

Documentos de Trabajo | 2022 | N 99

*Nowcasting durante la pandemia:
Un apartado para Argentina*



ie | BCRA
INVESTIGACIONES ECONÓMICAS

Investigaciones Económicas

Documentos de trabajo | 2022 | N 99

*Nowcasting durante la pandemia:
Un apartado para Argentina*

*Emilio Blanco
Banco Central de la República Argentina*

*Fiorella Dogliolo
Banco Central de la República Argentina*

*Lorena Garegnani
Banco Central de la República Argentina*

Marzo 2022



ie | BCRA
INVESTIGACIONES ECONÓMICAS

Documentos de Trabajo, N 99

Nowcasting durante la pandemia: Un apartado para Argentina

Emilio Blanco
Banco Central de la República Argentina

Fiorella Dogliolo
Banco Central de la República Argentina

Lorena Garegnani
Banco Central de la República Argentina

Marzo 2022
ISSN 1850-3977
Edición electrónica

Reconquista 266, C1003ABF
Ciudad Autónoma de Buenos Aires, Argentina
Teléfono | 54 11 4348-3582
Correo electrónico | investig@bcra.gob.ar
Página web | www.bcra.gob.ar

Las opiniones vertidas en este trabajo son exclusiva responsabilidad de los autores y no reflejan necesariamente la posición del Banco Central de la República Argentina. La serie Documentos de trabajo está compuesta por material preliminar que se hace circular con el propósito de estimular el debate académico y recibir comentarios. Toda referencia que desee efectuarse a estos Documentos deberá contar con la autorización del o los autores.

Nowcasting durante la Pandemia: un apartado para Argentina^{*}

Emilio Blanco
BCRA y UBA

Fiorella Dogliolo
BCRA y UNLP

Lorena Garegnani
BCRA y UNLP

Marzo 2022

Resumen

En este trabajo pronosticamos la actividad económica trimestral en tiempo real usando modelos de factores dinámicos (dynamic factors models, DFM) (Blanco et al. 2018, Blanco et al. 2021) y evaluamos su desempeño predictivo durante la pandemia originada por el COVID-19. Comparamos los resultados de los pronósticos de una estimación realizada con los parámetros pre pandemia y una versión del DFM en que los parámetros son actualizados usando la información más reciente. Considerando las observaciones extremas que se registraron en 2020, exploramos si la inclusión de nuevos indicadores de alta frecuencia (tales como consumo de energía y movilidad) ayuda a capturar de manera más precisa la abrupta caída de la economía.

Palabras Clave: Nowcasting, modelos de factores dinámicos, COVID-19

Clasificación JEL: C22, C53, E37

Abstract

We forecast economic activity in Argentina on a quarterly real-time basis using dynamic factors models (DFM) (Blanco et al. 2018) and evaluate their forecasting performance during the COVID-19 pandemic of 2020. We compare the results of forecasts based on a pre-pandemic estimation of the parameters in the DFM and a re-estimated DFM with updated parameters using the most recent information. Considering the extreme observations that occurred during this particular year, we explore whether including new high frequency indicators (such as energy consumption and mobility) help capture more accurately the severe downturn.

^{*}Las opiniones vertidas en este trabajo son exclusivas de los autores y no reflejan necesariamente las del Banco Central de la República Argentina o sus autoridades. Queríamos agradecer los comentarios y sugerencias de Esther Ruiz-Ortega (Universidad Carlos III de Madrid) y del resto de los participantes de la Onceava Conferencia de Investigación del Consejo Consultivo de las Américas del BIS "The Economics of the Covid-19 Pandemic", 16-18 Noviembre de 2021. También queremos dar las gracias a la referí externa Laura D'Amato por sus recomendaciones. Email: emilio.blanco@bcra.gob.ar, fiorella.dogliolo@bcra.gob.ar, lgaregnani@bcra.gob.ar

1. Introducción

La pandemia y las cuarentenas o *lockdowns* de 2020 desafiaron a las herramientas tradicionales utilizadas por las autoridades monetarias y los hacedores de política. Además, resaltaron la necesidad de contar con pronósticos de la actividad económica precisos y oportunos, dado el *sudden stop* mundial sin precedentes. La evaluación de las condiciones económicas prevalecientes es un ingrediente crucial en la toma de decisiones de los bancos centrales y otras áreas del gobierno. No obstante, este proceso, que debe realizarse en tiempo real, usualmente se basa en información incompleta, debido a que el PIB -principal fuente de información sobre la actividad económica- se publica trimestralmente y con un importante rezago. En la última década se generaron indicadores de ciclo económico más oportunos, que brindan información cuantitativa sobre las decisiones de gasto (indicadores duros), así como información cualitativa mediante diferentes encuestas (indicadores blandos). La mayoría de los bancos centrales ha realizado ejercicios de Nowcasting utilizando estos indicadores, pero la incertidumbre en torno al impacto del COVID-19 fue una prueba crucial para las metodologías de pronóstico habituales.

En este sentido, el desafío a las herramientas tradicionales llevó al desarrollo de nuevas metodologías y a cambios o reversiones de las metodologías existentes, con el fin de poder capturar la dinámica de la actividad económica. Así, en esta línea de avances metodológicos, Huber et al. (2020) desarrollan métodos econométricos bayesianos para la inferencia posterior en VARs no paramétricos de frecuencia mixta (MF-BAVART), utilizando árboles de regresión aditiva. Los vectores autorregresivos de frecuencia mixta (MF-VAR) han sido una herramienta estándar para producir Nowcasts de alta frecuencia de variables de baja frecuencia durante varios años. Con la llegada de la pandemia de COVID-19 de 2020, la necesidad de tales Nowcast se ha vuelto aún más crítica. Sin embargo, los MF-VAR lineales tuvieron un desempeño pobre debido a su incapacidad para lidiar de manera efectiva con los *outliers* u observaciones extremas. Huber et al. (2020) argumentan que los modelos de árboles de regresión son ideales para el Nowcast para variables macroeconómicas frente a observaciones extremas como, por ejemplo, las producidas por la pandemia de COVID-19 de 2020. Esto se debe a su flexibilidad y capacidad para modelar valores atípicos. En una aplicación en la que incorporan cuatro países de la zona del euro, encuentran mejoras sustanciales en el rendimiento predictivo de corto plazo en relación con un VAR lineal de frecuencia mixta.

Otros avances metodológicos pueden encontrarse en Schorfheide y Song (2020), que estiman un vector autoregresivo de frecuencia mixta (MF-VAR), desarrollado en Schorfheide y Song (2015), para generar pronósticos macroeconómicos en tiempo real para EE.UU. durante la pandemia de COVID-19. Deliberadamente no modifican la especificación del modelo. Combinan once series de tiempo observadas con frecuencia trimestral y mensual, y encuentran que los pronósticos de un VAR basados en una estimación previa a la crisis, utilizando datos hasta finales de 2019, parecen ser más estables y razonables que los pronósticos basados en una secuencia de estimaciones recursivas que incluyen las observaciones más recientes. En general, las perspectivas del MF-VAR son bastante pesimistas. El MF-VAR estimado implica que las variables en niveles son altamente persistentes, lo que significa que el shock COVID-19 genera una reducción duradera de la actividad real. Finalmente, enfatizan que con el tiempo se confirmará si esta predicción es acertada, o si es posible reiniciar el crecimiento económico rápidamente, acortando la duración del efecto recesivo que tiene el shock y recuperar la senda previa para fines de 2021.

Una contribución adicional teniendo en cuenta estimaciones recursivas, tanto para los parámetros

como para los errores de pronóstico, fue desarrollada por Siliverstovs (2021). Presenta los resultados del pronóstico de crecimiento del PIB de la zona del euro durante el período comprendido entre el primer trimestre de 2006 y el tercer trimestre de 2020, prestando especial atención al desempeño de los modelos durante la pandemia de COVID-19. Al utilizar los datos del período anterior al COVID-19, muestra que ignorar las asimetrías en la precisión de pronóstico de un modelo a lo largo de las fases del ciclo económico generalmente conduce a un juicio sesgado de la capacidad predictiva del modelo en cada fase. Dados los cambios drásticos en las tasas de crecimiento del PIB en una amplia gama de países durante la pandemia de coronavirus, es muy probable que los errores de pronóstico de los modelos econométricos para estos trimestres también sean extraordinariamente grandes. Sin lugar a dudas, estos grandes errores de pronóstico ejercen una gran influencia en las métricas de precisión del pronóstico basadas en los promedios de los errores de pronóstico al cuadrado y sus diferencias. En tales situaciones, las medidas recursivas que analizan la capacidad de pronóstico de los modelos, observación por observación, permiten obtener información detallada sobre las causas subyacentes de la superioridad de un modelo sobre los demás. En su trabajo, Siliverstovs sugiere una métrica novedosa denominada error de pronóstico cuadrático medio relativo recursivo y muestra cómo este nuevo indicador, junto con la suma acumulada de la diferencia de error de pronóstico cuadrático de Welch y Goyal (2008), conducen a diferencias significativas en la capacidad de pronóstico relativo entre un modelo de factores dinámicos y modelos *benchmark* univariados simples o *naive* en expansiones y recesiones que generalmente no son visibles cuando sólo se informan estimaciones puntuales de capacidad predictiva relativa de los pronósticos.

Por su parte, Ankargren y Lindholm (2021) realizan un Nowcast para el crecimiento del PIB sueco, utilizando varios tipos de modelos de pronóstico de corto plazo. Sus resultados indican que las regresiones MIDAS de tamaño mediano y los modelos de ecuaciones puente a pequeña escala superan a un modelo de factores dinámicos en un período de evaluación establecido en 2010:T1– 2019:T4. Entre los modelos de factores dinámicos, encuentran que un conjunto más grande de variables es más apropiado. En su mayor parte, los Nowcasts del modelo de factores dinámicos son cualitativamente similares a aquellos de los modelos MIDAS y de ecuaciones puente, pero los últimos modelos exhiben un mayor grado de inercia y menos volatilidad a lo largo del tiempo. En un examen más detenido durante la pandemia de COVID-19, encuentran que el modelo de factores dinámicos reacciona mucho más enérgicamente durante 2020:T2 y 2020:T3, que los desarrollados por pronosticadores profesionales. Por lo tanto, encuentran una clara discrepancia entre, por un lado, un mejor desempeño histórico de los pronósticos y, por otro lado, la performance en capturar la desaceleración inducida por la pandemia y la posterior recuperación en 2020:T2 y 2020:T3. No obstante, la combinación de pronósticos igualmente ponderados es superior a cualquier método individual. Al descomponer las revisiones de los pronósticos inmediatos del modelo de factores dinámicos en contribuciones, encuentran que los parámetros actualizados causaron grandes revisiones. Sin embargo, en comparación con un modelo que no se vuelve a estimar durante la pandemia, las predicciones inmediatas del modelo re-estimado son más razonables y precisas. Finalmente, encuentran que la incorporación de nuevas fuentes de datos que miden la actividad económica con mayor frecuencia no mejora históricamente la precisión de los pronósticos, pero amplifica la señal de recesión durante el pico de la pandemia.

En otra línea de estudio, la investigación aplicada sobre la dinámica de actividad o precios se ha visto revolucionada por el surgimiento de nuevos tipos de indicadores de alta frecuencia. Búsquedas en Internet, datos administrativos granulares, transacciones con tarjetas de crédito, reservas en restaurantes, consumo de electricidad, informes de movilidad, prensa y noticias, son algunos ejemplos

de nuevas fuentes de datos aplicadas recientemente¹. En un artículo reciente, Buell et. al. (2021) presentan un conjunto de herramientas basadas en indicadores granulares y de alta frecuencia a nivel de país para África subsahariana (ASS) que se puede utilizar para pronosticar el PIB y realizar un seguimiento de los cambios en la actividad económica. Presentan resultados de Nowcast del PIB del cuarto trimestre de 2019 y del primer trimestre de 2020 para Kenia, Nigeria, Sudáfrica, Uganda y Ghana, utilizando las búsquedas de Google Trends y los datos de pagos móviles en un contexto de *machine learning* o aprendizaje automatizado para modelos de factores paramétricos. Argumentan que la metodología podría generalizarse para pronosticar el PIB de otros países del ASS, que tienen disponibilidad de datos limitada y muestras más cortas.

En este trabajo consideramos desarrollos anteriores (Blanco et. al. 2017 y 2018) y evaluamos el desempeño del pronóstico de un modelo de factores dinámicos (DFM, por su sigla en inglés) para la variación trimestral desestacionalizada del PIB de Argentina durante el particular bienio 2020/2021. La gran inestabilidad macroeconómica y los quiebres estructurales que caracterizan el ciclo económico de Argentina, hacen del Nowcasting una herramienta predictiva particularmente atractiva, mientras que en estos contextos los modelos autorregresivos suelen presentar un desempeño predictivo pobre (Banco de Inglaterra, 2014). Pesaran y Timmerman (2007) consideran que la utilización de diferentes ventanas de estimación para un mismo modelo puede ayudar cuando los quiebres ocurren dentro de la muestra. A tal efecto, el ya mencionado Siliverstovs (2021) encontró que los pronósticos basados en coeficientes estimados de manera recursiva, lograron una mejor proyección del crecimiento del PIB en la zona del euro en el segundo y tercer trimestre de 2020 en comparación con las proyecciones que mantenían los coeficientes en los valores del período anterior a la pandemia del COVID-19. De este modo, resulta de interés estudiar si la reestimación de los parámetros durante el período de pandemia genera mejoras en la capacidad predictiva del Nowcast del PIB en Argentina. Además, dadas las limitaciones de datos durante los primeros meses del confinamiento, también exploramos el uso de fuentes de información alternativas, como el consumo de energía y los reportes de movilidad de Google.

El documento está organizado de la siguiente manera. En la sección 2 presentamos una breve descripción general del confinamiento y las medidas sanitarias en Argentina. El enfoque metodológico se desarrolla en la tercera sección. El siguiente segmento contiene los resultados principales de nuestro ejercicio de Nowcasting y la comparación en términos de capacidad predictiva con otros modelos, usando como benchmark un modelo de series de tiempo y una estimación pre pandemia de los parámetros del DFM. La sección 4 analiza si el uso de nuevas fuentes de información de alta frecuencia permite obtener una mejora en el pronóstico. Finalmente, se presentan las conclusiones en la sección 5.

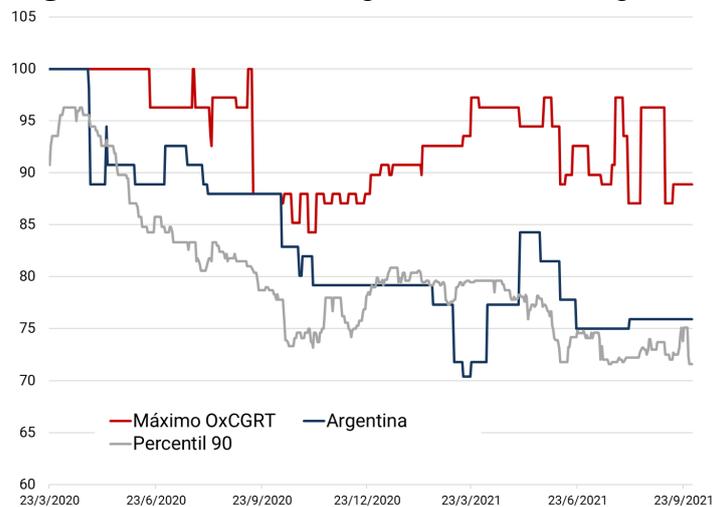
2. Contexto General: Medidas sanitarias y confinamiento en Argentina

Durante los últimos dos años el mundo debió enfrentar el impacto del COVID-19 y Argentina no fue la excepción. Luego de encontrarse el primer caso de COVID-19 en el país, el Gobierno Nacional

¹Con respecto al uso de fuentes de datos originales en Argentina, siguiendo el artículo fundamental de Choi y Varian (2011), Blanco (2014) construye un indicador de consumo mensual utilizando palabras clave y categorías de Google Trends. Los resultados sugieren que la inclusión de un índice basado en las búsquedas en línea mejora el rendimiento de los pronósticos.

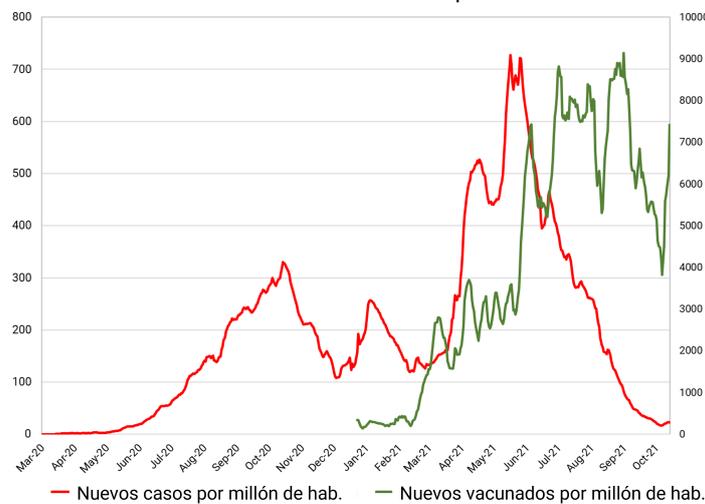
implementó medidas en pos de contener la expansión del virus, y, mediante un Decreto, dispuso el 19 de marzo de 2020 el Aislamiento Social, Preventivo y Obligatorio. Como resultado, los trabajadores considerados no esenciales no tenían permitido movilizarse y concurrir a sus trabajos, lo que generó un freno en diversas actividades económicas. A nivel internacional, surgieron indicadores que intentaban cuantificar la severidad de las políticas tomadas por los distintos gobiernos para frenar la transmisión del virus. Un ejemplo de esto es el Índice de Astringencia de la Universidad de Oxford (COVID-19 Government Response Tracker (OxCGRT))² que puede apreciarse en el panel A de la Figura 1. Esta medida compuesta es un puntaje aditivo simple de siete indicadores (políticas como el cierre de escuelas, prohibiciones de viaje, etc.) medidos en una escala ordinal, reescalada para variar entre 0 y 100. La evolución de dicho índice para Argentina nos muestra la rigurosidad de las medidas adoptadas en 2020: el indicador para Argentina se ubica generalmente por encima del percentil 90, considerando la totalidad de los 186 países en la muestra.

Figura 1A. Índice de Astringencia de Oxford. Argentina



Fuente: <https://covidtracker.bsg.ox.ac.uk/>

Figura 1B. Argentina. Nuevos Casos Diarios de COVID-19 Confirmados por millón de habitantes (eje izq.) y Número de Personas Vacunadas contra COVID-19 por millón de habitantes (eje der.)



Fuente: ourworldindata.org

²Para mayor detalle sobre este indicador ver Hale et. al. (2021).

Dada la naturaleza epidemiológica y las medidas de salud implementadas por las autoridades para manejar la crisis, se podrían identificar tres fases: una primera etapa caracterizada por fuertes restricciones a la movilidad, una fase posterior en que se evidencia una progresiva relajación y finalmente una vuelta a una "nueva normalidad".

En la primera fase, la implementación de las medidas de aislamiento social impactaron negativamente sobre las actividades productivas "no esenciales" y se observó una caída del PIB, a pesar del levantamiento de las restricciones en algunas áreas geográficas o ciertos sectores económicos. En esta primera etapa, las políticas económicas se focalizaron en sostener la demanda y en preservar a las actividades productivas centrales y al sistema financiero.

La segunda fase del manejo de la crisis de la pandemia del COVID-19 comenzó durante el segundo trimestre de 2020, cuando las medidas de aislamiento social empezaron a relajarse gradualmente y se observaron los primeros signos de recuperación económica. Durante esta fase, disminuyeron algunas restricciones a la movilidad (aunque aún permaneciendo bajo estrictas regulaciones sanitarias), y se restablecieron progresivamente varias de las actividades en diversos sectores productivos, respetando protocolos de salud.

La evolución del sistema de salud y la implementación de estímulos fiscales y monetarios permitieron un proceso de recuperación económica y, como resultado, en diciembre de 2020 el PIB en términos reales se ubicó sólo un 3% por debajo de los niveles pre pandemia. En tanto, un año después del inicio de la pandemia de COVID-19, la economía argentina³ avanzó gradualmente hacia una recuperación, a medida que los sectores fueron reanudando sus actividades, producto de la implementación de protocolos sanitarios y la campaña de vacunación.

La situación epidemiológica empeoró hacia mediados de marzo de 2021, con el arribo de la segunda ola del COVID-19. El Gobierno Nacional implementó nuevas restricciones a la circulación, pero menos estrictas que las adoptadas en 2020. En este contexto, la actividad económica mostró signos de recuperación desde junio de 2021, tras el estancamiento observado en abril y mayo como consecuencia de la segunda ola de COVID-19. La circulación de nuevas cepas del virus, tal como ocurre en diversos países, podría modificar este escenario y postergar este proceso.

3. Nuestro Ejercicio de Nowcast

Nuestro ejercicio consiste en producir estimaciones tempranas del crecimiento trimestral del PIB desestacionalizado durante el período de *lockdown* y brote de la pandemia de COVID-19 (2020:T1-2021:T2)⁴. El conjunto inicial de datos incorpora 112 indicadores del ciclo, incluyendo tanto indicadores *hard o duros* como *soft o blandos*, que van desde indicadores financieros a datos de recaudación, datos desagregados de producción, encuestas de confianza del consumidor y ventas de automóviles, entre otros. Las variables incorporadas en el análisis están descritas en el Anexo 1. Todas las series fueron inicialmente estudiadas, y en caso de ser necesario fueron desestacionalizadas a través del

³El desarrollo de la pandemia fue heterogéneo entre las distintas regiones de Argentina. La tasa de infección se redujo gradualmente durante el tercer trimestre de 2020 en el Área Metropolitana de Buenos Aires (AMBA), mientras que se incrementó en el resto del país hasta mediados de octubre, cuando comenzó a declinar. A medida que se reanudaron las actividades en el Área Metropolitana, se observó una recuperación de la economía, como consecuencia de la elevada participación que posee esta región en el PIB de Argentina.

⁴En Argentina las cifras oficiales del Producto Interno Bruto son publicadas alrededor de 10 semanas luego de terminado el trimestre.

programa X-13 ARIMA-SEATS. Se les aplicó una transformación logarítmica y, con el fin de trabajar con series estacionarias, en caso de ser requerido, se calculó la primera diferencia o se eliminó la tendencia. Finalmente, fueron estandarizadas.

Según el calendario de publicación de las series, dividimos el conjunto de indicadores en 2 grupos: aquellos que están disponibles dentro de los 10 días posteriores a la culminación del mes (Grupo 1) y las series que se divulgan entre los 10 y 30 días posteriores a la finalización de mismo (Grupo 2). Siguiendo este agrupamiento, el Nowcast puede ser actualizado de manera secuencial, según el ejemplo establecido en la Figura 2.

Figura 2: Ejemplo de Actualización Secuencial

Fecha	15/2/2019	28/2/2019	15/3/2019	31/3/2019	15/4/2019	30/4/2019	15/5/2019	31/5/2019	15/6/2019
<i>Datos Disponibles</i>									
<i>Grupo 1</i>	Ene-19	Ene-19	Feb-19	Feb-19	Mar-19	Mar-19	Abr-19	Abr-19	May-19
<i>Grupo 2</i>	Dic-18	Ene-19	Ene-19	Feb-19	Feb-19	Mar-19	Mar-19	Abr-19	Abr-19
Nowcast	I 2019	II 2019	II 2019	II 2019					
<i>Comunicados Oficiales</i>									Comunicado Oficial I 2019

De acuerdo con el esquema de actualización, podemos obtener 6 estimaciones tempranas del PIB para cada trimestre. Utilizando una muestra inicial de estimación, que comprende el período 2016:T1-2019:T4, realizamos un ejercicio de Nowcasting pseudo-real-time del crecimiento del PIB mediante ventanas móviles. En línea con los resultados obtenidos en trabajos anteriores (D'Amato et. al. 2015, Blanco et. al. 2018), las variables consideradas para realizar la estimación fueron seleccionadas de acuerdo al coeficiente de correlación entre la variación trimestral de la variable y la variación trimestral del PIB, y a su vez según el juicio de experto.

3.1. Metodología de Nowcasting

Siguiendo a Giannone, Reichlin y Small (2005), el Nowcast puede ser realizado a través de la estimación de factores comunes extraídos de un gran conjunto de datos de alta frecuencia (diarios, semanales, mensuales) y luego usando dichos factores como regresores del PIB. La idea subyacente a este enfoque es que las variables dentro del set de interés son direccionadas o movidas por un conjunto pequeño de factores comunes latentes o no observables.

Más concretamente, la covarianza entre un gran número n de series de tiempo con sus adelantos (*leads*) y sus rezagos (*lags*) puede ser representada por un número reducido de q factores no observables (con $n > q$). Las perturbaciones en estos factores pueden representar en este contexto shocks a la oferta o demanda agregada.

Entonces, el vector X_t de n indicadores mensuales del ciclo económico puede ser explicado por un modelo de rezagos distribuidos de los q factores comunes latentes más n perturbaciones idiosincráticas, que potencialmente pueden estar correlacionadas serialmente (así como también correlacionadas entre las i).

El *dynamic factor model* o modelo de factores dinámicos (DFM) es por ende:

$$X_t = \lambda(L)f_t + e_t \quad (1)$$

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

Con f_t un vector de dimensión $q \times 1$ de factores latentes o no observables, las matrices de polinomios de rezagos $\lambda(L)$ y $\Psi(L)$ de dimensión $N \times q$ y $q \times q$, respectivamente, y η es un vector de $q \times 1$ innovaciones a los factores (no correlacionados serialmente). La fila i de $\lambda(L)$ es lo que se conoce comunmente como la carga factorial dinámica (*dynamic factor loadings*) de la serie i -ésima, X_{it} , mientras que e_t son las perturbaciones ideosincráticas que se asumen no correlacionadas con los factores ni en adelantos ni en rezagos⁵, es decir $E(f_t e_{it}) = 0 \forall i, t$.

Dada una variable objetivo y_t (en nuestro caso el logaritmo natural del crecimiento trimestral del PIB en términos desestacionalizados), el objetivo es estimar $E(y_t | X_t)$

$$y_t = \beta(L)f_t + \gamma(L)y_{t-1} + \varepsilon_t \quad (3)$$

Notar que es posible plantear al modelo formado por las ecuaciones (3) y (2) en una representación de Espacio-Estado (*State-Space*), siendo (3) la ecuación de medición que vincula las variables observables (y_t y X_t) con las variables de estado no observables (los f factores) y (2) la ecuación de transición que describe la dinámica de los factores subyacentes.

En este trabajo seguimos el proceso iterativo descrito en Banbura et. al. (2013) y Banbura y Modugno (2014) para estimar los f factores. Primero, se asume que el componente de errores sistemáticos e_t se comporta como un proceso autoregresivo independiente univariado ($e_{it} = \delta_i(L)e_{it-1} + \nu_{it}$, con $\nu_{it} \sim N(0, \sigma_{\nu_i}^2)$), y se define a θ como el vector que incorpora todos los parámetros del modelo (λ -cargas factoriales o *factor loadings*-, ε_t y σ_t). Luego, dados los parámetros capturados en θ , es posible usar el filtro de Kalman para computar la likelihood y emplear el Kalman smoother para obtener estimaciones de los factores subyacentes a X_t . Este procedimiento se basa en el algoritmo Expectation Maximization (EM). En resumidas cuentas, este proceso iterativo involucra:

- (i) Realizar una primera aproximación extrayendo los factores subyacentes a través de componentes principales
- (ii) Luego estimar los coeficientes del modelo de espacio-estado a partir de estos factores iniciales
- (iii) Finalmente re-estimar los factores con la ayuda del filtro de Kalman y el Kalman smoother.⁶

3.2. Evaluando la Capacidad Predictiva de los Modelos

Para decidir cuál de los modelos de Nowcast es superior para estimar la variable de interés se utiliza como criterio la capacidad predictiva. Para ello se emplea el test de Giacomini y White (2006), que permite evaluar si las diferencias en capacidad predictiva entre dos modelos son estadísticamente significativas y de este modo seleccionar el modelo que presenta la mejor performance de pronóstico. El enfoque metodológico planteado por Giacomini y White (GW) difiere de otros test desarrollados

⁵Ver Stock y Watson (2016) para casos donde e_i se encuentra correlacionado serialmente.

⁶Para mayores detalles sobre el método es recomendable revisar el apéndice de *Now-casting and the real-time data flow* Banbura et al. (2013).

previamente, como los propuestos por Diebold y Mariano (1995) y West (2006), debido a que se basa en expectativas condicionales. En este sentido, Giacomini y White se focalizan en seleccionar el mejor método de pronóstico para el período futuro de interés. Así, esta metodología es relevante cuando el objetivo es encontrar los modelos que son superiores en capacidad predictiva en lugar de evaluar la validez de algún modelo teórico en particular.⁷

El test posee diversas ventajas: (i) refleja el efecto de la incertidumbre en la estimación sobre la performance relativa de pronóstico, (ii) permite comparar de manera unificada pronósticos provenientes de una amplia variedad de modelos, entre los que se incluyen modelos anidados y no anidados, (iii) se puede utilizar para comparar la performance de pronósticos utilizando distintas técnicas de estimación, y (iv) también presenta una ventaja práctica, que radica en la facilidad de su cómputo a través de la realización de una regresión en los paquetes econométricos tradicionales.

Específicamente, la metodología del test de Giacomini y White consiste en evaluar pronósticos realizados mediante ventanas móviles (rolling windows). Esto es, con una muestra finita de tamaño R disponible en el momento t , se realizan las estimaciones de y_t y se utilizan para generar los pronósticos τ pasos adelante. El test asume que hay dos métodos, f_{Rt} y g_{Rt} para generar los pronósticos y_t utilizando el conjunto de información disponible \mathcal{F}_t .

$$\begin{aligned} f_{Rt} &= f_{Rt}(\hat{\gamma}_{R,t}) \\ g_{Rt} &= g_{Rt}(\hat{\theta}_{R,t}) \end{aligned}$$

Un total de P_n pronósticos que satisfacen $R + (P_n - 1) + \tau = T + 1$ son generados. La secuencia de los pronósticos producidos son evaluados a partir de una función de pérdida $L_{t+\tau}(y_{t+\tau}, f_{R,t})$, que depende del pronóstico y de la realización de la variable. Dada la función de pérdida, la hipótesis nula de igual capacidad predictiva condicional de los pronósticos f y g se puede escribir:

$$\begin{aligned} H_0 &: E[h_t(L_{t+\tau}(y_{t+\tau}, f_{R,t}) - L_{t+\tau}(y_{t+\tau}, g_{R,t})) | \mathcal{F}_t] = 0 \\ &\text{o alternativamente} \\ H_0 &: E[h_t \Delta L_{t+\tau} | \mathcal{F}_t] = 0 \quad \forall t \geq 0 \end{aligned}$$

para el conjunto de información \mathcal{F}_t y la función mensurable h_t .

En la práctica, el test consiste en realizar una regresión de las diferencias en las funciones de pérdida contra una constante y evaluar su significatividad utilizando el estadístico t convencional para la hipótesis nula de un coeficiente igual a 0. En el caso en que el horizonte de pronóstico sea mayor a uno, los errores estándar se calculan utilizando el estimador de covarianzas de Newey-West, que permite la presencia de heteroscedasticidad y autocorrelación residual.

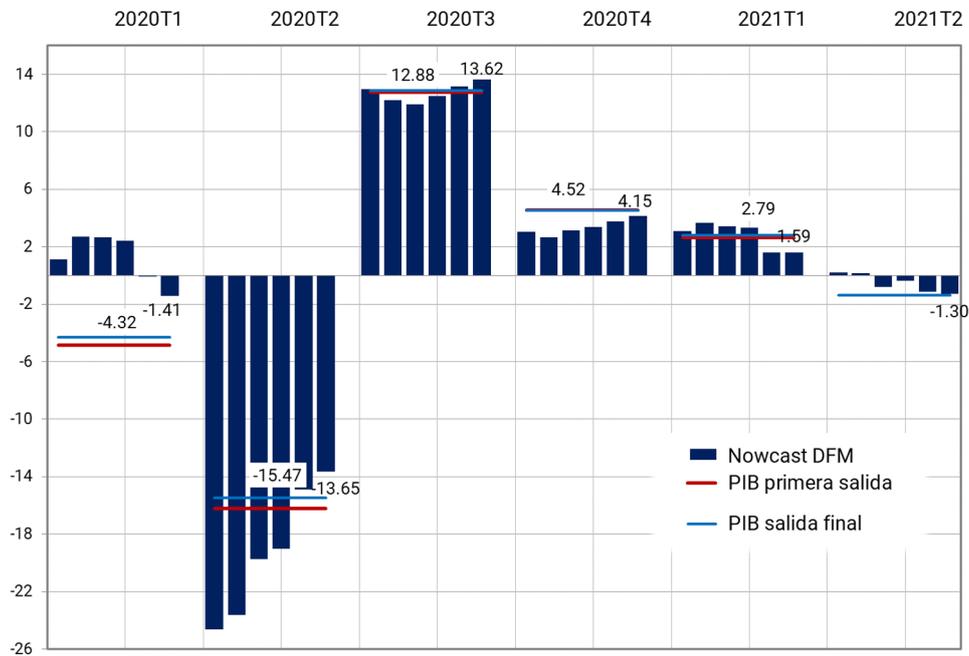
4. Resultados

El impacto del shock en la economía Argentina fue de una magnitud significativa. En particular, se registró la mayor caída anual del PIB desde la crisis económica de 2002 y la disminución que se

⁷Ver Pincheira (2006) para una descripción y aplicación del test.

observó en el segundo trimestre de 2020 fue la más pronunciada desde que se lleva un registro de las Cuentas Nacionales.

Figura 3. Actualización Secuencial del Nowcast

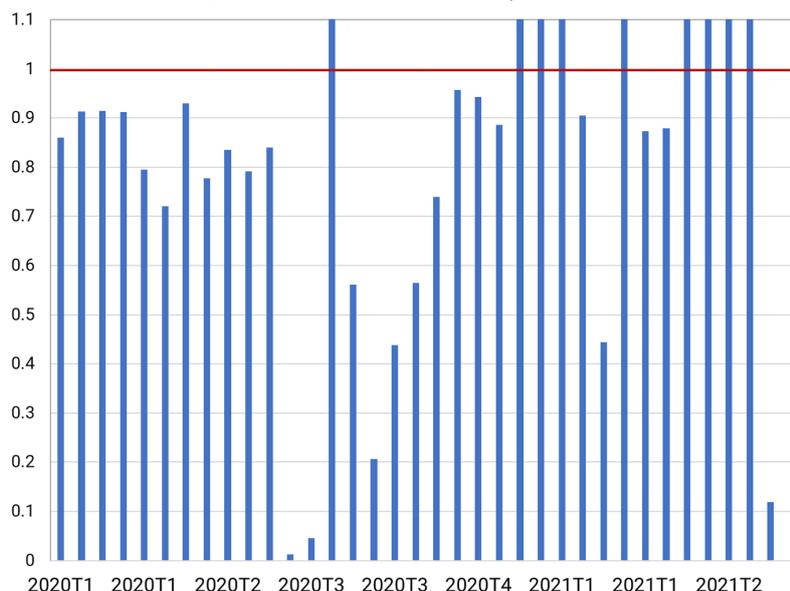


La Figura 3 presenta la actualización secuencial de nuestro ejercicio de Nowcast del PIB y las cifras oficiales, tanto de la primera publicación como de la última revisión de la serie. En términos generales, puede observarse que nuestro modelo de factores dinámicos captura el signo y, en la mayoría de los casos, la magnitud de la variación trimestral del Producto desestacionalizado. Cabe mencionar que los coeficientes del modelo son actualizados en cada estimación, esto es, cuando se dispone de nueva información.

Con el fin de comparar los resultados, estimamos un modelo autorregresivo utilizado como benchmark.⁸ En la Figura 4 puede observarse el ratio entre el RMSE de nuestro modelo Nowcast de factores dinámicos y el AR considerado como benchmark, cuando se los compara con la primera publicación del PIB oficial.

⁸Se busca el modelo autorregresivo con mejor bondad del ajuste y mejores resultados de capacidad predictiva dentro de la muestra. Los resultados de las estimaciones están disponibles para quien lo solicite.

Figura 4. RMSE Nowcast / RMSE AR



Nota: Un número menor a 1 indica que nuestro Nowcast supera al benchmark AR

En el 75% de los casos nuestro Nowcast es superior al benchmark, dado que los errores de pronóstico del modelo Nowcast son inferiores a los generados por el modelo AR. Para establecer si la ganancia en capacidad predictiva es estadísticamente significativa, se utiliza el test de Giacomini y White. La Tabla 1 muestra los resultados del test, donde se observa que el Nowcast supera al AR en capacidad predictiva con una significatividad del 5%⁹.

Tabla 1. Resultados del Test de Giacomini y White

<i>RMSE AR- RMSE DFM</i>	
t test	p-value
2.804	0.0101

4.1. Esquema de Estimación

Las estimaciones realizadas hasta el momento se basaron en un esquema de ventanas móviles (rolling windows), en el que los parámetros del modelo de Nowcasting son permanentemente actualizados, a medida que se cuenta con nueva información. Siliverstovs (2021) encontró que los pronósticos basados en coeficientes estimados de manera recursiva, lograron una mejor proyección del crecimiento del PIB en el segundo y tercer trimestre de 2020 en comparación con las proyecciones que mantenían los coeficientes en los valores del período anterior a la pandemia del COVID-19. De este modo, resulta de interés estudiar si la reestimación de los parámetros durante el período de pandemia genera mejoras en la capacidad predictiva del Nowcast del PIB en Argentina. En la Tabla 2 se presentan los resultados del test de Giacomini y White, que evalúa ambos esquemas.

⁹Dado el comentario de Martins y Perron (2016) acerca del poder del test de Giacomini y White para evaluar diferencias en capacidad predictiva en presencia de quiebres estructurales, evaluamos la estabilidad de la media de la diferencia de las funciones de pérdida en todos los casos. En ninguno de los pares de modelos considerados se ha encontrado un quiebre estructural en las diferencias en capacidad predictiva.

Tabla 2. Resultados del Test de Giacomini y White

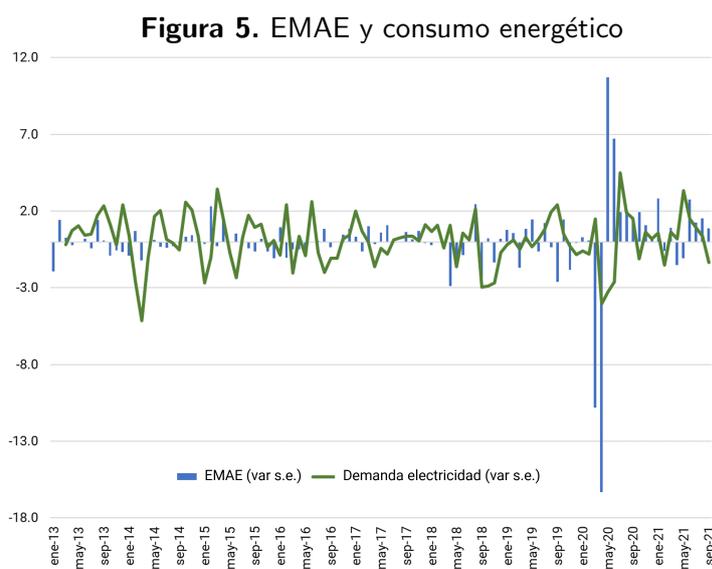
<i>RMSE DFM.fijo_ - RMSE DFM</i>	
test t	p-value
0.000004	0.9909

Los resultados del test señalan que ambos modelos son indistinguibles: mantener los coeficientes en los valores del período anterior a la pandemia del COVID-19 no genera una ganancia en la performance del pronóstico. Una posible explicación podría ser la inestabilidad histórica de la economía de Argentina que hace que, al considerar los datos más recientes y descartar las observaciones más antiguas —es decir, utilizando un esquema rolling windows—, se pueda capturar de mejor manera la caída observada en 2020.¹⁰

5. Nowcasting Utilizando Nuevas Fuentes de Información

Como fue mencionado anteriormente, el freno que experimentó la actividad económica en 2020, nunca antes registrado, implicó también un desafío en la recolección de datos del ciclo económico. La producción industrial, uno de los principales elementos dentro del ejercicio de Nowcasting, fue una de las actividades más afectadas. En los primeros meses de las fuertes restricciones, varios sectores industriales cerraron sus plantas y se observaron retrasos en la recolección de datos. Para poder dar respuesta sobre el desempeño de la actividad económica y poder tener una magnitud del impacto de la crisis sanitaria, se consideraron indicadores económicos adicionales de alta frecuencia: consumo de energía e información de movilidad de Google.

La literatura ha documentado que el consumo de energía brinda información relevante para realizar un seguimiento de la actividad económica (Bok et.al., 2017) y, adicionalmente, como se muestra en el siguiente gráfico, puede observarse que exhibe un movimiento similar al indicador que captura la actividad económica mensual (Estimador Mensual de la Actividad Económica -EMAE-).



Fuente: INDEC y CAMMESA

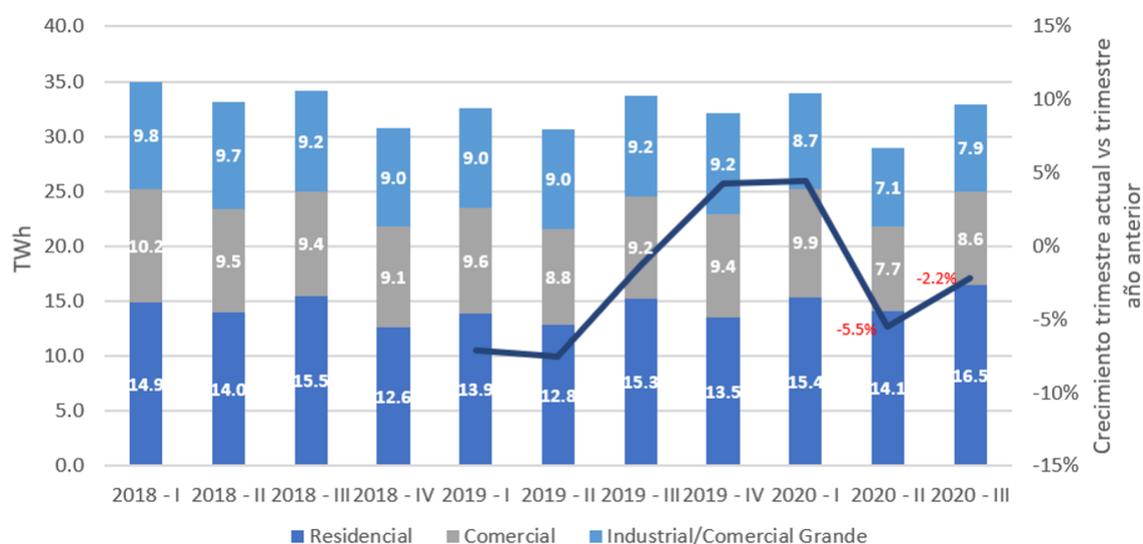
¹⁰En investigaciones futuras se explorará este hecho.

El análisis de índices de movilidad ha ganado relevancia en el seguimiento de la actividad en los últimos años (Ferrara y Simoni, 2019) y en particular durante la Pandemia (Arini y Putra, 2020). Es así que exploramos la posibilidad de complementar el ejercicio ya realizado a partir de indicadores tradicionales del ciclo con el índice de movilidad publicado por Google (basado en las ubicaciones reportadas por los usuarios de Google Maps).

5.1. Consumo de Energía

La principal fuente de información sobre el sector de energía eléctrica en Argentina es la Compañía Administradora del Mercado Mayorista Eléctrico (CAMMESA), una empresa de gestión privada con propósito público. El dato considerado para incorporar en el Nowcast es la demanda diaria neta de energía del sector mayorista, segmentado por actividad (residencial, comercial e industrial/comercial grande). Como puede observarse en la Figura 6, la demanda de electricidad en Argentina se redujo 5,5 % en el segundo trimestre de 2020 y 2,2 % en el tercero, en comparación con iguales trimestres de 2019.¹¹

Figura 6. Consumo de Energía en Argentina

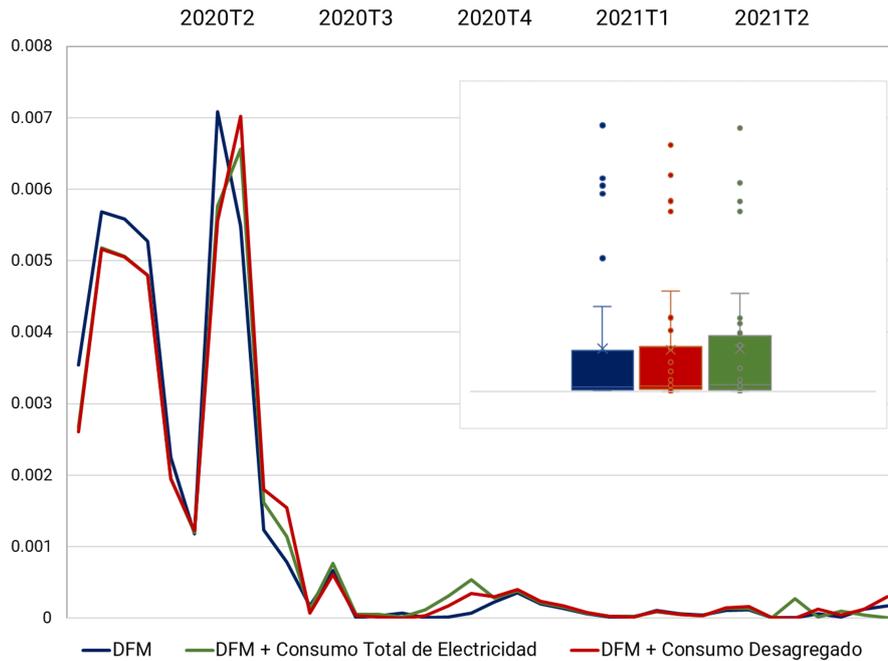


Fuente: IADB en base a datos de Cammesa

El indicador de energía se incluyó de dos maneras distintas. Por un lado, se incorporó como una variable adicional dentro del conjunto de indicadores utilizados en el modelo de factores (DFM + Consumo Total de Electricidad), y por otro lado, se incluyó como un regresor desagregado en la ecuación de Nowcasting (DFM + Consumo Desagregado de Electricidad). Dada la metodología de estimación, se transformaron las series diarias a la frecuencia de la variable objetivo. Por otro lado, se está trabajando actualmente en una nueva versión que permita trabajar con frecuencias mixtas.

¹¹IADB, 2020 "Demanda y precio de la energía eléctrica en Argentina: impacto de la pandemia y tendencias".

Figura 7. RMSE de los Distintos Modelos



Al observar el gráfico, los modelos de Nowcast lucen similares, presentando todos el mayor error de pronóstico en el segundo trimestre de 2020. Cuando se analiza la distribución de los errores, el modelo de Nowcast de factores dinámicos inicial parece tener la menor mediana de los errores. Sin embargo, cuando se utiliza el test de Giacomini y White para evaluar las diferencias en capacidad predictiva, el modelo que incorpora el consumo de energía como regresor independiente en la ecuación de estimación es el que presenta la mejor performance de pronóstico.

Tabla 3. Resultados del Test Giacomini y White

RMSE modelo en fila - RMSE modelo en columna

	DFM	DFM+Consumo Total	DFM+Consumo Desagregado
DFM		-0.00002	0.00014
DFM+Consumo Total	0.00002		0.00011
DFM+Consumo Desagregado	-0.00014	-0.00011	

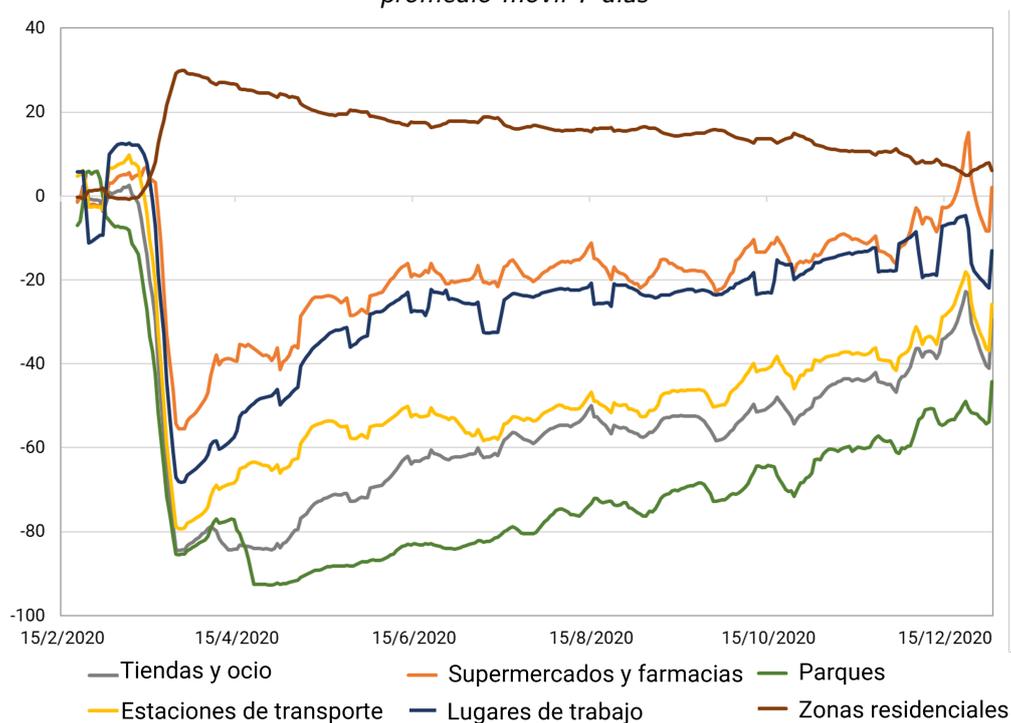
significativo al 5%

5.2. Movilidad de Google

Desde inicios de 2020, Google comenzó a compartir su información sobre movilidad.¹² Los datos muestran cómo se modifican las visitas a distintos lugares, tales como supermercados y parques, en una región geográfica en comparación con un día base (en particular, un valor normal para ese día de la semana, establecido como el valor de la mediana para una semana de 5 días en el período entre el 3 de enero y el 6 de febrero de 2020). La Figura 8 presenta el promedio móvil 7 días de los datos que comprende el reporte de Google.

¹²Ver <https://support.google.com/covid19-mobility> para mayores detalles

Figura 8. Reporte de Movilidad para Argentina
promedio móvil 7 días



Fuente: Reporte de Movilidad de Google (CSVs)

La Figura anterior evidencia un punto obvio pero no de menor relevancia: la movilidad sufrió un cambio significativo cuando se impusieron las medidas sanitarias de aislamiento social y de restricciones a la movilidad. A medida que las restricciones fueron gradualmente eliminadas, la movilidad fue retornando a niveles más similares a los del período de referencia. Para evaluar si esta información genera una mejora en la estimación del ciclo económico, se transformó la serie a la frecuencia de la variable objetivo y se decidió incorporarla como una variable adicional en la estimación de los factores¹³. Se presentan los resultados del test de Giacomini y White en la Tabla 4.

Tabla 4. Resultados del Test de Giacomini y White

<i>RMSE DFM - RMSE DFM+ Google</i>	
test t	p-value
0.000157	0.6322

En resumen, encontramos que incluir al indicador de movilidad de Google en el modelo Nowcast de factores dinámicos no genera una ganancia significativa en términos de pronósticos en relación a nuestro modelo inicial.

¹³La metodología adoptada permite la incorporación de nuevas series independientemente de la longitud de la muestra.

6. Conclusiones

La pandemia ocasionada por el COVID-19 y la consecuente crisis global sin precedente del 2020, generaron un desafío a las herramientas tradicionales utilizadas por los bancos centrales para la realización de los pronósticos macroeconómicos. En este trabajo, evaluamos un ejercicio de Nowcast del Producto para Argentina, realizado mediante una estimación de un modelo de factores dinámicos, para el período de aislamiento social y crisis sanitaria de 2020 y 2021 (período muestral 2020:T1 - 2021:T2).

El impacto del shock en la economía Argentina fue de una magnitud significativa. En particular, se registró la mayor caída anual del PIB desde la crisis económica de 2002 y la disminución que se observó en el segundo trimestre de 2020 fue la más pronunciada desde que se lleva un registro de las Cuentas Nacionales. Más allá de estos valores extremos, nuestro ejercicio logró capturar el signo y la magnitud de la variación trimestral del Producto en términos desestacionalizados. A su vez, resultó ser superior en capacidad de pronóstico que el modelo AR considerado como benchmark. También se estudió la ganancia en capacidad predictiva de trabajar con diferentes esquemas de estimación. En particular, se encontró que no existen diferencias significativas en los resultados obtenidos en el Nowcast cuando se estiman nuevamente los parámetros del modelo o cuando permanecen fijos en los niveles previos a la pandemia del COVID-19.

Finalmente, se exploraron nuevas fuentes de información de alta frecuencia. En este sentido, se encontró que incorporar al consumo de energía como una variable adicional en la regresión mejora los resultados del Nowcast, mientras que el índice de movilidad de Google no necesariamente genera una mejor estimación del ciclo económico.

Una agenda futura de investigación incluye explorar otras fuentes de información de alta frecuencia (por ejemplo variables financieras) y trabajar con otras metodologías que permitan estimaciones con frecuencias mixtas.

Referencias

- [1] Ankargren, S. y U. Lindholm (2021). "Nowcasting Swedish GDP Growth", Working paper No. 154, National Institute of Economic Research (NIER).
- [2] Arini, S. y R. Putra (2020). "Measuring the Economics of a Pandemic: How People Mobility depict Economics? An Evidence of People's Mobility Data towards Economic Activities", Presentado en el *8th IMF Statistical Forum*.
- [3] Banbura M., Giannone, D., Modugno, M. y L. Reichlin (2013) "Now-casting and the real-time data flow", *Handbook of Economic Forecasting*, Elliot G. and A. Timmermann, eds., Chapter 4, Vol. 2, North-Holland.
- [4] Banbura M. y M. Modugno (2014). "Maximum likelihood estimation of factor models on data sets with arbitrary pattern of missing data", *Journal of Applied Econometrics*, vol. 29(1), pp. 133-160.
- [5] Blanco, E., L. D'Amato, F. Dogliolo y L. Garegnani (2021). "Nowcast de Agregados Macroeconómicos en Argentina: Comparando la capacidad predictiva de diferentes modelos", Documento de Trabajo 2021 N° 90, BCRA.

- [6] Blanco, E., L. D'Amato, F. Dogliolo y L. Garegnani (2018). "Nowcasting Activity in Argentina using Dynamic Factor Models", AAEP Reunión Anual LIII, Nov. 2018.
- [7] Blanco, E., L. D'Amato, F. Dogliolo y L. Garegnani (2017). "Nowcasting GDP in Argentina: Comparing the predictive ability of different models", Economic Research Working Papers 2017 N° 74, BCRA.
- [8] Blanco, E. (2014). "Herramientas de Big Data: ¿Podemos aprovechar Google Trends para pronosticar algunas variables macro relevantes?". Mimeo.
- [9] Bok, B., Caratelli, D., Giannone, D., Sbordone, A. y A. Tambalotti (2017). "Macroeconomic Nowcasting and Forecasting with Big Data, Federal Reserve Bank of New York Staff Reports", no. 830 November 2017
- [10] Buell, B., Chen, C., Cherif, R., Seo, H., Tang, J. y N. Wendt (2021). "Impact of COVID-19: Nowcasting and Big Data to Track Economic Activity in Sub-Saharan Africa", IMF Working Paper No.21/124, Abril 2021.
- [11] Choi, H y H. Varian (2011). "Predicting the Present with Google Trends", Google Technical Report.
- [12] Clark, T. y K. West (2007). "Approximately normal tests for equal predictive accuracy in nested models, *Journal of Econometrics*, Vol. 138, Issue 1, pp. 291-311.
- [13] Clements, M. y D. Hendry (2006). "Forecasting with breaks in Handbook of Economic Forecasting, Elliot, G., C. Granger and A. Timmermann, eds., Chapter 12, Vol. 1, North-Holland.
- [14] Croushore, D. (2006). "Forecasting with real-time macroeconomic data", in *Handbook of Economic Forecasting*, Elliot, G., C. Granger and A. Timmermann, eds., Chapter 17, Vol. 1, North-Holland.
- [15] D'Amato L., L. Garegnani y E. Blanco (2015). "GDP Nowcasting: Assessing business cycle conditions in Argentina", Estudios BCRA, Working Paper 2015 nro. 69.
- [16] Diebold, F. y R. Mariano (1995). "Comparing Predictive Accuracy", *Journal of Business Economic Statistics*, Vol. 13(3), pp. 253-63.
- [17] Drechsel, K. y L. Maurin (2008). "Flow of Conjunctural Information and Forecast of Euro Area Economic Activity", ECB WP No. 925, Agosto.
- [18] Evans, M. (2005). "Where are we now? Real-time Estimates of the Macro Economy", *The International Journal of Central Banking*, Vol. 1, 2, pp. 127-175.
- [19] Ferrara, L., y A. Simoni (2019). "When Are Google Data Useful to Nowcast Gdp? An Approach Via Pre-Selection and Shrinkage", SSRN Electronic Journal, April.
- [20] Forni, C. y M. Marcellino (2013). "A Survey of Econometric Methods for Mixed-Frequency Data", EUI Working Paper ECO 2013/02.
- [21] Giacomini, R. y H. White, (2006). "Tests of conditional predictive ability", *Econometrica*, Vol 74 N° 6, 1545-1578.

- [22] Giannone, D., L. Reichlin y D. Small (2005). "Nowcasting GDP and Inflation: The Real Time Informational Content of Macroeconomic Data Releases", *CEPR Discussion Papers* 5178, C.E.P.R. Discussion Papers.
- [23] Giannone, D., L. Reichlin y D. Small (2008). "Nowcasting: The real-time informational content of macroeconomic data", *Journal of Monetary Economics* 55 (2008) 665– 676.
- [24] Granger, C. y R. Ramanathan (1984). "Improved methods of forecasting", *Journal of Forecasting*, Vol. 3, pp. 197-204.
- [25] Hale, T., Angrist, N., Goldszmidt, R., Kira, B., Petherick, A., Phillips, T., Webster, S., Cameron-Blake, E., Hallas, L., Majumdar, S. y Tatlow (2021), 'A global panel database of pandemic policies (Oxford COVID-19 government response tracker)', *Nature Human Behaviour* .
- [26] Huber, F., Koop, G., Onorante, L., Pfarrhofer, M. y J. Schreiner (2020). "Nowcasting in a pandemic using non-parametric mixed frequency VARs", *Journal of Econometrics*, 2020.
- [27] Jansen W. J., X. Jin y J M.de Winter, (2016). "Forecasting and nowcasting real GDP: Comparing statistical models and subjective forecasts", *International Journal of Forecasting* 32, pp 411-436.
- [28] Kitchen, J. y R. Monaco (2003). "Real-Time Forecasting in Practice", *Business Economics*, Department of the US Treasury, October.
- [29] Lenza, M. y G. Primiceri (2020). "How to estimate a VAR after March 2020". NBER Working Paper, 27771 (2020).
- [30] Martins, L. F. y P. Perron (2016). "Improved Tests for Forecast Comparisons in the Presence of Instabilities", *Journal of Time Series Analysis*, Wiley Blackwell, vol. 37(5), pp. 650-659, septiembre.
- [31] Paramo, A., Weiss, M., Hallack, M. y E. Malagón (2020). "Demanda y precio de la energía eléctrica en Argentina: impacto de la pandemia y tendencias". IADB. [Disponible aquí](#).
- [32] Pesaran, M. y A. Timmermann (2007). "Selection of estimation window in the presence of breaks", *Journal of Econometrics*, Vol. 137, 1, pp. 134-161.
- [33] Pincheira, P. (2006). "Conditional evaluation of exchange rate predictive ability in long run regressions", Central Bank of Chile, Working Paper No. 378.
- [34] Rünstler, G. y F. Sédillot (2003). "Short-term estimates of Euro Area real GDP by means of monthly data", European Central Bank Working Paper No. 276.
- [35] Schorfheide, F. y D. Song (2020). "Real-Time Forecasting with a (Standard) Mixed-Frequency VAR During a Pandemic". FRB of Philadelphia Working Paper No. 20-26, julio.
- [36] Siliverstovs, B. (2021). "Gauging the Effect of Influential Observations on Measures of Relative Forecast Accuracy in a Post-COVID-19 Era: Application to Nowcasting Euro Area GDP Growth". Working Papers 2021/01, Latvijas Banka.
- [37] Stock, J. y M. Watson (2002a), "Macroeconomic Forecasting using diffusion indexes", *Journal of Business and Economic Statistics*, Vol. 20, pp. 147-162.
- [38] Stock, J. y M. Watson (2006). "Forecasting with many predictors", in *Handbook of Economic Forecasting*, Elliot, G., C. Granger and A. Timmermann, eds., Chapter 10, Vol. 1, North-Holland.

- [39] Stock, J. y M. Watson (2016). "Dynamic Factor Models, Factor-Augmented Vector Autoregressions, and Structural Vector Autoregressions in Macroeconomics", in *Handbook of Macroeconomics*, John B. Taylor and Harald Uhlig (Editors), Chapter 8, Vol. 2A.
- [40] Watson, M. (2001). "Macroeconomic Forecasting Using Many Predictors", in *Advances in Economics and Econometrics: Theory and Applications*, Eight World Congress, Vol. III, Chapter 3, Econometric Society.
- [41] West, K. (2006). "Forecast Evaluation", in *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann, eds., Chapter 3, Vol. 1, North-Holland.

Anexo 1: Base de datos completa

Nro de Serie	Fuente	Descripción Serie	Grupo
serie1	ADEFA	Producción Nacional de Vehículos	1
serie2	ADEFA	Exportación de Vehículos	1
serie3	ADEFA	Ventas a Concesionarios de Vehículos	1
serie4	ADEFA	Ventas a Concesionarios de Vehículos Nacionales	1
serie5	AFCP	Despachos provisorios de cemento	1
serie6	MECON	Recaudación de Impuesto a las Ganancias (Total)	1
serie7	MECON	Recaudación de Impuesto a las Ganancias DGI	1
serie8	MECON	Recaudación de Impuesto a las Ganancias DGA	1
serie9	MECON	Recaudación de IVA bruto	1
serie10	MECON	Recaudación de IVA DGI	1
serie11	MERVAL	Índice merval_avg	1
serie12	MERVAL	Índice merval_last	1
serie13	BCRA	M2* Amplio Privado Nominal	1
serie14	BCRA	Tasa de interes plazo fijo 30 a 59 días Bancos privados	1
serie15	CCA	Ventas de autos usados	1
serie16	UTDT	Confianza del Consumidor - Nivel General-Capital Federal	1
serie17	UTDT	Confianza del Consumidor - Nivel General	1
serie18	UTDT	Confianza del Consumidor-Durables e Inmuebles	1
serie19	UTDT	Confianza del Consumidor-Situación Macroeconómica	1
serie20	UTDT	Confianza del Consumidor-Situación Personal	1
serie21	UTDT	Confianza del Consumidor-Condiciones Presentes	1
serie22	UTDT	Confianza del Consumidor-Expectativas	1
serie23	Cámara del Acero	Hierro Primario	1
serie24	Cámara del Acero	Acero Crudo	1
serie25	Cámara del Acero	Lam. Frío	1
serie26	Cámara del Acero	Lam. En caliente Total No Planos	1
serie27	Cámara del Acero	Lam. En caliente Planos	1
serie28	FIEL	IPI - nivel general	2
serie29	FIEL	IPI - bienes de consumo no durables	2
serie30	FIEL	IPI - bienes de consumo durables	2

Nro de Serie	Fuente	Descripción Serie	Grupo
serie31	FIEL	IPI - bienes de uso intermedio	2
serie32	FIEL	IPI - bienes de capital	2
serie33	FIEL	IPI - alimentos y bebidas	2
serie34	FIEL	IPI - cigarrillos	2
serie35	FIEL	IPI - insumos textiles	2
serie36	FIEL	IPI - pasta y papel	2
serie37	FIEL	IPI - combustible	2
serie38	FIEL	IPI - quimicos y plasticos	2
serie39	FIEL	IPI - minerales no metalicos	2
serie40	FIEL	IPI - siderurgia	2
serie41	FIEL	IPI - metalmeccanica	2
serie42	FIEL	IPI - autom6viles	2
serie43	AGIP - CABA	Recaudaci6n de Ingresos Brutos	2
serie44	Direcci6n Provincial Pol3tica Tributaria	Recaudaci6n de Ingresos Brutos Provincia Buenos Aires	2
serie45	Mrio Agroindustria	Faena de aves	2
serie46	CAME	Ventas Minoristas- Nivel general	1
serie47	CAME	Ventas Minoristas- Alimentos y bebidas	1
serie48	CAME	Ventas Minoristas- Bazar y regalos	1
serie49	CAME	Ventas Minoristas- Bijouterie	1
serie50	CAME	Ventas Minoristas- Calzados	1
serie51	CAME	Ventas Minoristas- Deportes	1
serie52	CAME	Ventas Minoristas- Electrodom3sticos	1
serie53	CAME	Ventas Minoristas- Farmacias	1
serie54	CAME	Ventas Minoristas- Ferreteria	1
serie55	CAME	Ventas Minoristas- Golosinas y Gaseosas	1
serie56	CAME	Ventas Minoristas- Jugueteria	1
serie57	CAME	Ventas Minoristas- Marroquineria	1
serie58	CAME	Ventas Minoristas- Materiales El3ctricos	1
serie59	CAME	Ventas Minoristas- Materiales para la Construcci6n	1
serie60	CAME	Ventas Minoristas- Muebles del Hogar	1

Nro de Serie	Fuente	Descripción Serie	Grupo
serie61	CAME	Ventas Minoristas- Muebles de Oficina	1
serie62	CAME	Ventas Minoristas- Perfumería	1
serie63	CAME	Ventas Minoristas- Textil - Indumentaria	1
serie64	CAME	Ventas Minoristas- Textil - Blanco	1
serie65	CONSTRUYA	Indice Construya. s.o.	1
serie66	CONSTRUYA	Indice Construya. s.e.	1
serie67	INDEC	Exportaciones en cantidades- Nivel general	2
serie68	INDEC	Exportaciones en cantidades- PP	2
serie69	INDEC	Exportaciones en cantidades- MOA	2
serie70	INDEC	Exportaciones en cantidades-MOI	2
serie71	INDEC	Exportaciones en cantidades- Combustibles y energia	2
serie72	INDEC	Precio de las Exportaciones- Nivel general	2
serie73	INDEC	Precio de las Exportaciones- PP	2
serie74	INDEC	Precio de las Exportaciones- MOA	2
serie75	INDEC	Precio de las Exportaciones-MOI	2
serie76	INDEC	Precio de las Exportaciones- Combustibles y energia	2
serie77	INDEC	Importaciones en Cantidades- Nivel general	2
serie78	INDEC	Importaciones en Cantidades- bienes capital	2
serie79	INDEC	Importaciones en Cantidades- bienes intermedios	2
serie80	INDEC	Importaciones en Cantidades- Combustibles y energia	2
serie81	INDEC	Importaciones en Cantidades- Piezas y accesorios	2
serie82	INDEC	Importaciones en Cantidades- bienes de consumo	2
serie83	INDEC	Importaciones en Cantidades- vehiculos	2
serie84	INDEC	Precio de las Importaciones- Nivel general	2
serie85	INDEC	Precio de las Importaciones- bienes de capital	2
serie86	INDEC	Precio de las Importaciones- bienes intermedios	2
serie87	INDEC	Precio de las Importaciones- Combustibles y energia	2
serie88	INDEC	Precio de las Importaciones- Piezas y accesorios	2
serie89	INDEC	Precio de las Importaciones- bienes de consumo	2
serie90	INDEC	Precio de las Importaciones- vehiculos	2

Nro de Serie	Fuente	Descripción Serie	Grupo
serie91	Mrio Agroindustria	Molienda soja	2
serie92	Secretaría de Hacienda	Inversión real directa + Transferencias de capital a provincias	2
serie93	Secretaría de Hacienda	Inversión real directa	2
serie94	Secretaría de Hacienda	Transferencias de capital a provincias	2
serie95	Consultora Tendencias	Índice de despidos (1986=100)	1
serie96	Consultora Tendencias	Índice de suspensiones (1986=100)	1
serie97	Ministerio de Trabajo	Expectativa neta de empleo	2
serie98	Ministerio de Trabajo	Empresas que realizaron búsqueda de personal	2
serie99	BCRA	ITCNM (base 17-12-15=100)	1
serie100	BCRA	Créditos Personales	1
serie101	BCRA	Créditos con Tarjetas	1
serie102	BCRA	Créditos Personales+ Tarjetas	1
serie103	GCBA	Patentamientos Autos CABA	2
serie104	GCBA	Patentamientos Autos Argentina	2
serie105	GCBA	Peajes (recaudación)	2
serie106	GCBA	Peajes (circulación vehículos)	2
serie107	GCBA	Peajes (vehículos promedio)	2
serie108	GCBA	Impuesto de sellos-CABA	2
serie109	GCBA	Pasajeros transportados en ferrocarril	2
serie110	BC de BRASIL	Producción industrial s.a.	2
serie111	BC de BRASIL	Producción industrial	2
serie112	BC de BRASIL	Indicador de actividad	2
serie113	BC de BRASIL	Indicador de actividad s.a.	2
serie114	Secretaria de energía	Asfalto (en toneladas)	2
serie115	Colegio de Escribanos	Escrituras Ciudad de Buenos Aires	2
serie116	Colegio de Escribanos	Escrituras Provincia Buenos Aires	2
serie117	Consultora Econviews	Indicador de condiciones financieras	1
serie118	Vialidad Nacional	carga por ferrocarril	2