Q1 a 2013Q4. El periodo inicial de estimación es 1999Q1 to 2009Q4 y el periodo a pronosticar es 2009Q4+h a 2013Q4. Las RECMF también son presentadas como porcentaje del AR. Primero, los pronósticos son estimados para cada uno de los modelos alternativos descritos en el documento. Segundo, la tabla muestra los resultados para el modelo MIDAS al usar el primer factor diario de las 392 variables financieras mostradas en el apéndice A. Posteriormente, los pronósticos también son estimados usando el primer factor de cada grupo de variables financieras. Finalmente, se presenta una combinación de pronóstico basada en los primeros cinco factores. Se utiliza una ventana recursiva para todas las estimaciones.

La estimación de factores también se aplica a cada grupo de variables financieras. A partir de esta descomposición se extraen 5 factores, uno para cada uno de los 5 grupos de variables financieras. La Tabla 1 muestra los resultados del pronóstico con el primer factor

de cada grupo. El esquema de ponderación Beta es usado y se selecciona el número de rezagos usando los Criterios de Información Bayesiana y de Akaike. Solo se incluye el primer factor en cada regresión, ya que las variables en cada grupo están altamente relacionadas entre ellas. Aunque esta es una especificación de ponderación parsimoniosa, el poder predictivo de todos los grupos de variables, excepto por los tipos de cambio, no parece mejorar con respecto a los modelos benchmark. En otras palabras, la incertidumbre asociada con la estimación de los parámetros para estas especificaciones supera el poder predictivo adicional incorporado a través de los conjuntos individuales de las series financieras. El papel de los tipos de cambio para pronosticar el PIB podría explicarse en parte por el estatus de México como una pequeña economía abierta. Las depreciaciones del tipo de cambio tienden a alentar las exportaciones y, por lo tanto, a aumentar el crecimiento del producto.

Si bien es evidente a partir del conjunto de datos que el riesgo corporativo y la renta fija son dos grupos que se centran principalmente en la economía de EE.UU., y aunque existen algunas variables como las tasas de interés para México, estas por si mismas no parecen proporcionar información suficiente para predecir el crecimiento del PIB mexicano. Las acciones también pueden presentar un problema similar.

La última sección de la tabla presenta una combinación de pronóstico basada en el ECM utilizando cinco especificaciones MIDAS, una para cada uno de los primeros cinco factores. Cada uno de estos modelos es óptimo en el sentido de AIC-BIC, aunque para diferentes factores. Como se esperaba, la combinación produce una RECMF más baja. Esta mejora puede explicarse por el hecho de que dicha combinación considera la información contenida en cada factor. Por lo tanto, aunque la precisión del pronóstico no parece mejorar cuando los grupos individuales de variables financieras se incluyen en el modelo, cuando todas las variables se incluyen de manera conjunta y los factores contienen información mixta, es evidente que tienen éxito en mejorar la precisión del pronóstico del modelo. Estos hallazgos son consistentes con Stock y Watson (2003), quienes han encontrado que el poder predictivo de las variables financieras se rescata combinando pronósticos basados en variables individuales.

4.3. Resultados de Pronóstico para Modelos con Factores Financieros Diarios y Factores Macroeconómicos Trimestrales

El objetivo de la parte final de esta sección es investigar si la introducción de datos financieros diarios dentro de un esquema de regresión MIDAS es útil para pronosticar el PIB, más allá de los datos macroeconómicos. También se compara la precisión del pronóstico del modelo MIDAS con los modelos alternativos que toman un promedio simple de datos financieros diarios, es decir, un esquema de ponderación simple.

La Tabla 2 contiene un resumen de la RECMF para diferentes modelos. El modelo denotado como *FAR* (autoregresivo con factores) bajo datos macro trimestrales incorpora los datos macro trimestrales al modelo AR utilizando un modelo de factores como en Stock y Watson (2002b). En particular, se extraen 3 factores macroeconómicos trimestrales de la base de datos de 20 series macroeconómicas trimestrales descritas en la sección de datos. Como resultado, los primeros 3 factores explican casi el 76% de la variación total de las 20 series macroeconómicas trimestrales.⁹ Estos factores estimados aumentan el modelo AR benchmark para obtener los modelos FAR. Una segunda familia de modelos MIDAS se presenta como *datos macro mensuales + datos macro trimestrales*. Esta familia consta de modelos en los que las variables de alta frecuencia utilizadas para la estimación del modelo son el mismo conjunto de variables macroeconómicas mensuales que se promediaron utilizando un esquema de ponderación simple. *Simple* se usa para denotar la familia de modelos que usan un esquema de ponderación simple para datos de alta frecuencia, así como datos macro trimestrales. En otras palabras, los valores para todos los días hábiles bursátiles de los activos financieros diarios dentro del trimestre se promediaron para obtener un valor único por trimestre.¹⁰ *MIDAS combinado* se utiliza para referirse a una

⁹ Ibarra (2012) encuentra que, para el caso de México, los factores estimados de un amplio conjunto de variables macroeconómicas para el período 1992-2009 están altamente relacionados con subconjuntos relevantes de importantes variables macroeconómicas clave como el producto y la inflación. Es decir, los factores estimados parecen ser informativos e interpretables desde un punto de vista económico. Nuestros resultados son consistentes con esos hallazgos.

¹⁰ Se usan promedios trimestrales en lugar de los datos de fin de trimestre para suavizar las fluctuaciones de corto plazo que podrían potencialmente conducir a errores en nuestros pronósticos de crecimiento del PIB.

Tabla 2: Comparativo de RCMP de modelos alternativos con PIB sin ajuste estacional

Modelo	h=1	h=4		
	RCMP	RCMP como % del AR	RCMP	RCMP como % del AR
Modelos alternativos				
AR	1.1348	1	1.1136	1
RW	1.2899	1.1367	3.2331	2.9033
VAR	1.1156	0.9831	1.2112	1.0877
BVAR	0.9285	0.8182	0.9899	0.8889
EEEESP	0.9687	0.8537		
Datos macro trimestrales				
FAR	0.7407	0.6527	0.7308	0.6563
Datos macro mensuales + datos macro trimestrales				
Beta (p=4, q=3)	0.9671	0.8522	1.1151	1.0014
MIDAS combinado	0.9827	0.8659	1.1415	1.0250
Datos financieros				
Simple	1.8181	1.6021	1.5537	1.3952
Beta (p=2, q=6)	1.6978	1.4961	1.8168	1.6315
MIDAS combinado	1.0453	0.9211	1.1936	1.0718
Datos financieros + datos macro trimestrales				
Simple	0.7159	0.6309	0.6682	0.6000
Beta (p=2, q=1)	0.4709	0.4150	0.5131	0.4608
MIDAS combinado	0.4614	0.4066	0.5003	0.4492

Nota: Esta tabla muestra la raíz del error cuadrático medio de pronóstico (RCMP) para h=1 y h=4 pasos adelante del PIB para la muestra 1999Q1-2013Q4. El periodo de estudio es 1999Q1 a 2013Q4. El periodo inicial de estimación es 1999Q1 to 2009Q4 y el periodo a pronosticar es 2009Q4+h a 2013Q4. Las RCMP también son presentadas como porcentaje del AR. Los cinco pronósticos del MIDAS estimados usando cada uno de los factores diarios se combinan para obtener el pronóstico de MIDAS combinado. Se utiliza una ventana recursiva para todas las estimaciones.

combinación que utiliza el ECM de 5 especificaciones MIDAS: una para cada uno de los primeros 5 factores. Finalmente, los modelos denotados como *datos financieros* incorporan la información contenida en las 392 series financieras diarias.

Como antes, la RECMP para diferentes especificaciones se presenta en la Tabla 2. Los resultados muestran que agregar datos trimestrales al modelo AR mejora la precisión del pronóstico en términos de la RECMP en ambos horizontes. En particular, el modelo de factores que incluye datos macroeconómicos trimestrales supera los pronósticos del AR, VAR, BVAR y EEEESP. Es decir, los datos macroeconómicos trimestrales, tal como el consumo, la inversión, el comercio, la inflación y las variables macroeconómicas extranjeras parecen proporcionar información importante para predecir el PIB futuro. Del mismo modo, los datos macro mensuales mejoran la precisión del pronóstico en relación con el modelo AR en el horizonte de un trimestre adelante. Sin embargo, las ganancias en términos de precisión parecen ser menores en comparación con las obtenidas al agregar datos macroeconómicos trimestrales, posiblemente debido a la incertidumbre de la estimación asociada con un mayor número de parámetros.

Los resultados de agregar datos financieros son de particular interés. Como lo muestra la RECMP para estas especificaciones, incluir estas variables dentro de un modelo MIDAS combinado mejora la precisión del pronóstico. En particular, los resultados también sugieren que las ganancias en términos de la RECMP derivadas de la inclusión de datos financieros son mayores bajo un esquema de regresión MIDAS que bajo un esquema de ponderación simple.

Los resultados más importantes de este documento se muestran en la última parte de la Tabla 2, en la cual se agregan los datos financieros a las especificaciones que incluyen datos macro trimestrales. Los resultados muestran que agregar datos financieros diarios con un esquema de regresión MIDAS mejora la precisión del pronóstico, sobre un modelo tradicional que contiene solo datos macro trimestrales, en ambos horizontes de pronóstico. Es decir, los datos financieros tienen un papel importante para predecir el PIB, posiblemente debido a su naturaleza como indicadores adelantados. Otro resultado importante es que las combinaciones de pronósticos de los modelos de regresión MIDAS basados en diferentes grupos de variables financieras mejoran la precisión del pronóstico. Por lo tanto, las ganancias de pronóstico al agregar datos financieros parecen atribuirse en gran medida al esquema de ponderación flexible en el enfoque de regresión MIDAS.

En resumen, el modelo MIDAS combinado con datos financieros tiene, en general, una RECMR más baja que los modelos benchmark.¹¹ Sin embargo, también es importante notar que los regresores macroeconómicos ayudan a mejorar la precisión del pronóstico en ambos modelos. Esto no es sorprendente ya que están altamente correlacionados con el PIB. Por último, se encuentra que el enfoque de regresión MIDAS que incorpora variables financieras diarias parece superar el esquema de ponderación simple.¹²

Las pruebas de igual capacidad predictiva entre los modelos seleccionados se pueden encontrar en la Tabla 3. En particular, la tabla muestra los valores p obtenidos de una prueba de Diebold-Mariano (1995), como se describió anteriormente.¹³ Los resultados muestran que la hipótesis nula de igual precisión de pronóstico entre el modelo AR benchmark y el modelo AR aumentado con datos financieros no puede ser rechazada. De manera similar, la hipótesis nula de igual precisión de pronóstico entre el modelo MIDAS con datos financieros y el modelo AR con datos trimestrales no puede rechazarse en los niveles de significancia convencionales.

En particular, de acuerdo con la prueba de Diebold y Mariano, el modelo MIDAS con datos financieros y trimestrales supera al modelo con datos macro trimestrales. Es decir, las ganancias de pronóstico, al agregar datos financieros a través de una combinación del modelo de regresión MIDAS, sobre el enfoque alternativo de usar solo datos macroeconómicos, son estadísticamente significativas al 5% en los horizontes de un

¹¹ Aunque los gráficos de los pronósticos versus los valores reales no se presentan en el documento para ahorrar espacio, se encuentra que, en general, los resultados sobre el desempeño del pronóstico del modelo MIDAS son robustos durante todo el período de pronóstico. Los resultados están disponibles de parte de los autores a petición.

¹² También se ha realizado el ejercicio de pronóstico utilizando datos ajustados estacionalmente. Los resultados se presentan en la Tabla B.1 del Apéndice. Las conclusiones son similares a las que utilizan datos no ajustados estacionalmente. En particular, se encuentra que en el horizonte de un trimestre por delante, el uso del enfoque MIDAS y la inclusión de las variables financieras diarias mejoran la precisión del pronóstico sobre los modelos alternativos que usan datos macroeconómicos trimestrales o promedios de datos financieros diarios.

¹³ Note que las comparaciones de pronóstico son no-anidadas porque los modelos potencialmente tienen diferentes estructuras de rezago. Por esta razón se usa la prueba de Diebold y Mariano (1995) en lugar de las pruebas de igual capacidad predictiva diseñadas para modelos anidados.

Tabla 3: Pruebas de misma capacidad predictiva

Modelo	h=1	h=4
	DM	DM
Datos financieros vs AR		
MIDAS combinado	0.2198	0.2000
Datos financieros vs Datos macro trimestrales		
MIDAS combinado	0.1830	0.0920
Datos financieros + macro vs Datos macro trimestrales		
MIDAS combinado	0.0023	0.5010
Datos financieros + macro vs Datos macro mensuales + macro trimestrales		
MIDAS combinado	0.0108	0.0590
MIDAS vs Simple		
Datos financieros	0.1178	0.5560
Datos financieros + macro	0.0000	0.0270

Esta tabla reporta los p-values de la prueba de la hipótesis nula de que los modelos de la izquierda tienen la misma capacidad predictiva. La comparación se basa en la prueba de Diebold-Mariano. El periodo de estudio es 1999Q1 a 2013Q4. El periodo inicial de estimación es 1999Q1 to 2009Q4 y el periodo a pronosticar es 2009Q4+h a 2013Q4. Se utiliza una ventana recursiva para todas las estimaciones.

trimestre adelante. Otro resultado importante es que el modelo MIDAS que incluye variables financieras es superior al modelo MIDAS que incluye variables mensuales. Aunque el modelo MIDAS con datos financieros y el esquema de ponderación simple tienen una capacidad predictiva similar cuando excluyen los datos macroeconómicos, el modelo MIDAS que incluye datos trimestrales supera al esquema de ponderación simple que incluye datos trimestrales. Este resultado sugiere que los factores financieros necesitan ser usados junto con las variables macroeconómicas para extraer todo su potencial de pronóstico.

En resumen, a partir de la información contenida en las tablas 2 y 3 se encuentra que el uso de datos macro trimestrales y datos financieros, a través de un modelo de regresión MIDAS, mejora la capacidad de pronóstico sobre los modelos alternativos que solo

incluyen datos macro. Los resultados sugieren que la inclusión de datos financieros proporciona al modelo información útil para pronosticar el PIB. También es posible observar que las ganancias de pronóstico del modelo MIDAS, sobre el esquema de ponderación simple, son significativas en los niveles convencionales. Se concluye que MIDAS es superior a un esquema de ponderación simple. En general, nuestros resultados sobre el papel de las variables financieras y el modelo de regresión MIDAS para pronosticar el PIB mexicano están en línea con los de Andreou et al. (2013) para los Estados Unidos. Sin embargo, para $h = 4$ Andreou et al. (2013) encuentran diferencias estadísticamente significativas en el poder predictivo que favorecen el modelo MIDAS, mientras que nuestros resultados están más en línea con los de Marcellino y Schumacher (2010) y Arnesto et al. (2010). Estos autores concluyen que las ganancias de pronóstico del enfoque MIDAS, sobre metodologías alternativas que emplean información de alta frecuencia, son menores para horizontes largos.

4.4. Pronósticos MIDAS con Adelantos

La Tabla 4 muestra los resultados de pronóstico para el PIB, en horizontes de uno y cuatro trimestres adelante, utilizando información del primer mes dentro del trimestre. En este ejercicio se investiga si la inclusión de información reciente es útil para mejorar los pronósticos del PIB y si el enfoque MIDAS supera el esquema alternativo de ponderación simple. Como antes, las variables financieras diarias dentro de un enfoque MIDAS conducen a importantes ganancias sobre el modelo benchmark, especialmente cuando también se incluyen datos macroeconómicos trimestrales. Las RECMF del ejercicio de nowcasting son similares para los pronósticos que se muestran en la Tabla 4 para la mayoría de las especificaciones. Este ejercicio destaca el uso del enfoque MIDAS para nowcasting cuando se introduce información trimestral actual para proporcionar actualizaciones del crecimiento trimestral del PIB.

Tabla 4: Comparativo de RCMP de modelos alternativos con PIB sin ajuste estacional

Modelo	h=1	h=4		
	RCMP	RCMP como % del AR	RCMP	RCMP como % del AR
Datos financieros				
Simple	1.3790	1.2150	1.3190	1.1621
MIDAS combinado	0.9370	0.8256	1.0338	0.9109
Datos financieros + datos macro				
Simple	0.6891	0.6072	0.7130	0.6282
MIDAS combinado	0.4886	0.4305	0.5301	0.4670

Nota: Esta tabla muestra la raíz del error cuadrático medio de pronóstico (RCMP) para $h=1$ y $h=4$ pasos adelante del PIB para la muestra 1999Q1-2013Q4. El periodo de estudio es 1999Q1 a 2013Q4. El periodo inicial de estimación es 1999Q1 to 2009Q4 y el periodo a pronosticar es 2009Q4+h a 2013Q4. Las RCMP también son presentadas como porcentaje del AR. Los cinco pronósticos del MIDAS estimados usando cada uno de los factores diarios se combinan para obtener el pronóstico de MIDAS combinado. Se utiliza una ventana recursiva para todas las estimaciones.

Finalmente, la Tabla 5 muestra la prueba de Diebold y Mariano para el ejercicio de nowcasting. Con base en la información contenida es esta tabla, no se puede rechazar la hipótesis nula de que el pronóstico y el nowcasting con MIDAS tienen una capacidad predictiva similar. Es decir, la información contenida en el mes actual no parece mejorar la precisión predictiva para el crecimiento del PIB. Este resultado para el ejercicio de nowcasting es similar al de Andreou et al. (2013). Una posible explicación es que, debido a la naturaleza de los datos financieros como indicadores adelantados, el papel de las variables financieras para predecir el PIB en un futuro próximo puede ser más importante que su función para proporcionar actualizaciones del pronóstico del PIB actual. De manera importante, se encuentra que el MIDAS con adelantos es estadísticamente superior, en cuanto a su capacidad predictiva, al esquema de ponderación simple con adelantos, cuando ambos modelos contienen información macroeconómica trimestral.

Tabla 5: Pruebas de misma capacidad predictiva

Modelo	h=1	h=4
	DM	DM
Nowcasting vs pronóstico		
Simple (datos financieros)	0.0810	0.2080
MIDAS combinado (datos financieros)	0.2117	0.0767
Simple (datos financieros + macro)	0.4110	0.2350
MIDAS combinado (datos financieros + macro)	0.1841	0.3610
Simple vs MIDAS		
Datos financieros	0.0760	0.2294
Datos financieros + macro	0.0001	0.0229

Esta tabla reporta los p valores de la prueba de la hipótesis nula de que los modelos de la izquierda tienen la misma capacidad predictiva. La comparación se basa en la prueba de Diebold-Mariano. Muestra: 1999Q1-2013Q4. El periodo de estimación: 1999Q1-2009Q4. Periodo a pronosticar: 2010Q1-2013Q4. Se utiliza una ventana recursiva para todas las estimaciones.

5. Conclusión

Siguiendo la metodología propuesta por Ghysels et al. (2007), se estima un modelo MIDAS que incorpora la información contenida en un entorno rico en datos de variables financieras diarias. Posteriormente, este modelo se utiliza para generar pronósticos por fuera de la muestra para el PIB mexicano en horizontes de uno y cuatro trimestres adelante. Se encuentra que el uso de esta metodología y la inclusión de las variables financieras diarias mejoran la precisión del pronóstico sobre los modelos alternativos que utilizan datos macroeconómicos trimestrales. El esquema MIDAS contribuye a eludir los problemas inicialmente encontrados cuando se trabaja con datos en diferentes frecuencias de muestreo, sin dejar de ser parsimoniosos. El análisis de factores y las combinaciones de pronósticos son usados para tratar con grandes conjuntos de datos de variables financieras.

Las comparaciones entre los modelos favorecen el uso del enfoque MIDAS sobre el esquema de ponderación simple. Adicionalmente, se encuentra que un modelo MIDAS tiene un mejor desempeño de pronóstico que un modelo AR aumentado con factores basados en variables macro. En un ejercicio de nowcasting, los resultados favorecen al

modelo MIDAS sobre el esquema de ponderación simple. No obstante, el modelo MIDAS con adelantos parece tener una precisión predictiva similar en comparación con el modelo MIDAS sin adelantos.

Los resultados presentados en este documento tienen implicaciones importantes para los pronosticadores profesionales, hacedores de políticas e investigadores. En particular, nuestros resultados sugieren que las variables financieras contienen información útil para predecir el PIB, posiblemente debido a su naturaleza como indicadores adelantados. Esto podría estar asociado con el desarrollo de los mercados financieros en México en los últimos años. Desde el punto de vista de la política, nuestros hallazgos implican que las variables financieras deberían ser monitoreadas cuidadosamente para anticipar las fluctuaciones del ciclo económico. Desde el punto de vista de la teoría, nuestros resultados apuntan a favor de vincular los sectores financiero y real de la economía en los modelos macroeconómicos. El papel de las variables financieras para predecir el crecimiento del PIB no solo se atribuye a su naturaleza como indicadores adelantados, sino también al esquema de ponderación flexible de los datos, utilizado para agregar las series diarias, en el cual la información reciente puede recibir mayor peso que la información rezagada. Nuestros resultados también sugieren que el análisis de factores es útil para extraer los factores comunes, filtrando las variaciones idiosincrásicas que podrían afectar el desempeño del pronóstico. Similarmente, las combinaciones de pronósticos son útiles para agregar los pronósticos basados en factores individuales de una forma parsimoniosa, mejorando así la eficiencia de los pronósticos de crecimiento del PIB.

Se concluye que esta metodología mejora los pronósticos, incluso en una economía emergente que presenta mayor volatilidad. Con el fin de mejorar o extender este trabajo, un grupo de variables financieras que esté directamente más relacionado a la economía mexicana podría ser empleado. La falta de disponibilidad de datos históricos sobre las variables útiles podría ser una limitación que sería resuelta mediante la realización del ejercicio en unos años. Esta metodología también podría usarse para predecir otras variables macro mensuales o trimestrales, tal como el desempleo. Finalmente, debido a que solo se consideraron datos mexicanos, sería útil evaluar si el modelo MIDAS que incluye

datos financieros diarios también tiene éxito en la predicción del PIB para otros países en desarrollo. Estas extensiones son dejadas para futuras investigaciones.

Apéndice A: Datos

Datos Financieros

	Tipo	Descripción
1	Materia prima	RJ CRB
2	Materia prima	PLATA
3	Materia prima	Petróleo Brent
4	Materia prima	PL-NYD
5	Materia prima	ZINC
6	Materia prima	XPD-D
7	Materia prima	TRIGO
8	Materia prima	C-US2D
9	Materia prima	SOYA
10	Materia prima	ALGODÓN
11	Materia prima	AZÚCAR
12	Materia prima	CAFÉ
13	Materia prima	CACAO
14	Materia prima	GANADO BOVINO
15	Materia prima	CERDOS
16	Materia prima	ORO
17	Materia prima	ALUMINIO
18	Materia prima	PETRÓLEO WTI
19	Materia prima	PLOMO
20	Materia prima	NÍQUEL
21	Materia prima	ESTAÑO
22	Materia prima	ALUMINIO FUT
23	Materia prima	PLOMO FWD
24	Materia prima	NÍQUEL FWD
25	Materia prima	ESTAÑO FWD
26	Materia prima	1ero wti
27	Materia prima	1ero combustible de calefacción
28	Materia prima	1ero diésel
29	Materia prima	1ero gas natural
30	Materia prima	1ero maíz
31	Materia prima	1ero soya
32	Materia prima	1ero trigo
33	Materia prima	1ero arroz paddy
34	Materia prima	1ero madera
35	Materia prima	1ero azúcar

36	Materia prima	Oro
37	Materia prima	Acervo de cobre
38	Materia prima	Acervo de níquel
39	Materia prima	Acervo de aluminio
40	Materia prima	Acervo de zinc
41	Materia prima	Acervo de plomo
42	Materia prima	Acervo de estaño
43	Materia prima	wti spot Midland
44	Materia prima	crudo brent europeo
45	Materia prima	cobre precio de cierre
46	Materia prima	aluminio precio de cierre
47	Materia prima	níquel precio de cierre
48	Materia prima	zinc precio de cierre
49	Materia prima	estaño precio de cierre
50	Materia prima	cobre precio fwd
51	Materia prima	aluminio precio fwd
52	Materia prima	níquel precio fwd
53	Materia prima	zinc precio fwd
54	Materia prima	plomo precio fwd
55	Materia prima	estaño precio fwd
56	Materia prima	fibra todos los ítems
57	Materia prima	fibra de metal
58	Materia prima	fibra textil
59	Materia prima	fibra de petróleo
60	Materia prima	gsci combustible de calefacción
61	Materia prima	gsci petróleo crudo
62	Materia prima	gsci gasolina
63	Materia prima	gsci diésel
64	Materia prima	gsci gas
65	Materia prima	gsci metales
66	Materia prima	gsci aluminio
67	Materia prima	gsci cobre
68	Materia prima	gsci plomo
69	Materia prima	gsci níquel
70	Materia prima	gsci zinc
71	Materia prima	gsci metales preciosos
72	Materia prima	gsci oro
73	Materia prima	gsci plata
74	Materia prima	gsci agricultura

75	Materia prima	gsci trigo
76	Materia prima	gsci soya
77	Materia prima	gsci algodón
78	Materia prima	gsci azúcar
79	Materia prima	gsci café
80	Materia prima	gsci cacao
81	Materia prima	gsci energía
82	Materia prima	gsci ganado
83	Materia prima	gsci ganado bovino
84	Materia prima	gsci cerdos
85	Materia prima	gsci productos blandos
86	Materia prima	gsci energía lumínica
87	Materia prima	Metales de energía
88	Materia prima	gsci sin ganado
89	Materia prima	gsci granos
90	Materia prima	gsci todos los trigos
91	Materia prima	gsci todos los crudos
92	Materia prima	gsci biocombustible
93	Materia prima	gsci 1 m fwd
94	Materia prima	gsci 3m fwd
95	Materia prima	gsci 2m fwd
96	Materia prima	gsci 4m fwd
97	Materia prima	gsci 5m fwd
98	Materia prima	rendimiento en exceso total
99	Materia prima	rendimiento en exceso petróleo crudo
100	Materia prima	rendimiento en exceso Brent
101	Materia prima	rendimiento en exceso gasolina
102	Materia prima	rendimiento en exceso combustible de calefacción
103	Materia prima	rendimiento en exceso diésel
104	Materia prima	rendimiento en exceso gas natural
105	Materia prima	rendimiento en exceso metales
106	Materia prima	rendimiento en exceso aluminio
107	Materia prima	rendimiento en exceso cobre
108	Materia prima	rendimiento en exceso plomo
109	Materia prima	rendimiento en exceso zinc
110	Materia prima	rendimiento en exceso metales preciosos
111	Materia prima	rendimiento en exceso oro
112	Materia prima	rendimiento en exceso plata
113	Materia prima	rendimiento en exceso agricultura y ganadería

114	Materia prima	rendimiento en exceso soya
115	Materia prima	rendimiento en exceso maíz
116	Materia prima	rendimiento en exceso algodón
117	Materia prima	rendimiento en exceso azúcar
118	Materia prima	rendimiento en exceso café
119	Materia prima	rendimiento en exceso cacao
120	Materia prima	rendimiento en exceso ganado
121	Materia prima	rendimiento en exceso cerdos
122	Materia prima	rendimiento en exceso no energético
123	Materia prima	rendimiento en exceso energía lumínica
124	Materia prima	rendimiento en exceso ultra energía
125	Materia prima	rendimiento en exceso energy metals
126	Materia prima	rendimiento en exceso petróleo
127	Materia prima	rendimiento en exceso granos
128	Materia prima	rendimiento en exceso todos los trigos
129	Materia prima	rendimiento en exceso todos los crudos
130	Materia prima	rendimiento en exceso biocombustible
131	Materia prima	Retorno total total
132	Materia prima	Retorno total petróleo
133	Materia prima	retorno total energía
134	Materia prima	retorno total gasolina
135	Materia prima	retorno total combustible de calefacción
136	Materia prima	retorno total diésel
137	Materia prima	retorno total gas natural
138	Materia prima	retorno total metales
139	Materia prima	retorno total aluminio
140	Materia prima	retorno total cobre
141	Materia prima	retorno total zinc
142	Materia prima	retorno total metales preciosos
143	Materia prima	retorno total oro
144	Materia prima	retorno total plata
145	Materia prima	retorno total agricultura y ganadería
146	Materia prima	retorno total agricultura
147	Materia prima	retorno total soya
148	Materia prima	retorno total maíz
149	Materia prima	retorno total algodón
150	Materia prima	retorno total azúcar
151	Materia prima	retorno total café
152	Materia prima	retorno total cacao

153	Materia prima	retorno total ganado
154	Materia prima	retorno total ganado bovino
155	Materia prima	retorno total cerdos
156	Materia prima	retorno total no energético
157	Materia prima	retorno total energía lumínica
158	Materia prima	retorno total ultra energía
159	Materia prima	retorno total metales de energía
160	Materia prima	retorno total petróleo
161	Materia prima	retorno total granos
162	Materia prima	retorno total todos los crudos
163	Materia prima	philadelphia semiconductor
164	Materia prima	maíz precio spot
165	Materia prima	Paladio
166	Materia prima	Platino
167	Acción	INMEX
168	Acción	S&P500
169	Acción	Índice S&P 500 Industrials Sector GICS Nivel 1
170	Acción	Promedio industrial Dow Jones - DJI
171	Acción	NASDAQ
172	Acción	NASDAQ 100
173	Acción	VIX
174	Acción	IPC
175	Acción	Índice Dow Jones Industrial Goods and Services Titans 30 Euros
176	Acción	Promedio de transportes Dow Jones
177	Acción	Promedio de Utilidades Dow Jones
178	Acción	Promedio Compuesto Dow Jones
179	Acción	Índice Dow Jones Internet Commerce
180	Acción	Índice Dow Jones Internet Composite
181	Acción	Índice S&P 500 Sector Industrials TR
182	Acción	Índice S&P 500 Financials Sector GICS Nivel 1
183	Acción	Índice S&P Smallcap 600
184	Acción	Índice NASDAQ Industrial
185	Acción	Índice Russell 2000
186	Acción	Índice Value Line Arithmetic
187	Acción	Índice Value Line Geometric
188	Acción	Índice de retorno total Dow Jones Equity REIT
189	Acción	Índice de retorno total Dow Jones US Completion Total Stock Market
190	Acción	Ratio CBOE Equity Put/Call
191	Acción	Ratio compuesto intradía CBOE US Put/Call

192	Acción	RATIOS COMPUESTOS PUT/CALL
193	Acción	Ratio intradía CBOE US SPX Put/Call
194	Acción	Ratio Put/Call Volume sobre SPX Pt/Cl
195	Acción	Índice CBOE US Ratio intradía Put/Call
196	Acción	Ratios Put/Call OEX Pt/Cl
197	Acción	Ratio intradía CBOE US OEX Put/Call
198	Acción	Ratios Put/Call RUT Pt/Cl
199	Acción	US Option Call Volumes sobre CBOE
200	Acción	US Option Put Volumes sobre CBOE
201	Acción	Acciones avanzadas de la Bolsa de Nueva York
202	Acción	Acciones en declive de la Bolsa de Nueva York
203	Acción	NASDAQ Total Volume Composite
204	Acción	Índice de Acciones avanzadas NASDAQ
205	Acción	Índice de Acciones en declive NASDAQ
206	Acción	Índice FTSE 100
207	Acción	Índice FTSEurofirst 300
208	Acción	Índice Dow Jones Islamic Market World
209	Acción	Índice compuesto Dow Jones Sustainability World
210	Acción	Índice Dow Jones World Technology
211	Acción	Índice compuesto de retorno total Dow Jones Sustainability World USD
212	Acción	Índice compuesto de retorno total Dow Jones Sustainability World Euro
213	Acción	Índice Dow Jones Islamic Market World Developed
214	Acción	Índice de retorno total Dow Jones Islamic Market World
215	Acción	Índice Dow Jones World Financials
216	Acción	Índice Dow Jones Sustainability en Euros
217	Acción	Índice Dow Jones World Consumer Goods
218	Acción	Índice de retorno total Dow Jones Sustainability World Ex AGTAF Euro
219	Acción	Índice Dow Jones World Consumer Services
220	Acción	Índice Dow Jones Sustainability World Ex Alcohol Tobacco Gambling Armaments & Firearms
221	Acción	Índice Dow Jones World Oil & Gas
222	Acción	Índice Dow Jones Islamic Market World Malaysia USD
223	Acción	Índice de retorno total Dow Jones Islamic Market World Developed
224	Acción	Índice Dow Jones World Basic Materials
225	Acción	Índice: Dow Jones Islamic Market World Excluding US
226	Acción	Índice Dow Jones Sustainability World Excluding Tobacco

227	Acción	Índice Dow Jones World Healthcare
228	Acción	Índice de retorno total Dow Jones Islamic Market World Emerging Markets
229	Acción	Índice Dow Jones Sustainability World in CHF
230	Acción	Índice Dow Jones Sustainability World Total Return Ex Gambling USD
231	Acción	Índice de retorno total Dow Jones Sustainability World Ex Tobacco USD
232	Acción	Índice de retorno total Dow Jones Sustainability World Ex Tobacco Euro
233	Acción	Índice de retorno total Dow Jones Islamic Market World Developed Excluding US
234	Acción	Índice de retorno total Dow Jones Islamic Market World Excluding US
235	Acción	Índice Dow Jones Sustainability World ex Australia ex Tobacco AUD
236	Acción	Índice de retorno total Dow Jones Sustainability World ex Australia ex Tobacco AUD
237	Acción	Índice Dow Jones World Industrials
238	Acción	Índice de retorno total Dow Jones Sustainability World in CHF
239	Acción	Índice de retorno total Dow Jones Sustainability World Ex AGTAF USD
240	Acción	Índice Dow Jones Sustainability World Excluding Gambling
241	Acción	Índice de retorno total Dow Jones Sustainability World Ex Gambling Euro
242	Acción	Índice Dow Jones World Excluding US Technology
243	Acción	Índice Dow Jones World Excluding US Utilities
244	Acción	Índice Dow Jones World Developed - Ex. U.S.
245	Acción	Índice Dow Jones World Ex Asia Basic Materials
246	Acción	Índice Dow Jones World - Ex Asia/Pacific Consumer Services
247	Acción	Índice Dow Jones World - Ex Asia/Pacific Oil & Gas
248	Acción	Índice Dow Jones World - Ex Asia/Pacific Financials
249	Acción	Índice Dow Jones World Ex Asia Healthcare
250	Acción	Índice Dow Jones World - Ex Asia/Pacific Industrials
251	Acción	Índice Dow Jones World - Ex Asia/Pacific Consumer Goods
252	Acción	Índice Dow Jones World Ex Asia Technology
253	Acción	Índice Dow Jones World Ex Asia Telecommunications
254	Acción	Índice Dow Jones World Ex Asia Utilities
255	Acción	Índice EURO STOXX
256	Acción	Índice MOVE Merrill Lynch Option Volatility Estimate

257	Acción	Merrill Lynch Option Volatility Estimate 3-Month
258	Acción	Merrill Lynch Swaption Option Volatility Estimate 3 Month
259	Acción	Merrill Lynch Swaption Option Volatility Estimate 6 Month
260	Acción	Índice Morgan Stanley Cyclical
261	Corporativo	Tasa LIBOR a 1 mes
262	Corporativo	Tasa LIBOR a 3 meses
263	Corporativo	Tasa LIBOR a 6 meses
264	Corporativo	Tasa LIBOR a 1 año
265	Corporativo	Fondos federales
266	Corporativo	Tasa de interés de papel comercial no financiero A2 P2 a 30 días Reserva Federal
267	Corporativo	Papel comercial A de 30 días Reserva Federal
268	Corporativo	Tasa de interés de papel comercial financiero AA a 30 días Reserva Federal
269	Corporativo	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 3 meses
270	Corporativo	Índices de bonos corporativos AAA Moody's
271	Corporativo	Índices de bonos corporativos BAA Moody's
272	Corporativo	Rendimiento de 10 años del Gobierno Genérico de EE.UU.
273	Corporativo	Fondo de bonos corporativos BlackRock (Londres)
274	Corporativo	Fondo de bonos corporativos BlackRock (Londres)
275	Corporativo	Fondo de retorno total BlackRock (Trade Reporting Facility LLC)
276	Corporativo	Fondos Globales BlackRock – Fondo US Dollar High Yield Bond (Luxemburgo)
277	Corporativo	Fondos Globales BlackRock – Fondo US Dollar High Yield Bond (Luxemburgo)
278	Corporativo	Fondos Globales BlackRock – Fondo Global High Yield Bond (Luxemburgo)
279	Corporativo	Retorno total Merrill Lynch 10-year U.S. Treasury Futures
280	Corporativo	Rendimiento en exceso Merrill Lynch 5-year U.S. Treasury Futures
281	Corporativo	Retorno total Merrill Lynch 2-year U.S. Treasury Futures
282	Corporativo	Retorno total Merrill Lynch 30-year U.S. Treasury Futures
283	Corporativo	Retorno total Merrill Lynch 5-year U.S. Treasury Futures
284	Corporativo	Rendimiento en exceso Merrill Lynch 10-year U.S. Treasury Futures
285	Corporativo	Rendimiento en exceso Merrill Lynch 2-year U.S. Treasury Futures
286	Corporativo	Rendimiento en exceso Merrill Lynch 30-year U.S. Treasury Futures
287	Corporativo	ICE LIBOR USD 1 semana
288	Corporativo	Papel comercial financiero Base de Descuento 1 día Reserva Federal
289	Corporativo	Tasa de interés de papel comercial financiero AA a 7 días Reserva

		Federal
290	Corporativo	Papel comercial financiero Base de rendimiento 1 día Reserva Federal
291	Corporativo	Papel comercial no financiero Base de rendimiento 1 día Reserva Federal
292	Corporativo	Tasa de interés de papel comercial financiero AA a 60 días Reserva Federal
293	Corporativo	Tasa de interés de papel comercial financiero AA a un día Reserva Federal
294	Corporativo	Papel comercial no financiero Base de Descuento 1 día Reserva Federal
295	Corporativo	Tasa de interés de papel comercial no financiero AA a 7 días Reserva Federal
296	Corporativo	Tasa de interés de papel comercial no financiero A2 P2 a 15 días Reserva Federal
297	Corporativo	Tasa de interés de papel comercial no financiero AA a 15 días Reserva Federal
298	Corporativo	Tasa de interés de papel comercial no financiero A2 P2 a 7 días Reserva Federal
299	Corporativo	Tasa de interés de papel comercial no financiero A2 P2 a un día Reserva Federal
300	Corporativo	Hipoteca bvigente Cpns Fnma a 30 años
301	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 30 años día 30
302	Corporativo	Mtge Current Cpns FNMA 30 Year Spread
303	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 30 años día 60
304	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 15 años día 30
305	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 30 años día 10
306	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 20 años día 30
307	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 30 años día 90
308	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija de 10 años día 30
309	Corporativo	DBIQ MBS TBA: FNMA: 30 Years FNCL
310	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija quincenal de 15 años día 30
311	Corporativo	Citigroup Mortgage 30 Year FNMA Sector Local Currency
312	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija quincenal de 30 años día 10
313	Corporativo	Tasas de compromiso de Fannie Mae Tasa fija quincenal de 30 años día 30
314	Tipo de cambio	Tasa cruzada de EE.UU.

315	TIPO DE CAMBIO	Tasa cruzada de Suiza
316	TIPO DE CAMBIO	USD Fwd
317	TIPO DE CAMBIO	Canadá
318	TIPO DE CAMBIO	Japón
319	TIPO DE CAMBIO	Costa Rica
320	TIPO DE CAMBIO	República Dominicana
321	TIPO DE CAMBIO	Islandia
322	TIPO DE CAMBIO	Israel
323	TIPO DE CAMBIO	Kazajstán
324	TIPO DE CAMBIO	Emiratos Árabes Unidos
325	TIPO DE CAMBIO	Australia
326	TIPO DE CAMBIO	Suiza
327	TIPO DE CAMBIO	Chile
328	TIPO DE CAMBIO	Euro
329	TIPO DE CAMBIO	Gran Bretaña
330	TIPO DE CAMBIO	Guatemala
331	TIPO DE CAMBIO	Nueva Zelanda
332	TIPO DE CAMBIO	Estados Unidos
333	TIPO DE CAMBIO	Perú
334	TIPO DE	Paraguay

	CAMBIO	
335	TIPO DE CAMBIO	Romania
336	TIPO DE CAMBIO	Arabia Saudita
337	TIPO DE CAMBIO	Eslovaquia
338	TIPO DE CAMBIO	Tailandia
339	TIPO DE CAMBIO	Turquía
340	TIPO DE CAMBIO	Sudáfrica
341	Renta fija	3M Bono del Tesoro
342	Renta fija	6M Bono del Tesoro
343	Renta fija	6 M Bono del Tesoro
344	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 1 año
345	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 2 años
346	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 3 años
347	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 5 años
348	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 10 años
349	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 20 años
350	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante de 2 años de la curva de rendimiento de EE.UU.
351	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante de 3 años de la curva de rendimiento de EE.UU.
352	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante de 3 meses de la curva de rendimiento de EE.UU.
353	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante de 7 años de la curva de rendimiento de EE.UU.
354	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante de 20 años de la curva de rendimiento de EE.UU.
355	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante de 6 meses de

		la curva de rendimiento de EE.UU.
356	Renta fija	Nota del Tesoro de EE.UU. con vencimiento constante no promediado de 7 años
357	Renta fija	Tasa de las Notas de Tesoro con vencimiento constante compuesto sobre 10 años de la curva de rendimiento de EE.UU.
358	Renta fija	Nota del Tesoro de la Reserva Federal de los Estados Unidos Vencimiento constante No promediado a 6 meses
359	Renta fija	Nota del Tesoro de la Reserva Federal de los Estados Unidos Vencimiento constante No promediado Compuesto 30+ Año
360	Renta fija	Gobierno General de los Estados Unidos Rendimiento a 30 años
361	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 10 años
362	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 10 años
363	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 3 meses
364	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 1 año
365	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero
366	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 1 año
367	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 30 años
368	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 6 meses
369	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 5 años
370	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 7 años
371	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 30 años
372	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 5 años
373	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 2 años
374	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 2 años
375	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 3 años

376	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 9 años
377	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 20 años
378	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 6 meses
379	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 20 años
380	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 4 años
381	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 6 años
382	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 7 años
383	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 4 años
384	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 3 años
385	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 15 años
386	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 8 años
387	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 6 años
388	Renta fija	USD Activos del Tesoro (IYC 25) Rendimiento de cupón cero a 9 años
389	Renta fija	USD Bonos / Notas del Tesoro de EE. UU. (FMC 82) Rendimiento de cupón cero a 8 años
390	Renta fija	USD Bonos / Notas del Tesoro de los Estados Unidos (FMC 82) Rendimiento de cupón cero a 15 años
391	Renta fija	Cetes 28
392	Renta fija	Cetes 91

Datos Macro Mensuales

	Descripción
1	Producción industrial
2	Trabajadores permanentes del IMSS
3	Inversión neta

- 4 Exportaciones no petroleras
- 5 Exportaciones petroleras
- 6 IPC: alimentos, bebidas y tabaco
- 7 IPC: vivienda
- 8 IPC: ropa, calzado y accesorios
- 9 IPC: muebles y electrodomésticos
- 10 IPC: salud
- 11 IPC: transporte
- 12 IPC: educación y recreación
- 13 IPC: otros servicios
- 14 Actividad industrial
- 15 M1
- 16 M2
- 17 IGAE
- 18 IPC de EE.UU.

Datos Macro Trimestrales

	Descripción
1	Consumo privado
2	Consumo del gobierno
3	Importaciones
4	Inversión neta
5	Exportaciones no petroleras
6	Exportaciones petroleras
7	IPC: alimentos, bebidas y tabaco
8	IPC: vivienda
9	IPC: ropa, calzado y accesorios
10	IPC: muebles y electrodomésticos
11	IPC: salud
12	IPC: transporte
13	IPC: educación y recreación
14	IPC: otros servicios
15	Actividad industrial
16	M1
17	M2
18	IGAE
19	PIB de EE.UU.
20	IPC de EE. UU.

Apéndice B: Resultados Complementarios

Tabla B.1.: Comparativo de RCMP de modelos alternativos con PIB con ajuste estacional

Modelo	h=1		h=4	
	RECMF		RECMF	
	RECMF	% del AR	RECMF	% del AR
Modelos alternativos				
AR	0.7162	1	0.6030	1
RW	0.7869	1.0987	0.9555	1.5845
VAR	0.7246	1.0117	0.6810	1.1294
BVAR	0.6303	0.8801	0.6187	1.0261
EEEESP	1.0043	1.4022		
Datos macro trimestrales				
FAR	0.6691	0.9342	0.6253	1.0368
Datos financieros				
Simple	0.8392	1.1718	0.6359	1.0545
Beta (p=1, q=3)	0.8434	1.1775	0.8690	1.4409
MIDAS combinado	0.6772	0.9455	0.7317	1.2133
Datos financieros + datos macro trimestrales				
Simple	0.6294	0.8788	0.5921	0.9818
Beta (p=1, q=3)	0.6768	0.9450	0.7185	1.1915
MIDAS combinado	0.6047	0.8442	0.6096	1.0109

Nota: Esta tabla muestra la raíz del error cuadrático medio de pronóstico (RECMF) para $h=1$ y $h=4$ pasos adelante del PIB. El periodo de estudio es 1999T1 a 2013T4. El periodo inicial de estimación es 1999T1 a 2009T4 y el periodo a pronosticar es 2009T4+h a 2013T4. Las RCMPs se presentan también como porcentaje del AR. Los 5 pronósticos del MIDAS estimados usando cada uno de los factores diarios se combinan para obtener el pronóstico de MIDAS combinado. Se utiliza una ventana recursiva para todos los pronósticos.

Referencias

- 1) Andreou, E., Ghysels, E. y Kourtellos, A. (2013). Should Macroeconomic Forecasters Use Daily Financial Data and How?, *Journal of Business and Economic Statistics*, 31(2), 240-251.
- 2) Arnesto, M. T., Engerman, K. M. y Owyang, M. T. (2010). Forecasting with Mixed Frequencies, *Federal Reserve Bank of St. Louis Review*, 92(6), 521-536.
- 3) Artis, M. J., y Zhang, W. (1990). BVAR Forecasts for the G-7. *International Journal of Forecasting*, 6(3), 349-362.
- 4) Baffigi, A., Roberto G., y Giuseppe P. (2004). Bridge Models to Forecast the Euro Area GDP. *International Journal of Forecasting*, 20(3) 447-460.
- 5) Bai, J., Gysels, E. y Wright, J. H. (2013). State Space Models and MIDAS Regressions. *Econometric Reviews*, 32(7), 779-813.
- 6) Bańbura, M., Giannone, D., y Reichlin, L. (2010). Large Bayesian vector auto regressions. *Journal of Applied Econometrics*, 25(1), 71-92.
- 7) Boivin, J., y Ng, S. (2005). Understanding and Comparing Factor-Based Forecasts. *International Journal of Central Banking*, 1(3).
- 8) Canova, F. (2007). *Methods for Applied Macroeconomic Research* (Vol. 13). Princeton University Press.

- 9) Capistrán, C., y López-Moctezuma, G. (2010). Las expectativas macroeconómicas de los especialistas: Una evaluación de pronósticos de corto plazo en México. *El Trimestre Económico*, 77(306 (2)), 275-312.
- 10) Chauvet, M., y Potter, S. (2013), Forecasting Output, in *Handbook of Economic Forecasting* (vol. 2), eds. G. Elliott, and A. Timmermann, Amsterdam, Netherlands: Elsevier.
- 11) Clements, M. P. y Galvão, A. B. (2008). Macroeconomic Forecasting With Mixed-Frequency Data. *Journal of Business & Economic Statistics*, 26(4), 546-554.
- 12) Cogley, T., y Nason, J. M. (1995). Effects of the Hodrick-Prescott Filter on Trend and Difference Stationary Time series Implications for Business Cycle Research. *Journal of Economic Dynamics and Control*, 19(1), 253-278.
- 13) Diebold, F. X., y Mariano, R. S. (1995). Comparing Predictive Accuracy. *Journal of Business and Economic Statistics*, 13(3), 253–265.
- 14) Doan, T., Litterman, R., y Sims, C. (1984). Forecasting and Conditional Projection using Realistic Prior Distributions. *Econometric Reviews*, 3(1), 1-100.
- 15) Dua, P., y Ray, S. C. (1995). A BVAR model for the Connecticut economy. *Journal of Forecasting*, 14(3), 167-180.
- 16) Espinoza, R., Fornari, F., y Lombardi, M. J. (2012). The Role of Financial Variables in Predicting Economic Activity. *Journal of Forecasting*, 31(1), 15-46.

- 17) Forni, M., Hallin, M., Lippi, M., y Reichlin, L. (2000). The Generalized Dynamic-Factor Model: Identification and Estimation. *Review of Economics and Statistics*, 82(4), 540-554.
- 18) Forni, M., Hallin, M., Lippi, M., y Reichlin, L. (2003). Do Financial Variables Help Forecasting Inflation and Real Activity in the Euro Area? *Journal of Monetary Economics*, 50(6), 1243-1255.
- 19) Friedman, M., y Schwartz, A. J. (2008). *A Monetary History of the United States, 1867-1960*. Princeton University Press.
- 20) Galvão, A. B. (2013). Changes in Predictive Ability with Mixed Frequency Data. *International Journal of Forecasting*, 29(3), 395-410.
- 21) Ghysels, E. (2015). Matlab Toolbox for Mixed Sampling Frequency Data Analysis using MIDAS Regression Models. Unpublished Manuscript.
- 22) Ghysels, E., Sinko, A., y Valkanov, R. (2007). MIDAS Regressions: Further Results and New Directions. *Econometric Reviews*, 26(1), 53-90.
- 23) Giannone, D., Reichlin, L., y Small, D. (2008). Nowcasting: The Real-Time Informational Content of Macroeconomic Data. *Journal of Monetary Economics*, 55(4), 665-676.
- 24) Forni, M., Hallin, M., Lippi, M., y Reichlin, L. (2003). Do Financial Variables Help Forecasting Inflation and Real Activity in the Euro Area? *Journal of Monetary Economics*, 50(6), 1243-1255.

- 25) Herrera-Hernandez, J. (2004). Business Cycles in Mexico and the United States: Do They Share Common Movements? *Journal of Applied Economics*, 7(2), 303-323.

- 26) Hodrick, R. J., y Prescott, E. C. (1997). Postwar US Business Cycles: An Empirical Investigation. *Journal of Money, Credit, and Banking*, 29(1), 1-16.

- 27) Ibarra, R. (2012). Do Disaggregated CPI Data Improve the Accuracy of Inflation Forecasts? *Economic Modelling*, 29(4), 1305-1313.

- 28) LeSage, J. P. (1999). Applied Econometrics using MATLAB. Manuscript, Dept. of Economics, University of Toronto, 154-159.

- 29) Levy-Yeyati, E., y Sturzenegger, F. (2003). To Float or to Fix: Evidence on the Impact of Exchange Rate Regimes on Growth. *The American Economic Review*, 93(4), 1173-1193.

- 30) Litterman, R. B. (1986). Forecasting with Bayesian Vector Autoregressions—Five Years of Experience. *Journal of Business & Economic Statistics*, 4(1), 25-38.

- 31) Marcellino, M. y Schumacher, C. (2010). Factor MIDAS for Nowcasting and Forecasting with Ragged-Edge Data: A Model Comparison for German GDP, *Oxford Bulletin of Economics and Statistics*, 72(4), 518-550.

- 32) Marcellino, M., Stock, J. H., y Watson, M. W. (2003). Macroeconomic Forecasting in the Euro Area: Country Specific versus Area-Wide Information. *European Economic Review*, 47(1), 1-18.

- 33) Mariano, R. S., y Murasawa, Y. (2003). A New Coincident Index of Business Cycles based on Monthly and Quarterly Series. *Journal of Applied Econometrics*, 18(4), 427-443.
- 34) McNees, S. K. (1986). Forecasting Accuracy of Alternative Techniques: A Comparison of US Macroeconomic Forecasts. *Journal of Business & Economic Statistics*, 4(1), 5-15.
- 35) Sidaoui, J. J. (2006). The Mexican Financial System: Reforms and Evolution 1995-2005. *BIS Papers*, 28, 277-93.
- 36) Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica: Journal of the Econometric Society*, 48(1), 1-48.
- 37) Stock, J. H., y Watson, M. W. (2002a). Forecasting Using Principal Components From a Large Number of Predictors, *Journal of the American Statistical Association*, 97(460), 1167–1179.
- 38) Stock, J. H., y Watson, M. W. (2002b). Macroeconomic forecasting using diffusion indexes. *Journal of Business & Economic Statistics*, 20(2), 147-162.
- 39) Stock, J. H., y Watson, M. W. (2003). Forecasting Output and Inflation: The Role of Asset Prices. *Journal of Economic Literature*, 41(3), 788-829.
- 40) Stock, J. H., y Watson, M. W. (2008). Forecasting in Dynamic Factor Models subject to Structural Instability, In *The Methodology and Practice of Econometrics, A Festschrift in Honour of Professor David F. Hendry*, eds. J. Castle and N. Shephard, Oxford: Oxford University Press.

- 41) Theil, H., y Goldberger, A. S. (1961). On Pure and Mixed Statistical Estimation in Economics. *International Economic Review*, 2(1), 65-78.
- 42) Timmermann, A. (2006). Forecast Combinations, in *Handbook of Economic Forecasting* (Vol. 1), eds. G. Elliott, C. Granger, and A. Timmermann, Holland, pp. 136–196. Amsterdam: Elsevier-North.