

FORECASTING DEL PIB ARGENTINO

Autor: Martín Llada

Fuente: Revista de Economía Política de Buenos Aires, Año 16 Vol 25 (noviembre 2022), pp 37-72

Publicado por: Facultad de Ciencias Económicas de la Universidad de Buenos Aires.

RESUMEN

Este trabajo realiza un ejercicio de pronóstico de la tasa de crecimiento del PIB de Argentina durante 1998:Q1-2021:Q2. Se estima un modelo factorial para obtener una estimación temprana de la variable objetivo. Se evidencia que: i) el modelo factorial supera la performance de los modelos base; ii) las predicciones son más precisas conforme se acumula toda la información disponible; iii) la capacidad predictiva del modelo factorial aumenta cuando se incorpora un indicador de tono sobre el ciclo económico argentino, un indicador de incertidumbre económica, y un índice de presión sobre el mercado cambiario; iv) existen ganancias en términos de precisión predictiva derivadas de la combinación de modelos de pronóstico.

Palabras clave: Covid-19, frecuencias mixtas, modelo factorial, procesamiento de lenguaje natural, pronóstico macroeconómico

Llada, M. (2022). FORECASTING DEL PIB ARGENTINO. Revista de Economía Política de Buenos Aires, (25). 37-72. Recuperado a partir de <https://ojs.econ.uba.ar/index.php/REPBA/article/view/2411>



Esta revista está protegida bajo una licencia Creative Commons Attribution-NonCommercialNoDerivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>.

FORECASTING DEL PIB ARGENTINO¹

FORECASTING OF ARGENTINE GDP

Recibido: 5/10/2021. Aceptado: 24/08/2022

Martín Llada

<https://orcid.org/0000-0002-7526-8816>

RESUMEN

Este trabajo realiza un ejercicio de pronóstico de la tasa de crecimiento del PIB de Argentina durante 1998:Q1-2021:Q2. Se estima un modelo factorial para obtener una estimación temprana de la variable objetivo. Se evidencia que: i) el modelo factorial supera la performance de los modelos base; ii) las predicciones son más precisas conforme se acumula toda la información disponible; iii) la capacidad predictiva del modelo factorial aumenta cuando se incorpora un indicador de tono sobre el ciclo económico argentino, un indicador de incertidumbre económica, y un índice de presión sobre el mercado cambiario; iv) existen ganancias en términos de precisión predictiva derivadas de la combinación de modelos de pronóstico.

Palabras Clave: Covid-19, frecuencias mixtas, modelo factorial, procesamiento de lenguaje natural, pronóstico macroeconómico

ABSTRACT

We develop a forecast exercise of the real gross domestic product (GDP) growth of Argentina for the period 1998:Q1-2021:Q2. We estimated a factor model to produce an early estimation of the target variable. We evidence that: i) the factor model overperforms benchmark models, ii) the predictions are more accurate as all the available information is accumulated; iii) the forecast accuracy of the factor model increases when an economic uncertainty indicator, an exchange market pressure index and an indicator of economic sentiment are incorporated; iv) forecast model combinations allow gains in forecast accuracy.

Key words: Covid-19, dynamic factor model, natural language processing, macroeconomic forecasting, mixed frequency

¹ Agradezco los valiosos comentarios y múltiples interacciones con Daniel Aromí, Eva Senra y Pilar Poncela. * Universidad de Buenos Aires, Facultad de Ciencias Económicas, Instituto Interdisciplinario de Economía Política Email: lladamartin@gmail.com.

Códigos JEL: E32, E37, C33, C53

I. Introducción

Los hacedores de políticas de las diferentes áreas del gobierno requieren monitorear el estado actual de la economía, formar expectativas sobre éste y revisar dichas expectativas ante el arribo de nueva información conforme el estado de la economía diverja de las perspectivas formuladas en el pasado. La información sobre el estado actual de la economía es útil para la toma de decisiones y el diseño de la política económica. Una limitación que enfrentan los *policymakers* se vincula al retraso con el cual se publican los datos de indicadores económicos necesarios para monitorear la actividad económica. Por ejemplo, el Producto Interno Bruto (PIB) trimestral de Argentina se publica aproximadamente 80 días posterior a la finalización de dicho trimestre. Una forma de lidiar con esta limitación es utilizar modelos de pronósticos, por ejemplo, realizar un *nowcasting*, es decir, una predicción del presente, del futuro muy cercano y el pasado muy reciente de la variable objetivo (Giannone et al., 2008, Banbura et al., 2013). La esencia del *nowcasting* implica explotar información publicada de forma temprana y con mayor frecuencia, con el objeto de obtener una estimación temprana de la variable objetivo antes que la publicación del dato oficial.

Este trabajo pretende realizar una predicción de la tasa de crecimiento del PIB trimestral de Argentina -variable objetivo- explotando información pasada y corriente de un amplio set de indicadores económicos. Esta tarea involucra abordar dos cuestiones centrales. En primer lugar, la variable objetivo posee una frecuencia trimestral, mientras que la mayoría de los indicadores económicos están disponible a una frecuencia más alta. A través de un modelo econométrico se combinará los datos de diferente frecuencia muestral. En segundo lugar, las variables económicas están disponibles con un considerable retraso, esto es, existe una distancia entre el día en que se publican los datos y el periodo al cual refiere. Esto implica que el panel de datos utilizado en los modelos de pronósticos se encuentra desbalanceado al final del periodo muestral (problema que se conoce como datos *ragged-edge*). Como se mencionó previamente, la variable objetivo de este trabajo posee un retraso de aproximadamente 80 días con respecto al periodo de referencia. Por lo tanto, al momento de realizarse el pronóstico, no se cuenta con información sobre el trimestre previo y,

consecuentemente, se requiere realizar un pronóstico a dos pasos adelante (*two-step-ahead*) para obtener una predicción del trimestre corriente. El pronóstico a un paso adelante es un *backcast* de la tasa de crecimiento del PIB (es decir, pronosticar el valor del periodo pasado), mientras el pronóstico dos pasos adelante se denomina *nowcast* (pronosticar el valor del periodo corriente). Este trabajo pretende realizar un *backcasting/nowcasting* de la variable objetivo.

Más específicamente, en este trabajo se estima un modelo de factores dinámicos (DFM, por su sigla en inglés), el cual permite trabajar con paneles desbalanceados caracterizados por indicadores que poseen frecuencias mixtas y periodos de publicación no sincronizados. Además, con el objeto de realizar un ejercicio más realista, el modelo de pronóstico es evaluado utilizando grupos de datos (*vintages of data*), esto es, datasets que incluyen solo la información que se encuentra disponible en el momento en que se realiza el pronóstico. Más precisamente, se realizan tres rondas de pronósticos (*nowcasting/backcasting*) dentro de cada trimestre, con el objeto de explotar la mayor cantidad de información disponible. La precisión de las predicciones del modelo de pronóstico se cuantifica utilizando la raíz cuadrada del error cuadrático medio (RMSE, por su sigla en inglés). Se utiliza el test de Giacomini y White (2006) para comparar la habilidad predictiva de cada modelo.

A partir de un ejercicio de pronóstico en pseudo tiempo real para Argentina durante el periodo 1998:Q1 – 2021:Q2, se evidencia que: i) el modelo DFM tiene una performance superior tanto en el *backcast* como en el *nowcast* respecto a diferentes modelos base: un AR(1) y un modelo de crecimiento naive, ii) las predicciones son progresivamente más precisas conforme el trimestre concluye, es decir, toda la información acumulada es incorporada, iii) la precisión de los modelos factoriales en el *nowcast* aumenta con la incorporación de un índice de tono sobre el ciclo económico argentino, un indicador que aproxima niveles de incertidumbre económica, un indicador que captura presión sobre el mercado cambiario, iv) existen ganancias en términos de aumentos en la capacidad predictiva derivadas de la combinación de modelos de pronóstico.

El presente trabajo se alinea a un conjunto reducido de documentos

que realizan un *forecasting* de la tasa de crecimiento del PIB de Argentina. Blanco *et al.* (2017) comparan la capacidad predictiva fuera de la muestra de diferentes modelos de *nowcasting* (utilizan un DFM y un modelo FAVAR -modelo VAR ampliado con factores) explotando información económica mensual de 112 indicadores. Los autores evidencian que para el periodo analizado, 2006:Q1 – 2017:Q1, la combinación de modelos de pronóstico supera la performance de modelos individuales, mientras que no encuentran evidencia sobre la prevalencia de un modelo sobre otro en términos de capacidad predictiva. Camacho *et al.* (2013), estiman un DFM utilizando sólo cuatro indicadores económicos mensuales para el periodo 1993-2012. A partir de un ejercicio en pseudo tiempo real fuera de la muestra, los autores evidencian que la capacidad predictiva del DFM supera los pronósticos de los modelos bases, tanto en el *backcasting* como en el *nowcasting*. El presente trabajo arriba a similares conclusiones a partir de explotar un conjunto reducido de indicadores económicos con frecuencia mensual para el periodo 1998:Q1-2021:Q2. Asimismo, este documento evidencia ganancias en términos de precisión predictiva a partir de incorporar indicadores basados en fuentes no tradicionales de información y un indicador que captura presiones sobre el mercado cambiario.

Teniendo en cuenta que, durante el periodo bajo análisis, el ciclo económico argentino exhibió una gran inestabilidad, la explotación de datos disponibles a alta frecuencia puede contribuir a mejorar la precisión de los modelos de pronóstico. En este sentido, se presenta un indicador de sentimiento económico basado en información no estructurada. En línea con la literatura de procesamiento de lenguaje natural en contextos macroeconómicos, y siguiendo el trabajo de Aguilar *et al.* (2021) y Baker *et al.* (2016), se construye un indicador del tono sobre el ciclo económico de Argentina, el cual logra capturar la dinámica de la tasa de crecimiento del PIB. La construcción de este indicador explota los artículos periodísticos de la sección de economía del diario *Ámbito Financiero*, *La Nación* y *Página 12*.

Adicionalmente, este trabajo también se vincula con un cuerpo de la literatura que aproxima niveles de incertidumbre económica utilizando fuentes de información no estructuradas. Existe una amplia evidencia sobre los efectos distorsivos que los saltos en los niveles de incertidumbre ge-

neran sobre la dinámica de múltiples variables económicas (Bloom, 2009; Baker et al., 2016, Ghirelli et al., 2019; Aromí, 2020; Llada, 2021). Sin embargo, la incertidumbre es un concepto no observable, por lo que requiere ser estimado. En este sentido, el presente trabajo, siguiendo el trabajo de Baker *et al.* (2016), propone un indicador cuantitativo que aproxima manifestaciones de incertidumbre basado en los artículos periodísticos de la sección de economía del diario *Ámbito Financiero*, *La Nación* y *Página 12*.

La economía argentina durante el periodo analizado, sufrió oscilaciones del tipo de cambio debido factores tanto domésticos como externos. Resulta de interés incorporar un indicador que capture las presiones globales que se ejercen sobre el tipo de cambio, las cuales repercuten en última instancia sobre el nivel de actividad económica. Se construye un índice de presión sobre el mercado cambiario (EMP, por su sigla en inglés) que captura de forma conjunta los movimientos del tipo de cambio nominal, las reservas internacionales y el spread de la tasa de interés. De esta manera, el presente documento se relaciona con la literatura de Exchange Market Pressure Index – EMP (ver, por ejemplo, Eichengreen *et al.* 1996; Reinhart y Kaminsky, 1999; Hegerty et al., 2012; Goldberg y Krogstrup, 2018, entre otros).

Por último, mediante un ejercicio estadístico, se estima la asociación entre los errores de pronóstico y el indicador de incertidumbre basado en información no estructurada. Se evidencia que el indicador que aproxima niveles de incertidumbre económica está asociado positivamente con los errores de pronósticos, tanto en el *nowcasting* como en el *backcasting*. En particular, se encuentra que un incremento de una desviación estándar en el indicador de incertidumbre basado en noticias de la prensa está asociado, en promedio, a un incremento del 53% en el error de predicción de la tasa de crecimiento del PIB corriente. Este resultado sugiere que existen potenciales ganancias en términos de incrementos en la precisión predictiva derivada de incorporar indicadores que capturen diferentes estados de incertidumbre económica.

Luego de esta introducción, el trabajo se organiza de la siguiente manera. En la sección II, se exhibe la metodología. En la sección III se presentan los datos utilizados. A continuación, en la sección IV, se resumen los

principales resultados. En la sección V se presenta un conjunto de indicadores que explotan información disponible a alta frecuencia y se evalúa su impacto sobre la capacidad predictiva de los modelos de pronóstico. La sección VI exhibe un análisis de robustez. Por último, en la sección VII se mencionan las conclusiones.

II. Metodología

Los *policymakers* requieren monitorear la evolución de la actividad económica para el diseño de política económica, formular expectativas y evaluar si el estado de la economía se aparta o no de las expectativas formuladas ante el arribo de nueva información. Teniendo en cuenta que los indicadores de actividad económica de baja frecuencia poseen sustanciales retrasos en su publicación, una forma de lidiar con esta limitación se asocia con inferir la evolución de la variable objetivo (por ejemplo, el PIB trimestral) utilizando indicadores de más alta frecuencia. En este trabajo, se estima un DFM para extraer la dinámica común de un conjunto de indicadores económicos de alta frecuencia con el objetivo de obtener una estimación temprana del PIB trimestral de Argentina, nuestra variable de interés.

Dentro de cada trimestre, t , el valor contemporáneo y pasado de la tasa de crecimiento del PIB (y_t) no se encuentra disponible, el cual puede ser estimado utilizando indicadores de alta frecuencia cuya publicación es más oportuna. La evaluación condicional de y_t viene dada por $Proj[y_t | \Omega_v^n]$, donde Ω_v^n representa el set de información relevante en el mes v , el cual incluye n indicadores económicos relevantes con información reciente hasta el mes v . Teniendo en cuenta que la disponibilidad de las variables económicas de alta frecuencia no es homogénea, el panel de datos relevante para realizar las proyecciones de y_t es desbalanceado (problema que se conoce como “jagged edge”), dado que algunas variables poseen datos y otras no.

En pos de realizar un ejercicio de predicción más realista, el set de información es definido como $\Omega_v^n = \{X_{it | v_j}; t = 3k, k = 1, 2, \dots, [T_{iv_j}/3]; i = 1, \dots, n\}$, el cual está compuesto por n indicadores, $X_{it | v_j}$, donde $i = 1, \dots, n$ identifica las series de tiempo individuales y $t = k, 2k, \dots, T_{iv_j}$ representa el tiempo en meses desde la primera observación hasta la última disponible, la cual varía dependiendo del indicador (i) y el vintaje (v_j). Si se asume que el

primer mes de la muestra corresponde al comienzo de un trimestre (esto es, $t = 1$ si el mes es enero, abril, julio u octubre), tenemos que $t = 3k$. Esto genera tres dataset dentro de cada trimestre, conforme se publiquen nuevos datos mensuales j , esto es, Ω_{v_j} , donde $v = 3k - 2, 3k - 1$ y $3k$ en el primer, segundo y tercer mes del trimestre, respectivamente. Luego, para cada set de información dentro de un trimestre dado, el *backcast/nowcast* es computado como el valor esperado de la tasa de crecimiento del PIB de Argentina condicional a la información disponible: $\hat{y}_{3k|v_j} = E[y_{3k}|\Omega_{v_j}]$. Para ver más detalles ver Giannone *et al.* (2008).

Para estimar la esperanza condicional se debe especificar un modelo. En este trabajo se estima un modelo factorial, el cual permite resumir la información de un conjunto de variables a través de un número reducido de factores comunes (Giannone *et al.*, 2008; Banbura *et al.*, 2013). Una proyección sobre el espacio de los factores comunes es capaz de capturar la mayor parte de las interacciones dinámicas entre los indicadores y proveer un modelo parsimonioso que posee buena performance en términos de pronóstico.

En los modelos factoriales, el conjunto de predictores mensuales estacionarios, disponibles para un vintage v_j , se representa como la suma de dos componentes ortogonales ($X_{it|v_j} = \lambda_{i1}f_{1k} + \dots + \lambda_{ir}f_{rk} + \epsilon_{it|v_j}$): un componente común y un componente idiosincrático. El componente común $x_{it} = \lambda_{i1}f_{1k} + \dots + \lambda_{ir}f_{rk}$ es impulsado por un número reducido ($r < n$) de factores comunes a todas las variables, mientras que el componente idiosincrático ϵ_{it} responde a perturbaciones o variaciones específicas de cada variable. Si bien los factores son comunes a todas las variables, poseen un efecto específico sobre estas (λ_{ir}). En particular, sea $X_t = (X_{1t|v_j}, \dots, X_{nt|v_j})'$ el vector de variables estacionarias observadas en el periodo t , el cual puede expresarse de forma compacta como:

$$X_{t|v_j} = \Lambda F_t + e_t \quad (1)$$

donde $F_t = (f_{it}, \dots, f_{rt})'$ es un vector de factores no observables de dimensión $r \times 1$, Λ es una matrix de carga de dimensión $r \times n$ que recoge la influencia del factor común en cada uno de los indicadores (λ_{ir}) y el vector $e_t = (\epsilon_{1t|v_j}, \dots, \epsilon_{nt|v_j})'$ recoge las variaciones idiosincráticas.

Siguiendo Ghysels y Marcellino (2018), el modelo factorial puede re-

presentarse como un modelo de espacio de los estados utilizando la ecuación (1), en la cual los indicadores observados dependen de un número reducido de factores latentes:

$$X_t = \Lambda F_t + e_t, \quad e_t \sim N(0, \Sigma_\xi) \quad (1)$$

$$f_t = Z(L)f_{t-1} + \zeta_t \quad (2)$$

$$\zeta_t = B\eta_t, \quad \eta_t \sim N(0, I_q) \quad (3)$$

La ecuación (1) se denomina ecuación de observación, la cual modela las variables observables como una función lineal de las variables de estado y el ruido, mientras que la ecuación (2) se denomina ecuación de estado, la cual describe la evolución de la variable estado. Los factores latentes siguen un proceso autorregresivo de orden p , donde $Z(L)$ es una matriz de polinomio de rezagos de dimensión $r \times r$. El término de error e_t es un ruido blanco con matriz de covarianzas diagonal Σ_ξ . Por su parte, el término de error ζ_t es un ruido blanco q -dimensional, donde B es una matriz $n \times q$, con $q \leq r$, donde q es el número de shocks comunes. Por lo tanto, $\zeta_t \sim N(0, BB')$.

A la hora de extraer la información común sobre los indicadores económicos se pueden utilizar las diversas técnicas de estimación disponibles en la literatura de análisis factorial dinámico. Por un lado, se puede estimar el DFM de manera consistente utilizando componentes principales -PCA (Stock y Watson, 2002a). Por otro lado, Giannone *et al.* (2008) estiman el sistema (1)-(3) a través del procedimiento en dos etapas, el cual combina las técnicas PCA y Filtro de Kalman para estimar los factores. Doz *et al.* (2011), evidencia que el estimador en dos etapas es consistente. Por su parte, Doz *et al.* (2012) muestran que el sistema (1)-(3) puede ser estimado por máxima verosimilitud. Los autores utilizan el algoritmo EM (Expectation Maximization) para obtener las estimaciones de máxima verosimilitud. El algoritmo EM es una herramienta potente para estimar los parámetros de modelos con variables latentes y observaciones faltantes. Los parámetros a estimar son $\theta = (Z, \Lambda, Q, H)$. Este procedimiento describe el modelo de probabilidad en términos de los datos observados y no observados y luego itera entre dos operaciones: i) computa la expectativa del logaritmo de la probabilidad

condicional en los datos $E_{\theta}[l(X, F; \theta)|\Omega_v]$, utilizando los parámetros estimados de la iteración previa, ii) reestima los parámetros a través de maximizar el logaritmo de la distribución. Los parámetros iniciales que requiere el algoritmo EM son obtenidos utilizando componentes principales para la estimación de los factores.² La estimación de los parámetros de la función de verosimilitud se realiza utilizando Filtro de Kalman.

En este trabajo se estima el modelo de factores dinámicos utilizando máxima verosimilitud debido a sus ventajas sobre el estimador en dos etapas y componentes principales. En primer lugar, es más eficiente para sistemas pequeños. En segundo lugar, permite abordar el problema de observaciones faltantes. Más detalles se puede encontrar en Banbura *et al.* (2013).

III. Datos

Con el objetivo de realizar un pronóstico de la tasa de crecimiento del PIB de Argentina, se construye un panel de datos con 16 indicadores económicos mensuales, el cual cubre el periodo 1998:M1 a 2021:M7. Este ejercicio requiere incorporar indicadores que estén disponibles a alta frecuencia y que sean publicados de forma oportuna. El panel de datos se compone de indicadores “*hard*” y “*soft*”. Acorde con Banbura *et al.* (2013), los indicadores “*hard*” corresponden a indicadores que capturan la actividad económica real (indicadores como, por ejemplo, el Indicador de Producción Industrial (IPI), el Indicador Sintético de Actividad Económico (ISAC), el Estimador Mensual de Actividad Económica (EMAE), etc), mientras que los indicadores “*soft*” son aquellos que capturan las expectativas del mercado basados en encuestas (por ejemplo, el Indicador de Confianza al Consumidor (ICC) de la Universidad de Di Tella). Por lo tanto, el objetivo de este trabajo es obtener información temprana sobre la evolución de la actividad económica intratrimestral a partir de un panel de indicadores que potencialmente influye sobre la tasa de crecimiento del PIB de Argentina, el cual posee un retraso de aproximadamente 80 días.

² Requiere valores iniciales para las variables de estado y una matriz de covarianzas para iniciar el proceso autorregresivo. Estos valores iniciales se obtienen a partir de los coeficientes estimados de una regresión línea de X_t es f_t , dado que este último sigue un proceso autorregresivo.

Los datos de los indicadores económicos provienen de múltiples fuentes. Las variables fueron ajustadas por estacionalidad, cuando corresponde, utilizando X-13 ARIMA-SEATS. Cuando corresponde, se trabaja con series en términos reales. Por último, las series fueron transformadas en logaritmos y, finalmente, fueron diferenciadas o se les restó su tendencia para hacerlas estacionarias. Los indicadores utilizados en este trabajo se pueden encontrar en la tabla 1.

Tabla 1. Indicadores económicos

id	Serie	Frecuencia	Fuente	Vintage
pib	Producto Interno Bruto	Trimestral	INDEC	-
demanda_energia	Demanda total de Electricidad	Mensual	MECON	2
despacho_cemento	Despacho nacional de cemento	Mensual	MECON	1
emaee	Estimador Mensual de Actividad Económica	Mensual	MECON	2
empleo	Empleo asalariado registrado del sector privado	Mensual	SIPA	3
ganancias	Recaudación impuesto a las ganancias	Mensual	MECON	1
icc	Índice de Confianza del Consumir	Mensual	UTDT	1
ipi	Índice de Producción Industrial	Mensual	MECON	2
isac	Indicador Sintético de Actividad de la Construcción	Mensual	MECON	2
iva	Recaudación impuesto IVA	mensual	MECON	1
naftas	Venta de naftas	mensual	MECON	2
patentamientos_autos	Patentamientos de autos en Argentina	Mensual	DGEyC CABA	2
producción_nacional_autos	Producción nacional de autos	Mensual	ADEFa	1
producción_cemento	Producción de cemento	Mensual	MECON	1
Shoppings	Ventas en shoppings	Mensual	MECON	3
Supermercados	Ventas en supermercados	Mensual	MECON	3
transferencias_autos	Transferencias de autos en Argentina	Mensual	DGEyC CABA	2

Teniendo en cuenta que los indicadores mensuales no poseen una publicación de datos homogénea, se considera el retraso en la publicación a la hora de incorporar los indicadores en el modelo de pronóstico. Se considera el vintage al final del mes, por lo tanto, no se modela explícitamente el flujo de datos intramensual. Por lo tanto, se agrupan los indicadores teniendo en cuenta la disponibilidad de la observación mensual al momento de realizar el pronóstico. Más específicamente, se agrupan los indicadores teniendo en cuenta la información disponible en el mes 1 a 3 de cada tri-

mestre (ver columna 5 de la tabla 1). Por ejemplo, en el mes de julio se realiza un *backcast* del segundo trimestre y un *nowcast* del tercer trimestre, con información del EMAE correspondiente al mes de mayo.

IV. Pronósticos y Evaluación de los pronósticos

En este apartado se exhiben los resultados derivados de un ejercicio de pronóstico fuera de la muestra. El ejercicio consiste en utilizar el enfoque de ventanas expansiva o recursiva para evaluar los modelos de pronóstico asociados al *nowcast/backcast*. Este enfoque asigna igual peso a todas las observaciones de la muestra, es decir, pondera igual todos los datos desde el principio hasta el punto donde se realiza el pronóstico. El periodo muestral se divide en el periodo de estimación: 1998:M1-2011:M12 y el periodo de evaluación, el cual cubre el periodo 2012:M1-2021:M7. Entonces para cada trimestre en el subperiodo muestral de evaluación, se computa el pronóstico y se expande la ventana en un trimestre. Los indicadores económicos que se explotan en esta sección son aquellos reportados en la tabla 1 (16 indicadores).

Como se mencionó anteriormente, en pos de realizar un ejercicio en pseudo tiempo real, se evalúa una secuencia de pronósticos para diferentes meses teniendo en cuenta el vintage, explotando de esta manera, la mayor cantidad de información disponible al momento de realizarse el pronóstico. Más específicamente, se realizan tres pronósticos trimestrales en base a la información disponibles en los meses 1 a 3 de cada trimestre.

Las predicciones del modelo de factores dinámicos se comparan contra aquellas reportadas por un modelo base. Teniendo en cuenta que el retraso en la publicación de información de la tasa de crecimiento del PIB es de 80 días, en este trabajo se evalúa el *backcast* y el *nowcast* del modelo de factores dinámicos contra la performance de un modelo de pronóstico base: un modelo AR(1) y un modelo de pronóstico de crecimiento naive estimado recursivamente. Más específicamente, se computa la tasa de crecimiento promedio durante el periodo $1, \dots, t - 1$, para proveer el pronóstico de la tasa de crecimiento naive para el periodo t . Para el *backcast* y *nowcast*, se computa el pronóstico un paso hacia adelante y dos pasos hacia adelante, respectivamente. Adicionalmente, se computa la Raíz Cuadrada del Error

Cuadrático Medio (RMSE) para evaluar la performance del modelo de factores dinámicos respecto de los modelos base.

La tabla 2 y 3 exhiben las métricas de evaluación de los modelos de pronóstico. A partir de los resultados de esta tabla se pueden extraer una serie de conclusiones. En primer lugar, el modelo de factores dinámicos supera la performance de los modelos clásicos de serie de tiempo. Las diferencias en RMSE es mayor para el *backcast* y menor para el *nowcast*. Este resultado sugiere que la precisión de los modelos de pronóstico disminuye conforme el horizonte temporal se extiende. En segundo lugar, se evidencia que conforme se acumula información, las ganancias en términos de precisión del pronóstico son sustanciales. Este resultado se aprecia tanto en los modelos de *backcasting* como de *nowcasting*. Este último resultado sugiere que los modelos de factores dinámicos se benefician del arribo de información económica publicada de forma oportuna. En este sentido, se evidencia la habilidad de los modelos de factores dinámicos para incorporar información en tiempo real, una característica relevante de estos modelos para la mejora de su performance. Este resultado se alinea con aquellos reportados en la literatura (Banbura *et al.*, 2013).

Tabla 2. Backcasting de la tasa de crecimiento del PIB

Modelo de Pronostico	RMSE	GW
DFM M1	0.01724	0.009
DFM M2	0.01750	0.019
DFM M3	0.01051	0.000
AR1	0.02164	0.966
Crecimiento naive	0.02212	-

Nota: La evaluación del pronóstico cubre el periodo 2012:M1-2021:M7 (38 trimestres). DFM refiere al modelo de factores dinámicos para el mes 1 (M1), mes 2 (M2) y mes 3 (M3) de cada trimestre. La especificación del DFM es $r=2$, $p=2$, donde r es el número de factores y p es el orden del proceso autorregresivo de la ecuación 2. AR1 representa el pronóstico asociado al modelo autorregresivo de orden 1. Crecimiento naive corresponde al pronóstico realizado utilizando la tasa de crecimiento promedio del periodo previo al momento en que se realiza el pronóstico. La columna GW reporta el p-valor del test Giacomini y White con el modelo Crecimiento naive como base.

Tabla 3. Nowcasting de la tasa de crecimiento del PIB

Modelo de Pronostico	RMSE	GW
DFM M1	0.02112	0.550
DFM M2	0.01982	0.439
DFM M3	0.01877	0.072
AR1	0.02370	0.267
Crecimiento naïve	0.02206	-

Nota: La evaluación del pronóstico cubre el periodo 2012:M1-2021:M7 (38 trimestres). DFM refiere al modelo de factores dinámicos para el mes 1 (M1), mes 2 (M2) y mes 3 (M3) de cada trimestre. La especificación del DFM es $r=2, p=2$, donde r es el número de factores y p es el orden del proceso autorregresivo de la ecuación 2. AR1 representa el pronóstico asociado al modelo autorregresivo de orden 1. Crecimiento naïve corresponde al pronóstico realizado utilizando la tasa de crecimiento promedio del periodo previo al momento en que se realiza el pronóstico. La columna GW reporta el p -valor del test Giacomini y White con el modelo Crecimiento naïve como base.

La figura 1 y 2, exhiben las predicciones de cada uno de los modelos. A partir estas, se puede apreciar que, si bien la performance de los modelos de factores dinámicos supera aquella de los modelos base, también se evidencian que, durante ciertos periodos, los modelos menos sofisticados poseen una mejor performance. Asimismo, se puede apreciar que el pronóstico realizado por el modelo de factores dinámicos logra capturar la sustancial caída que sufrió al economía argentina producto de la pandemia COVID-19 originada por el virus SARS-CoV-2, durante el segundo trimestre del 2020, como así también su posterior recuperación parcial (2020:Q3).

Figura 1. Evaluación del pronóstico – backcast

La figura muestra la tasa de crecimiento del PIB trimestral de Argentina (círculo negro), el pronóstico un paso hacia adelante (backcast) realizado con el modelo de factores dinámicos (DFM) M3 (línea sólida), el pronóstico del modelo de crecimiento naíve (línea punteada), el pronóstico del modelo autorregresivo de orden uno (línea discontinua). El periodo de evaluación es 2012:M1-2021:M7.





Figura 2. Evaluación del pronóstico – nowcast

La figura muestra la tasa de crecimiento del PIB trimestral de Argentina (círculo negro), el pronóstico dos pasos hacia adelante (nowkcast) realizado con el modelo de factores dinámicos (DFM) M3 (línea sólida), el pronóstico del modelo de crecimiento naive (línea punteada), el pronóstico del modelo autorregresivo de orden uno (línea discontinua). El periodo de evaluación es 2012:M1-2021:M7.



La comparación de estos resultados con otros trabajos es dificultosa debido a que los periodos de estimación y evaluación son diferentes. Sin embargo, Camacho *et al.* (2013) evidencia que modelos de factores diná-

nicos estimados en dos etapas poseen una capacidad predictiva superior respecto a los modelos base: random walk y AR(2). Los autores evidencian que las diferencias en la capacidad predictiva son estadísticamente significativas. Por su parte, Blanco *et al.* (2017) comparan la capacidad predictiva de múltiples modelos de factores dinámicos y modelo FAVAR (VAR aumentados con factores). Los autores evidencian que sólo la combinación de pronósticos supera la performance de los modelos individuales, mientras que no encuentran evidencia estadísticamente significativa respecto a que un modelo individual tenga una performance predictiva superior sobre otro.

En este sentido, en pos de evaluar si las diferencias en la capacidad predictiva reportadas son estadísticamente significativas, se procede a realizar el test de Giacomini y White (2006) entre dos modelos predictivos, donde el modelo de crecimiento naive sirve como modelo base. Este test permite evaluar la hipótesis nula respecto de que dos modelos de pronósticos poseen igual precisión predictiva. Los resultados son reportados en la columna 3 de la tabla 2 y 3. Como se puede apreciar, se evidencia que el modelo de crecimiento naive es superado por el modelo de factores dinámicos. Mas específicamente, para el caso del modelo de *backcast*, la ganancia en términos predictivos es estadísticamente significativos para todos los grupos de datos, mientras que para el caso del modelo de *now-cast* solo se puede rechazar la hipótesis nula cuando se acumula la máxima cantidad de información disponible (M3). Por último, los resultados presentados en este apartado se mantienen cuando el modelo de espacio de los estados se estima mediante el método en dos etapas siguiendo el trabajo de Giannone *et al.* (2008), ver Anexo A.

V. Evaluación de indicadores alternativos

Este trabajo evidencia que los modelos factoriales poseen una performance predictiva superior a modelos tradicionales de series de tiempo propuestos. Sin embargo, también se evidencia que durante ciertos periodos los modelos factoriales poseen una baja capacidad predictiva. A partir de este análisis, emerge a una serie de preguntas: i) ¿la performance de estos modelos empeora durante periodos de incertidumbre económica?; ii)

la incorporación de indicadores cuantitativos que explotan información disponible a más alta frecuencia, ¿mejora la capacidad predictiva de los modelos de pronóstico propuestos?

En este sentido, esta sección presenta un conjunto de indicadores cuantitativos que explota información disponible a alta frecuencia y evalúa en qué medida los modelos de pronóstico se beneficiarían de su incorporación. Más específicamente, se propone un indicador de sentimiento o tono sobre el ciclo económico argentino en base a información publicada en artículos periodísticos, un indicador de incertidumbre económica que explota el mismo conjunto de datos y un indicador de presión sobre el mercado cambiario en base a la evolución del tipo de cambio, las reservas internacionales y el spread de tasas de interés. La metodología utilizada para la construcción de estos indicadores, se presenta a continuación.

V.1. Indicadores alternativos

V.1.1. Indicador de sentimiento

Durante tiempos normales, la actividad económica real evoluciona de forma lenta, entonces la información que proveen los agregados macroeconómicos con frecuencia mensual y trimestral es suficiente para monitorear y pronosticar la evolución de la economía. Sin embargo, cuando las condiciones económicas evolucionan rápidamente, adquiere mayor importancia contar con información disponible a más alta frecuencia que permitan capturar señales tempranas sobre la evolución de la economía. En este sentido, se presenta un indicador que pretende explotar información disponible con frecuencia diaria para capturar señales tempranas sobre el ciclo económico argentino.

En este apartado se presenta la metodología utilizada para construir un indicador de sentimiento/tono basado en artículos publicados en la prensa. Específicamente, este índice pretende capturar el sentimiento/tono en los artículos periodísticos publicados en tres prominentes diarios de Argentina. Este indicador refleja la diferencia entre el número de artículos que contienen palabras claves relacionadas a una recuperación del ciclo económico argentino y el número de artículos que contienen palabras asociadas a una recesión del ciclo. Para su construcción, se utilizan los artícu-


los periodísticos publicados en la sección de economía del diario *Ámbito Financiero*, *La Nación* y *Página 12*.

Más específicamente, siguiendo Aguilar *et al.* (2021), en primer lugar, se cuenta el número de artículos que contienen al menos una palabra clave asociada a recuperación: *recuperación*, *aceler**, *crec**, *expansi**, *increment**, *augment**, *recuper** o *mejora**, si ésta se encuentra precedida o seguida por alguna de las siguientes palabras: *economic** o *economía*, dentro de una distancia de 5 palabras. En segundo lugar, se cuenta el número de artículos que contienen al menos una palabra clave asociada a recesión: *recesión*, *crisis*, *descen**, *disminu**, *redu**, *ralentiz**, *decrec**, *desaceler** o *contracción*, si ésta se encuentra precedida o seguida por alguna de las siguientes palabras: *economic** o *economía*, dentro de una distancia de 5 palabras.

Por último, se construye el índice de sentimiento/tono siguiendo el trabajo de Baker *et al.* (2016). En primer lugar, se construye la diferencia entre el indicador de recuperación y recesión para cada diario. Luego, esta diferencia es normalizada por el número de artículos publicados por cada diario en un periodo de tiempo (día, semana, mes, etc). Por último, se promedian las series normalizadas y se estandariza de manera que el indicador tenga media cero y desvío estándar igual a uno.

La figura 3 exhibe la evolución del indicador de sentimiento con frecuencia trimestral. Se puede apreciar, que el índice de tono captura de forma razonable las etapas de recuperación y contracción de la tasa de crecimiento del PIB de Argentina. Asimismo, teniendo en cuenta la frecuencia con la cual se dispone de este indicador basado en información no estructurada, la información que captura puede ser complementaria y valiosa para los modelos de pronóstico.

Figura 3. Evolución del indicador de sentimiento y la tasa de crecimiento del PIB



Nota: para facilitar la comparación, los indicadores han sido estandarizados

V.1.2. Indicador de incertidumbre

Existe una amplia evidencia sobre los efectos distorsivos que los saltos en los niveles de incertidumbre generan sobre la dinámica de múltiples variables económicas (Bloom, 2009; Baker *et al.*, 2016, Ghirelli *et al.*, 2019; Aromí, 2020; Llada, 2021). A pesar de su relevancia, la incertidumbre es un concepto no observado y, por lo tanto, requiere ser estimado. La literatura ha propuesto múltiples formas para aproximar este estado subjetivo. Algunas aproximaciones se asocian con el nivel de volatilidad en los rendimientos

del mercado de valores (Bloom, 2009), la discrepancia en las respuestas que se extraen de las encuestas de expectativas empresariales, de consumidores y o de pronosticadores profesionales (Bachmann *et al.*, 2013), o la ocurrencia de palabras claves asociadas al concepto de incertidumbre en artículos periodísticos (Baker *et al.*, 2016, Ghirelli *et al.*, 2019, Aromí, 2020).

En esta subsección, se presenta la metodología utilizada para construir un indicador de incertidumbre basado en información no estructurada. Este indicador pretende aproximar los niveles de incertidumbre económica, un fenómeno no observable, mediante artículos difundido por medios de comunicación. En particular, se utilizan los artículos periodísticos publicados en la sección de economía del diario *Ámbito Financiero*, *La Nación* y *Página 12*.

Siguiendo Baker *et al.* (2016) y Ghirelli *et al.* (2019), el indicador de incertidumbre económica cuenta el número de artículos que contienen simultáneamente al menos una palabra relacionada a las categorías “*incertidumbre*”, “*economía*” y “*política*”:


- Incertidumbre: *inciert** o *incertidumbr** o *inestabl** o *inestabilidad* o *inestabilidades* o *riesgo* o *riesgos*;
- Economía: *economic** o *economía*;
- Política: *Poder Ejecutivo* o *Congreso* o *Cámara de Diputados* o *Cámara de Senadores* o *Gobierno Nacional* o *Gobierno* o *Hacienda* o *Ministerio de Economía* o *Banco Central* o *Banco Central de la República Argentina* o *BCRA* o *déficit* o *presupuest** o *gasto público* o *gastos públicos* o *deuda pública* o *deudas públicas* o *política fiscal* o *políticas fiscales* o *política monetaria* o *políticas monetarias* o *el impuesto* o *de impuesto* o *del impuesto* o *un impuesto* o *por impuesto* o *este impuesto* o *ese impuesto* o *aquel impuesto* o *impuestos* o *legislación* o *legislaciones* o *reforma* o *reformas* o *norma* o *normas* o *normativ** o *regulación* o *regulaciones* o *reglamento* o *reglamentos* o *ley* o *leyes*;

Siguiendo este procedimiento, se obtiene un indicador bruto que captura el número de artículo asociados a incertidumbre económica para cada diario, para un periodo de tiempo determinado. Luego, estos indicadores son normalizados por el número de artículos publicados por cada diario en un periodo de tiempo (día, semana, mes, etc). Por último, se promedian

las series normalizadas y se estandariza de manera que el indicador tenga media cero y desvío estándar igual a uno.

La figura 4 muestra la evolución del indicador de incertidumbre económica basado en noticias de la prensa y la tasa de crecimiento del PIB de Argentina. Se puede apreciar que el indicador de incertidumbre se acelera durante periodos de inestabilidad económica. Este indicador parece capturar información valiosa sobre la evolución de la actividad económica. De forma análoga al indicador de sentimiento, los indicadores basados en información no estructurada pueden aportar información valiosa, oportuna y complementaria a aquella que reflejan los indicadores económicos *hard* y *soft* presentados previamente.

Figura 4. Evolución del indicador de incertidumbre y la tasa de crecimiento del PIB



Nota: para facilitar la comparación, los indicadores han sido estandarizados.

V.1.3. Índice de presión sobre el mercado cambiario

El periodo analizado en este trabajo se caracterizó por intensas oscilaciones del tipo de cambio asociadas a factores doméstico y externos, las cuales repercutieron sobre el nivel de actividad económica. En este sentido, este apartado presenta la metodología para la construcción de un índice de presión sobre el mercado cambiario.

Este indicador económico pretende capturar las presiones que múltiples factores domésticos y externos ejercen sobre el mercado cambiario. Más específicamente, el indicador captura de forma conjunta los cambios en el tipo de cambio nominal, las reservas internacionales y el diferencial de tasa de interés. El índice se calcula de la siguiente manera:

$$EMP_t = \beta_{TCN}\Delta TCN_t - \beta_R\Delta R_t + \beta_i\Delta(i - i^*)_t$$


donde β_{TCN} , β_R y β_i y son los pesos de cada uno de los componentes cuya función es filtrar las señales ruidosas de cada variable, ΔTCN_t es la tasa de devaluación computada como la diferencia en logaritmos del tipo de cambio nominal (TCN), ΔR_t es la variación de las reservas internacionales y $\Delta(i - i^*)_t$ es la tasa de variación de la diferencia entre la tasa de política monetaria doméstica y la tasa de política monetaria de un país desarrollado. Si EMP es positivo, indica que la presión neta conduce a una depreciación, mientras que si es negativo indica que la presión neta ejerce presión hacia la apreciación. La serie del tipo de cambio nominal y las reservas internacionales provienen del BCRA. El spread de tasas de interés será aproximado por el EMBI que computa y difunde el J.P.Morgan debido a la dificultad de contar con una tasa de interés de política monetaria para Argentina. Los datos del EMBI provienen del diario *Ámbito Financiero*. Por último, las series se expresan como promedio mensual debido a que todas poseen una frecuencia diaria.

Cabe mencionar que en la literatura no existe un consenso sobre cómo definir las variables que integran el EMP y cómo ponderar cada uno de sus componentes (ver, por ejemplo, Eichengreen *et al.* 1996; Reinhart y Kaminsky, 1999; Hegerty *et al.*, 2012; Goldberg y Krogstrup, 2018, entre otros). El presente trabajo utiliza componentes principales para asignar pesos a cada una de las variables. A partir de esta técnica, se utiliza la primera

componente principal como proxy del índice EMP, dado que esta variable captura la dirección de máxima variabilidad explicada por el subespacio generado por los tres indicadores propuestos.

La figura 5 exhibe la evolución del índice de presión sobre el mercado cambiario y la tasa de crecimiento del PIB de Argentina. Como se puede apreciar, el indicador EMP captura de forma razonable los periodos de vorágine en el frente cambiario. Más específicamente, el índice EMP se acelera con intensidad a partir del último trimestre del 2001, el tercer trimestre del 2008, y el tercer trimestre del 2018 y 2019. A partir de este análisis exploratorio, se evidencia que la información oportuna que brinda este indicador puede contribuir de forma positiva a la mejora de los modelos de pronósticos.

Figura 5. Evolución del índice de presión sobre el mercado cambiario (EMP) y la tasa de crecimiento del PIB



Nota: para facilitar la comparación, los indicadores han sido estandarizados.

V.2. Asociación entre errores de pronóstico e incertidumbre económica

Los resultados exhibidos en la sección IV, permiten concluir que los modelos factoriales poseen una capacidad predictiva superior a los modelos tradicionales de serie de tiempo propuestos. Sin embargo, la performance del DFM empeora durante periodos de incertidumbre económica. Un resultado que se alinee a esta hipótesis, sugiere que los errores de pronóstico deberían estar asociados con los indicadores de incertidumbre económica. Para realizar la evaluación de esta hipótesis, se estima la asociación entre los errores de pronóstico y el indicador de incertidumbre económica propuesto. Los errores de pronósticos vienen dados por $\hat{\epsilon}_t = |y_t - \hat{f}_{t|t-1}|$, donde $\hat{\epsilon}_t$ son los errores de pronóstico de *backcast/nowcast* producidos en t , es decir, la diferencia entre la tasa de crecimiento observada del periodo y aquella estimada por el modelo factorial condicional a la información disponible en $t - 1$. Entonces, el modelo viene dado por:

$$\log(\hat{\epsilon}_t) = \alpha + \beta I_t + \mu_t$$

donde los errores de pronóstico son función de una constante (α), un indicador que captura incertidumbre económica (I_t) y el termino de error (μ_t). Teniendo en cuenta que el valor absoluto de los errores de pronóstico puede ser una proxy de incertidumbre (Rossi y Sekhposyan, 2015), se espera que $\hat{\beta}$ sea positivo. Por lo tanto, si $\hat{\beta}$ es positivo y estadísticamente significativo, el modelo sugiere que existe una asociación positiva entre los errores de pronóstico y la incertidumbre económica. Un resultado en esta línea, sugiere que los modelos factoriales deberían incorporar indicadores que capturen incertidumbre económica.

La tabla 4 y 5 reportan los resultados derivados de estimar la asociación entre los indicadores de incertidumbre y los modelos de pronóstico referidos al *backcast* y *nowcast*, respectivamente. En general, se evidencia una asociación positiva y estadísticamente significativa entre los errores de pronóstico y las métricas propuestas para aproximar los niveles de incertidumbre económica, esto es, el índice de incertidumbre basado en información no estructurada. En particular, un aumento de una desviación estándar en el indicador que aproxima niveles de incertidumbre en base artículos periodísticos está asociado, en promedio, a un aumento en el error de pronóstico de

aproximadamente 51% en el caso del *backcast* y en el orden de un 53% en el caso de *nowcast*, cuando el modelo de *forecasting* utiliza los indicadores económicos propuestos en la sección IV. Los resultados se mantienen cuando se estima la asociación considerando los niveles de presión sobre el mercado cambiario y se incorpora como regresor los niveles de incertidumbre previa a realizarse el pronóstico. Estos resultados sugieren que existen ganancias en términos de precisión predictivas a partir de incorporar indicadores que aproximen diferentes estados de incertidumbre económica.

Tabla 4. Asociación entre errores de pronóstico e incertidumbre económica - backcast

La tabla 4 exhibe la asociación entre los errores de pronóstico fuera de la muestra (*backcast*) y el indicador de incertidumbre (Incertidumbre). Los errores se aproximan por el valor absoluto del error de pronóstico. Los modelos de pronóstico corresponden a un modelo de factores dinámicos utilizando todas las variables incorporadas en el DFM exhibido en la tabla 2 (). El periodo de evaluación es 2012:M1-2021:M7. Para facilitar la comparación, las variables explicativas han sido estandarizadas.

	(0)	(0)	(0)	(0)
	0.513*** (0.173)			
		0.378** (0.180)		
			0.439*** (0.158)	
				0.190** (0.085)
Constante	- 5.339*** (0.203)	-5.339*** (0.191)	-5.339*** (0.213)	-5.339*** (0.233)
Observaciones	38	38	38	38
	0.143	0.065	0.097	-0.004

Nota: entre paréntesis se reporta el desvío estándar. El estadístico t fue estimado siguiendo Newey y West (1987,1994). * $p < 0.1$; ** $p < 0.05$; *** $p < 0.01$.

Tabla 5. Asociación entre errores de pronóstico e incertidumbre económica - nowcast

La tabla 5 exhibe la asociación entre los errores de pronóstico fuera de la muestra (nowcast) y el indicador de incertidumbre (Incertidumbre). Los errores se aproximan por el valor absoluto del error de pronóstico. Los modelos de pronóstico corresponden a un modelo de factores dinámicos utilizando todas las variables incorporadas en el DFM exhibido en la tabla 3 (). El periodo de evaluación es 2012:M1-2021:M7. Para facilitar la comparación, las variables explicativas han sido estandarizadas.

	()	()	()	()
	0.525*** (0.139)			
		0.473*** (0.154)		
			0.327*** (0.093)	
				0.015 (0.134)
Constante	-4.653*** (0.168)	-4.653*** (0.161)	-4.653*** (0.203)	-4.653*** (0.210)
Observaciones	38	38	38	38
	0.162	0.126	0.071	-0.028

*Nota: entre paréntesis se reporta el desvío estándar. El estadístico $-t$ fue estimado siguiendo Newey y West (1987,1994). * $p<0.1$; ** $p<0.05$; *** $p<0.01$.*

VI. Especificaciones alternativas

En esta sección se realiza un análisis de robustez en pos de evaluar cuán sensibles son los resultados reportados en la sección IV a cambios en la especificación del modelo. Este ejercicio pretende evaluar si la performance de los modelos de pronósticos varía significativamente cuando excluimos ciertos indicadores económicos o incorporamos otros. A partir de los resultados expuestos en la sección V, es de interés evaluar si la precisión del DFM aumenta cuando se incorporan los indicadores propuestos en dicha sección. Este análisis permite aprender sobre la contribución de cierto grupo de variables a la capacidad predictiva del modelo.

La tabla 6 y 7 reportan los resultados del modelo de factores dinámicos

utilizado para realizar un *backcast/nowcast*. Al igual que en la sección IV, se utiliza como métrica de evaluación de los pronósticos el RMSE. La influencia sobre la performance del modelo, se analiza comparando el RMSE reportado en esta sección respecto de aquellos reportados en la tabla 2 y 3. Por último, se reporta el p-valor del test de Giacomini y White especificando como modelo base el modelo de crecimiento naive y el modelo factorial propuesto en la sección IV, en las columnas 3 y 4, respectivamente.

El primer ejercicio pretende evaluar cuánta información capturan los indicadores “*hard*” para monitorear la actividad económica. Los resultados sugieren que este grupo de indicadores posee una performance en términos predictivos similar al modelo factorial propuesto en la sección IV, tanto en el *backcasting*, como en el *nowcasting*. Si bien esta nueva especificación del DFM continúa siendo superior al modelo de crecimiento naive, solo mejora la performance del modelo factorial presentado en la sección IV, cuando se incorpora toda la información disponible (ver columna 3, tabla 7). Dicha ganancia predictiva es estadísticamente significativa.

El segundo ejercicio, extiende el conjunto de indicadores del DFM propuesto en la sección IV a partir de incorporar el indicador de tono sobre el ciclo económico argentino. Los resultados sugieren que la extensión del DFM permite mejorar la performance predictiva en el *backcasting* y *nowcasting* en todos los grupos de datos. Dicha mejora en la ganancia en términos de precisión es solo estadísticamente significativa al 1% en el *nowcast*, cuando se acumula toda la información disponible (ver columna 3, tabla 7).

El tercer ejercicio, incorpora el indicador que captura las presiones sobre el mercado cambiario al DFM, propuesto en la sección IV. Los pesos del indicador EMP son estimados utilizando el enfoque recursivo presentado en la sección IV. Teniendo en cuenta que, durante el periodo muestral analizado, la economía argentina alternó periodos de vorágine en el frente cambiario debido a factores doméstico y externos, el siguiente ejercicio incorpora el indicador EMP en los modelos de pronóstico. Este ejercicio pretende evaluar si el índice EMP contribuye a aumentar la capacidad predictiva del modelo de pronóstico. Los resultados reportados en la tabla 6, permiten apreciar que, si bien la incorporación de este nuevo indicador mejora levemente el desempeño del modelo a la hora de realizar un *back-*

casting, lo cual se refleja en su performance superior al modelo naive, esta diferencia solo es estadísticamente significativa en el *vintage* 1 y 2 cuando se lo compara con el modelo factorial propuesto en la sección IV. Por su parte, la tabla 7 exhibe la performance del DFM que incorporar el indicador EMP durante el *nowcasting*. El test de Giacomini y White permite concluir que la capacidad predictiva del modelo factorial que incorpora el índice de presión sobre el mercado cambiario es superior respecto al modelo naive y aquel propuesto en la sección IV, cuando se acumula toda la información disponible (ver columna 3 de la tabla 7).

El siguiente ejercicio, involucra la incorporación del indicador de incertidumbre económica, propuesto en la sección V, con el objeto de evaluar, como se realizó previamente, su contribución a la mejora en la capacidad predictiva del modelo de pronóstico. Los resultados del *backcasting* y el *nowcasting* se exhiben en la tabla 6 y 7, respectivamente. Se puede apreciar que, durante el *backcast*, la incorporación de este indicador genera un efecto positivo sobre la precisión del modelo. Esta nueva especificación del DFM posee una performance superior a la del modelo naive y al DFM propuesto en la sección IV (ver columna 3 y 4 de la tabla 6). Con respecto al *nowcast*, la performance del DFM ampliado con el indicador de incertidumbre mejora respecto de aquel modelo propuesto en la sección IV. Las ganancias en términos predictivos son estadísticamente significativas cuando se acumula toda la información (ver columna 3 y 4 de la tabla 7).

Por último, el cuarto ejercicio evalúa si la combinación de diferentes modelos de pronóstico permite mejorar la performance predictiva respecto a una serie de modelos propuestos como base. La tabla 6 y 7 exhiben los resultados de la combinación de los modelos de pronóstico propuestos para realizar un *backcast* y un *nowcast*, respectivamente. La combinación de modelos pronostico se realiza mediante un promedio con igual peso de los modelos propuestos en esta sección y aquel modelo propuesto en la sección IV. El pronóstico resultante de la combinación se compara contra el modelo de crecimiento naive y aquel propuesto en la sección IV. Los resultados sugieren que, durante el *backcast*, la combinación de pronósticos permite superar la performance del modelo de crecimiento naive y del modelo factorial propuesto en la sección IV, siendo esta ganancia en precisión estadísticamente

significativa en el primer caso. Con respecto al *nowcast*, en línea con Blanco *et al.* (2017), la combinación de pronósticos supera la performance del modelo naive y del modelo propuesto en la sección IV, solo cuando se acumula toda la información disponible. Dichas ganancias en términos de predicción predictiva, son estadísticamente significativa al 1%.

Tabla 6. Especificación alternativa 2 - backcast

Modelo de Pronostico	RMSE		
Indicadores "hard"			
DFM M1	0.01718	0.014	0.967
DFM M2	0.01736	0.014	0.409
DFM M3	0.01081	0.000	0.939
Indicadores + "Sentimiento"			
DFM M1	0.01650	0.005	0.000
DFM M2	0.01708	0.007	0.105
DFM M3	0.01081	0.000	0.995
Indicadores + EMP			
DFM M1	0.01658	0.007	0.002
DFM M2	0.01714	0.008	0.028
DFM M3	0.01037	0.000	0.172
Indicadores + Incertidumbre			
DFM M1	0.01693	0.010	0.503
DFM M2	0.01695	0.004	0.006
DFM M3	0.01024	0.000	0.008
Combinación			
DFM M1	0.01684	0.008	0.210
DFM M2	0.01717	0.008	0.001
DFM M3	0.01049	0.000	0.230

Nota: La evaluación del pronóstico cubre el periodo 2012:M1-2021:M7 (38 trimestres). DFM refiere al modelo de factores dinámicos para el mes 1 (M1), mes 2 (M2) y mes 3 (M3) de cada trimestre. La especificación del DFM es $r=2$, $p=2$, donde r es el número de factores y p es el orden del proceso autorregresivo de la ecuación 2. Indicadores: representa las variables económicas utilizadas en el DFM exhibido en la tabla 2. Combinación: promedio simple de los pronósticos generados por el DFM propuesto en la tabla 2 y tres DFM: indicadores hard, indicadores + el indicador EMP e indicadores + indicador de incertidumbre. La columna reporta el p-valor del test Giacomini y White con el modelo de Crecimiento naive como base, mientras que la columna reporta el p-valor del test Giacomini y White con el modelo factorial estimado en la sección IV como base.

Tabla 7. Especificación alternativa2 - nowcast

Modelo de Pronostico	RMSE		
Indicadores "hard"			
DFM M1	0.02130	0.676	0.086
DFM M2	0.01992	0.473	0.516
DFM M3	0.01823	0.029	0.069
Indicadores + "Sentimiento"			
DFM M1	0.02117	0.544	0.646
DFM M2	0.01888	0.285	0.400
DFM M3	0.01819	0.035	0.003
Indicadores + EMP			
DFM M1	0.02094	0.597	0.910
DFM M2	0.01896	0.284	0.331
DFM M3	0.01816	0.038	0.005
Indicadores + Incertidumbre			
DFM M1	0.02092	0.734	0.896
DFM M2	0.01875	0.292	0.302
DFM M3	0.01788	0.033	0.005
Combinación			
DFM M1	0.02094	0.570	0.767
DFM M2	0.01917	0.315	0.160
DFM M3	0.01820	0.035	0.000

Nota: La evaluación del pronóstico cubre el periodo 2012:M1-2021:M7 (38 trimestres). DFM refiere al modelo de factores dinámicos para el mes 1 (M1), mes 2 (M2) y mes 3 (M3) de cada trimestre.

La especificación del DFM es $r=2$, $p=2$, donde r es el número de factores y p es el orden del proceso autorregresivo de la ecuación 2. Indicadores: representa las variables económicas utilizadas en el DFM exhibido en la tabla 3. Combinación: promedio simple de los pronósticos generados por el DFM propuesto en la tabla 2 y tres DFM: indicadores hard, indicadores + el indicador EMP e indicadores + indicador de incertidumbre. La columna reporta el p-valor del test Giacomini y White con el modelo de Crecimiento naive como base, mientras que la columna reporta el p-valor del test Giacomini y White o con el modelo factorial estimado en la sección IV como base.

VII. Conclusiones

El monitoreo de la actividad económica es una tarea esencial para los agentes económicos. Los *policymaker*, por ejemplo, requieren conocer la evolución actual de la economía para formular expectativas y para el diseño y evaluación de políticas económicas. Sin embargo, una limitación que enfrentan a la hora de monitorear el estado actual de la economía se asocia con el retraso con el cual se publican los datos de variables relevantes para

dicha tarea. Por ejemplo, el PIB trimestral de Argentina se publica aproximadamente 80 días posterior a la finalización de dicho trimestre. Una solución para abordar esta limitación se asocia con explotar información publicada de forma temprana y con mayor frecuencia para obtener una estimación anticipada de cierta variable objetivo. En esta línea, este trabajo estima un modelo de factores dinámicos con el objetivo de realizar un *backcast/nowcast* de la tasa de crecimiento del PIB de Argentina, explotando información económica de alta frecuencia.

A partir de un ejercicio de pronóstico fuera de la muestra en pseudo tiempo real que cubre el periodo 1998:Q1-2021:Q2, se evidencia que: i) el modelo DFM tiene una performance superior tanto en el *backcast* como en el *nowcast* respecto a diferentes modelos base: un AR(1) y un modelo de crecimiento naive, ii) las predicciones son progresivamente más precisas conforme el trimestre concluye, es decir, toda la información acumulada es incorporada, iii) la precisión de los modelos factoriales en el *nowcast* aumenta con la incorporación de un indicador de tono sobre el ciclo económico argentino, un indicador que captura presión sobre el mercado cambiario y un indicador que aproxima niveles de incertidumbre económica, iv) existen ganancias en términos de aumentos en la capacidad predictiva derivados de la combinación de modelos de pronóstico.

Asimismo, a través de un ejercicio estadístico se evidencia una asociación positiva y estadísticamente significativa entre los errores de pronóstico e indicadores que captura incertidumbre económica. A partir de este ejercicio, se puede inferir que el indicador de incertidumbre económica basado en información no estructurada captura de forma adecuada la incertidumbre, aproximada por los errores de pronóstico. Este resultado sugiere que existen ganancias en términos de precisión predictiva asociados a incorporar indicadores que capturen estados de incertidumbre económica.

Existe diversas líneas en las cuales se puede extender este documento. En primer lugar, explotar información de más alta frecuencia con el objeto de capturar flujos de información intramensual. En segundo lugar, este trabajo explota sólo un conjunto reducido de indicadores económicos, por lo tanto, queda espacio para incorporar variables económicas de diversa naturaleza en pos de evaluar si contribuye a aumentar la capacidad pre-

dictiva del modelo. En tercer lugar, emplear otras técnicas de modelos de pronóstico como por ejemplo MIDAS y FAVAR, evaluar su performance y combinar las predicciones de estos modelos con aquellas derivadas de modelos factoriales. Por último, evaluar de forma precisa la contribución a la precisión predictiva aportada por cada variable.

Referencias

- Aguilar, P., Ghirelli, C., Pacce, M., y Urtasun, A. (2021). "Can news help measure economic sentiment? An application in COVID-19 times", *Economics Letters*, 199, 109730.
- Aromí, J. D. (2020). "Linking words in Economic Discourse: Implications for Macroeconomic Forecasts", *International Journal of Forecasting*, 36(4), 1517-1530.
- Bachmann, R., Steffen E. & Eric R. Sims (2013). "Uncertainty and Economic Activity: Evidence from Business Survey Data", *American Economic Journal: Macroeconomics*, 5(2): 217-49.
- Banbura, M., Giannone, D., Modugno, M. y Reichlin, L. (2013). "Now-casting and the real-time data Flow", *European Central Bank, Working Paper N° 1564*.
- Baker, S. R., Bloom, N., y Davis, S. J. (2016). "Measuring economic policy uncertainty", *The Quarterly Journal of Economics*, 131(4), 1593-1636.
- Blanco, E., D' Amato, L., Dogliolo, F. y Garegnani, L. (2017). "Nowcasting GDP in Argentina: Comparing the Predictive Ability of Different Models", *Banco Central de la República Argentina (BCRA), Working Paper N° 74*.
- Bloom, N. (2009). "The impact of uncertainty shocks", *Econometrica*, 77(3), 623-685.
- Camacho, M., Dal Bianco, M. y Martínez-Martín, J. (2013). "Short-Run Forecasting of Argentine GDP Growth", *BBVA, Working Paper N° 13/14*.
- Doz, C., Giannone, D., y Reichlin, L. (2011). "A two-step estimator for large approximate dynamic factor models based on Kalman filtering", *Journal of Econometrics*, 164(1), 188-205.
- Doz, C., Giannone, D., y Reichlin, L. (2012). "A quasi-maximum likelihood approach for large, approximate dynamic factor models", *The Review of Economics and Statistics*, 94(4), 1014-1024.
- Eichengreen, B., Rose, B. y Wyplosz, C. (1996). "Contagious Currency Crises: First Tests", *The Scandinavian Journal of Economics*, 98(4), 463-484.
- Giannone, D. Reichlin, L. y Small, D. (2008). "Nowcasting: The real-time informational content of macroeconomic data", *Journal of Monetary Economics*, 55, 665-676.
- Giacomini, R. y White, H., (2006). "Tests of conditional predictive ability", *Econometrica*, 74(6), 1545-1578.
- Ghirelli, C., Pérez, J. J., y Urtasun, A. (2019). "A new economic policy uncertainty index for Spain", *Economics Letters*, 182, 64-67.
- Ghysels, E. y Marcellino, M. (2018). "State Space Models". En *Applied Economic Forecasting using Time Series Methods*, capítulo 11, pp. 419-449. Oxford University Press.
- Goldberg, L. y Krogstrup, S. (2018). "International Capital Flow Pressures", *International Monetary Fund, IMF Working Papers N 18/30*.
- Hegerty, S. W. (2014). "Exchange market pressure, commodity prices, and contagion in Latin America", *The Journal of International Trade & Economic Development: An International and Comparative Review*, 23(1), 56-77.
-

- Kaminsky, G. y Reinhart, C. (1999). "The twin crises: The Causes of Banking and Balance-of-Payments Problems", *American Economic Review*, 89(3), 473-500.
- Llada, M. (2021). "Relationship between country risk volatility and indices based on unstructured information", *Estudios de Economía*, 48, 175-218.
- Newey W. K., y West K. D. (1987). "A Simple, Positive Semi-Definite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix", *Econometrica*, Vol. 55, pp. 703-708.
- Newey, W. K., y West, K. D. (1994). "Automatic lag selection in covariance matrix estimation", *The Review of Economic Studies*, 61(4), 631-653.
- Rossi, B., y Sekhposyan, T. (2015). "Macroeconomic Uncertainty Indices Based on Nowcast and Forecast Error Distributions", *American Economic Review*, 105(5), 650-655.
-

Anexo A

En este apartado se presentando los resultados del *backcasting* y *nowcasting* que resultan de estimar el DFM a través del método en dos etapas siguiendo el Giannone *et al.* (2008).

Tabla A1. Backcasting de la tasa de crecimiento del PIB

Modelo de Pronostico	RMSE	GW
DFM M1	0.01423	0.012
DFM M2	0.01564	0.012
DFM M3	0.01419	0.006
AR1	0.02164	0.966
Crecimiento naive	0.02212	-

Nota: La evaluación del pronóstico cubre el periodo 2012:M1-2021:M7 (38 trimestres). DFM refiere al modelo de factores dinámicos para el mes 1 (M1), mes 2 (M2) y mes 3 (M3) de cada trimestre. El DFM se estima a través del método en dos etapas siguiendo Giannone et al. (2008). AR1 representa el pronóstico asociado al modelo autorregresivo de orden 1. Crecimiento naive corresponde al pronóstico realizado utilizando la tasa de crecimiento promedio del periodo previo al momento en que se realiza el pronóstico. La columna GW reporta el p-valor del test Giacomini y White con el modelo Crecimiento naive como base.

Tabla A2. Nowcasting de la tasa de crecimiento del PIB

Modelo de Pronostico	RMSE	GW
DFM M1	0.02025	0.290
DFM M2	0.01943	0.635
DFM M3	0.01535	0.013
AR1	0.02106	0.267
Crecimiento naive	0.02206	-

Nota: La evaluación del pronóstico cubre el periodo 2012:M1-2021:M7 (38 trimestres). DFM refiere al modelo de factores dinámicos para el mes 1 (M1), mes 2 (M2) y mes 3 (M3) de cada trimestre. El DFM se estima a través del método en dos etapas siguiendo Giannone et al. (2008). AR1 representa el pronóstico asociado al modelo autorregresivo de orden 1. Crecimiento naive corresponde al pronóstico realizado utilizando la tasa de crecimiento promedio del periodo previo al momento en que se realiza el pronóstico. La columna GW reporta el p-valor del test Giacomini y White con el modelo Crecimiento naive como base.

