



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY



UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE CIENCIAS SOCIALES
DEPARTAMENTO DE ECONOMÍA

Tesis Maestría en Economía

**Proyecciones macroeconómicas con datos en
frecuencias mixtas.**

Modelos ADL-MIDAS, U-MIDAS y TF-MIDAS con
aplicaciones para Uruguay

Santiago Etchegaray Alvarez
Tutor: Nicolás Bonino-Gayoso
Tutor: Jorge Ponce

2021

Etchegaray Alvarez, Santiago

Proyecciones macroeconómicas con datos en frecuencias mixtas. / Santiago Etchegaray Alvarez. - Montevideo: Universidad de la República, Departamento de Economía - Facultad de Ciencias Sociales, 2021.

V, 46 p. 29, 7cm.

Director:

Nicolás Bonino-Gayoso

Director académico:

Jorge Ponce

Tesis de Maestría – Universidad de la República, Programa : Maestría en Economía, 2021.

Referencias bibliográficas: p. 33 – 36.

1. Proyecciones macroeconómicas, 2. Frecuencias mixtas, 3. TF-MIDAS, 4. U-MIDAS, 5. ADL-MIDAS, 6. Nowcasting, 7. Combinación de pronósticos.
I. Bonino-Gayoso, Nicolás, . II. Universidad de la República, Programa de Posgrado : Maestría en Economía. III. Título.

RESUMEN

La presente tesis de maestría se centra en la estimación, evaluación y comparación del desempeño predictivo de los modelos ADL-MIDAS, U-MIDAS y TF-MIDAS para realizar predicciones de corto plazo del nivel de actividad de la economía uruguaya. Para llevar a cabo la comparación de las tres metodologías se realiza un ejercicio de *nowcasting* y un ejercicio de *forecasting*, utilizando 25 series mensuales como posibles indicadores de la evolución del PIB. La evaluación de la capacidad predictiva se analiza en dos períodos solapados: un período que incluye a la pandemia de COVID-19 y otro que no la incluye. Se observa que el modelo TF-MIDAS es el que realiza predicciones más precisas cuando se incluye el período de pandemia, mientras que en la evaluación hasta el 2019 las tres metodologías obtienen resultados similares. Luego se compara el desempeño relativo entre distintas formas de combinaciones no paramétricas de predicciones, obteniendo resultados similares para la mayoría de ellas y, en general, mejores que cuando se considera solo al mejor modelo.

Palabras claves:

Proyecciones macroeconómicas, Frecuencias mixtas, TF-MIDAS, U-MIDAS, ADL-MIDAS, Nowcasting, Combinación de pronósticos.

Tabla de contenidos

1	Introducción	1
2	Marco teórico y antecedentes	4
2.1	Modelo DL-MIDAS y ADL-MIDAS	4
2.2	Modelo U-MIDAS	7
2.3	Modelo TF-MIDAS	8
3	Evaluación de proyecciones	10
3.1	Datos	10
3.2	Estrategia de estimación y evaluación	11
3.3	Resultados	16
4	Combinación de predicciones	23
5	Conclusiones	30
	Referencias bibliográficas	33
	Glosario	36
	Anexos	37
Anexo 1	Tablas	38

Capítulo 1

Introducción

El correcto y oportuno diagnóstico de la situación económica del país es un insumo clave para implementar políticas económicas adecuadas. Sin embargo, el considerable rezago con el que, por lo general, se publican los datos de las cuentas nacionales, dificulta la toma de estas decisiones de forma oportuna. En Uruguay las cuentas nacionales se publican cerca de 75 días después de cerrado el trimestre. Esto lleva a que sea de especial interés la realización de pronósticos sobre el nivel de actividad del último trimestre y qué se espera para el trimestre en curso y el siguiente.

En esta línea, durante las últimas décadas la literatura sobre *nowcasting* ha tenido un desarrollo muy importante en el mundo. Esta literatura se caracteriza por utilizar datos contemporáneos para predecir un agregado que por su frecuencia, o su mayor rezago, aún no está disponible. En contraposición, cuando se realizan ejercicios de *forecasting* la información disponible es anterior al período que se quiere predecir. Entre las metodologías de *nowcasting* más extendidas se pueden mencionar los modelos puente (también conocidos como modelos *bridge*), los modelos factoriales dinámicos y los modelos MIDAS. Los modelos puente intentan predecir la variable observada a una frecuencia más baja (por ejemplo, trimestral) a través de variables observadas a una frecuencia más alta (por ejemplo, mensual) por medio de una agregación temporal simple, de forma de hacer coincidir temporalmente ambas variables. Por otro lado, en la metodología de modelos factoriales dinámicos, a partir de un conjunto de indicadores de alta o baja frecuencia, se proyecta la variable de interés descomponiéndola en un componente común de las variables y un componente de error idiosincrático.

El presente trabajo tiene como objetivo principal la estimación, evaluación y comparación del desempeño predictivo de los modelos ADL-MIDAS, U-MIDAS y TF-MIDAS para realizar el *nowcasting* y *forecasting* de muy corto plazo del nivel de actividad de la economía uruguaya. Estos modelos se derivan del modelo MIDAS (*Mixed Data Sampling*) introducido por Ghysels et al. (2002). Los modelos MIDAS son modelos en frecuencias mixtas, que logran combinar de forma parsimoniosa datos de alta frecuencia con datos de baja frecuencia.

Al realizar predicciones para el período 2016T1 a 2021T2 de los modelos ADL-MIDAS, U-MIDAS y TF-MIDAS, utilizando 25 indicadores mensuales vinculados con el nivel de actividad, se encuentra que el modelo TF-MIDAS es el que realiza predicciones de *nowcasting* más precisas. Al restringir el análisis al período que no se vio afectado por la pandemia de COVID-19, los resultados de las tres metodologías son similares tanto en el ejercicio de *nowcasting* como de *forecasting*. Luego, siguiendo la literatura de la combinación de pronósticos, se evalúan distintas formas de combinar las predicciones generadas a partir de los modelos estimados con cada uno de los 25 indicadores mensuales. Las distintas combinaciones de predicciones obtienen resultados similares en el análisis fuera de la muestra, y en general, más estables que los observados al considerar solo el mejor modelo.

A lo largo del documento se sigue la notación utilizada en Forni et al. (2015) y en Bonino-Gayoso & Garcia-Hiernaux (2021). Las variables de alta frecuencia, que en este ejercicio son variables mensuales, serán observables en cada período $t = 1, 2, \dots, T$. El operador de rezagos de las variables de alta frecuencia se denota L . Mientras tanto, el parámetro k denotará la cantidad de veces que los indicadores de alta frecuencia se observan por cada uno de baja frecuencia. En este caso, al trabajar con series trimestrales y mensuales, $k = 3$. El indicador temporal de la serie de baja frecuencia será $t_q = 1, 2, \dots, T_q$, mientras que el operador de rezagos en esta frecuencia será Z , siendo $Z \equiv L^k$, y $Zy_{t_q} = y_{t_q-1}$. Por otro lado, se denominará h al período de proyección medido en unidades de tiempo t , mientras que s determina la cantidad de trimestres hacia adelante que se realiza la predicción, tomando como referencia el último dato de baja frecuencia disponible al momento de la predicción.

El documento se organiza como sigue: primero se realiza un repaso sobre los antecedentes y el marco teórico del modelo MIDAS y algunas de sus sucesivas derivaciones. Luego se brinda una breve descripción de los datos utilizados

en el trabajo, se presenta la estrategia de estimación y predicción de las metodologías ADL-MIDAS, U-MIDAS y TF-MIDAS, para luego analizar sus resultados. En el cuarto capítulo se evalúa cómo combinar las predicciones de los distintos modelos. Finalmente se comentan algunas conclusiones y resultados más importantes del trabajo.

Capítulo 2

Marco teórico y antecedentes

2.1. Modelo DL-MIDAS y ADL-MIDAS

El modelo DL-MIDAS¹ fue introducido por primera vez en Ghysels et al. (2002). Uno de los objetivos fundamentales del desarrollo de este modelo es poder combinar series obtenidas en distinta frecuencia, de hecho, es esta característica la que da el nombre al modelo *Mixed Data Sampling*. Originalmente el modelo MIDAS estuvo asociado principalmente a aplicaciones en el campo de las finanzas, aplicándose para predicciones de volatilidad (Ghysels et al. (2005, 2006), Ghysels et al. (2007)). Sin embargo, tiempo después comenzaron a realizarse aplicaciones para predicciones macroeconómicas (Clements & Galvão (2008, 2009), Ghysels & Wright (2009), Armesto et al. (2009, 2010), Marcellino & Schumacher (2010), Kuzin et al. (2011), Andreou et al. (2013), Duarte et al. (2017), Galli et al. (2019)).

Las frecuencias mixtas son un desafío econométrico frecuente al trabajar con series macroeconómicas; sin embargo, también son una oportunidad ya que permiten trabajar con información adicional, observada con más alta frecuencia y así realizar ejercicios de *nowcasting*. En Uruguay los datos de las cuentas nacionales se publican de forma trimestral, mientras que otras series de actividad relevantes, como la producción industrial o la información sobre el mercado de trabajo, se encuentran disponibles con frecuencia mensual.

Una aproximación frecuente para afrontar esta dificultad es a través de los modelos puente (*bridge model*). En estos modelos, por lo general, se realiza

¹A lo largo del presente documento se denomina DL-MIDAS al modelo original propuesto por Ghysels et al. (2002), para diferenciarlo del modelo ADL-MIDAS que incorpora el término autorregresivo, y del resto de las derivaciones analizadas.

la agregación temporal de la serie de alta frecuencia mediante un promedio simple. De esta forma se iguala la frecuencia de las series de mayor frecuencia a la de la serie de baja frecuencia y se realiza una regresión donde todos los datos se encuentran en una misma frecuencia. Esta aproximación puede implicar la pérdida de información de alta frecuencia que puede ser importante para predecir de mejor manera a nuestra variable de interés. La agregación temporal mediante el promedio simple implica asumir igual ponderación para todas las observaciones de la variable de alta frecuencia dentro de cada período. Otra posibilidad es permitir una ponderación diferente para las observaciones de alta frecuencia, que puede resultar útil si, por ejemplo, se cree que una de ellas (la primera observación del trimestre, por ejemplo) podría ser más importante que las demás. El problema de esta aproximación es que rápidamente se sufre el problema de proliferación de parámetros. Si se trabajase por ejemplo con datos diarios, se tendrían cerca de 20 parámetros a estimar por mes (considerando solo los días hábiles). Si además se incluyen rezagos mensuales de la variable de alta frecuencia, se multiplicarán estos parámetros y rápidamente resultará muy difícil poder estimar estas ecuaciones por un problema de sobre-parametrización.

Los modelos DL-MIDAS buscan solucionar estos problemas y emplear de forma parsimoniosa y sin pérdida de información relevante variables de alta frecuencia en el ejercicio de predicción de variables de menor frecuencia que se obtienen con mayor rezago. Para lograr esto, se toman algunas herramientas de los modelos de rezagos distribuidos. La ecuación de un modelo estilizado de rezagos distribuidos se define como: $y_t = \alpha + B(L)x_t + \varepsilon_t$ donde $B(L)$ es un polinomio operador de rezagos finito o infinito. En el caso de los modelos DL-MIDAS, los coeficientes del polinomio de rezagos no son libres, sino que están definidos por una función con pocos parámetros a estimar (θ). Las funciones más utilizadas son la exponencial de Almon y la Beta. La ecuación del modelo DL-MIDAS para N variables explicativas introducido por Ghysels et al. (2002) se define como:

$$y_t = \beta_0 + \sum_{i=1}^N \beta_{1i} B_i(L; \theta_i) x_{i,t-h} + \varepsilon_t \quad t = k, 2k, \dots, Tk \quad (2.1)$$

donde $B_i(L; \theta_i) = \sum_{j=0}^{j^{max}} b_i(j; \theta_i) L^j$.

La parametrización de la función de ponderación $b(j; \theta)$ de forma

parsimoniosa es una de las claves de los modelos DL-MIDAS. En este sentido, una de las opciones más utilizadas es la función de ponderación exponencial de Almon que se puede definir como:

$$b(j; \theta) = \frac{\exp(\theta_1 j + \theta_2 j^2 + \dots + \theta_Q j^Q)}{\sum_{j=0}^{j_{max}} \exp(\theta_1 j + \theta_2 j^2 + \dots + \theta_Q j^Q)} \quad (2.2)$$

Esta función es conocida por su flexibilidad para tomar distintas formas con solo unos pocos parámetros. Específicamente Ghysels et al. (2005) utilizan este polinomio con solo dos hiperparámetros, mientras que Andreou et al. (2013), al asumir que la memoria de los rezagos va disminuyendo a medida que se retrocede temporalmente, pueden trabajar con un polinomio exponencial de Almon teniendo que estimar solo un hiperparámetro.

Otra posible parametrización con solo dos parámetros utilizada es la función de ponderación de rezagos Beta:

$$b(j; \theta_1; \theta_2) = \frac{f\left(\frac{j}{j_{max}}; \theta_1; \theta_2\right)}{\sum_{j=1}^{j_{max}} f\left(\frac{j}{j_{max}}; \theta_1; \theta_2\right)} \quad (2.3)$$

donde f es la función de densidad Beta.

Andreou et al. (2010, 2011) demuestran que los modelos DL-MIDAS contienen a los modelos lineales de agregación temporal. Mediante una descomposición de la media condicional separan al modelo DL-MIDAS en un componente lineal similar a lo que sería una agregación temporal por promedio simple, y otro componente no lineal, aportado por los modelos DL-MIDAS. De esta forma, encuentran que al omitir el componente no lineal, la agregación temporal es asintóticamente ineficiente frente a los modelos DL-MIDAS; además en aquellos casos en que los indicadores de alta frecuencia tienen una dependencia temporal la agregación temporal resulta ineficiente e inconsistente.

Clements & Galvão (2008) desarrollan los modelos ADL-MIDAS (*Augmented Distributed Lag MIDAS*) donde se incluye un término autorregresivo de la variable a predecir. Esta innovación es de interés ya que muchas de las series macroeconómicas tienen un componente autorregresivo. Ghysels et al. (2007) muestran que la introducción de este componente autorregresivo en los modelos DL-MIDAS puede no ser trivial, ya que podrían generarse problemas de estacionalidad en el modelo. Así, aplicando

un factor común en la ecuación original, Clements & Galvão (2008) obtienen la siguiente ecuación que permite la estimación de un modelo DL-MIDAS con un componente autorregresivo, evitando el riesgo de introducir un patrón estacional al modelo, y N variables explicativas:

$$y_t = \beta_0 + \lambda y_{t-sk} + \sum_{i=1}^N \beta_{1i} B_i(L; \theta_i) (1 - \lambda L^{hk}) x_{i,t-h} + \varepsilon_t \quad (2.4)$$

donde $B_i(L; \theta) = \sum_{j=0}^{j^{max}} b_i(j; \theta) L^j$; s es la cantidad de trimestres hacia adelante, desde el último dato disponible, para el que se realiza la predicción. Clements & Galvão (2008, 2009) obtienen que estos modelos resultan buenos prediciendo en el corto plazo.

En trabajos posteriores (ver Andreou et al. (2013), Duarte (2014), Duarte et al. (2017)) se discute la necesidad de realizar este factor común sugerido por Clements & Galvão (2008) para incorporar el componente autorregresivo al modelo MIDAS, incluyendo finalmente los rezagos de la variable dependiente sin el factor común sugerido por Clements & Galvão (2008).

2.2. Modelo U-MIDAS

Los modelos U-MIDAS (*Unrestricted MIDAS*) fueron propuestos en primer lugar por Koenig et al. (2003), y luego utilizados por Clements & Galvão (2008, 2009) y Marcellino & Schumacher (2010) en el contexto de estimaciones en tiempo real. Sin embargo, fueron Forni et al. (2011, 2015) quienes analizaron en detalle este modelo, estudiando el rol de la forma funcional del polinomio de rezagos y bajo qué condiciones se pueden identificar los parámetros del modelo de alta frecuencia.

Este modelo se presenta como un modelo muy competitivo en las predicciones de corto plazo con frecuencias mixtas. Esto se observa particularmente cuando la diferencia de frecuencia entre las variables de alta frecuencia y la de baja frecuencia no es muy elevada, por ejemplo, al trabajar con variables mensuales y trimestrales. Este suele ser el caso en análisis macroeconómicos, donde se intenta predecir el PIB, a partir de indicadores mensuales tales como variables de empleo o la producción industrial. En estos casos, el problema de proliferación de parámetros es menor, por lo que en lugar de emplear un polinomio de rezagos funcionalmente distribuidos, se puede

aplicar un polinomio lineal de rezagos.

El modelo U-MIDAS para N variables explicativas se define tal que:

$$C(L^k)y_t = \sum_{i=1}^N \delta_i(L)x_{i,t-h} + \varepsilon_t \quad t = k, 2k, \dots, Tk \quad (2.5)$$

donde $C(L^k) = 1 - c_1L^k - \dots - c_cL^{kc}$; $\delta_i(L) = \sum_{j=0}^{j_{max}} \delta_{i,j}L^j$; $i = 1, 2, \dots, N$; x_i es el i -ésimo indicador de alta frecuencia. Se asume que si los órdenes de rezagos c y j_{max} son lo suficientemente largos, entonces el término de error ε_t está incorrelacionado y los parámetros del modelo pueden estimarse por mínimos cuadrados ordinarios (MCO). Siguiendo a Foroni et al. (2015), si bien se entiende que por lo general el término de error de la ecuación tiene una estructura de media móvil, por simplicidad se asume una estructura autorregresiva.

Foroni et al. (2015) muestran que el modelo ADL-MIDAS tradicional está contenido dentro del modelo U-MIDAS, ya que se obtiene imponiendo un determinado patrón en la dinámica de los rezagos. La principal ventaja del modelo ADL-MIDAS es que esta especificación permite incorporar un gran número de rezagos sin generar problemas de proliferación de parámetros, especialmente útil cuando se trabaja con datos diarios. Sin embargo, en aplicaciones macroeconómicas como esta, imponer una estructura de rezagos a priori puede no ser óptimo ya que ésta puede no resultar lo suficientemente general para adaptarse a los datos. A esto se agrega que si los datos solo necesitan una cantidad acotada de rezagos para predecir la variable de baja frecuencia, no sería necesario imponer la restricción del polinomio de rezagos no lineal, y se podría estimar el modelo a través de métodos lineales, cómo MCO.

Por otro lado, Foroni et al. (2015) presentan un ejercicio de simulación en el que se compara el desempeño en términos de precisión del modelo U-MIDAS contra el ADL-MIDAS. Encuentran, para distintos procesos generadores de datos, que los modelos U-MIDAS obtienen mejores predicciones respecto a los modelos ADL-MIDAS cuando el valor de k es bajo.

2.3. Modelo TF-MIDAS

En esta aproximación introducida por Bonino-Gayoso & Garcia-Hiernaux (2021) se presenta una alternativa para la especificación de modelos MIDAS a través de una función de transferencia, en lugar del tradicional polinomio de rezagos distribuidos. Estos modelos tienen como novedad que permiten la incorporación de infinitos rezagos de los indicadores y de un componente de media móvil en el término de error.

En términos generales, el modelo TF-MIDAS para N indicadores puede definirse por las siguientes dos ecuaciones:

$$y_t = \beta_0 + \sum_{i=1}^N \sum_{j=h}^{k+h-1} \frac{a_{ij}(Z)}{b_{ij}(Z)} x_{i,t-j} + \varepsilon_t \quad (2.6)$$

$$\phi(Z)\varepsilon_t = \theta(Z)a_t \quad (2.7)$$

donde $a_{ij}(Z)$ y $b_{ij}(Z)$ son polinomios de rezagos finitos, $Z \equiv L^k$; $\phi(Z)$ y $\theta(Z)$ son polinomios autorregresivos y de medias móviles de orden p y q , respectivamente, estacionarios e invertibles.

Bonino-Gayoso & Garcia-Hiernaux (2021) muestran que imponiendo como restricciones que (i) $\theta(Z) = 1$ y que (ii) $b_i(Z) = \phi(Z)$ al modelo TF-MIDAS, se llega al modelo U-MIDAS. Por lo tanto, la utilización del modelo U-MIDAS será buena siempre y cuando se cumplan estas condiciones en el proceso generador de datos. En caso contrario, el modelo U-MIDAS será una aproximación del verdadero modelo.

Una de las principales desventajas del modelo TF-MIDAS frente al modelo U-MIDAS es que debe estimarse mediante métodos de estimación no lineal, como por ejemplo por máxima verosimilitud. Esto conlleva un mayor esfuerzo computacional.

Capítulo 3

Evaluación de proyecciones

3.1. Datos

El objetivo del trabajo es realizar predicciones de la evolución del Índice de Volumen Físico del PIB trimestral de Uruguay, serie publicada trimestralmente por el Banco Central del Uruguay cerca de unos 75-80 días luego de finalizado el trimestre. En tanto, como regresores para la estimación y predicción de estos modelos se utilizarán distintos indicadores mensuales. Todas las series que presentan algún patrón estacional se incorporan tras ser desestacionalizadas, y a todas las series se les realizan las transformaciones necesarias para volverlas estacionarias. En total, se utilizan 25 indicadores mensuales que de distinta forma se pueden vincular con la actividad doméstica. En estos 25 indicadores se incluyen algunos indicadores conocidos en la literatura como indicadores *hard*, que refieren principalmente a indicadores de actividad directamente relacionados con los distintos componentes del PIB, al tiempo que también se incluyen algunos indicadores *soft*, principalmente indicadores de expectativas. En este marco, se seleccionaron indicadores vinculados al comercio exterior, a la industria, al mercado de trabajo, al consumo de los hogares, al crédito, a las expectativas de los consumidores y a la actividad regional y mundial. En la tabla 3.1 se detallan las series empleadas, su fuente y las transformaciones realizadas. El índice de confianza al consumidor, elaborado por la Instituto de Competitividad de la Universidad Católica con Equipos Consultores, y sus subíndices, así como el Índice de Confianza de los Consumidores de Brasil, elaborado por la Fundación Getulio Vargas, se incluyeron en los modelos en niveles (no se les realizó diferencias) siguiendo la línea de Rodríguez (2014),

Tabla 3.1: Indicadores mensuales utilizados

Indicador	Fuente	Rezago en publicación	Transformaciones
Unidades vendidas de automóviles 0 km	ASCOMA	1 mes	1 diferencia logarítmica
Importaciones de bienes sin petróleo constantes	BCU	1 mes	1 diferencia logarítmica
Importaciones de bienes intermedios sin energéticos constantes	BCU	1 mes	1 diferencia logarítmica
Importaciones de bienes de consumo constantes	BCU	1 mes	1 diferencia logarítmica
Importaciones de bienes de consumo sin autos constantes	BCU	1 mes	1 diferencia logarítmica
Exportaciones de bienes constantes	BCU	1 mes	1 diferencia logarítmica
Exportaciones de bienes sin cultivos constantes	BCU	1 mes	1 diferencia logarítmica
Recaudación neta de la DGI constantes	DGI con elaboración propia	1 mes	1 diferencia logarítmica
Recaudación de IVA constantes	DGI con elaboración propia	1 mes	1 diferencia logarítmica
Cotizantes de BPS	BPS	1 mes	1 diferencia logarítmica
Índice de confianza al consumidor	Equipos Consultores y Universidad Católica	1 mes	Niveles
ICC - Subíndice situación económica personal	Equipos Consultores y Universidad Católica	1 mes	Niveles
ICC - Subíndice situación económica del país	Equipos Consultores y Universidad Católica	1 mes	Niveles
ICC - Subíndice Intención de compra de bienes durables	Equipos Consultores y Universidad Católica	1 mes	Niveles
Índice de confianza al consumidor de Brasil	Fundación Getulio Vargas - Brasil	1 mes	Niveles
IVF Producción Industrias Manufactureras	INE	2 meses	1 diferencia logarítmica
IVF Producción Núcleo Industrias Manufactureras	INE	2 meses	1 diferencia logarítmica
Masa Salarial real	INE	2 meses	1 diferencia logarítmica
Población Ocupada total país	INE	2 meses	1 diferencia logarítmica
Población Activa total país	INE	2 meses	1 diferencia logarítmica
Stock de crédito en moneda extranjera	BCU	2 meses	1 diferencia logarítmica
Stock de crédito total	BCU	2 meses	1 diferencia logarítmica
IBC - Brasil	Banco Central de Brasil	2 meses	1 diferencia logarítmica
EMAE - Argentina	INDEC - Argentina	3 meses	1 diferencia logarítmica
Comercio Mundial	CPB Netherlands Bureau for Economic Policy Analysis	3 meses	1 diferencia logarítmica

Camacho & Perez-Quiros (2010) y Clements & Galvão (2009).

La base de datos considerada comienza en el primer trimestre de 2005 y los últimos datos corresponden al segundo trimestre de 2021. En algunos casos, las series de los indicadores mensuales están disponibles desde algunos meses más adelante, por lo que para estimar los modelos de estos indicadores se toma en cuenta esta restricción y se los estima desde el momento en que los datos están disponibles.

3.2. Estrategia de estimación y evaluación

Para evaluar el desempeño de las tres metodologías analizadas se lleva a cabo una estimación recursiva utilizando los 25 indicadores mensuales por separado. Se divide la base de datos en un período de evaluación y en un período de estimación que inicialmente corresponde al período 2005T1-2015T4 y que luego es expandido recursivamente a lo largo del tiempo. En total, se realizan predicciones fuera de la muestra para 22 trimestres, siendo el período de evaluación fuera de la muestra 2016T1-2021T2. Por otro lado, también se realizó el ejercicio de evaluación de predicciones excluyendo los datos atípicos del 2020 y 2021, resultado de la pandemia de COVID-19, realizando una evaluación separada para el período 2016T1-2019T4 (16 trimestres).

Tanto la serie del PIB de Uruguay, como los indicadores de alta frecuencia se incorporan en sus versiones revisadas. En este sentido, para todas las series se considera la versión que se tenía disponible en setiembre de 2021, tras la publicación de las cuentas nacionales del segundo trimestre de 2021.

Si bien en algunos trabajos (ver Koenig et al. (2003), Clements & Galvão (2008, 2009)) se han manifestado algunos aspectos positivos de considerar las series preliminares que se tenían disponibles en cada momento del tiempo (*real time vintages*), y no considerar las series ya revisadas, en Uruguay no se dispone de una base de datos amplia con esta información. Además, en los trabajos de Schumacher & Breitung (2008) para Alemania y en Bernanke & Boivin (2003) para Estados Unidos se encuentra que la diferencia en la capacidad predictiva no varía sustancialmente al utilizar series revisadas. Se sigue entonces la estrategia llevada a cabo por Armesto et al. (2009), Marcellino & Schumacher (2010), Kuzin et al. (2011) y Galli et al. (2019) entre otros y se trabaja con un enfoque *pseudo real-time*. Se consideran los datos revisados de cada una de las series (de alta y de baja frecuencia) pero para la estimación y predicción de los modelos se tiene en cuenta el calendario de publicación de los indicadores mensuales, respetando el rezago con el que cada indicador se publica (ver en la tabla 3.1 información sobre rezago en la publicación de cada indicador).

Para cada uno de los trimestres proyectados se realizan 2 predicciones. Una primera predicción, considerada *forecasting*, que se realiza cuando el trimestre a predecir aún no ha comenzado, por lo que los datos de alta frecuencia del trimestre a predecir aún no están disponibles, todavía no se dispone del dato previo del PIB, pero se acaba de dar a conocer el dato de 2 trimestres atrás. La segunda predicción, considerada *nowcasting*, se realiza cuando se acaba de conocer el dato previo del PIB y se dispone de algunos indicadores de alta frecuencia del trimestre que se quiere proyectar. Para realizar las predicciones se utiliza la información que se tendría disponible en el momento inmediato en que el Banco Central del Uruguay realiza una publicación de las cuentas nacionales, agregando un nuevo dato del PIB. Por ejemplo, el primer período para el que se realizan predicciones fuera de la muestra es el primer trimestre del 2016. Si se toma como regresor las unidades vendidas de automóviles 0 km, que se publican con un mes de rezago, el *forecasting* se realizará con información del PIB disponible hasta 2015T3, y con información mensual de alta frecuencia disponible hasta 2015M11 (recordando el rezago de 75-80 días en la publicación de las cuentas nacionales en Uruguay, el analista estaría situado cerca del 20 de diciembre de 2015). Mientras que, el *nowcasting* se realizará con información del PIB hasta 2015T4, y con información mensual de alta frecuencia hasta 2016M02 (se estaría situado cerca del 20 de marzo de

2016).

En esta misma línea, y al seguir un método recursivo, las predicciones del segundo trimestre de 2016 se realizan con la información que se tendría disponible en los últimos días de marzo de 2016 (información del PIB hasta 2015T4 e información de alta frecuencia hasta 2016M02) en el ejercicio de *forecasting*, mientras que en el ejercicio de *nowcasting* se consideraría la información disponible a finales de junio de 2016 (información del PIB hasta 2016T1 e información de alta frecuencia hasta 2016M05).

Para estimar los modelos U-MIDAS y ADL-MIDAS se debe determinar la cantidad de rezagos a incluir en la estimación. Para esto se utiliza el criterio de información *Bayesian Information Criterion* (BIC). En ambos casos se fijó en 9 la cantidad máxima de rezagos. En el caso del modelo U-MIDAS la inclusión de muchos rezagos implica un costo directo por el incremento de la cantidad de parámetros a estimar. En este marco, los modelos U-MIDAS seleccionados por el criterio BIC son en la mayoría de los casos modelos parsimoniosos, con pocos rezagos de los indicadores de alta frecuencia¹.

Para el modelo TF-MIDAS se consideraron 16 posibles modelos (en la tabla 1.1 en anexo se encuentra el detalle de los 16 modelos considerados), con distintos órdenes de rezago en los polinomios $a_j(Z)$, $b_j(Z)$, $\theta(Z)$ y $\phi(Z)$. Al igual que en los casos de ADL-MIDAS y U-MIDAS, para cada estimación se seleccionó el modelo que minimizara el criterio de información BIC.

Se definen a continuación las ecuaciones estimadas para cada uno de los tres modelos.

En primer lugar, el modelo ADL-MIDAS se estimó con un término autorregresivo de la variable de baja frecuencia y una sola variable de alta frecuencia como segundo regresor. El modelo estimado entonces se escribe tal que:

$$y_t = \beta_0 + cy_{t-sk} + \beta_1 B(L; \theta)x_{t-h} + \varepsilon_t \quad t = k, 2k, \dots, T_q k \quad (3.1)$$

donde $B(L; \theta) = \sum_{j=0}^{j_{max}} b(j; \theta_1; \theta_2)L^j$ y la función de ponderación utilizada es la exponencial de Almon; s es la cantidad de trimestres hacia adelante que se realiza la predicción, desde el último dato de baja frecuencia disponible al momento de la predicción. La ecuación del modelo ADL-MIDAS para realizar

¹Al utilizar el criterio de información de Akaike, que no penaliza tanto la inclusión de más rezagos, no se observan cambios importantes en los resultados.

una predicción h pasos adelante con información de la serie de baja frecuencia hasta el período T_qk , y de la serie de alta frecuencia hasta $T_qk + sk - h$ se define como sigue:

$$\hat{y}_{T_qk+sk|T_qk+sk-h} = \hat{\beta}_0 + \hat{c}y_{T_qk} + \hat{\beta}_1 B(L; \hat{\theta})x_{T_qk+sk-h} \quad (3.2)$$

donde $B(L; \hat{\theta})$ se obtiene proyectando y_t en la información de $t - h$ o antes, para $t = k, 2k, \dots, T_qk$.

En segundo lugar, el modelo U-MIDAS con un término autorregresivo de la variable de baja frecuencia y con un solo indicador de alta frecuencia como regresor adicional se define como sigue:

$$y_t = \beta_0 + cy_{t-sk} + \delta(L)x_{t-h} + \varepsilon_t \quad t = k, 2k, \dots, T_qk \quad (3.3)$$

donde $\delta(L) = \sum_{j=0}^{j_{max}} \delta_j L^j$; s es la cantidad de trimestres hacia adelante que se realiza la predicción, desde el último dato de baja frecuencia disponible. En tanto, la ecuación del modelo U-MIDAS para realizar una predicción h pasos adelante con información de la serie de baja frecuencia hasta el período T_qk , y con una sola serie de alta frecuencia con información hasta $T_qk + sk - h$ se define como sigue:

$$\hat{y}_{T_qk+sk|T_qk+sk-h} = \hat{\beta}_0 + \hat{c}y_{T_qk} + \hat{\delta}(L)x_{T_qk+sk-h} \quad (3.4)$$

donde el polinomio $\hat{\delta}(L)$ se obtiene proyectando y_t en la información de $t - h$ o antes, para $t = k, 2k, \dots, T_qk$.

Por último, el modelo TF-MIDAS con datos trimestrales y mensuales ($k = 3$) y con un solo indicador de alta frecuencia se define tal que:

$$y_t = \beta_0 + \frac{a_1(Z)}{b_1(Z)}x_{t-h} + \frac{a_2(Z)}{b_2(Z)}x_{t-h-1} + \frac{a_3(Z)}{b_3(Z)}x_{t-h-2} + \varepsilon_t \quad (3.5)$$

$$\phi(Z)\varepsilon_t = \theta(Z)a_t \quad (3.6)$$

donde para el caso en que $h = 1$, x_{t-1} es un vector conformado por las observaciones del segundo mes de cada trimestre, x_{t-2} es un vector conformado por las observaciones del primer mes de cada trimestre y x_{t-3} es un vector conformado por las observaciones del último mes del trimestre previo. Mientras que la correspondiente ecuación del modelo TF-MIDAS para realizar una

predicción h pasos adelante es:

$$\hat{y}_{T_q k+sk|T_q k+sk-h} = \hat{\beta}_0 + \frac{\hat{a}_1(Z)}{\hat{b}_1(Z)} x_{t-h} + \frac{\hat{a}_2(Z)}{\hat{b}_2(Z)} x_{t-h-1} + \frac{\hat{a}_3(Z)}{\hat{b}_3(Z)} x_{t-h-2} + \frac{\hat{\theta}(Z)}{\hat{\phi}(Z)} \hat{a}_{T_q k+sk} \quad (3.7)$$

donde $\hat{\theta}(Z) = \hat{\theta}_1 Z + \hat{\theta}_2 Z^2 + \dots + \hat{\theta}_q Z^q$, y $\hat{\phi}(Z) = 1 + \hat{\phi}_1 Z + \hat{\phi}_2 Z^2 + \dots + \hat{\phi}_p Z^p$.¹

Para la estimación y predicción de los tres modelos se utilizó el software Matlab. Los parámetros del modelo TF-MIDAS se estimaron por máxima verosimilitud a través del filtro de Kalman, utilizando el paquete $E4^2$ (ver Casals et al. (2016), capítulos 5 y 6). Mientras que los modelos ADL-MIDAS y U-MIDAS se estimaron a través del paquete *MIDAS Matlab Toolbox Version 2.4*³ (Ghysels (2021)).

En la tabla 3.2 se detallan los horizontes de predicción (h) utilizados para cada indicador de alta frecuencia en el ejercicio de *nowcasting* y en el ejercicio de *forecasting*, considerando en todos los casos el calendario de publicación de cada variable.

3.3. Resultados

Para evaluar los resultados de las tres metodologías (ADL-MIDAS, U-MIDAS y TF-MIDAS) se considera como *benchmark* un modelo AR(1) estimado de forma recursiva¹.

La principal medida de precisión en la predicción considerada es la raíz del error cuadrático medio (RECM). Se detalla en la ecuación 3.8 su cálculo.

$$RECM = \sqrt{\frac{1}{ES} \sum_{es=1}^{ES} (\hat{y}_{T_k+esk|T_k+esk-h} - y_{T_k+esk})^2} \quad (3.8)$$

donde $es = 1, 2, \dots, ES$, refiere a los distintos períodos para los que se realizó la evaluación fuera de la muestra.

¹Notar que el polinomio $\hat{\theta}(Z)$ no incluye el término unitario, ya que $\hat{a}_{T_q k+sk}$ no es conocido en el momento $T_q k + sk$.

²Disponible en: <https://www.ucm.es/e-4/>. El código de Matlab fue proporcionado por los profs. Nicolás Bonino-Gayoso y Alfredo Garcia-Hiernaux.

³Disponible en: <https://la.mathworks.com/matlabcentral/fileexchange/45150-midas-matlabtoolbox>

¹En anexo se colocan también los resultados de considerar como *benchmark* un modelo AR(2) y el promedio histórico, ambos estimados de forma recursiva.

Tabla 3.2: Horizonte de predicción (h) para cada variable de alta frecuencia

Indicador	h utilizado para nowcasting	h utilizado para forecasting
Unidades vendidas de automóviles 0 km	1	4
Importaciones de bienes sin petróleo constantes	1	4
Importaciones de bienes intermedios sin energéticos constantes	1	4
Importaciones de bienes de consumo constantes	1	4
Importaciones de bienes de consumo sin autos constantes	1	4
Exportaciones de bienes constantes	1	4
Exportaciones de bienes sin cultivos constantes	1	4
Recaudación neta de la DGI constantes	1	4
Recaudación de IVA constantes	1	4
Cotizantes de BPS	1	4
Índice de confianza al consumidor	1	4
ICC - Subíndice situación económica personal	1	4
ICC - Subíndice situación económica del país	1	4
ICC - Subíndice Intención de compra de bienes durables	1	4
Índice de confianza al consumidor de Brasil	1	4
IVF Producción Industrias Manufactureras	2	5
IVF Producción Núcleo Industrias Manufactureras	2	5
Masa Salarial real	2	5
Población Ocupada total país	2	5
Población Activa total país	2	5
Stock de crédito en moneda extranjera	2	5
Stock de crédito total	2	5
IBC - Brasil	2	5
EMAE - Argentina	3	6
Comercio Mundial	3	6

En la tabla 3.3 se presentan los resultados de las tres metodologías aplicadas utilizando los 25 indicadores por separado. El resultado presentado es el ratio de la RECM del modelo MIDAS en cuestión, contra la RECM del modelo AR(1). Por lo tanto, cuando el ratio es menor a 1, indicaría que la predicción del modelo MIDAS obtiene una raíz del error cuadrático medio inferior a la del AR(1), y por lo tanto, brindaría predicciones más precisas.

En términos generales, se observa que al considerar la muestra de evaluación completa, 2016T1-2021T2, el modelo TF-MIDAS tiene un muy buen desempeño en el *nowcasting*. La metodología TF-MIDAS obtiene una RECM menor a la del AR(1) con los 25 indicadores de alta frecuencia utilizados. En tanto, los modelos U-MIDAS presentan una RECM relativa menor a la unidad al utilizar 17 de los 25 indicadores. Mientras que, al utilizar la metodología ADL-MIDAS, solo se logra un ratio menor a 1 en 12 de los 25 indicadores.²

Si se analiza el desempeño en el *forecasting*, se observa que son pocos los indicadores que presentan una RECM menor a la del AR(1) en este horizonte. En los modelos TF-MIDAS solo se logra con 10 de los 25 indicadores, mientras que en los ADL-MIDAS solo se logra con 2 de los 25 indicadores, y en los

²Si se considera el criterio de exigir al menos un valor de 0,95 para afirmar que el modelo es más preciso que el AR(1), entonces se aprecia aun más el mejor desempeño relativo de TF-MIDAS: TF-MIDAS (25 de 25); U-MIDAS (4 de 25); ADL-MIDAS (6 de 25).

Tabla 3.3: RECM relativa de modelos ADL-MIDAS, U-MIDAS y TF-MIDAS para cada uno de los 25 indicadores vs AR(1)¹

Indicador	Metodología	Nowcasting ²	Forecasting ²	Nowcasting 19 ³	Forecasting 19 ³
Unidades vendidas de automóviles 0 km	ADL-MIDAS	0,97	1,03	1,01	1,03
	U-MIDAS	0,97	1,02	1,03	0,95
	TF-MIDAS	0,66	1,17	0,98	0,96
Importaciones de bienes sin petróleo constantes	ADL-MIDAS	1,01	1,05	1,15	1,13
	U-MIDAS	0,98	1,05	1,05	1,05
	TF-MIDAS	0,86	1,01	1,05	0,88
Importaciones de bienes intermedios sin energéticos constantes	ADL-MIDAS	0,95	1,04	0,96	1,07
	U-MIDAS	0,99	1,06	0,98	1,09
	TF-MIDAS	0,90	1,21	0,93	0,93
Importaciones de bienes de consumo constantes	ADL-MIDAS	1,04	1,02	1,19	0,96
	U-MIDAS	0,99	1,03	1,05	0,93
	TF-MIDAS	0,70	1,07	1,05	0,94
Importaciones de bienes de consumo sin autos constantes	ADL-MIDAS	0,98	1,04	1,10	0,91
	U-MIDAS	0,94	1,05	0,89	0,92
	TF-MIDAS	0,79	0,94	1,00	1,00
Exportaciones de bienes constantes	ADL-MIDAS	1,06	1,09	0,93	0,99
	U-MIDAS	1,00	1,03	0,96	0,97
	TF-MIDAS	0,92	0,97	0,98	1,09
Exportaciones de bienes sin cultivos constantes	ADL-MIDAS	1,01	1,06	0,98	0,92
	U-MIDAS	0,98	1,03	0,97	0,92
	TF-MIDAS	0,87	0,97	1,03	1,02
Recaudación neta de la DGI constantes	ADL-MIDAS	0,99	1,02	0,91	0,93
	U-MIDAS	0,98	1,02	0,93	0,94
	TF-MIDAS	0,78	1,12	1,01	0,97
Recaudación de IVA constantes	ADL-MIDAS	1,06	1,02	0,98	0,95
	U-MIDAS	0,98	1,04	0,99	0,92
	TF-MIDAS	0,84	1,04	1,07	1,00
Cotizantes de BPS	ADL-MIDAS	0,99	1,03	0,80	0,87
	U-MIDAS	0,97	1,03	0,89	0,92
	TF-MIDAS	0,83	0,99	0,86	1,04
Índice de confianza al consumidor	ADL-MIDAS	0,90	1,01	0,76	0,81
	U-MIDAS	0,91	1,01	0,77	0,82
	TF-MIDAS	0,84	0,99	0,75	0,85
ICC - Subíndice situación económica personal	ADL-MIDAS	0,95	1,02	0,78	0,89
	U-MIDAS	0,98	1,04	0,88	0,89
	TF-MIDAS	0,86	0,97	0,87	0,93
ICC - Subíndice situación económica del país	ADL-MIDAS	0,98	1,00	0,87	0,82
	U-MIDAS	1,02	1,01	0,90	0,82
	TF-MIDAS	0,87	0,99	0,88	0,88
ICC - Subíndice Intención de compra de bienes durables	ADL-MIDAS	0,93	1,01	0,74	0,83
	U-MIDAS	0,87	1,02	0,71	0,83
	TF-MIDAS	0,86	1,00	0,68	0,89
Índice de confianza al consumidor de Brasil	ADL-MIDAS	0,88	1,03	0,82	0,79
	U-MIDAS	0,80	1,02	0,81	0,79
	TF-MIDAS	0,64	1,05	0,76	0,85
IVF Producción Industrias Manufactureras	ADL-MIDAS	1,15	1,02	0,90	0,93
	U-MIDAS	1,10	1,03	0,84	0,95
	TF-MIDAS	0,92	0,94	0,87	1,08
IVF Producción Núcleo Industrias Manufactureras	ADL-MIDAS	1,07	1,00	1,12	0,98
	U-MIDAS	0,98	1,06	1,00	0,96
	TF-MIDAS	0,67	1,04	0,96	0,81
Masa Salarial real	ADL-MIDAS	1,03	0,99	0,87	0,95
	U-MIDAS	1,05	1,04	0,99	0,95
	TF-MIDAS	0,68	0,91	0,98	1,07
Población Ocupada total país	ADL-MIDAS	1,07	1,08	0,87	0,94
	U-MIDAS	1,06	1,05	1,01	0,93
	TF-MIDAS	0,69	1,00	1,03	0,89
Población Activa total país	ADL-MIDAS	1,10	1,04	0,95	0,96
	U-MIDAS	1,06	1,05	0,97	0,96
	TF-MIDAS	0,70	1,07	0,91	0,89
Stock de crédito en moneda extranjera	ADL-MIDAS	0,94	1,01	0,77	0,93
	U-MIDAS	0,97	1,02	0,80	0,93
	TF-MIDAS	0,88	1,04	0,83	0,91
Stock de crédito total	ADL-MIDAS	0,99	1,05	0,90	1,02
	U-MIDAS	0,97	1,05	0,90	1,02
	TF-MIDAS	0,88	0,97	0,86	0,96
IBC - Brasil	ADL-MIDAS	1,13	1,28	1,04	1,02
	U-MIDAS	1,10	1,10	1,05	1,02
	TF-MIDAS	0,75	1,27	0,99	0,95
EMAE - Argentina	ADL-MIDAS	1,53	1,04	0,95	0,93
	U-MIDAS	1,47	1,05	1,00	0,94
	TF-MIDAS	0,63	1,34	0,93	0,99
Comercio Mundial	ADL-MIDAS	1,16	1,12	1,10	1,01
	U-MIDAS	1,18	1,01	1,00	0,95
	TF-MIDAS	0,92	1,03	0,94	1,02

¹ Se resaltan aquellos casos en que la RECM relativa es al menos un 5% menor.

² Período de evaluación 2016T1-2021T2.

³ Período de evaluación 2016T1-2019T4.

U-MIDAS con ninguno de los 25. Se observa entonces, en un principio, una importante dificultad para predecir la variable de interés 2 trimestres adelante¹.

Al limitar la muestra de evaluación al período 2016T1-2019T4 que excluye la pandemia de COVID-19, las tres metodologías presentan resultados más parecidos y mejoran mucho su capacidad de realizar *forecasting*. En primer lugar, en el *nowcasting*, las tres metodologías obtienen una RECM menor a la del AR(1) con 18 de los 25 indicadores (aunque no son los mismos 18 indicadores para las tres metodologías)². En tanto, en cuanto al *forecasting*, el U-MIDAS obtiene una RECM inferior a la del AR(1) en 21 de los 25 indicadores, mientras que el ADL-MIDAS y el TF-MIDAS lo hacen mejor que el AR(1) con 19 de los 25 indicadores³.

Para poder evaluar de forma más sintética el desempeño relativo entre las tres metodologías de frecuencias mixtas, y el modelo tomado como *benchmark*, se presentan en la tabla 3.4 el promedio y la mediana del ratio de la RECM de las predicciones realizadas por los respectivos modelos MIDAS contra el modelo AR(1). En línea con lo que observado más arriba, el modelo TF-MIDAS resulta, en promedio y en mediana, ser el mejor al momento de realizar *nowcasting*, obteniendo mejores resultados que el AR(1) y que las otras dos metodologías. En tanto, en el *forecasting* los resultados son más parejos entre las tres metodologías MIDAS. En este horizonte, al considerar la muestra de evaluación completa, las tres metodologías obtienen peores resultados que el AR(1). Mientras que, al excluir de la muestra de evaluación el período afectado por la pandemia de COVID-19, las tres metodologías obtienen resultados muy parecidos y mejores que los del AR(1).

En paralelo, en la tabla 3.5 se presentan los mismos resultados pero en lugar de considerar la RECM, se considera el error mediano absoluto (EMA) de los distintos modelos. En la ecuación 3.9 se detalla el cálculo del error absoluto.

$$EA = |\hat{y}_{Tk+esk|Tk+esk-h} - y_{Tk+esk}| \quad (3.9)$$

donde $es = 1, 2, \dots, ES$, refiere a los distintos períodos para los que se realizó la evaluación fuera de la muestra. Se obtienen entonces los ES errores absolutos

¹Si se consideran solo los modelos que obtienen una RECM al menos 5% menor a la del AR(1) se obtiene: TF-MIDAS (3 de 25); U-MIDAS y ADL-MIDAS (0 de 25).

²Si se consideran solo los modelos que obtienen una RECM al menos 5% menor a la del AR(1) se obtiene: TF-MIDAS (13 de 25); U-MIDAS (10 de 25) y ADL-MIDAS (14 de 25).

³Si se consideran solo los modelos que obtienen una RECM al menos 5% menor a la del AR(1) se obtiene: TF-MIDAS (13 de 25); U-MIDAS (18 de 25) y ADL-MIDAS (15 de 25).

Tabla 3.4: Promedio y mediana de la RECM relativa de ADL-MIDAS, U-MIDAS y TF-MIDAS para los 25 indicadores vs AR(1)¹

		Nowcasting ²	Forecasting ²	Nowcasting 19 ³	Forecasting 19 ³
ADL-MIDAS		1,04	1,04	0,94	0,94
U-MIDAS	Promedio	1,01	1,04	0,94	0,94
TF-MIDAS		0,80	1,04	0,93	0,95
ADL-MIDAS		1,01	1,03	0,93	0,94
U-MIDAS	Mediana	0,98	1,03	0,97	0,94
TF-MIDAS		0,84	1,01	0,94	0,95

¹ Se resaltan aquellos casos en que la RECM relativa es al menos un 5% menor.
² Período de evaluación 2016T1-2021T2.
³ Período de evaluación 2016T1-2019T4.

y se calcula la mediana.

Esta evaluación se presenta como un complemento de lo visto con la RECM, ya que la RECM castiga más severamente a los errores más grandes. Esto en parte puede ser deseable, ya que un error muy grande puede llevar a decisiones de política equivocadas, pero también puede llevar a que un modelo que funciona muy bien en la gran mayoría de los trimestres se vea afectado de sobremanera en su evaluación de precisión por unos pocos trimestres en los que tuvo un mal desempeño. En este sentido, la RECM puede estar bastante afectada por los resultados obtenidos durante los peores trimestres del año 2020, período en el que la pandemia de COVID-19 afectó severamente a las economías del mundo, de formas poco usuales, y los modelos tuvieron problemas importantes para realizar predicciones acertadas en este contexto.

De esta forma, los resultados observados en la tabla 3.5 son en términos generales más parecidos a los que se observan cuando el período de evaluación se corta en 2019, ya que los errores atípicos del 2020 quedan por arriba de la mediana y no la afectan de manera importante. En este sentido, las tres metodologías logran, con la mayoría de los indicadores y para ambos horizontes de proyección, un error mediano absoluto menor al obtenido por el modelo AR(1). El modelo TF-MIDAS se mantiene como el modelo más preciso al momento de realizar *nowcasting* en la muestra de evaluación completa, y en este caso, también lo es al realizar *forecasting*¹. En la tabla 3.6, se observa que las tres metodologías MIDAS logran, en promedio y en mediana, en la muestra

¹Si se consideran solo los modelos que obtienen un EMA al menos 5% menor al del AR(1) en el caso del *nowcasting* se obtiene: TF-MIDAS (16 de 25); U-MIDAS (14 de 25) y ADL-MIDAS (15 de 25). En el caso del *forecasting* se obtiene: TF-MIDAS (20 de 25); U-MIDAS (17 de 25) y ADL-MIDAS (17 de 25).

completa y para los dos horizontes de proyección, un menor error mediano absoluto que el modelo AR(1). Esto estaría en línea con lo observado en la RECM de las tres metodologías considerando solo el período de evaluación 2016T1-2019T4.

En el anexo se colocan las tablas con los resultados que surgen de comparar el desempeño predictivo de las tres metodologías MIDAS contra un modelo AR(2) estimado de forma recursiva y contra el promedio histórico del crecimiento del PIB de la muestra de estimación (también calculado de forma recursiva). En el primer caso, las tres metodologías MIDAS tienen un mejor desempeño que el modelo AR(2) tomado como referencia, tanto en la muestra completa como en la evaluación hasta 2019T4, y tanto en el *nowcasting* como en el *forecasting*. En tanto, al tomar como referencia el promedio histórico de la muestra de estimación, solo el promedio de los TF-MIDAS obtiene un RECM menor que el de referencia cuando se realiza el *nowcasting* en el período de evaluación completo. Mientras que en este mismo período de evaluación las tres metodologías MIDAS tienen un peor desempeño que el promedio histórico en el *forecasting*. Por otro lado, al considerar solo el período de evaluación hasta 2019, los tres modelos obtienen mejores resultados predictivos que el modelo de referencia, tanto en el *nowcasting* como en el *forecasting*.

Tabla 3.5: Error mediano absoluto relativo de modelos ADL-MIDAS, U-MIDAS y TF-MIDAS para cada uno de los 25 indicadores vs AR(1)¹

Indicador	Metodología	Nowcasting ²	Forecasting ²	Nowcasting 19 ³	Forecasting 19 ³
Unidades vendidas de automóviles 0 km	ADL-MIDAS	1,14	0,89	0,92	1,02
	U-MIDAS	1,35	0,96	0,74	1,01
	TF-MIDAS	1,03	1,01	1,16	0,91
Importaciones de bienes sin petróleo constantes	ADL-MIDAS	0,86	1,06	0,61	0,87
	U-MIDAS	0,82	0,95	0,93	0,90
	TF-MIDAS	1,04	0,72	0,95	0,85
Importaciones de bienes intermedios sin energéticos constantes	ADL-MIDAS	1,03	0,76	0,98	0,79
	U-MIDAS	0,90	1,03	0,99	0,96
	TF-MIDAS	0,75	0,77	0,83	1,00
Importaciones de bienes de consumo constantes	ADL-MIDAS	1,01	0,82	0,94	0,84
	U-MIDAS	0,93	0,94	0,88	1,06
	TF-MIDAS	0,76	0,95	0,95	1,19
Importaciones de bienes de consumo sin autos constantes	ADL-MIDAS	1,20	0,93	0,99	1,10
	U-MIDAS	1,00	0,94	1,10	1,06
	TF-MIDAS	0,90	0,91	0,93	1,03
Exportaciones de bienes constantes	ADL-MIDAS	0,98	0,96	0,93	0,91
	U-MIDAS	0,98	0,97	0,98	1,14
	TF-MIDAS	1,01	0,85	1,12	1,00
Exportaciones de bienes sin cultivos constantes	ADL-MIDAS	0,85	0,89	0,98	0,96
	U-MIDAS	1,01	0,90	0,98	0,99
	TF-MIDAS	0,81	0,85	0,98	0,98
Recaudación neta de la DGI constantes	ADL-MIDAS	0,89	0,86	0,64	0,97
	U-MIDAS	0,92	0,92	0,87	1,04
	TF-MIDAS	1,04	0,91	0,71	1,05
Recaudación de IVA constantes	ADL-MIDAS	0,84	0,82	0,93	0,88
	U-MIDAS	0,97	0,95	1,00	0,91
	TF-MIDAS	0,87	0,84	1,09	0,82
Cotizantes de BPS	ADL-MIDAS	0,88	0,83	0,95	0,74
	U-MIDAS	0,84	0,85	0,90	1,10
	TF-MIDAS	0,96	0,80	0,99	0,90
Índice de confianza al consumidor	ADL-MIDAS	0,73	0,67	0,62	0,83
	U-MIDAS	0,93	0,67	0,77	0,84
	TF-MIDAS	0,86	0,71	0,86	0,96
ICC - Subíndice situación económica personal	ADL-MIDAS	0,67	0,90	0,74	1,09
	U-MIDAS	0,95	1,00	0,96	1,05
	TF-MIDAS	0,99	0,99	0,70	1,32
ICC - Subíndice situación económica del país	ADL-MIDAS	1,04	0,77	0,96	0,85
	U-MIDAS	0,99	0,83	1,04	0,83
	TF-MIDAS	0,81	0,60	0,96	0,75
ICC - Subíndice Intención de compra de bienes durables	ADL-MIDAS	0,88	0,77	0,68	0,88
	U-MIDAS	0,84	0,69	0,69	0,89
	TF-MIDAS	0,66	0,78	0,73	0,82
Índice de confianza al consumidor de Brasil	ADL-MIDAS	0,90	0,72	0,92	0,91
	U-MIDAS	0,86	0,75	0,97	0,96
	TF-MIDAS	0,72	0,78	0,88	1,02
IVF Producción Industrias Manufactureras	ADL-MIDAS	0,73	0,91	0,77	1,01
	U-MIDAS	0,71	0,93	0,77	1,06
	TF-MIDAS	0,46	0,84	0,51	1,08
IVF Producción Núcleo Industrias Manufactureras	ADL-MIDAS	1,34	0,86	1,01	1,22
	U-MIDAS	1,11	1,01	0,89	1,13
	TF-MIDAS	1,19	0,69	0,83	0,91
Masa Salarial real	ADL-MIDAS	0,75	0,95	0,73	1,04
	U-MIDAS	0,93	0,93	1,01	1,03
	TF-MIDAS	0,84	0,78	1,05	1,11
Población Ocupada total país	ADL-MIDAS	0,99	1,01	0,95	0,98
	U-MIDAS	1,03	0,91	1,06	1,02
	TF-MIDAS	1,00	0,70	1,13	0,97
Población Activa total país	ADL-MIDAS	0,92	0,97	1,07	1,23
	U-MIDAS	0,95	0,96	1,02	1,16
	TF-MIDAS	0,82	0,78	0,76	0,97
Stock de crédito en moneda extranjera	ADL-MIDAS	0,76	0,97	0,87	1,06
	U-MIDAS	0,78	0,94	0,84	1,10
	TF-MIDAS	0,76	0,84	0,85	1,03
Stock de crédito total	ADL-MIDAS	0,82	1,07	0,92	0,92
	U-MIDAS	0,90	1,12	0,92	0,92
	TF-MIDAS	0,85	0,82	0,86	0,70
IBC - Brasil	ADL-MIDAS	1,17	1,08	0,95	1,08
	U-MIDAS	1,10	1,02	0,92	1,22
	TF-MIDAS	0,82	0,86	0,97	0,93
EMAE - Argentina	ADL-MIDAS	1,12	0,95	0,89	0,85
	U-MIDAS	1,03	0,87	1,03	1,04
	TF-MIDAS	0,77	1,10	0,95	0,99
Comercio Mundial	ADL-MIDAS	0,92	1,12	0,73	0,98
	U-MIDAS	1,05	0,94	1,00	1,02
	TF-MIDAS	0,59	1,02	0,74	1,01

¹ Se resaltan aquellos casos en que la EMA relativa es al menos un 5% menor.

² Período de evaluación 2016T1-2021T2.

³ Período de evaluación 2016T1-2019T4.

Tabla 3.6: Promedio y mediana del EMA relativo de ADL-MIDAS, U-MIDAS y TF-MIDAS para los 25 indicadores vs AR(1)¹

		Nowcasting ²	Forecasting ²	Nowcasting 19 ³	Forecasting 19 ³
ADL-MIDAS		0,94	0,90	0,87	0,96
U-MIDAS	Promedio	0,96	0,92	0,93	1,02
TF-MIDAS		0,85	0,84	0,90	0,97
ADL-MIDAS		0,90	0,90	0,92	0,96
U-MIDAS	Mediana	0,95	0,94	0,96	1,03
TF-MIDAS		0,84	0,84	0,93	0,98

¹ Se resaltan aquellos casos en que la EMA relativa es al menos un 5% menor.

² Período de evaluación 2016T1-2021T2.

³ Período de evaluación 2016T1-2019T4.

Capítulo 4

Combinación de predicciones

Se ha escrito una amplia literatura sobre las ventajas de optar por algún tipo de combinación de predicciones, en lugar de considerar solo un modelo específico (Bates & Granger (1969), Hendry & Clements (2004), Stock & Watson (2004), Timmermann (2006) y Aiolfi et al. (2011)). La combinación de pronósticos permite una ganancia en la diversificación frente a considerar un único modelo predictivo. Distintos modelos pueden verse afectados de distinta manera frente a cambios estructurales. Por ejemplo, modelos cuyos parámetros tardan más en adaptarse a nuevos datos, puede que en tiempos estables funcionen mejor, pero que tras un cambio estructural importante demoren mucho en ajustarse a la nueva realidad. Mientras que otros modelos que ajustan con mayor velocidad sus parámetros se verán afectados solo transitoriamente por el cambio estructural, pero serán a la vez más inestables.

Por otro lado, los modelos considerados de forma individual están sujetos a una mala especificación y a sesgos de forma desconocida. Incluso en un mundo de procesos estacionarios, el verdadero proceso generador de datos es desconocido y probablemente más complejo de lo que nuestro mejor modelo puede representar. Por lo que es poco probable que un solo modelo domine a todo el resto de los modelos bajo todos los escenarios y momentos del tiempo. La combinación de modelos puede ser vista entonces como una forma de encontrar mayor robustez contra los sesgos y errores de medida en nuestros datos y modelos.

En este sentido, cuando se dispone de predicciones que fueron realizadas a partir de supuestos diferentes sobre la relación entre las variables, o a partir de diferentes indicadores que no están perfectamente correlacionados, se podrían

lograr ganancias de la combinación de predicciones.

Timmermann (2006) analiza de forma extensiva distintas posibilidades de combinación de pronósticos y algunas de sus ventajas y desventajas. Al asumir una función de pérdidas de tipo error cuadrático medio se puede derivar un esquema de combinaciones óptimo. Sin embargo, las dificultades en la estimación de los parámetros para la ponderación bajo este esquema hacen que los resultados empíricos no hayan sido buenos. Estas dificultades en la estimación de los parámetros se atribuyen en buena medida a las dificultades de estimación de la matriz de varianzas y covarianzas de los errores. Este problema es mayor aún cuando la cantidad de pronósticos a combinar es elevada en comparación con el tamaño de la muestra.

En este marco surgen distintas combinaciones que no requieren la estimación de parámetros, por lo cual se les denomina no paramétricas. Si bien los resultados de los ejercicios empíricos sobre combinación de pronósticos deben tomarse con precaución, las combinaciones simples de modelos han sido difíciles de superar. Esta cautela se debe a que estos resultados dependen del número de modelos empleados, del tamaño de la muestra de estimación, de la inestabilidad de los datos analizados, y de la estructura de la matriz de varianzas y covarianzas de los errores de predicción.

Al mismo tiempo, dentro de esta familia de combinaciones de pronósticos no paramétricas, Stock & Watson (2004) encuentran en su ejercicio empírico que las combinaciones que obtienen un mejor desempeño son las que menos adaptan el esquema de ponderación a los resultados previos. Los esquemas de ponderación con menor variación en sus pesos ponderados son también los que resultan más estables a lo largo del tiempo. Cuando se permiten cambios muy importantes en las ponderaciones a lo largo del tiempo no se obtienen buenos resultados al compararlos en distintos períodos. Este resultado estaría en contra de lo que se podría pensar intuitivamente, ya que los cambios en los pesos permitirían lidiar con la inestabilidad de los datos.

Siguiendo esta literatura se realizan algunos ejercicios de combinaciones de pronósticos no paramétricas de forma de explotar de la mejor manera posible la información de los 25 modelos estimados para cada una de las metodologías.

Se evalúan entonces en primer lugar cuatro tipos de combinaciones de pronósticos: promedio simple de todos los modelos, promedio simple descartando los peores 2 (8% del total) modelos en la evaluación fuera de la muestra hasta el momento de la predicción, promedio ponderado por la inversa

del error cuadrático medio con un factor de descuento temporal y el promedio ponderado por la inversa del error cuadrático medio de los últimos 4 períodos (sin factor de descuento temporal). Por último, se evalúa el desempeño de considerar solo las predicciones del modelo con menor error cuadrático medio hasta el momento de la predicción (utilizando el mismo factor de descuento temporal empleado en la combinación de pronósticos por la inversa del ECM).

La combinación de modelos puede definirse para los 4 métodos de combinación analizados como sigue:

$$\hat{y}_{t+sk|t+sk-h} = \sum_{i=1}^M w_{i,t} \hat{y}_{i,t+sk|t+sk-h} \quad (4.1)$$

siendo M la cantidad de modelos a combinar, $w_{i,t}$ el peso otorgado al modelo i . En los casos de combinación mediante el promedio simple $w_{i,t} = 1/M$. En tanto, en los casos de las combinaciones mediante la inversa del error cuadrático medio se tiene:

$$w_{i,t} = \frac{\lambda_{i,t}^{-1}}{\sum_{j=1}^M \lambda_{j,t}^{-1}}; \quad \lambda_{i,t} = \sum_{\tau=0}^{T_0} \delta^\tau (y_{t-\tau k} - \hat{y}_{i,t-\tau k|t-\tau k-h})^2 \quad (4.2)$$

donde δ es el factor de descuento temporal que permite darle mayor importancia al desempeño reciente del modelo, frente al desempeño obtenido con anterioridad. En el ejercicio de combinación de pronósticos ponderando por la inversa del error cuadrático medio se definió $\delta = 0,85^1$. En tanto, T_0 refiere a la cantidad de trimestres hacia atrás para los que se considera el ECM. En este ejercicio se consideran los errores desde 2015T1. De esta forma, si bien el período 2015T1-2015T4 no es considerado en los resultados de evaluación fuera de la muestra, sí se computa su error cuadrático medio (siguiendo la misma metodología de evaluación recursiva y pseudo-fuera de la muestra) para poder utilizarlo en las ponderaciones del período evaluado (2016T1 - 2021T2). Por otro lado, al realizar el promedio ponderado por la inversa del error cuadrático medio de los últimos 4 períodos no se aplicó un factor de descuento dentro de estos cuatros períodos, por lo que $\delta = 1$ y $T_0 = 4$.

En la tabla 4.1 se presentan los resultados de estas cuatro posibilidades de combinación de pronósticos y de considerar solo el mejor modelo, para cada una de las tres metodologías. En términos generales, se observa que no hay

¹También se realizó el ejercicio con $\delta = 0,90$ y con $\delta = 0,95$ y los resultados fueron similares.

grandes diferencias en los resultados de las cuatro metodologías de combinación de pronósticos analizadas. En tanto, al considerar solo el mejor modelo se obtienen resultados que difieren más de los observados con las metodologías de combinación de pronósticos.

En línea con lo observado en el capítulo 3, al realizar las combinaciones de pronósticos, el modelo TF-MIDAS continúa siendo el que muestra un mejor desempeño predictivo. En este sentido, el modelo TF-MIDAS obtiene una RECM menor a la del AR(1) tanto en el ejercicio de evaluación de *nowcasting* de la muestra completa, como en el *nowcasting* y *forecasting* evaluado para el período 2016T1-2019T4. En el caso del *forecasting* evaluado para el período de evaluación completo, el resultado es similar al de AR(1).

La combinación de predicciones del modelo U-MIDAS permite obtener resultados mínimamente mejores que los del AR(1) para el *nowcasting* en la evaluación completa, al tiempo que en el *forecasting* son mínimamente peores. Al reducir la evaluación al período 2016T1-2019T4 los resultados de las combinaciones de pronósticos son mejores que los del AR(1) y más parecidas a las del TF-MIDAS en ambos horizontes de predicción.

En tanto, la combinación de los modelos ADL-MIDAS en el período de evaluación 2016T1-2019T4 obtiene resultados similares a los vistos para U-MIDAS y TF-MIDAS, mientras que en la muestra completa no logra realizar mejores predicciones que el AR(1), ni en *nowcasting* ni en *forecasting*.

Si se observa el desempeño de seleccionar el mejor modelo los resultados son más volátiles. Si bien en el caso del ADL-MIDAS y del U-MIDAS se observa una mejora en el *nowcasting* al considerar la muestra de evaluación completa, si se restringe la evaluación fuera de la muestra al período 2016T1-2019T4 este resultado se invierte. Al mismo tiempo, las predicciones del mejor modelo de *nowcasting* de la metodología TF-MIDAS obtiene peores resultados que la combinación de predicciones, tanto en la evaluación completa, como al reducir el período de evaluación hasta 2019. Mientras, en el caso de *forecasting*, los resultados aplicando el mejor modelo son peores para las tres metodologías que los obtenidos mediante las combinaciones de predicciones.

Por otro lado, como una medida de la bondad de la combinación de pronósticos, se presenta en la tabla 4.2 el porcentaje de modelos que considerados individualmente reportan una RECM menor a la obtenida mediante la combinación de pronósticos. En este sentido, se observa que la combinación de pronósticos implica una mejora de las predicciones respecto a

Tabla 4.1: RECM relativa de las combinaciones de pronósticos vs AR(1)¹

		Nowcasting ²	Forecasting ²	Nowcasting19 ³	Forecasting19 ³
ADL-MIDAS	Promedio simple	1,00	1,02	0,87	0,91
	Promedio recortado	1,01	1,02	0,87	0,90
	ECM 4 períodos	1,00	1,02	0,87	0,90
	ECM descontado	1,00	1,02	0,87	0,91
	Mejor modelo	0,93	1,05	0,95	0,92
U-MIDAS	Promedio simple	0,99	1,03	0,89	0,92
	Promedio recortado	0,97	1,03	0,89	0,91
	ECM 4 períodos	0,98	1,03	0,88	0,90
	ECM descontado	0,98	1,03	0,88	0,91
	Mejor modelo	0,83	1,05	0,90	0,87
TF-MIDAS	Promedio simple	0,76	1,01	0,86	0,90
	Promedio recortado	0,75	1,00	0,86	0,89
	ECM 4 períodos	0,74	1,00	0,84	0,90
	ECM descontado	0,74	1,00	0,85	0,90
	Mejor modelo	0,90	1,07	0,93	1,04

¹ Se resaltan aquellos casos en que la RECM relativa es al menos un 5 % menor.
² Período de evaluación 2016T1-2021T2.
³ Período de evaluación 2016T1-2019T4.

la mayoría de los modelos considerados individualmente.

Al observar el período de evaluación completo, se observa que en casi todos los casos la combinación de modelos obtiene mejores resultados que más de la mitad de los modelos considerados individualmente. Mientras que al considerar el período de evaluación hasta 2019 la mejora lograda por la combinación de predicciones es aún mayor. En este período la combinación de predicciones realiza pronósticos más precisos para más del 75 % de los modelos considerados individualmente en cualquiera de las tres metodologías (excepto en el ejercicio de *forecasting* del TF-MIDAS, donde esta mejora se observa frente al 68 % de los modelos).

Tabla 4.2: Porcentaje de modelos individuales que reportan una RECM menor a la combinación de modelos

	Nowcasting ¹	Forecasting ¹	Nowcasting19 ²	Forecasting19 ²
ADL-MIDAS	48 %	44 %	24 %	24 %
U-MIDAS	52 %	36 %	20 %	20 %
TF-MIDAS	32 %	44 %	16 %	32 %

¹ Período de evaluación 2016T1-2021T2.
² Período de evaluación 2016T1-2019T4.

Por último, se realiza una comparación del desempeño predictivo de los indicadores *soft* y de los indicadores *hard*. En la tabla 1.10 en anexo se detallan los indicadores considerados *soft* y los indicadores considerados *hard* (indicadores *hard* refieren principalmente a indicadores de actividad

directamente relacionados con los distintos componentes del PIB; indicadores *soft*, principalmente relacionados con indicadores de expectativas). Para esto, se opta por combinar por un lado los indicadores *soft* y por otro lado los indicadores *hard* y evaluar el desempeño de ambas combinaciones de variables. En algunos trabajos de predicciones en tiempo real con frecuencias mixtas (Bańbura & Rünstler (2007), Giannone et al. (2008), Bańbura et al. (2013)) se ha destacado el rol de las variables *soft* en las predicciones del nivel de actividad. Este tipo de variables suelen publicarse muy rápido, por lo que son muy oportunas. Al trabajar con frecuencias mixtas esta ventaja puede ser explotada, utilizando más información disponible que en la mayoría de los indicadores *hard*, que son publicados con mayor rezago. Además, estos indicadores incorporan un cierto componente de predicciones propios de los agentes que pueden brindar información adicional a los modelos no contenida dentro de los indicadores *hard*.

Por un lado se realizó el promedio simple de las predicciones que surgen de los modelos de los indicadores *soft* (en total se dispone de 5 indicadores *soft*) y por otro lado se realizó el promedio simple de las predicciones que surgen de los modelos de los indicadores *hard* (en total 20 indicadores *hard*). Se presenta en el cuadro 4.3 el ratio de la RECM de estas dos combinaciones de modelos frente a la RECM del modelo AR(1) considerado como benchmark. Se observa en el caso de ADL-MIDAS y U-MIDAS que la combinación de modelos con indicadores *soft* logra mejores resultados que la combinación de modelos con indicadores *hard* en ambos horizontes de predicción y en ambos períodos de evaluación. En el caso del modelo TF-MIDAS, la combinación de predicciones obtenidas con indicadores *hard* logra un mejor desempeño en *nowcasting* en la muestra de evaluación completa, mientras que al restringir la evaluación al período 2016T1-2019T4 la combinación de predicciones obtenidas con indicadores *soft* logra un mejor desempeño. En tanto, la combinación de modelos con indicadores *soft* también logra mayor precisión en los ejercicios de forecasting con esta metodología, cualquiera sea el período de evaluación considerado.

Por último, se realiza el promedio simple de las predicciones obtenidas mediante la combinación de modelos con indicadores *soft* por un lado y la combinación de modelos con indicadores *hard* por otro lado para evaluar si así el desempeño es mejor al obtenido por el promedio simple de todos los indicadores. Se observa que si bien el desempeño entre ambas formas de realizar

las combinaciones no difieren demasiado en sus resultados, en casi todos los casos la combinación de modelos con indicadores *soft* y *hard* por separado y luego promediados obtienen resultados levemente mejores que el promedio simple de todos los indicadores.

Tabla 4.3: RECM relativa de combinación de modelos con indicadores *hard* y *soft* vs AR(1)¹

		Nowcasting ²	Forecasting ²	Nowcasting19 ³	Forecasting19 ³
ADL-MIDAS	Hard	1,04	1,03	0,91	0,94
	Soft	0,92	1,01	0,77	0,81
	Hard+Soft	0,96	1,02	0,82	0,87
	Promedio simple	1,00	1,02	0,87	0,91
U-MIDAS	Hard	1,02	1,03	0,93	0,95
	Soft	0,91	1,02	0,79	0,81
	Hard+Soft	0,95	1,02	0,84	0,87
	Promedio simple	0,99	1,03	0,89	0,92
TF-MIDAS	Hard	0,75	1,02	0,91	0,91
	Soft	0,80	0,99	0,73	0,86
	Hard+Soft	0,77	1,00	0,80	0,88
	Promedio simple	0,76	1,01	0,86	0,90

¹ Se resaltan aquellos casos en que la RECM relativa es al menos un 5% menor.

² Período de evaluación 2016T1-2021T2.

³ Período de evaluación 2016T1-2019T4.

Capítulo 5

Conclusiones

En este trabajo se realizó la estimación, evaluación y comparación del desempeño predictivo de los modelos en frecuencias mixtas ADL-MIDAS, U-MIDAS y TF-MIDAS para realizar *nowcasting* y *forecasting* de muy corto plazo de la evolución del nivel de actividad de la economía uruguaya.

Se evaluó la precisión predictiva de las tres metodologías MIDAS consideradas en dos períodos de evaluación solapados, uno desde el primer trimestre de 2016 hasta el segundo trimestre de 2021 (incluyendo la pandemia del COVID-19) y otro desde el primer trimestre de 2016 hasta el cuarto trimestre de 2019. Se consideraron dos medidas de precisión (RECM y EMA) y se compararon los resultados obtenidos con los correspondientes a varios modelos de referencia (AR(1), AR(2) y el promedio histórico). En términos generales, la pandemia de COVID-19 supuso una mayor dificultad para generar predicciones certeras. En el primer período de evaluación solo los modelos TF-MIDAS lograron un mejor desempeño que los modelos *benchmark* en el ejercicio de *nowcasting*, mientras que en el *forecasting* ninguna metodología logró vencer a los modelos *benchmark*. En tanto, cuando se excluyen los datos del 2020 y 2021 las tres metodologías mejoran sustantivamente y vencen a los modelos *benchmark* en ambos horizontes de predicción analizados. Estos resultados están en línea con los observados cuando en lugar de considerar como medida de precisión la raíz del error cuadrático medio (RECM) se considera la mediana de los errores absolutos (EMA). Con esta medida, que penaliza menos los errores más grandes, las tres metodologías obtienen mejores resultados que los modelos *benchmark* en cualquiera de los dos períodos de evaluación considerados.

En línea con lo que se podría esperar en la teoría (Bonino-Gayoso & Garcia-Hiernaux (2021)), la metodología TF-MIDAS resultó ser la que realizó predicciones más precisas, tanto en *nowcasting* como en *forecasting*, especialmente al realizar *nowcasting* en el período de evaluación que incluye la pandemia por COVID-19. Las metodologías U-MIDAS y ADL-MIDAS, por su parte, obtuvieron un desempeño predictivo similar en ambos horizontes de predicción.

El mejor desempeño relativo de la metodología TF-MIDAS se observó principalmente en los años 2020 y 2021. En estos años si bien la capacidad predictiva empeoró respecto a los años anteriores, a causa de la irrupción del COVID-19, esta metodología fue la que logró mejores resultados. De hecho, cuando el período de evaluación se limita a 2016T1-2019T4, la RECM de predicción de las tres metodologías es similar, tanto para *nowcasting* como para *forecasting*, y en todos los casos es menor que la de los modelos *benchmark* considerados. Esta mayor capacidad predictiva observada en los modelos TF-MIDAS ante un cambio importante como el COVID-19 puede asociarse a que esta metodología incorpora un componente de medias móviles al término del error del modelo.

Los modelos TF-MIDAS serían entonces especialmente recomendables para aquellos períodos con mayor inestabilidad e incertidumbre, mientras que en períodos más estables cualquiera de las tres metodologías MIDAS analizadas reporta un desempeño predictivo similar y superior al de los modelos *benchmark* considerados.

Por otro lado, siguiendo la literatura de la combinación de pronósticos, se evalúan cuatro métodos de combinación de las predicciones generadas a partir de los modelos estimados con los 25 indicadores mensuales considerados. En este sentido, se evalúa la combinación de predicciones mediante el promedio simple de modelos, mediante un promedio simple donde no se consideran los 2 modelos de peor desempeño predictivo pasado, mediante la inversa del ECM de predicción y mediante la inversa del ECM de predicción de los últimos 4 períodos. Los resultados de las distintas formas de combinación de modelos obtienen resultados similares. Además, estos resultados serían más estables, en los distintos horizontes de predicción y en los distintos períodos de evaluación, que los observados al considerar solo el modelo de mejor desempeño predictivo en el pasado.

Por último, se evaluó el desempeño relativo entre los modelos que

incorporan como regresores indicadores *soft* (que incorporan las expectativas de los agentes) y los modelos con indicadores *hard* (asociados directamente a los distintos componentes del PIB). El desempeño obtenido por la combinación de modelos con indicadores *soft* es en general mejor al observado en la combinación de modelos con indicadores *hard*. Como se ha observado en algunos trabajos previos, esto podría explicarse por la mayor prontitud con la que son publicados los indicadores *soft* (al trabajar con frecuencias mixtas se puede explotar esa información adicional) y por la incorporación de expectativas de los propios agentes directamente vinculadas al futuro de la actividad económica.

Una posible futura línea de investigación sería incorporar el análisis factorial al proceso de generación de predicciones. En este caso el primer paso consistiría en aplicar el análisis factorial para resumir la información, y luego incorporar estos factores como regresores en las distintas metodologías MIDAS analizadas. En este sentido, algunos trabajos han realizado este ejercicio con relativo éxito tanto a través de la metodología ADL-MIDAS, como U-MIDAS (Marcellino & Schumacher (2010), Andreou et al. (2013)), pero ninguno considera la metodología TF-MIDAS.

Referencias bibliográficas

- Aiolfi, M., Capistrán, C. & Timmermann, A. (2011), Forecast combinations, *in* M. P. Clements & D. Hendry, eds, ‘Oxford Handbook of Economic Forecasting’, Oxford University Press, pp. 355–388.
- Andreou, E., Ghysels, E. & Kourtellis, A. (2010), ‘Regression models with mixed sampling frequencies.’, *Journal of Econometrics* **158**(2), 246–261.
- Andreou, E., Ghysels, E. & Kourtellis, A. (2011), Forecasting with mixed-frequency data, *in* M. P. Clements & D. Hendry, eds, ‘Oxford Handbook of Economic Forecasting’, Oxford University Press, pp. 225–246.
- Andreou, E., Ghysels, E. & Kourtellis, A. (2013), ‘Should macroeconomic forecasters use daily financial data and how?’, *Journal of Business & Economic Statistics* **31**(2), 240–251.
- Armesto, M. T., Engemann, K. M. & Owyang, M. T. (2010), ‘Forecasting with mixed frequencies’, *Federal Reserve Bank of St. Louis Review* **92**(6), 521–536.
- Armesto, M. T., Hernández-Murillo, R., Owyang, M. T. & Piger, J. (2009), ‘Measuring the information content of the beige book: A mixed data sampling approach’, *Journal of Money, Credit and Banking* **41**(1), 35–55.
- Bańbura, M., Giannone, D., Modugno, M. & Reichlin, L. (2013), Now-casting and the real-time data flow, *in* G. Elliott & A. Timmermann, eds, ‘Handbook of Economic Forecasting’, Vol. 2 A, North Holland, chapter 4, pp. 195–237.
- Bańbura, M. & Rünstler, G. (2007), ‘A look into the factor model black box. publication lags and the role of hard and soft data in forecasting GDP’, *European Central Bank. Working paper* (751).

- Bates, J. M. & Granger, C. W. J. (1969), ‘The combination of forecasts’, *Operational Research Quarterly* **20**(4), 451–468.
- Bernanke, B. S. & Boivin, J. (2003), ‘Monetary policy in a data-rich environment’, *Journal of Monetary Economics* **50**(3), 525–546.
- Bonino-Gayoso, N. & Garcia-Hiernaux, A. (2021), ‘TF-MIDAS: a transfer function based mixed-frequency model’, *Journal of Statistical Computation and Simulation* **91**(10), 1980–2017.
- Camacho, M. & Perez-Quiros, G. (2010), ‘Introducing the euro-sting: Short-term indicator of euro area growth’, *Journal of applied Econometrics* **25**(4), 663–694.
- Casals, J. M., García-Hiernaux, A., Jerez, M., Sotoca, S. & Trindade, A. A. (2016), *State-Space Methods for Time Series Analysis: Theory, Applications and Software.*, Chapman and Hall.
- Clements, M. P. & Galvão, A. B. (2008), ‘Macroeconomic forecasting with mixed-frequency data: Forecasting output growth in the United States’, *Journal of Business & Economic Statistics* **26**(4), 546–554.
- Clements, M. P. & Galvão, A. B. (2009), ‘Forecasting US output growth using leading indicators: an appraisal using MIDAS models’, *Journal of Applied Econometrics* **24**(7), 1187–1206.
- Duarte, C. (2014), ‘Autorregresive augmentation of midas regressions’, *Banco de Portugal. Working paper* (1).
- Duarte, C., Rodrigues, P. M. M. & Rua, A. (2017), ‘A mixed frequency approach to the forecasting of private consumption with ATM/POS data’, *International Journal of Forecasting* **33**, 61–75.
- Froni, C., Marcellino, M. & Schumacher, C. (2011), ‘U-MIDAS: MIDAS regressions with unrestricted lag polynomials’, *Deutsche Bundesbank Discussion Paper* (35/2011).
- Froni, C., Marcellino, M. & Schumacher, C. (2015), ‘Unrestricted mixed data sampling (MIDAS): MIDAS regressions with unrestricted lag polynomials’, *Journal of the Royal Statistical Society Series* **178**, 57–82.

- Galli, A., Hepenstrick, C. & Scheufele, R. (2019), ‘Mixed-frequency models for tracking short-term economic developments in Switzerland’, *International Journal of Central Banking* **15**(2), 151–177.
- Ghysels, E. (2021), ‘MIDAS Matlab Toolbox’, *Technical report* .
- Ghysels, E., Santa-Clara, P. & Valkanov, R. (2002), ‘The MIDAS Touch: Mixed Data Sampling Regression Models’, *Working paper, UNC and UCLA* .
- Ghysels, E., Santa-Clara, P. & Valkanov, R. (2005), ‘There is a risk-return trade-off after all’, *Journal of Financial Economics* **76**(3), 509–548.
- Ghysels, E., Santa-Clara, P. & Valkanov, R. (2006), ‘Predicting volatility: getting the most out of return data sampled at different frequencies’, *Journal of Econometrics* **131**(1), 59–95.
- Ghysels, E., Sinko, A. & Valkanov, R. (2007), ‘MIDAS regressions: Further results and new directions’, *Econometric reviews* **26**(41), 56–90.
- Ghysels, E. & Wright, J. (2009), ‘Forecasting professional forecasters’, *Journal of Business & Economic Statistics* **27**(4), 504–516.
- Giannone, D., Reichlin, L. & Small, D. (2008), ‘Nowcasting: The real-time informational content of macroeconomic data’, *Journal of Monetary Economics* **55**, 665–676.
- Hendry, D. F. & Clements, P. (2004), ‘Pooling of forecasts’, *Econometrics Journal* **7**, 1–31.
- Koenig, E. F., Dolmas, S. & Piger, J. (2003), ‘The use and abuse of real-time data in economic forecasting’, *The Review of Economics and Statistics* **85**(3), 618–628.
- Kuzin, V., Marcellino, M. & Schumacher, C. (2011), ‘MIDAS vs. mixed-frequency VAR: Nowcasting GDP in the euro area’, *International Journal of Forecasting* **27**, 529–542.
- Marcellino, M. & Schumacher, C. (2010), ‘Factor-MIDAS for nowcasting and forecasting with ragged-edge data: a model comparison of German GDP’, *Oxford Bulletin of Economics and Statistics* **72**, 518–550.

- Rodríguez, H. (2014), ‘Un indicador de la evolución del PIB uruguayo en tiempo real’, *Banco Central del Uruguay, Documento de trabajo N°009* .
- Schumacher, C. & Breitung, J. (2008), ‘Real-time forecasting of German GDP based on a large factor model with monthly and quarterly data’, *International Journal of Forecasting* **24**, 386–398.
- Stock, J. H. & Watson, M. W. (2004), ‘Combination forecasts of output growth in a seven-country data set’, *Journal of Forecasting* **23**, 405–430.
- Timmermann, A. (2006), Forecast combinations, *in* G. Elliott, C. W. J. Granger & A. Timmermann, eds, ‘Handbook of Economic Forecasting’, Vol. 1, Amsterdam: North Holland, pp. 135–196.