

**Nowcasting de Inversión. Una estimación en tiempo real con
indicadores de alta frecuencia**

Fiorella Dogliolo

Tesis de Maestría
Maestría en Economía
Universidad Nacional de La Plata

Director de Tesis: María Lorena Garegnani

Fecha de defensa: 23 de marzo de 2018

Códigos JEL: C22, C53, E37

Resumen

En el presente trabajo se realizó una estimación en tiempo real de la evolución de la Inversión a partir de un conjunto amplio de indicadores económicos de alta frecuencia, lo que se conoce en la literatura como *Nowcasting*. Para realizar el *Nowcast* se consideraron tres grupos de indicadores de frecuencia mensual y mediante modelos de factores dinámicos se pronosticó el crecimiento trimestral de la Inversión. Adicionalmente, se realizó un ejercicio de *pooling* o combinación de pronósticos. A partir del test de Giacomini y White se pudo concluir que los modelos de factores y sus combinaciones exhiben una mejor capacidad predictiva en relación a un modelo AR(1) considerado como *benchmark*, y que la inclusión de un mayor número de indicadores no necesariamente mejora la *performance* del pronóstico.

Abstract

In this paper I present a real-time estimation of the evolution of the Investment, constructed from a broad set of high frequency economic indicators: known in the literature as *Nowcasting*. The *Nowcast* exercise was developed considering three groups of monthly indicators throughout dynamic factor models to forecast Investment growth. Additionally, I conducted a forecast-pooling exercise. Using the Giacomini and White test it was possible to conclude that factor models and the pooling exhibit a better relative predictive capacity than an AR (1) model considered as a benchmark. Furthermore, the inclusion of more indicators does not necessarily improve the predictive capacity.

Palabras clave: *Nowcasting*, modelos de factores dinámicos, pronósticos real-time, *pooling* de pronósticos

Contenido

1. Introducción	1
2. Revisión de la Literatura	4
2.1. Bridge Equations o Ecuaciones Puente	4
2.2. Modelo de Factores Dinámicos.....	8
3. El Ejercicio de Nowcast	11
3.1. Motivación	11
3.2. Datos	12
3.3. Metodología de Estimación: Modelo de Factores Dinámicos.....	16
3.4. Resultados de la Estimación.....	19
4. Evaluación de Capacidad Predictiva	24
5. Pooling de Pronósticos	29
6. Conclusiones	31
7. Referencias Bibliográficas	33
8. Anexos.....	35
8.1. Anexo I. Series Estudiadas.....	35
8.2. Anexo II. Coeficiente de Correlación.....	38
8.3. Anexo III. Componentes Principales	39
8.4. Anexo IV. Estimaciones.....	42

1. Introducción

Conocer la dinámica de la Inversión, una de las principales variables económicas, es fundamental para la toma de decisiones de los agentes económicos y de los responsables de la política económica.

Sin embargo, el conocimiento del desempeño de la Inversión —tal como ocurre con el resto de los componentes de la demanda agregada publicados en Cuentas Nacionales por INDEC— ocurre con rezago y no es lo suficientemente oportuno para la toma de decisiones, ya que la Inversión es una variable que se difunde con frecuencia trimestral y exhibe un retraso en su publicación cercano a los tres meses de finalizado el trimestre. Esta situación puede ser de particular relevancia cuando se está frente a un cambio de tendencia y la falta de información puede generar un retraso en la implementación de políticas contracíclicas o de incentivo a la Inversión.

Por otro lado, existe una gran cantidad de indicadores económicos de alta frecuencia — con frecuencia mensual, quincenal, semanal, o incluso diaria— que pueden ser de gran utilidad para dar cuenta del comportamiento actual de la Inversión y de un posible cambio en la tendencia de la misma. No obstante, producto justamente de la frecuencia, estos indicadores pueden contener ruido que afecta a la información y a la posibilidad de distinguir las señales que brinda la misma. En este sentido, si bien contar con un mayor número de indicadores podría favorecer a tener mayor y mejor información, puede ser que las señales que manifiestan sean heterogéneas y contradictorias, haciendo necesaria alguna metodología de agregación estadística que brinde una única respuesta.

Dada la falta de datos a tiempo, el objetivo del presente trabajo es realizar una estimación en tiempo real de la evolución de la Inversión a partir de un conjunto amplio de indicadores económicos. En particular, se pretende estimar el crecimiento trimestral de la Inversión durante el transcurso del mismo trimestre mediante la utilización de información de alta frecuencia, lo que se conoce en la literatura como *Nowcasting*. El *Nowcasting* —definido como la predicción del presente, el futuro muy cercano y el pasado muy reciente (Giannone et al., 2008; Banbura et al., 2013)— ha demostrado ser una herramienta útil para superar el problema de contar con información válida a distintas frecuencias. Este enfoque genera una estimación en tiempo real, dado que se actualiza continuamente a medida que se difunde la nueva información utilizada a tal fin.

La metodología de *Nowcasting* —término que surge de las palabras *now* (ahora) y *forecasting* (pronóstico)— se origina en la meteorología y su aplicación en la economía se ha expandido fuertemente en los últimos diez años. La literatura ha avanzado en el desarrollo de diversos modelos econométricos para trabajar con estimaciones en las que intervienen variables a diversas frecuencias. Entre las técnicas más utilizadas se encuentran las ecuaciones puentes o *bridge equations* y los modelos de factores dinámicos, siendo también empleados los modelos de Mixed Data Sampling (MIDAS), modelos VARs, entre otros.

La aplicación de esta metodología se concentra en obtener estimaciones del Producto Interno Bruto (PIB), principalmente entre los bancos centrales. Tal es el caso del Banco de Inglaterra, la Reserva Federal (Nueva York, Atlanta, Chicago, St. Louis), el Banco Central Europeo, el Banco Central de Irlanda, el Banco de Noruega, el Banco de Francia, el Banco de España, el Banco Central de Turquía, el Banco Central de Sudáfrica, entre otros. El Banco Central de Argentina también utiliza esta metodología para tener una predicción anticipada del crecimiento del PIB (Blanco, D'Amato, Dogliolo y Garegnani, 2017).

El *Nowcasting*, utilizado fundamentalmente para realizar predicciones del PIB, también puede ser aplicado para realizar estimaciones de otras variables de baja frecuencia publicadas con un sustancial rezago, como la Inversión, haciendo uso de información oportuna de alta frecuencia (según lo sugerido por Banbura et al., 2010). Sin embargo, no hay amplia difusión de trabajos realizados al respecto. Se conoce un documento de trabajo del Banco de Indonesia (Tardsidin, Idham y Robbi Nur Rakhman, 2017), en que utilizan el *Nowcasting* para realizar una estimación de la Inversión mediante un modelo de factores dinámicos. Por otro lado, si bien algunos bancos centrales también realizan estimaciones de la Inversión, lo hacen como parte del proceso de estimación de los componentes de la demanda agregada que utilizan para el *Nowcasting* del PIB. En este sentido, la Reserva Federal de Atlanta (Higgins, 2014) y el Banco de Israel (Krief, 2011), entre otros, estiman la Inversión mediante *bridge equations* a partir de indicadores económicos mensuales, y la utilizan como insumo de sus predicciones del Producto.

De este modo, el presente trabajo representa un aporte a la literatura existente hasta el momento. Particularmente en el caso de Argentina, en que no se cuenta con ningún indicador parcial adelantado de la Inversión, la estimación que surge de este trabajo permitiría obtener información temprana sobre el desempeño de esta variable. Así, los

hacedores de política podrían tener un conocimiento en tiempo real de la Inversión, lo que es fundamental para la implementación oportuna de políticas de incentivo a la Inversión y de políticas contracíclicas. En este sentido, el Nowcast de Inversión es una herramienta que permitiría conocer el desempeño de la Inversión y favorecería a una asignación eficiente de los recursos que permita lograr un crecimiento de la economía sostenible a largo plazo.

Asimismo, contar con una estimación de la Inversión es de gran utilidad para los modelos de equilibrios general, que hacen uso de modelos satélites de las principales variables macroeconómicas y son ampliamente utilizados en los bancos centrales y en el sistema de la Reserva Federal para la toma de decisiones en la implementación de la política monetaria.

El trabajo consistió, en una primera instancia, en realizar una selección y recopilación de los indicadores económicos a utilizar. Luego del estudio de las series y de realizarles las transformaciones necesarias (desestacionalización, diferenciación o eliminación de tendencia para trabajar con series estacionarias), se utilizó como criterio de elección de las series a incluir en la estimación la existencia de una correlación contemporánea significativa entre la tasa de crecimiento de cada una de las variables y la tasa de crecimiento de la Inversión. Posteriormente, se consideraron diversos conjuntos de indicadores —de acuerdo con el valor del coeficiente de correlación— para luego estimar los factores comunes a cada uno de los grupos y utilizarlos, mediante diversos modelos de factores dinámicos, para predecir el crecimiento de la Inversión. Finalmente, mediante el test de Giacomini y White (Giacomini y White, 2003), se analizó la capacidad predictiva relativa de los modelos de factores y se los comparó a su vez con un *benchmark* (modelo autoregresivo —AR—), y un *pooling* de pronósticos.

El documento se organiza de la siguiente manera. En la sección II se realiza una breve descripción de la literatura. En la Sección III.1 se introduce el ejercicio de *Nowcasting* realizado y su motivación. Los datos recolectados, las transformaciones aplicadas a las series y el criterio de selección de los indicadores económicos a incluir en la estimación de la Inversión se presentan en la Sección III.2. La metodología de estimación utilizada se explica en la Sección III.3, mientras que en la Sección III.4 se muestran los resultados de pronóstico obtenidos con los diversos modelos. En la Sección IV se analiza la capacidad predictiva de los modelos y en la sección V se presenta un ejercicio de *pooling* de pronósticos. Finalmente, en la sección VI se realizan las conclusiones.

2. Revisión de la Literatura

Los agentes económicos y, principalmente, los hacedores de política necesitan tener un conocimiento sobre el estado actual de la economía en tiempo real y sobre su desarrollo próximo esperado. Sin embargo, sólo disponen de información incompleta a la hora de la toma de decisiones. Por ejemplo, uno de los principales indicadores macroeconómicos de actividad —el PIB— se comunica de manera trimestral y se publica con un considerable rezago (diez semanas después de finalizado el trimestre), al tiempo que se encuentran disponibles una gran cantidad de indicadores adelantados o coincidentes con el ciclo económico de frecuencia mensual o aún mayor (quincenal, semanal o diaria).

Esta situación se plantea como un desafío para los pronosticadores al realizar la estimación, dado que se cuenta con información incompleta y desbalanceada. El desbalanceo en la base de datos puede provenir de tener información de distinta frecuencia y del hecho que los retrasos en la publicación de los diversos indicadores generan información faltante para algunas variables al final de la muestra (denominado esto último "*ragged -edge*" o borde irregular).

En este escenario, la literatura de pronóstico ha avanzado en los últimos años en el desarrollo de una vasta cantidad de modelos econométricos para trabajar con estimaciones en las que intervienen un gran conjunto de datos y variables de diversas frecuencias y fechas de publicación.

2.1. Bridge Equations o Ecuaciones Puente

Uno de los primeros enfoques econométricos para trabajar con datos de frecuencias mixtas fue el uso de *bridge equations* o ecuaciones puente. Este método es ampliamente empleado en varios bancos centrales y en diversas instituciones, especialmente para el *Nowcasting* y el pronóstico de corto plazo.

La técnica de *bridge models* permite computar estimaciones tempranas de la variable de baja frecuencia utilizando indicadores de alta frecuencia. *Bridge equations* son regresiones lineales que unen ("*bridge* o puente") las variables de alta frecuencia, como

la producción industrial, las ventas minoristas o las importaciones de bienes de capital, entre otras, con las variables de baja frecuencia, como el crecimiento trimestral del PIB o la Inversión en nuestro caso, proveyendo alguna estimación del desempeño actual o de corto plazo de esta variable con anterioridad a su publicación. Los modelos *bridge* requieren que los indicadores incluidos contengan información actualizada, esto es que el conjunto de todos los regresores sea conocido durante el período de proyección.

Varias especificaciones se incluyen dentro de esta metodología, por lo que puede haber diferencias de acuerdo con cada trabajo, pero en términos generales la aplicación de este enfoque consta de sucesivas etapas. Tomando por caso la proyección del PIB, dado que los indicadores son mensuales y generalmente están parcialmente disponibles durante el período de estimación, la proyección del crecimiento trimestral del PIB es obtenida en varios pasos. Primero, puede ser necesario proyectar los indicadores mensuales para lo que resta del trimestre, que puede ser realizado mediante un modelo de serie de tiempo univariado, y luego se los agrega para obtener el correspondiente valor trimestral de modo que los indicadores mensuales tengan la misma frecuencia que la variable de baja frecuencia. En esta instancia, puramente empírica, es necesario tener conocimiento de cómo es generada y expresada la información contenida en la variable y también es relevante el tipo de variable de que se trate. En el caso de los flujos, la agregación generalmente se realiza como promedio o suma de las variables de frecuencia mensual, mientras que en el caso de las variables *stock* muchas veces se promedia o se considera el último valor de la variable.

En segundo lugar, los valores agregados son utilizados como regresores de la *bridge equation*, la que permite obtener los pronósticos del crecimiento del PIB (en nuestro caso la Inversión). Generalmente, se estiman modelos bivariados autoregresivos de rezagos distribuidos para cada uno de los indicadores. De este modo, el modelo *bridge* a ser estimado para x_j consiste en:

$$y_t^Q = \alpha + \sum_{i=1}^p \alpha_i y_{t-i}^Q + \sum_{i=0}^p \beta_i x_{j,t-i}^Q + \mu_t$$

Donde y_t^Q es el crecimiento trimestral del PIB, α es una constante, x_j^Q corresponde al j -ésimo indicador mensual agregado en una frecuencia trimestral para ser homogéneo con el PIB, μ_t es el término de error que tiene una distribución normal y p denota el número

de rezagos en la *bridge equation*. El máximo rezago (p) se determina de acuerdo con la metodología de general a particular o con algún criterio de información, siendo el máximo número de rezagos igual a cuatro en el caso de las variables trimestrales.

Luego, los pronósticos generados por los n indicadores individuales pueden ser agregados considerando distintos criterios de ponderación para obtener un único pronóstico del PIB para el período corriente. Básicamente, el *pooling* o agregación de pronósticos se implementa con la siguiente fórmula:

$$\hat{y}_t = \sum_{i=1}^n w_i f_{i,t} \quad \text{con} \quad \sum_{i=1}^n w_i = 1$$

Siendo \hat{y}_t la combinación de los pronósticos, w_i el ponderador o peso asignado a los pronósticos individuales basados en el indicador i , $f_{i,t}$.

Como se describe en Drechsel y Maurin (2008), se han desarrollado diversos esquemas de ponderadores, w_i , además de utilizar la misma ponderación para todos los pronósticos.

Pueden ponderarse de acuerdo con el poder explicativo relativo dentro de la muestra (R^2), combinando de este modo los pronósticos de acuerdo con el ajuste de cada modelo.

$$w_i = \frac{R_i^2}{\sum_{j=1}^n R_j^2}$$

También pueden ponderarse los pronósticos de acuerdo con el desempeño fuera de la muestra, ponderándose de acuerdo con la inversa del error de pronóstico individual (la raíz cuadrada del error cuadrático medio—RMSE por su sigla en inglés—).

$$w_{it} = \frac{m_{it}^{-1}}{\sum_{j=1}^n m_{jt}^{-1}}; \quad \text{donde} \quad m_{it} = \sqrt{\frac{\sum_{t=T+1}^{T+h} (\hat{y}_{it} - y_t)^2}{h}}$$

Otros mecanismos alternativos de ponderación pueden ser aquellos que surgen de métodos Bayesianos.

Los modelos de *bridge equations* han sido de los primeros métodos utilizados en la metodología de *Nowcasting* para conocer el estado actual de la economía, haciendo uso de los indicadores mensuales disponibles. Estos estudios se han realizado en diferentes economías. Un resultado común a estos trabajos es que la explotación de información dentro del período de estimación reduce los errores de pronóstico en la mayoría de los

casos. La aplicación abarca tanto a modelos por el lado de la oferta como por el lado de la demanda.

Por ejemplo, Baffigi, Golinelli y Pargi (2004) examinan la habilidad de pronóstico de los *bridge models* para pronosticar el crecimiento del PIB en la zona del euro. En el trabajo, los modelos *bridge* son estimados para el PIB y sus componentes, tanto para la euro-area en su conjunto como para las principales economías de la zona. La performance de corto plazo (uno y dos trimestres hacia adelante) es comparada contra los modelos *benchmark* univariados y multivariados, y también es contrastada con pequeños modelos estructurales. Los resultados son contundentes, al señalar que los modelos *bridge* siempre superan a los *benchmark*, cuando al menos alguno de los indicadores esté disponible durante el horizonte de pronóstico. Además, encuentran que el PIB de la zona del euro y sus componentes se predicen con mayor precisión agregando pronósticos nacionales.

Diron (2008) hace uso de los modelos *bridge* con datos de la zona del euro para realizar una evaluación de los errores de pronóstico ante la revisión de datos. En particular, en un ejercicio con información de cuatro años, el documento proporciona estimaciones de los errores de pronóstico para el crecimiento del PIB real de la zona del euro en condiciones de tiempo real, y evalúa el impacto de las revisiones de datos sobre las predicciones a corto plazo del crecimiento real del PIB. Encuentra que las proyecciones tienden a ser similares, ya sea que se basen en datos preliminares o revisados, y que por consiguiente los RMSE basados en ejercicios en tiempo real y pseudo tiempo real son bastante semejantes, y en ambos casos más pequeños que los que surgen de los pronósticos de un modelo AR del PBI, considerado como *benchmark*. Es decir, encuentran que los pronósticos de corto plazo basados en *bridge equations* son informativos.

Un estudio de Barhoumi, Darné, Ferrara y Pluyaud (2011) presenta un modelo para predecir la tasa de crecimiento trimestral del Producto de Francia. Los autores emplean *bridge equations* para pronosticar cada componente del PIB, por el lado de la oferta y por el lado de la demanda, y seleccionan las variables explicativas de frecuencia mensual dentro de un gran conjunto de indicadores. Llevan a cabo un ejercicio de pronóstico mediante ventanas móviles para evaluar la performance en la predicción del PIB, tomando en cuenta los retrasos en la publicación de los datos para generar pronósticos en *pseudo-real time*. Encuentran que estos modelos resultan ser superiores al *benchmark* en términos de pronóstico.

Bencivelli, Marcellino y Moretti (2012) investigan la performance de los modelos *bridge* en un contexto donde la selección de las variables se realiza mediante un modelo Bayesiano. En el trabajo seleccionan en cada período el mejor conjunto de predictores de acuerdo con la función de distribución de probabilidades posterior del espacio del modelo. Esto permite hacer uso de un conjunto más amplio de indicadores que los que habitualmente se utilizan en los *bridge models* tradicionales. En un ejercicio pseudo *real-time* para la zona del euro y para Alemania, Francia e Italia, encuentran que los modelos construidos usando los promedios Bayesianos superan en capacidad predictiva a los *bridge models* tradicionales, basados en una selección fija y reducida de variables.

2.2. Modelo de Factores Dinámicos

Los modelos de factores dinámicos (*dynamic factor models*) resumen la información contenida en un conjunto amplio de datos utilizando un número reducido de factores, cuyo comportamiento dinámico está especificado como un proceso autoregresivo.

Los modelos de factores han sido empleados de manera generalizada en la literatura para trabajar con datos de distintas frecuencias, y se ha demostrado que permiten explotar una gran cantidad de información y obtener pronósticos más precisos que mediante otras metodologías.

Uno de los modelos más utilizados en la literatura de *Nowcasting* y en el que se basan los desarrollos de los modelos de factores es el de Stock y Watson (2002). Los autores emplearon estos modelos para extraer el estado no observado de la economía de Estados Unidos, con indicadores mensuales del ciclo combinados con el PIB real trimestral.

Particularmente, su metodología consiste en un modelo en que y_{t+1} es la variable que se quiere pronosticar, y X_t es el vector N-dimensional de variables observables utilizadas como predictores. Se supone que X_t, y_{t+1} admiten una representación a través de un modelo de factores dinámicos, con r factores dinámicos comunes no observables f_t , de la forma:

$$y_{t+1} = \beta(L)f_t + \gamma(L)y_t + \varepsilon_{t+1}$$

$$X_{it} = \lambda_i(L)f_t + e_{it}$$

para $i = 1, \dots, N$, donde $e_t = (e_{1t}, e_{2t}, \dots, e_{Nt})'$ es un vector $N \times 1$ de las perturbaciones idiosincráticas, y $\lambda_i(L)$ y $\beta(L)$ son los polinomios de rezagos en potencias no negativas de L .

Suponen que los polinomios de rezago $\lambda_i(L)$ y $\beta(L)$ son de orden finito no mayor a q , esto es, $\lambda_i(L) = \sum_{j=0}^q \lambda_{ij}L^j$ y $\beta(L) = \sum_{j=0}^q \beta_jL^j$. Producto de este supuesto, Stock y Watson demostraron que el modelo se puede reescribir como un modelo de factores estático, como se presenta a continuación, y que los factores f pueden ser estimados utilizando la metodología de componentes principales.

$$y_{t+1} = \beta' F_t + \gamma(L) y_t + \varepsilon_{t+1}$$

$$X_t = \Lambda F_t + e_t$$

donde $F_t = (f'_t, \dots, f'_{t-q})'$ es de $r \times 1$.

La proyección de la variable para h períodos adelante, y_{t+h} , se realiza en dos etapas. En un primer paso, a partir de la muestra $\{X_t\}_{t=1}^T$, se estiman los factores \hat{F} . En un segundo paso, se utilizan los factores y la variable a proyectar rezagada para obtener la proyección a partir de la ecuación

$$\widehat{y}_{t+h} = \widehat{\alpha}_h + \widehat{\beta}_h(L) \widehat{F}_t + \widehat{\gamma}_h(L) y_t$$

Otro de los modelos pioneros en la literatura de *Nowcasting* y usado como base para otras extensiones es el desarrollado por Giannone, Reichlin and Small (2008). Presentan un modelo de factores con frecuencias mixtas, cuyo objetivo es utilizar la información contenida en un conjunto amplio de series mensuales para pronosticar una variable trimestral.

La idea fundamental del enfoque es explotar la colinealidad de las series, resumiendo la información en un número reducido de factores comunes. Así, debido a la colinealidad, una proyección basada en los factores comunes es capaz de capturar la interacción dinámica de las series y de proveer un modelo parsimonioso para el pronóstico que requiere estimar sólo un número reducido de parámetros.

En particular, el modelo de factores dinámico (en su notación matricial) está dado por:

$$x_{tm} = \mu + \Lambda f_{tm} + \xi_{tm}$$

donde x_{tm} es el vector de los n indicadores mensuales estacionarios, μ es un vector de constantes, f_{tm} es un vector de r factores inobservables, Λ es la matriz de *factor loadings* de dimensión $n \times r$, con $r < n$, y ξ_{tm} es el componente idiosincrático, que se asume ruido blanco multivariado con una matriz de covarianza diagonal y ortogonales con los *shock* de los factores.

Para la estimación y para trabajar con el hecho de la falta de observaciones al final de la muestra ("*ragged-edge*"), en el trabajo se combina la metodología de componentes principales con el filtro de Kalman, en dos etapas. Primero, mediante componentes principales se calculan los factores que subyacen a los indicadores económicos mensuales contenidos en una versión balanceada de la base de datos, truncando la muestra hasta el momento que se cuenta con todas las observaciones.

En el segundo paso, el filtro de Kalman es utilizado para actualizar los factores, esto es, las estimaciones de las señales contenidas en las variables, utilizando la base de datos desbalanceada. Para ello es necesario tener definida la ecuación de movimiento de los factores, que se supone tienen un comportamiento autorregresivo de la forma:

$$f_{tm} = \sum_{i=1}^p A_i f_{tm-i} + B \eta_{tm}$$

donde A es una matriz de $r \times r$, B es una matriz de $r \times q$ y η es el vector de dimensión q de los *shocks* ruido blanco, con r mayor a q .

Una vez que se cuenta con la estimación de los factores, el *Nowcast* del PIB puede obtenerse mediante una regresión por MCO, en que se estiman los parámetros α y β de la ecuación:

$$\widehat{y}_{tq} = \alpha + \beta \widehat{f}_{tq}$$

donde \widehat{f}_{tq} es la agregación trimestral correspondiente a \widehat{f}_{tm} . De este modo, el pronóstico es definido como la proyección de la variable trimestral basada en los factores estimados de frecuencia trimestral.

Al observarse esta última ecuación puede apreciarse que se asemeja a la ecuación presentada en la metodología de *bridge equations*. Por eso, este enfoque puede interpretarse como un modelo *bridge* ampliado, que hace uso de un amplio número de

variables y que hace un puente entre las variables de frecuencia mensual con el pronóstico de una variable de frecuencia trimestral.

Este modelo fue implementado inicialmente en el *Board of Governors of the Federal Reserve* para generar un *Nowcast* del PIB para la economía de Estados Unidos, producto de un proyecto iniciado en 2003. A partir de ese momento, varias versiones se han desarrollado en diferentes economías y se ha implementado en otros bancos centrales, como el Banco Central Europeo, y en organismos multilaterales, como el Fondo Monetario Internacional (Matheson, 2011).

También hay diversos estudios que aplican esta metodología para Estados Unidos (Lahiri and Monokroussos, 2011), para la zona del euro en su conjunto (Angelini et al., 2011; Banbura and Modugno, 2010; Banbura and Rünstler, 2011; Camacho and Perez-Quiros, 2009), para países integrantes de la zona del euro como Francia (Barhoumi et al., 2010), para Alemania (Schumacher and Breitung, 2008), Irlanda (D'Agostino et al., 2008), Holanda (de Winter, 2011), entre otros.

3. El Ejercicio de Nowcast

3.1. Motivación

El objetivo del presente trabajo consiste en realizar estimaciones tempranas del crecimiento de la Inversión a partir de un conjunto amplio de indicadores de alta frecuencia.

Conocer el desempeño de la Inversión es fundamental para los diversos agentes económicos para la toma de decisiones óptimas y es de gran relevancia para los hacedores de política para la implementación oportuna de políticas de incentivo a la Inversión y de políticas contracíclicas. En Argentina la Inversión representa aproximadamente entre el 15% y el 19% del PIB, dependiendo del período considerado, ubicándose por debajo de los ratios de los países desarrollados o de los que presentan altas tasas de expansión económica. De este modo, es indispensable conocer el desempeño de la Inversión para favorecer a una asignación eficiente de los recursos y que permita lograr un crecimiento de la economía sostenible a largo plazo.

En Argentina el Instituto Nacional de Estadísticas y Censos (INDEC) difunde la información de la Inversión en conjunto con la información del PIB en cuentas nacionales, que es una información con periodicidad trimestral y que se publica con rezago. El dato del PIB y del componente de Inversión se conocen recién a las 10 semanas de finalizado el trimestre. Por caso, los datos relativos al primer trimestre de 2017 se dieron a conocer en la tercera semana de junio de ese año. A su vez, tampoco publica el INDEC ningún indicador parcial adelantado de la Inversión que nos permita tener una idea inmediata de su comportamiento, tal como ocurre con el estimador mensual industrial (EMI), el indicador de actividad de la construcción (ISAC), las ventas minoristas, el estimador mensual de la actividad económica (EMAE), entre otros.

Por otro lado, está disponible un conjunto amplio de indicadores económicos de alta frecuencia que puede servir para obtener información valiosa sobre el ciclo de la Inversión. Esto es, indicadores de periodicidad mensual, semanal o diaria.

La metodología de *Nowcasting*, que implica realizar estimaciones de variables de baja frecuencia con indicadores de alta frecuencia, demostró ser capaz de predecir de manera eficiente los acontecimientos en el corto plazo y de superar en capacidad predictiva a los modelos univariados, particularmente en contextos de alta volatilidad. Entre las ventajas que presenta esta metodología mencionadas en la literatura (Giannone et al., 2008) es que permite utilizar una gran cantidad de series de distinta fuente, que las estimaciones son actualizadas a medida que la nueva información está disponible —de acuerdo con el calendario de actualización de las series— y que sirve para articular datos de alta frecuencia con datos de baja frecuencia.

3.2. Datos

La variable objetivo de la estimación es la Formación Bruta de Capital Físico (FBCF), intentando proyectar su crecimiento trimestral desestacionalizado. En este proceso se consideró inicialmente un conjunto amplio de indicadores económicos, 116 en total, a ser potencialmente utilizados. Entre ellos se incluyeron indicadores “duros” (*hard indicators*), clasificados como tales por transmitir señales bastante precisas sobre el desempeño de la economía —producción en la industrial, actividad en la construcción, actividad en el sector agropecuario, comercio, empleo, comercio exterior, variables

fiscales y de actividad en Brasil— así como indicadores “blandos” (*soft indicators*), considerados menos precisos pero con información valiosa sobre las percepciones de distintos agentes económicos respecto de las condiciones presentes y futuras de la economía —encuestas de expectativas de empleo, confianza del consumidor, entre otros—. Generalmente hay sustanciales diferencias entre las series en cuanto a su publicación. En este sentido, las variables monetarias y financieras y las encuestas (indicadores blandos) están disponibles al final del período de referencia o aún con anterioridad (tal es el caso de la confianza del consumidor), mientras que los otros indicadores de la actividad económica (indicadores duros) se publican con rezago, que puede alcanzar a los 2 o 3 meses. De este modo, habría un *trade-off* entre la oportunidad y precisión de la información, por lo que la base de datos fue construida con la intención de contener ambos tipos de indicadores.

Para trabajar con las series se procedió en una primera instancia a realizar un estudio de la estacionalidad de las series mediante el programa ARIMA X12, realizándose el ajuste necesario en caso de corresponder, para obtener series sin estacionalidad. Luego se realizó la transformación logarítmica de las series, y mediante los test Dickey-Fuller aumentado y Phillips-Perron se analizó la existencia de raíz unitaria y, de corresponder, la fuente de no estacionariedad, con el fin de hacer la correcta transformación para obtener series estacionarias. Las tablas con los indicadores considerados y con los resultados del análisis de estacionalidad y estacionariedad se presentan en el Anexo I.

Tal como es usual en la realización de pronósticos macroeconómicos surge también en este trabajo el problema de seleccionar los indicadores a utilizar en la estimación dentro de un amplio conjunto de indicadores disponibles. Para seleccionar las series a incluir en el *Nowcast* se utilizó el coeficiente de correlación, siendo el criterio de elección inicial la existencia de una correlación contemporánea significativa entre la tasa de crecimiento de cada una de las variables y la tasa de crecimiento de la Inversión (FBCF). Para ello, al realizar la correlación de Spearman, se consideró al estadístico t del coeficiente de correlación, quedando seleccionadas aquellas series con un $t > 1,96$ (nivel de confianza del 95%) del conjunto potencial inicial (ver Anexo II). Luego, se conformaron tres grupos de indicadores para realizar el ejercicio de *Nowcast* con cada uno de ellos. Un primer grupo más amplio, Grupo 1 (G1), que comprende las series que presentan un valor del coeficiente de correlación superior a 0,30. Como resultado quedaron seleccionadas 36 series. El Grupo 2 (G2), formado por 26 series, resultado de tomar como criterio de

selección un coeficiente de correlación superior a 0.35, y el Grupo 3 (G3), integrado por 19 series, que surge de considerar un coeficiente de correlación superior a 0.40. Las series que incluye cada grupo se presenta en la Figura 1.

Figura 1: Series Seleccionadas para la Estimación del *Nowcast*

Serie	Fuente	Grupo 1	Grupo 2	Grupo 3
Importaciones en cantidades- Nivel General	INDEC	x	x	x
Importaciones en cantidades de Bienes intermedios	INDEC	x	x	x
Importaciones en cantidades de Piezas y accesorios	INDEC	x	x	x
Importaciones en cantidades de Bienes de consumo	INDEC	x	x	x
Indice de Confianza del Consumidor -Condiciones Presentes	UTDT	x	x	x
Ventas minoristas en Ferreterías	CAME	x	x	x
Ventas minoristas de Muebles de Oficina	CAME	x	x	x
Indice de Confianza del Consumidor - Nivel General-Nacional	UTDT	x	x	x
Indice de Producción Industrial - Automóviles	FIEL	x	x	x
Ventas minoristas de Electrodomésticos	CAME	x	x	x
Indice de Confianza del Consumidor -Situación Personal	UTDT	x	x	x
Precios de las Exportaciones de Productos Primarios	INDEC	x	x	x
Precios de las Exportaciones de MOI	INDEC	x	x	x
Producción Nacional de Vehículos	ADEFA	x	x	x
Indice de Confianza del Consumidor - Capital Federal	UTDT	x	x	x
Indice de Producción Industrial - Bienes de capital	FIEL	x	x	x
Producción industrial de Brasil	Banco Central de Brasil	x	x	x
Precios de las Exportaciones - Nivel general	INDEC	x	x	x
M2* Amplio Privado Nominal	BCRA	x	x	x
Indice de Producción Industrial - Bienes de consumo durables	FIEL	x	x	
Laminados en caliente Total no Planos	Cámara del Acero	x	x	
Expectativa neta de empleo	Ministerio de Trabajo	x	x	
Préstamos con Tarjetas	BCRA	x	x	
Escrituras en Ciudad de Buenos Aires	Colegio de Escribanos	x	x	
Importaciones en cantidades de vehículos	INDEC	x	x	
Ventas de Vehículos Nacionales	ADEFA	x	x	
Laminados en Frío	Cámara del Acero	x		
Laminados en caliente Planos	Cámara del Acero	x		
Indicador de actividad de Brasil	Banco Central de Brasil	x		
Ventas minoristas de Materiales para la Construcción	CAME	x		
Empresas que realizaron búsqueda de personal	Ministerio de Trabajo	x		
Exportaciones en cantidades de MOI	INDEC	x		
Ventas minoristas de Materiales Eléctricos	CAME	x		
Recaudación Impuesto a las Ganancias	MECON	x		
Indice de Confianza del Consumidor -Expectativas	UTDT	x		
Indice de Confianza del Consumidor -Durables e Inmuebles	UTDT	x		

La muestra utilizada para estimar los modelos abarca desde el primer trimestre de 2006 hasta el primer trimestre de 2016. Luego se realizaron ejercicios de *Nowcast* del crecimiento de la Inversión para el período comprendido por el primer trimestre de 2011 y el segundo trimestre de 2017 para cada uno de los modelos generados.

El ejercicio es *pseudo-real time*, dado que se confeccionó una base de datos tratando de replicar la información que hubiera estado disponible en cada momento del tiempo, considerando para ello el calendario de publicación de cada serie. De este modo, se toman en cuenta los rezagos en la publicación, pero se ignoran las revisiones que pudieron haber sufrido los datos, tanto de la Inversión como de los indicadores que se utilizan para la estimación. Esto último podría implicar una sobreestimación del ajuste de los modelos de pronóstico. Sin embargo, se cancelarían los efectos de la revisión de los datos sobre el pronóstico, dado que el método estadístico utilizado tiende a reducir el ruido del proceso, al extraer factores de un conjunto amplio de indicadores económicos. En este sentido, Shumacher y Breitung (2008) utilizan datos *real-time* para Alemania y no encuentran ningún impacto claro de la revisión de los datos sobre los errores de pronóstico del modelo de factores.

Para realizar la estimación del *Nowcast* de la Inversión, se divide el conjunto de indicadores en dos grupos, de acuerdo con el momento de publicación de las series: los que están disponibles en la primera quincena y aquellos que se difunden en la segunda mitad del mes. De este modo, producto de esta agrupación de las series y dado que el *Nowcast* se actualiza secuencialmente cuando se dispone de nueva información, se generan 6 estimaciones de la Inversión para cada trimestre. A modo de ejemplo, se presenta la actualización secuencial en la Figura 2.

Figura 2: Secuencia de Actualización del *Nowcast*

Fecha	15/2/2017	28/2/2017	15/3/2017	31/3/2017	15/4/2017	30/4/2017	15/5/2017	31/5/2017	15/6/2017
<i>Datos Disponibles</i>									
<i>Grupo 1</i>	Ene-17	Ene-17	Feb-17	Feb-17	Mar-17	Mar-17	Abr-17	Abr-17	May-17
<i>Grupo 2</i>	Dic-16	Ene-17	Ene-17	Feb-17	Feb-17	Mar-17	Mar-17	Abr-17	Abr-17
Nowcast	I 2017	I 2017	I 2017	I 2017	I 2017	I 2017	II 2017	II 2017	II 2017
<i>Comunicados Oficiales</i>									Comunicado Oficial I 2017

3.3. Metodología de Estimación: Modelo de Factores Dinámicos

La estimación del *Nowcast* de la Inversión se realiza considerando un modelo de factores, tal como es su aplicación generalizada para la estimación del PIB, en el que se relaciona una variable a pronosticar y_{t+1} con un conjunto de predictores contenidos en el vector X_{it} . El ejercicio de pronóstico es realizado en un proceso de dos pasos: primero se estiman los factores comunes al conjunto de los indicadores X_{it} por componentes principales, y posteriormente se utilizan esos factores para estimar y_{t+1} . La idea que subyace a esta metodología de modelos dinámicos de factores es que las variables en el conjunto de interés son impulsadas por un conjunto reducido de factores no observables. Así, la información contenida en un amplio número de predictores puede ser reemplazada por un número manejable de factores estimados.

Concretamente, la covarianza entre un gran número de n series de tiempo, con sus adelantos y rezagos, puede ser representada por un número reducido de q factores no observados, con $n > q$.

Por lo tanto, dado un vector X_{it} de n series de tiempo mensuales estacionarias $x_t = (x_{1t}, x_{2t}, \dots, x_{nt})'$, con $t = 1, \dots, T$, el vector de n variables observables en el ciclo puede ser explicado por los rezagos distribuidos de q factores comunes latentes más n perturbaciones idiosincráticas que pueden eventualmente estar correlacionadas serialmente, así como correlacionadas entre ellas.

$$X_{it} = \lambda_i(L)' f_t + \mu_{it}$$

Donde f_t es un vector $q \times 1$ de factores no observables, λ_i es un vector de polinomios de rezagos denominados *dynamic factor loadings* de dimensión $q \times 1$ y μ_{it} son las perturbaciones idiosincráticas. Se supone que los factores y las perturbaciones idiosincráticas no están correlacionadas entre sí (ni en sus adelantos ni en sus rezagos), es decir $E(f_t \mu_{it}) = 0 \forall i, t$.

El objetivo es entonces estimar $E(y_t/X_t)$, modelando y_t según:

$$y_t = \beta(L)' f_t + \gamma(L)' y_{t-1} + \varepsilon_t$$

Si los polinomios de rezagos $\lambda_i(L)$ y $\beta(L)$ son de orden finito p , Stock y Watson (2002) demostraron que los factores f pueden ser estimados utilizando la metodología de componentes principales.

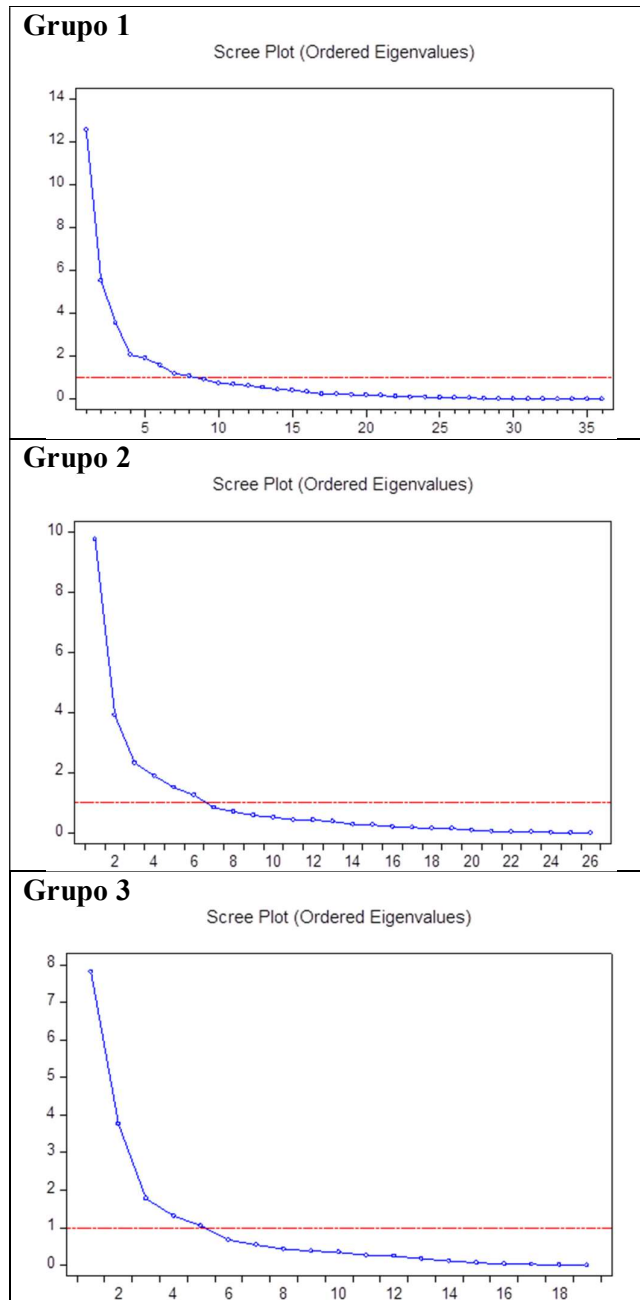
Si se define a la Inversión trimestral como el promedio de las observaciones mensuales latentes, $y_t^Q = (y_t + y_{t-1} + y_{t-2})/3$, y si se estiman los factores trimestrales f_t^Q de los datos considerados como predictores, es posible obtener estimaciones tempranas de la Inversión, esto es, dentro del trimestre, utilizando la siguiente ecuación:

$$\hat{y}_t^Q = \beta(L)'f_t^Q + \gamma(L)'y_{t-1}^Q$$

El ejercicio de *Nowcast* consistió en una primera instancia, como se comentó anteriormente, en seleccionar los indicadores a considerar en la estimación de acuerdo con el coeficiente de correlación de las series estacionarias y de la Inversión, también con su transformación a estacionaria. En base a esto se armaron 3 grupos de indicadores (G1, G2 y G3) a partir de los cuales se estimaron, mediante la metodología de componentes principales, los factores comunes a los indicadores pertenecientes a cada uno de estos grupos.

Para seleccionar el número de factores a considerar en la proyección, se utilizó el *scree plot*. De acuerdo con este gráfico, en que se dibujan los autovalores —que surgen del método de cálculo—, el criterio consiste en seleccionar la cantidad de factores que se suceden en la gráfica hasta que en la misma se produce un cambio en la pendiente o cuando la misma parece nivelarse con la parte derecha del dibujo. Teniendo en cuenta esto, se seleccionaron los primeros 3 o 4 factores, dependiendo del conjunto de información considerado (G1, G2 o G3), los que permiten explicar entre el 60% y 77% de la covarianza de las series de tiempo consideradas en cada conjunto para la estimación (ver Figura 3 y Anexo III).

Figura 3: Scree Plot



Los factores calculados se utilizaron para realizar la estimación de la Inversión. Se busca el modelo lo más parsimonioso posible, por lo que resultó significativo sólo el primer factor (ver Anexo IV). Este resultado está en línea con Stock y Watson (2002), que encuentran que sólo uno o dos factores son suficientes para obtener buenos pronósticos cuando se trata de una variable real.

En todos los casos, los modelos fueron especificados para garantizar residuos ruido blanco, homocedásticos y normales.

El ejercicio de *Nowcast* se realizó mediante ventanas móviles (*rolling window*) con un tamaño de la ventana de estimación de 40 trimestres. De este modo, el tamaño de la muestra permaneció constante durante todo el ejercicio, al incorporarse la nueva información y descartarse la información más antigua. Como se mencionó, producto de la actualización de los datos, se obtuvieron 6 estimaciones para cada trimestre.

La elección de la metodología de factores radica en las ventajas que presenta para trabajar con un gran número de indicadores y en la capacidad para incorporar información de manera inmediata. De este modo, logra capturar los posibles quiebres de tendencia y mantiene sus cualidades en capacidad predictiva en períodos inestables o de alta volatilidad. Esta característica es de particular relevancia en el caso de Argentina, más aún al considerar el cambio de régimen evidenciado en los últimos años.


De manera contraria, la metodología de *bridge equations* utiliza generalmente modelos con series de datos de largo historial, con un número de indicadores relativamente más reducido, y que no siempre logran responder rápidamente a la nueva información y capturar un cambio de tendencia de la variable estimada. A su vez, como estos modelos habitualmente incorporan a las variables dependientes e independientes de manera rezagada, pueden tener una fuerte dependencia de los valores pasados de estas variables, lo que puede afectar a la capacidad predictiva en los períodos de alta volatilidad.

3.4. Resultados de la Estimación

En esta sección se presentan los resultados del ejercicio de *Nowcast* de la Inversión a partir de los tres modelos de factores especificados (*Nowcast G1*, *Nowcast G2* y *Nowcast G3*), que surgen de considerar los tres conjuntos de información empleados (Grupo 1, Grupo 2 y Grupo 3), desde el primer trimestre de 2011 al segundo trimestre de 2017. También se presentan los resultados de la estimación, para igual período, provenientes de un modelo AR(1) para la Inversión, el que se considera como modelo *benchmark* contra el cual contrastar los resultados.

Los resultados que surgen de la estimación realizada están libres del juicio de experto. La metodología utilizada para realizar el ejercicio de *Nowcast* está basada en un modelo estadístico que se actualiza cuando se cuenta con nueva información, de acuerdo con el calendario de publicación previsto, sin ninguna intervención del juicio de experto. Esto difiere, por ejemplo, del *Nowcast* del PIB que realiza el Banco de Inglaterra (BoE) y que utiliza el Comité de Política Monetaria como insumo para la toma de decisiones, en el que la estimación no es un resultado mecánico de un modelo (Anesti et. al, 2017). En particular, el *Nowcast* del PIB del BoE está conformado por los resultados de tres modelos (modelo industrial, modelo MIDAS-combinado y modelo de factores dinámicos), que son combinados o ponderados de acuerdo con el criterio del *staff* del banco y considerando a su vez otra información que los modelos pueden no haber sido capaces de capturar.

Figura 4: Resultados de la Estimación de la Inversión: *Nowcast* vs. AR




Según se desprende de la Figura 4, en la mayoría de los trimestres los modelos de factores (*Nowcast* G1, *Nowcast* G2 y *Nowcast* G3) arrojan un mejor pronóstico de la Inversión que el que surge del modelo AR considerado como *benchmark*. Esto se observa particularmente en los momentos en que hay un cambio en la dinámica de la Inversión

entre los trimestres, en que los modelos de factores parecen poder reaccionar más rápidamente y reflejar el cambio de tendencia, producto de la incorporación inmediata de la nueva información (*news*).

Para evaluar la capacidad predictiva de los modelos se puede utilizar la raíz cuadrada del error cuadrático medio (RMSE, de acuerdo con su sigla en inglés) que surge de comparar los pronósticos y la realización de la variación trimestral de la Inversión para cada trimestre (valor observado). A partir de la observación de la Figura 5 que presenta la evolución de los RMSE para cada modelo en cada una de las seis realizaciones para el período de evaluación, no se puede distinguir una superioridad en capacidad predictiva de alguno de los modelos, si bien en términos generales los modelos de factores (*Nowcast G1*, *Nowcast G2* y *Nowcast G3*) parecen presentar un menor RMSE que el exhibido por el modelo AR. Teniendo en cuenta este resultado, se abordaron distintas estrategias, a partir de los RMSE, para poder obtener alguna conclusión sobre la elección del modelo más adecuado para el *Nowcast* de Inversión.

Figura 5: Errores de Pronóstico: *Nowcast* vs. AR

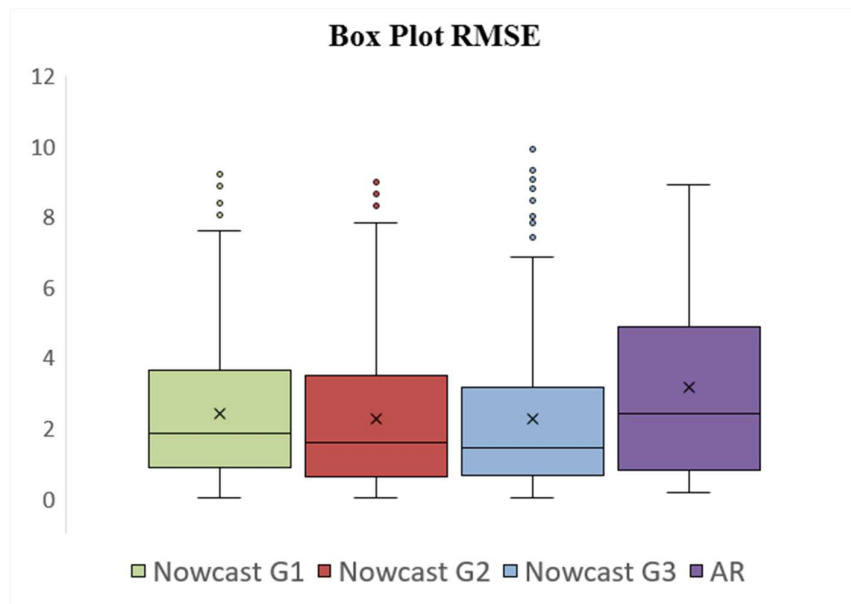


Una primera estrategia consistió en observar la distribución de los RMSE de cada uno de los modelos, reflejadas en un gráfico de caja o *box plot*. Este gráfico resume la información más relevante acerca de la distribución de una variable. La amplitud de la caja da una idea de la dispersión de los datos, dado que representa el rango intercuartílico

(RIC) comprendido entre los percentiles 25 y 75 de la distribución y contienen el 50% central de las observaciones. De este modo, cuanto más compacta sea la caja mayor es la concentración de la variable en torno al valor central de la distribución que es la mediana (la línea sólida que se observa al interior de la caja). Que esta línea se ubique por debajo de la media (representada en el gráfico por la cruz) es una evidencia de asimetría positiva en la distribución de los RMSE y significa que los valores más elevados traccionan a la media por encima de la mediana. Los “bigotes” se extienden desde la mediana hasta $\pm 1,5$ del RIC y las observaciones por encima o por debajo de los “bigotes” son observaciones atípicas o *outliers*.

De acuerdo con la distribución de los RMSE, se podría concluir que los modelos de factores (*Nowcast G1*, *Nowcast G2* y *Nowcast G3*) tienen una mejor performance que el modelo AR, ya que para los tres modelos de factores la caja es más compacta, y la mediana y la media son inferiores a las del modelo AR, más allá de los valores extremos o *outliers* que presentan. No obstante, es difícil establecer cuál de los modelos de factores posee la mejor performance, si bien podría pensarse a priori que correspondería a alguno de los modelos *Nowcast G2* o *Nowcast G3*, pues exhiben los menores valores en media y mediana (ver Figura 6).

Figura 6: Errores de Pronóstico: *Nowcast* vs. AR



Otra estrategia para poder tener conocimiento sobre la *performance* de los modelos en cuanto a la capacidad predictiva consistió en analizar la cantidad de veces sobre el total (frecuencia) en la que cada modelo presenta el menor error de pronóstico, en términos de RMSE (ver Figura 7). Para esto se consideró la muestra completa (desde el primer trimestre de 2011 al primer trimestre de 2017) y una muestra más reciente, que también incluye al cambio estructural o cambio de régimen de diciembre de 2015 (desde el primer trimestre de 2015 al primer trimestre de 2017). De acuerdo con este criterio, el modelo *Nowcast G3* es el que presenta la mejor *performance* en la muestra completa, tanto en relación con el AR como con respecto al resto de los modelos de factores (*Nowcast G1* y *Nowcast G2*). Para la muestra más reciente, el modelo *Nowcast G3* también exhibe el mejor desempeño (supera al AR y a los modelos *Nowcast G1* y *Nowcast G2*).

Figura 7: Desempeño en Pronóstico: *Nowcast* vs. AR

Frecuencia con la cual el modelo está rankeado en primer lugar en cuanto a capacidad predictiva (menor RMSE, en %)				
	Nowcast Grupo 1	Nowcast Grupo 2	Nowcast Grupo 3	AR
muestra completa 2011q1-2017q1	0.167	0.247	0.340	0.247
muestra 2015q1-2017q1	0.148	0.259	0.407	0.185

De este modo, parece que la inclusión de un mayor número de indicadores no estaría mejorando la capacidad de pronóstico del modelo, dado que el modelo *Nowcast G3* es el que incluye la menor cantidad de indicadores (Grupo 3 conformado por 19 series). Estos resultados también son reflejados por la literatura empírica. En este sentido, Banbura y Mondungo (2010) encuentran en su estimación que los modelos de factores superan en capacidad predictiva al *benchmark* AR, lo que confirma la importancia de contar con información contemporánea contenida en los indicadores mensuales. Sin embargo, entre los diversos modelos de factores que contienen distinta cantidad de información, encuentran que el que presenta la mayor desagregación de la información no arroja los mejores resultados de pronósticos y es superado por las estimaciones que consideran una desagregación mediana o pequeña. De acuerdo con sus conclusiones, esta situación

podría responder a que se genera una dificultad en extraer las señales relevantes. En igual dirección están los resultados encontrados por Brave et. al. (2016), quienes al realizar una estimación para el PIB de Estados Unidos concluyen que incluir mayor cantidad de variables o predictores no necesariamente aumenta la capacidad predictiva del modelo.

4. Evaluación de Capacidad Predictiva

Para evaluar si las diferencias en capacidad predictiva encontradas en la sección anterior son estadísticamente significativas y seleccionar el modelo que presenta la mejor performance de pronóstico se utiliza el test de Giacomini y White (2003).

Como se mencionó, conocer el desempeño y el pronóstico de las principales variables económicas es de fundamental relevancia para los agentes económicos y, en este contexto, uno de los problemas a enfrentar es seleccionar el mejor método de pronóstico entre dos o más alternativas. La respuesta econométrica a este problema consiste en el desarrollo de tests que permitan comparar la habilidad predictiva de dos métodos de pronósticos alternativos, dada la función de pérdida.

Giacomini y White (2003) propusieron un test para la selección de pronósticos *real-time*, esto es, para establecer cuál entre dos métodos competitivos de pronóstico es el que generará un mejor pronóstico en el futuro más próximo.

El enfoque metodológico planteado por Giacomini y White se basa en expectativas condicionales. De acuerdo con el trabajo, el enfoque consiste en evaluar lo que ellos llaman el método de pronóstico, lo que incluye al modelo así como también las decisiones que se deben tomar en cuanto a la elección de los procedimientos y de los datos a incluir, dado que todos los elementos afectan la performance del pronóstico. En este sentido, señalan que el hecho de tener un modelo que aproxime correctamente el proceso generador de los datos no garantiza que genere buenos pronósticos. Así, establecen que esta metodología es relevante cuando el objetivo es encontrar modelos con buena capacidad predictiva en lugar de evaluar la validez de algún modelo.

Por otro lado, una de las ventajas que presenta esta metodología es que permite trabajar con datos heterogéneos, en el sentido que las series de interés pueden presentar un proceso generador de los datos variable en el tiempo —no es necesario contar sólo con series que

presenten un proceso estacionario—. Según esgrimen, varias pueden ser las razones por las cuales las series económicas utilizadas para realizar los pronósticos pueden presentar heterogeneidades a través del tiempo. Ellas abarcan desde modificaciones en la medición, en el relevamiento, en la definición de la construcción de las variables, hasta cambios de los responsables de las instituciones y de la confección de los estadísticos. De este modo, el hecho de contar con heterogeneidad en la información también afecta al método de estimación, haciendo necesario contar con estimaciones de memoria finita. En este sentido, en vez de utilizar un enfoque recursivo, en el que se expande la ventana de los datos para la estimación adicionando la nueva información, se utiliza un procedimiento de ventanas móviles (*rolling window*), en el que los pronósticos están basados en una ventana móvil de los datos en que se descartan las observaciones más antiguas. En este enfoque, la ventana de estimación se considera como uno de los elementos de elección del método de pronóstico bajo evaluación.

Otra ventaja que presenta el test es que refleja el efecto de la incertidumbre en la estimación sobre la performance relativa de pronóstico. Al expresar la hipótesis nula en términos del parámetro estimado y al considerar una ventana de estimación finita, se genera una estimación que presenta una incertidumbre que no se reduce asintóticamente, sino que permanece como un factor determinante del pronóstico y por lo tanto de su performance.

Adicionalmente, el test permite comparar de manera unificada pronósticos provenientes de una amplia variedad de modelos, entre los que se incluyen modelos anidados y no anidados. También se puede utilizar para comparar la performance de pronósticos utilizando distintas técnicas de estimación, como métodos bayesianos, semi-paramétricos o no paramétricos.

A su vez, también presenta una ventaja práctica, que radica en la facilidad de su computo a través de la realización de una regresión en los paquetes econométricos tradicionales.

Específicamente, el test consiste en comparar dos modelos alternativos de pronóstico, para la variable de interés en τ pasos adelante, esto es $Y_{t+\tau}$. Los pronósticos son formulados en el momento t y se basan en el conjunto de información disponible \mathcal{F}_t . Los dos pronósticos que se comparan pueden definirse como $\hat{f}_{m,t}$ y $\hat{g}_{m,t}$, donde f y g son funciones mensurables. Los subíndices implican que el pronóstico realizado en el

momento t es una función mensurable de la muestra de, como máximo, tamaño m , considerando las más recientes m observaciones.

Los estimadores pueden ser paramétricos, semi-paramétricos o no paramétricos. El único requisito es que m (el tamaño de la ventana de estimación) debe ser finito. Todo el resto de los elementos de la estimación, esto es el modelo, el procedimiento de estimación, el tamaño de la ventana de estimación y la función de pérdida, son tratados como parte de la elección que realiza quien hace el pronóstico y parte de lo que se llama el método de estimación que está bajo evaluación.

La evaluación es realizada en una simulación *out-of-sample*. Se considera una muestra de tamaño T . Como los datos indexados $1, \dots, m$ son usados para la estimación del primer conjunto de parámetros, el primer pronóstico τ pasos adelante es formulado al momento m y comparado con la realización $Y_{m+\tau}$. El segundo pronóstico es producido al mover la ventana de estimación un paso hacia adelante y estimar los parámetros sobre los datos indexados $2, \dots, m + 1$. Este pronóstico es comparado con la realización $Y_{m+1+\tau}$. Este procedimiento es iterado y el último pronóstico es generado en el momento $T - \tau$, estimando los parámetros sobre los datos indexados $T - \tau - m + 1, \dots, T - \tau$, y es comparado con la realización y_T . Este procedimiento de ventanas móviles genera una secuencia de $n \equiv T - \tau - m + 1$ pronósticos y de los respectivos errores de pronóstico.

La secuencia de los pronósticos *out-of-sample* así producidos son evaluados a partir de una función de pérdida $L_{t+\tau}(Y_{t+\tau}, \hat{f}_{m,t})$, 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:

$$H_0: E[L_{t+\tau}(Y_{t+\tau}, \hat{f}_{m,t}) - L_{t+\tau}(Y_{t+\tau}, \hat{g}_{m,t})/\mathcal{F}_t] = 0$$

o alternativamente

$$H_0: E[\Delta L_{m,t+\tau}/\mathcal{F}_t] = 0, \text{ con } t = 1, 2, \dots$$

Si la hipótesis nula de igual capacidad predictiva condicional de los métodos de pronóstico f y g es rechazada, se incrementa la posibilidad de que se pueda seleccionar en el momento T el mejor método de pronóstico para el período $T + \tau$.

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. En este caso, como es un pronóstico un período adelante, no es necesario realizar este ajuste.

Los resultados de usar el test de Giacomini y White para evaluar la capacidad predictiva del *Nowcast* a partir de los diversos modelos de factores (*Nowcast G1*, *Nowcast G2* y *Nowcast G3*) en relación con el AR se muestran en la Figura 8.

Figura 8: Evaluación Capacidad Predictiva: *Nowcast* vs. AR

Resultados del Test Giacomini y White			
Muestra Q1 2011 - Q1 2017			
	coeficiente	estadístico t	p-value
Nowcast G1 vs AR	-6.51	-4.75	0.0000
Nowcast G2 vs AR	-7.27	-5.54	0.0000
Nowcast G3 vs AR	-6.18	-5.17	0.0000
Muestra Q1 2015 - Q1 2017			
	coeficiente	estadístico t	p-value
Nowcast G1 vs AR	-4.71	-4.16	0.0001
Nowcast G2 vs AR	-5.66	-4.94	0.0000
Nowcast G3 vs AR	-6.08	-4.82	0.0000

Se puede observar que todos los modelos de factores superan al AR considerado como *benchmark*, siendo las diferencias estadísticamente significativas (p-value de 0.000). Esto es, al realizar el test de Giacomini y White, el coeficiente es negativo, indicando que los errores de pronóstico de los modelos de factores son inferiores a los errores de pronóstico del modelo AR, y estadísticamente significativo, dado el valor del estadístico t y el *p-value* asociado. Este resultado se mantiene tanto para la muestra comprendida entre el primer trimestre de 2011 y el primer trimestre de 2017 como para muestra que se inicia en el primer trimestre de 2015 y finaliza el primer trimestre de 2017. Este resultado es interesante debido a que ambas muestras incluyen un punto de inflexión o cambio de

régimen, en el que los modelos *Nowcast* responden más favorablemente que el modelo autoregresivo.

También se realizó el test de Giacomini y White para comparar la capacidad de pronóstico relativa de los diversos modelos de factores. Esto es, se evaluó la capacidad de pronóstico relativa de los modelos *Nowcast* realizados con los distintos grupos de indicadores (Grupo 1, Grupo 2 y Grupo 3), definidos anteriormente. Los resultados para la muestra más amplia indican que el *Nowcast G2* supera en capacidad predictiva al *Nowcast G1*, dado el coeficiente negativo y estadísticamente significativo, y que también supera al *Nowcast G3*, a un nivel de significatividad del 10%. En tanto, de la comparación del *Nowcast G3* con el *Nowcast G1* no se pueden sacar conclusiones, pues el coeficiente no es estadísticamente significativo.

Por su parte, si consideramos la muestra del período más reciente, entre el primer trimestre de 2015 y el primer trimestre de 2017, se puede concluir que el *Nowcast G2* tiene una mejor capacidad de pronóstico que el *Nowcast G1*, dado un coeficiente negativo y estadísticamente significativo. En tanto, el *Nowcast G3* presenta un mejor desempeño en pronóstico que el *Nowcast G1* y, a un nivel de significativa del 10%, también es superior en capacidad predictiva al *Nowcast G2* (ver Figura 9).

De este modo, el modelo *Nowcast G3*, el que se genera con el grupo más reducido de indicadores (19 series), es el que presenta la mejor *performance* para el período más reciente y el que por lo tanto se selecciona para realizar las estimaciones del *Nowcast* entre los modelos aquí evaluados.

Figura 9: Evaluación Capacidad Predictiva: *Nowcast*

Resultados del Test Giacomini y White			
Muestra Q1 2011 - Q1 2017			
	coeficiente	estadístico t	p-value
Nowcast G2 vs G1	-0.76	-3.02	0.0029
Nowcast G2 vs G3	-1.10	-1.96	0.0519
Nowcast G3 vs G1	0.34	0.57	0.5722
Muestra Q1 2015 - Q1 2017			
	coeficiente	estadístico t	p-value
Nowcast G2 vs G1	-0.95	-3.46	0.0011
Nowcast G3 vs G2	-0.48	-1.74	0.0874
Nowcast G3 vs G1	-1.43	-3.30	0.0017

5. Pooling de Pronósticos

La literatura de pronóstico ha enfatizado que el *pooling* o la combinación de diferentes pronósticos puede resultar en una mejor *performance* en comparación con los modelos individuales. El *pooling* de pronósticos implica la combinación de dos o más pronósticos derivados de modelos que usan diferentes predictores para producir un pronóstico.

Teniendo en cuenta los resultados obtenidos en las secciones anteriores, se procedió a realizar un *pooling* de los pronósticos generados por los modelos *Nowcast* G2 y *Nowcast* G3, utilizando ponderadores w_i de igual peso.

De acuerdo con Ahumada y Garegnani (2012), la utilización de un promedio simple parece ser un método útil para ponderar los pronósticos debido a su simplicidad y al hecho de que la ganancia de utilizar otros métodos no parece ser muy elevada.

Confeccionado el *pooling* de pronósticos y calculados los respectivos RMSE para cada una de las estimaciones generadas, se procedió a realizar el test del Giacomini y White para evaluar su capacidad predictiva relativa al resto de los modelos. Las muestras que se consideran para realizar el test son las mismas que las de la sección anterior.

De acuerdo con los resultados que se muestran en la Figura 10, se puede concluir que tanto para la muestra completa (desde el primer trimestre de 2011 hasta el primer trimestre

de 2017) como para la muestra más reciente (desde el primer trimestre de 2015 hasta el primer trimestre de 2017) el *pooling* supera en capacidad predictiva al modelo AR, dado que el coeficiente es negativo y estadísticamente significativo.

Figura 10: Evaluación Capacidad Predictiva: Pooling de Pronósticos

Resultados del Test Giacomini y White			
Muestra Q1 2011 - Q1 2017			
	coeficiente	estadístico t	p-value
Pooling vs AR	-7.01	-5.72	0.0000
Pooling vs G1	-0.49	-1.38	0.1693
Pooling vs G2	0.26	0.97	0.3333
Pooling vs G3	-0.83	-2.87	0.0047
Muestra Q1 2015 - Q1 2017			
	coeficiente	estadístico t	p-value
Pooling vs AR	-6.12	-5.11	0.0000
Pooling vs G1	-1.41	-4.24	0.0001
Pooling vs G2	-0.46	-3.51	0.0009
Pooling vs G3	-0.04	-0.25	0.8026

En cuanto a su comparación con el resto de los modelos, se puede observar que para la muestra completa el *pooling* de pronósticos (de *Nowcast* G2 y *Nowcast* G3) supera en capacidad predictiva al *Nowcast* G3 de manera individual, mientras que en relación con el *Nowcast* G1 y el *Nowcast* G2 no se pueden sacar conclusiones, pues los coeficientes no son estadísticamente significativos.

Para la muestra más reciente, los resultados de Giacomini y White señalan que el *pooling* de pronósticos (de *Nowcast* G2 y *Nowcast* G3) posee una mejor performance que el *Nowcast* G1 y el *Nowcast* G2, cada uno de ellos de manera individual. En tanto, no resulta superador al *Nowcast* G3, dado que el coeficiente no es estadísticamente significativo.

Estos resultados están en línea con los obtenidos en la sección anterior, en los que se encuentra que para la muestra completa el *Nowcast* G2 arroja los mejores resultados (el *pooling* exhibe un coeficiente positivo y no estadísticamente significativo), mientras que

para la muestra reducida el *Nowcast* G3 es el que presenta la mejor capacidad de pronóstico relativa.

De todos modos, es importante enfatizar que los modelos *Nowcast* individuales y combinados son superiores al modelo AR para las muestras consideradas. Estos resultados ponen en evidencia la superioridad de los modelos *Nowcast* para la toma de decisiones y proyección de la Inversión. Dentro de estos modelos, para el período más reciente, el que incorpora la menor cantidad de indicadores es el que presenta el mejor desempeño, en línea con la literatura más reciente en que incluir mayor cantidad de variables o predictores no necesariamente aumenta la capacidad predictiva del modelo.

6. Conclusiones

Mientras que tener un conocimiento sobre la Inversión, así como del resto de las variables macroeconómicas, es fundamental para los agentes económicos y los hacedores de política, las cifras oficiales de Cuentas Nacionales poseen una frecuencia trimestral y se publican con rezago.

En el presente trabajo se realizó una estimación en tiempo real de la evolución de la Inversión a partir de un conjunto amplio de indicadores económicos de alta frecuencia, lo que se conoce en la literatura como *Nowcasting*. El *Nowcasting* —definido como la predicción del presente, el futuro muy cercano y el pasado muy reciente— ha demostrado ser una herramienta útil para superar el problema de contar con información válida a distintas frecuencias.

El ejercicio de *Nowcast* realizado permite contar con una primera estimación de la Inversión en el trimestre a 45 días de iniciado el mismo, con subsecuentes actualizaciones quincenales, lo que implica una ganancia informativa en cuanto a esta variable. De este modo, el *Nowcast* de Inversión constituye un elemento valioso para las decisiones de política.

Para realizar el *Nowcast* se consideraron tres grupos de indicadores de frecuencia mensual y mediante modelos de factores dinámicos (*Nowcast* G1—36 series—, *Nowcast* G2—26 series— y *Nowcast* G3—19 series—) se pronosticó el crecimiento trimestral de la Inversión. Luego, se estudiaron los errores de pronóstico y se utilizó el test de Giacomini

y White para analizar la capacidad predictiva relativa de los modelos *Nowcast* y de un modelo AR(1) considerado como un *benchmark*.

De las evaluaciones realizadas se desprende que los modelos *Nowcast* superan en capacidad predictiva al modelo AR, tanto para una muestra que comprende entre el primer trimestre de 2011 y el primer trimestre de 2017 como para una muestra más reciente, que abarca desde primer trimestre de 2015 hasta el primer trimestre de 2017. Este resultado es interesante debido a que ambas muestras incluyen un punto de inflexión o cambio de régimen, y los modelos *Nowcast* responden más favorablemente que el modelo autoregresivo al incorporar de manera inmediata la nueva información. Estos resultados ponen en evidencia la superioridad de los modelos *Nowcast* para la toma de decisiones y proyección de la Inversión.

Adicionalmente, se puede concluir que el modelo de factores *Nowcast* G3 genera el mejor pronóstico de la Inversión y es el que evidencia la mejor capacidad predictiva en el período más reciente. De este modo, dado que el Grupo 3 es el que contiene menor cantidad de indicadores —19 series—, el hecho de incluir un mayor número de indicadores no estaría mejorando la capacidad de pronóstico del modelo.

También se realizó un ejercicio de *pooling* de pronósticos con los modelos *Nowcast* G2 y *Nowcast* G3 —los que presentan el mejor desempeño relativo—. El test de Giacomini y White señala que la capacidad de pronóstico del *pooling* es superior a la del modelo AR (para ambas muestras consideradas). Para la muestra más reciente, el test indica que el *pooling* exhibe una mejor *performance* que los modelos *Nowcast* G1 y *Nowcast* G2, pero no se puede aseverar que sea superior a la del modelo *Nowcast* G3, por lo que este último sería el modelo elegido para realizar la estimación de la Inversión.

Cabe mencionar que el *Nowcast* de Inversión está basado en un modelo estadístico que se actualiza automáticamente, sin ninguna intervención del juicio de expertos. De este modo, permite a los hacedores de política tener un conocimiento en tiempo real de la Inversión, lo que es fundamental para la implementación oportuna de políticas de incentivo a la Inversión y de políticas contracíclicas. En este sentido, el *Nowcast* de Inversión es una herramienta que, al brindar información del desempeño de la Inversión, permite realizar una asignación eficiente de los recursos para lograr un crecimiento de la economía sostenible a largo plazo.

7. Referencias Bibliográficas

- Ahumada, Hildegard and Maria Lorena Garegnani. 2012. "Forecasting a monetary aggregate under instability: Argentina after 2001". *International Journal of Forecasting*, 28, p.p.412-427.
- Anesti, Nikoleta, Simon Hayes, Andre Moreira and James Tasker. 2017. "Peering into the present: the Bank's approach to GDP nowcasting". Bank's Monetary Analysis Directorate. Bank of England. Quarterly Bulletin 2017 Q2.
- Angelini, Elena, Gonzalo Camba-Mendez, Domenico Giannone, Lucrezia Reichlin and Gerhard Rünstler. 2011. "Short-term forecasts of euro area GDP growth". *The Econometrics Journal*, 14: C25–C44.
- Baffigi Alberto, Roberto Golinelli and Giuseppe Parigi. 2004. "Bridge models to forecast the euro area GDP". *International Journal of Forecasting*. Vol. 20. Issue 3, p.p. 447–460.
- Banbura, Marta, Domenico Giannone, and Lucrezia Reichlin. 2010. "Nowcasting". ECARES Working paper 2010-021.
- Banbura, Marta, Domenico Giannone, Michel Mondungo and Lucrezia Reichlin. 2013. "Now-Casting and the Real-Time Data Flow". ECB Working Paper Series. N° 1564.
- Banbura, Marta, and Michel Mondungo. 2010. "Maximun Likelihood Estimation of Factor Models on Data Sets with Arbitrary Pattern of Missing Data". ECB Working Paper Series. N° 1189.
- Banbura, Marta and Gerhard Rünstler. 2011. "A look into the factor model black box: Publication lags and the role of hard and soft data in forecasting GDP". *International Journal of Forecasting*, 27(2), p.p. 333–346.
- Barhoumi, Karim, Olivier Darné and Laurent Ferrara. 2010. ¿Are disaggregate data useful for factor analysis in forecasting French GDP? *Journal of Forecasting*, 29(1-2), p.p. 132–144.
- Barhoumi, Karim, Olivier Darné, Laurent Ferrara and Bertrand Pluyaud. 2012. "Monthly GDP forecasting using bridge models: application for the French economy". *Bulletin of Economic Research*, 2012. Vol. 64. Issue Supplement 1, s53-s70.
- Bencivelli, Lorenzo, Massimiliano Marcellino M. and Gianluca Moretti. 2012. "Selecting predictors by Bayesian model averaging in bridge models". Banca d'Italia. Working Paper 872. Rome.
- Blanco, Emilio, Laura D'Amato, Fiorella Dogliolo, Lorena Garegnani. 2017. "Nowcasting GDP in Argentina: Comparing the predictive ability of different models".
- Brave, Scott A., R. Andrew Butters and Alejandro Justiniano. 2016. "Forecasting Economic Activity with Mixed Frequency Bayesian VARs". Working Paper, No. 2016-05. Federeal Reserve Bank of Chicago.
- Camacho, Máximo y Gabriel Perez-Quiros. 2009. "Ñ- STING: España Short Term Indicador of Growth". Documentos de Trabajo N° 0912. Banco de España.
- D'Agostino, Antonello, Kieran Mc Quinn and Derry O'Brien. 2008. "Now-casting Irish GDP." Research Technical Papers 9/RT/08. Central Bank & Financial Services Authority of Ireland.
- D'Amato, Laura, Lorena Garegnani y Emilio Blanco. 2015. "Nowcasting de PIB: evaluando las condiciones cíclicas de la economía argentina". Estudios BCRA. Documentos de trabajo 2015/69.
- D'Amato, Laura, Lorena Garegnani y Emilio Blanco. 2011. "Using the Flow of High Frequency Information for Short Term Forecasting of Economic Activity in Argentina". *Ensayos Económicos* 64. BCRA.
- De Winter, Jasper. (2011): "Forecasting GDP growth in times of crisis: private sector forecasts versus statistical models." DNB Working Papers 320, Netherlands Central Bank, Research Department.
- Drechsel, Katja and Laurent Maurin. 2008. "Flow of Conjunctural Information and Forecast of Euro Area Economic Activity". European Central Bank. Working Paper N° 925.

- Diron, Marie 2008. "Short-term forecasts of euro area real GDP growth: an assessment of real-time performance based on vintage data". *Journal of Forecasting*. Vol. 27, Issue 5, p.p. 371–390.
- Forni, Claudia and Massimiliano Marcellino. 2013. "A survey of econometric methods for mixed-frequency data. European University Institute. Working paper, 2013/02.
- Giacomini, Raffaella and Halbert, White. 2003. "Test of conditional predictive ability". Boston College Working Papers in Economics.
- Giannone, Domenico, Lucrezia Reichlin and David Small. 2008. "Nowcasting: The real-time informational content of macroeconomic data". *Journal of Monetary Economics* 55 (2008), p.p. 665-676.
- Higgins, Patrick. 2014. "GDPNow: A Model for GDP Nowcasting" Working Paper 2014-7, Federal Reserve Bank of Atlanta.
- Jansen, W. Jos, Xiaowen Jin and Jasper M. de Winter. 2016. "Forecasting and nowcasting real GDP: Comparing statistical models and subjective forecast". *International Journal of Forecasting* 32 (2016), p.p. 411-436.
- Kitchen, John and Ralph Monaco. 2003. "Real-Time Forecasting in Practice". *Business Economics*, 38 (4): 10-19.
- Krief, Tomer. 2011. "A Nowcasting Model for GDP and its Components". Discussion paper N° 2011.01 Research Department, Bank of Israel.
- Lago Alves, Sergio Afonso y Angelo Marsiglia Fasolo. 2015. "Not Just Another Mixed Frequency Paper". Working Papers Series, 400. Banco Central do Brasil.
- Lahiri, Kajal and George Monokroussos. 2011. "Nowcasting US GDP: The role of ISM Business Surveys". Discussion Papers, University at Albany, SUNY, Department of Economics.
- Matheson, Troy. 2011. "New Indicators for Tracking Growth in Real Time". IMF Working Paper 11/43.
- Pincheira, Pablo. 2013. "Conditional predictive ability of exchange rate in long run regressions". *Revista de Análisis Económico*, Vol. 28, N°2, p.p.3-35.
- Shumacher, Christian and Jörg Breitung. 2008. Real-time forecasting of German GDP based on a large factor model with monthly and quarterly data. *International Journal of Forecasting*, 7 (3), p.p. 375-384.
- Stock, J. H., and M. W. Watson. 2002. "Macroeconomic Forecasting Using Diffusion Indexes". *Journal of Business and Economic Statistics*. Vol 20, N° 2, p.p.147-162.
- Tarsidin, Idham and Robbi Nur Rakhman. 2017. "Nowcasting Household Consumption and Investment". Proceedings 2nd ISI Regional Statistics Conference, Indonesia.

8. Anexos

8.1. Anexo I. Series Estudiadas

Nro Serie	Fuente	Descripción Serie	Análisis de estacionalidad				Análisis de estacionariedad			
			Ajuste estacional	Efecto calendario significativo	Modelo	Descomposición	Factores concurrentes	Factores proyectados	Decisión Factores	Transformación necesaria para la estacionariedad de la serie
serie1	ADEFA	Producción Nacional	si	no	(0,1,1)(0,1,1)	Aditiva	1701.23	2203.65	Conc	dl
serie2	ADEFA	Exportación	si	no	(0,1,1)(0,1,1)	Aditiva	1328.25	1536.56	Conc	dl
serie3	ADEFA	Ventas a Concesionarios	no	no						
serie4	ADEFA	Ventas a conc. Veh. Mac.	si	no	(0,1,1)(0,1,1)	Aditiva	563.93	797.14	Conc	dl
serie5	AFCP	Despachos provisorios	si	no	(3,1,1)(0,1,1)	Multiplicativa	1.24	1.44	Conc	dl
serie6	MECON	Ganancias (Total)	si	no	(0,1,1)(0,1,1)	Multiplicativa	1.58	2.06	Conc	dl
serie7	MECON	Ganancias DGI	si	no	(0,1,1)(0,1,1)	Multiplicativa	1.61	2.1	Conc	dl
serie8	MECON	Ganancias DGA	no	no						
serie9	MECON	IVA bruto	si	no	(0,1,1)(0,1,1)	Multiplicativa	1.3	1.58	Conc	dl
serie10	MECON	IVA DGI	si	no	(0,1,1)(0,1,1)	Multiplicativa	1.31	1.77	Conc	dl
serie11	MERVAL	merval_avg	no	no						
serie12	MERVAL	merval_last	no	no						
serie13	BCRA	M2* Amplio Privado Nominal	no	no						
serie14	BCRA	Tasa de interes plazo fijo 30 a 59 días Bancos privados	no	no						
serie15	CCA	Ventas de autos usados	no	no						
serie16	UTDT	ICC - Nivel General-Capital Federal	no	no						
serie17	UTDT	ICC - Nivel General	no	no						
serie18	UTDT	ICC-DI	no	no						
serie19	UTDT	ICC-SM	no	no						
serie20	UTDT	ICC-SP	no	no						
serie21	UTDT	ICC-Expectativas	no	no						
serie22	UTDT	ICC-Expectativas	no	no						
serie23	CIS	Hierro Primario	si	no	(0,1,1)(0,1,1)	Aditiva	2.85	6.62	Conc	nivel
serie24	CIS	Acero Crudo	si	no	(0,1,0)(0,1,1)	Aditiva	3.63	5.05	Conc	nivel
serie25	CIS	Lam. Frío	no	no						
serie26	CIS	Lam. En caliente Total No Planos	si	no	(0,1,2)(0,1,1)	Aditiva	3.74	4.46	Conc	dl
serie27	CIS	Lam. En caliente Planos	no	no						
serie28	FEL	PI - nivel general	no	no						
serie29	FEL	PI - bienes de consumo no durables	si	no	(1,0,1)(1,1,1)	Aditiva	0.87	1.17	Conc	dl
serie30	FEL	PI - bienes de consumo durables	si	no	(0,1,1)(0,1,1)	Aditiva	2.9	3.83	Conc	dl
serie31	FEL	PI - bienes de uso intermedio	si	no	(0,1,1)(0,1,1)	Multiplicativa	0.5	0.58	Conc	nivel
serie32	FEL	PI - bienes de capital	si	no	(0,1,1)(0,1,1)	Aditiva	6.84	9.8	Conc	dl
serie33	FEL	PI - alimentos y bebidas	si	no	(0,1,1)(0,1,1)	Aditiva	1.1	1.31	Conc	tend
serie34	FEL	PI - cigarrillos	no	no						
serie35	FEL	PI - insumos textiles	si	no	(0,1,1)(0,1,1)	Aditiva	0.66	0.85	Conc	nivel
serie36	FEL	PI - pasta y papel	si	no	(0,1,1)(0,1,1)	Multiplicativa	0.24	0.28	Conc	dl
serie37	FEL	PI - combustible	no	no						
serie38	FEL	PI - químicos y plásticos	no	no						
serie39	FEL	PI - minerales no metálicos	no	no						
serie40	FEL	PI - siderurgia	si	no	(0,1,1)(0,1,1)	Aditiva	2.07	2.95	Conc	dl
serie41	FEL	PI - metalmeccanica	si	no	(0,1,1)(0,1,1)	Aditiva	2.99	3.89	Conc	dl
serie42	FEL	PI - automóviles	si	no	(0,1,1)(0,1,1)	Aditiva	6.36	7.6	Conc	dl

Nro Serie	Fuente	Descripción Serie	Análisis de estacionalidad				Análisis de estacionariedad				
			Ajuste estacional	Efecto calendario significativo	Modelo	Descomposición	Factores concurrentes	Factores proyectados	Decisión Factores	Transformación necesaria para la estacionariedad de la serie	
serie43	AGIP - CABA	Recaudación de Ingresos Brutos	no								dl
serie44	Dirección Provincial de Política Tributaria - Prov.BSAS	Recaudación de Ingresos Brutos	no								dl
serie45	FAENA-aves (miles cab)		no								dl
serie46	CAME	Nivel general	si	no	(0,1,1)(0,1,1)	Multiplicativa	1,52	1,55	Conc		nivel
serie47	CAME	ALIMENTOS Y BEBIDAS	si	no	(0,1,1)(0,1,1)	Multiplicativa	0,51	0,9	Conc		nivel
serie48	CAME	BAZAR Y REGALOS	si	no	(0,1,1)(0,1,1)	Multiplicativa	2,41	3,52	Conc		nivel
serie49	CAME	Bijutería	si	no	(0,1,1)(0,2,1)	Multiplicativa	1,83	2,31	Conc		nivel
serie50	CAME	Calzados	si	no	(0,1,1)(0,1,1)	Multiplicativa	2,26	2,91	Conc		nivel
serie51	CAME	Deportes	si	no	(0,1,1)(0,1,1)	Multiplicativa	1,96	2,52	Conc		dl
serie52	CAME	Electrodomésticos	si	no	(0,1,0)(0,1,1)	Multiplicativa	2,41	3,78	Conc		dl
serie53	CAME	Farmacias	si	no	(1,0,0)(1,1,0)	Multiplicativa	1,3	1,92	Conc		dl
serie54	CAME	Ferretería	si	no	(0,1,0)(0,1,1)	Multiplicativa	1,97	1,84	Proj		dl
serie55	CAME	Golosinas Y Gaseosas	si	no	(2,0,0)(0,1,1)	Multiplicativa	1,64	2,21	Conc		dl
serie56	CAME	Juguetería	si	no	(0,1,1)(0,2,1)	Multiplicativa	1,82	2,2	Conc		nivel
serie57	CAME	Marroquinería	si	no	(1,1,0)(1,1,0)	Multiplicativa	1,78	2,4	Conc		dl
serie58	CAME	Materiales Eléctricos	si	no	(0,0,0)(0,1,0)	Multiplicativa	1,01	1,12	Conc		dl
serie59	CAME	Materiales para la Construcción	si	no	(0,1,1)(0,1,0)	Multiplicativa	1,43	1,76	Conc		dl
serie60	CAME	Muebles del Hogar	si	no	(3,1,0)(0,1,0)	Multiplicativa	0,9	1,14	Conc		dl
serie61	CAME	Muebles de Oficina	si	no	(1,0,1)(0,1,0)	Multiplicativa	1,24	1,76	Conc		dl
serie62	CAME	Perfumería	si	no	(0,1,1)(0,1,0)	Multiplicativa	0,99	2,02	Conc		dl
serie63	CAME	Textil - Indumentaria	si	no	(0,1,1)(0,1,0)	Multiplicativa	1,43	1,76	Conc		dl
serie64	CAME	Textil - Blanco	si	no	(0,1,0)(1,1,0)	Multiplicativa	1,64	1,97	Conc		dl
serie65	CONSTRUYA	Indice Construya. s.o.	si	no	(2,1,2)(0,1,1)	Multiplicativa	1,34	1,55	Conc		nivel
serie66	CONSTRUYA	Indice Construya. s.e.	no								tend
serie67	INDEC	XQ Nivel general	si	no	(0,1,1)(0,1,1)	Aditiva	1,55	1,96	Conc		nivel
serie68	INDEC	XQ PP	si	no	(1,0,0)(0,1,1)	Aditiva	3,95	5,38	Conc		nivel
serie69	INDEC	XQ MOA	no								dl
serie70	INDEC	XQ MOI	si	no	(0,1,1)(0,1,1)	Aditiva	2,31	3,03	Conc		tend
serie71	INDEC	XQ Combustibles y energia	no								dl
serie72	INDEC	XP Nivel general	no								dl
serie73	INDEC	XP PP	no								dl
serie74	INDEC	XP MOA	no								dl
serie75	INDEC	XP MOI	no								dl
serie76	INDEC	XP Combustibles y energia	no								dl
serie77	INDEC	MQ Nivel general	si	no	(3,1,1)(0,1,1)	Aditiva	3,49	4,36	Conc		nivel
serie78	INDEC	MQ bienes capital	no								dl
serie79	INDEC	MQ bienes intermedios	si	no	(3,1,1)(0,1,1)	Aditiva	2,34	3,11	Conc		dl
serie80	INDEC	MQ Combustibles y energia	si	no	(1,0,1)(0,1,1)	Multiplicativa	4,97	6,27	Conc		dl
serie81	INDEC	MQ Piezas y accesorios	si	no	(1,1,0)(0,1,1)	Multiplicativa	2,05	2,69	Conc		dl
serie82	INDEC	MQ bienes de consumo	si	no	(3,1,1)(0,1,1)	Aditiva	4,13	5,07	Conc		dl
serie83	INDEC	MQ vehiculos	no								dl
serie84	INDEC	MP Nivel general	si	no	(2,1,2)(0,1,1)	Multiplicativa	0,94	1,19	Conc		tend
serie85	INDEC	MP bienes de capital	no								dl
serie86	INDEC	MP bienes intermedios	no								dl
serie87	INDEC	MP Combustibles y energia	no								dl
serie88	INDEC	MP Piezas y accesorios	no								dl
serie89	INDEC	MP bienes de consumo	no								dl
serie90	INDEC	MP vehiculos	no								dl

Nro Serie	Fuente	Descripción Serie	Ajuste estacional	Efecto calendario significativo	Análisis de estacionalidad			Análisis de estacionariedad		
					Modelo	Descomposición	Factores concurrentes	Factores proyectados	Decisión Factores	Transformación necesaria para la estacionariedad de la serie
serie91	Ministerio de Agroindustria	Molienda soja	si	no	(1 0 0)(0 1 1)	Aditiva	113041.34	113076.53	Conc	tend
serie92	Secretaría de Hacienda	inversión real directa + transferencias de capital a provin	no	no						tend
serie93	Secretaría de Hacienda	inversión real directa	no	no						tend
serie94	Secretaría de Hacienda	transferencias de capital a provincias	no	no						tend
serie95	Tendencias	despidos (1986=100)	no	no						nivel
serie96	Tendencias	suspensiones (1986=100)	no	no						nivel
serie97	EL - Ministerio de Trabajo de la Nación	Expectativa neta de empleo	no	no						nivel
serie98	EL - Ministerio de Trabajo de la Nación	empresas que realizaron búsqueda de personal	si	no	(0 1 1)(0 1 1)	Multiplicativa	1.44	1.87	Conc	di
serie100	BCRA	ITCNM (base 17-12-15=100)	no	no						di
serie101	BCRA	Personales	si	no	(0 2 0)(0 1 1)	Multiplicativa	0.18	0.19	Conc	tend
serie102	BCRA	Tarjetas	si	no	(3 1 1)(0 1 1)	Multiplicativa	0.5	0.55	Conc	di
serie103	BCRA	Personales+ Tarjetas	si	no	(3 2 0)(0 1 1)	Multiplicativa	0.3	0.35	Conc	tend
serie104	GCBA	Patentamientos Autos CABA	si	no	(3 1 1)(0 1 1)	Multiplicativa	3.16	3.68	Conc	di
serie105	GCBA	Patentamientos Autos Argentina	si	no	(2 1 0)(0 1 1)	Multiplicativa	2.88	3.81	Conc	di
serie106	GCBA	Peajes (recaudación)	si	no	(0 1 1)(0 1 1)	Multiplicativa	0.67	1.01	Conc	di
serie107	GCBA	Peajes (ciclación vehículos)	si	no	(2 1 0)(0 1 1)	Aditiva	49954	65272	Conc	di
serie108	GCBA	Peajes (vehículos promedio)	si	no	(0 1 1)(0 1 1)	Multiplicativa	0.57	0.7	Conc	tend
serie109	GCBA	Impuesto de sellos-CABA	si	no	(0 1 1)(0 1 1)	Multiplicativa	2.11	2.81	Conc	di
serie110	Banco Central de BRASIL	Pasajeros transportados en ferrocarril (en miles)	si	no	(0 1 1)(0 1 1)	Multiplicativa	1.09	1.25	Conc	di
serie111	Banco Central de BRASIL	Producción industrial s. a.	no	no						di
serie112	Banco Central de BRASIL	Producción industrial s. o.	no	no						di
serie113	Banco Central de BRASIL	Indicador de actividad s. o.	no	no						di
serie114	Secretaría de energía	Indicador de actividad s. a.	no	no						di
serie115	Colegio de escribanos Ciudad de Buenos Aires	Asfalto (en toneladas)	si	no	(0 1 1)(0 1 1)	Multiplicativa	2.06	2.25	Conc	di
serie116	Colegio de escribanos Prov. de Buenos Aires	Escrituras CABA	no	no						di
		Escrituras BA								di

8.2. Anexo II. Coeficiente de Correlación

Serie	Fuente	Coeficiente de Correlación	t-Statistic
Producción Nacional	ADEFA	0.43	2.96
Ventas a conc. Veh. Nac.	ADEFA	0.34	2.24
Producción industrial s.a.	Banco Central de BRASIL	0.39	2.62
Indicador de actividad s.a.	Banco Central de BRASIL	0.32	2.09
M2* Amplio Privado Nominal	BCRA	0.39	2.59
Tarjetas	BCRA	0.38	2.52
Ferretería	CAME	0.49	3.50
Muebles de Oficina	CAME	0.49	3.46
Electrodomésticos	CAME	0.48	3.38
Materiales para la Construcción	CAME	0.31	2.03
Materiales Eléctricos	CAME	0.31	2.01
Lam. En caliente Total No Planos	CIS	0.38	2.57
Lam. Frío	CIS	0.33	2.15
Lam. En caliente Planos	CIS	0.32	2.11
Escrituras CABA	Colegio de escribanos Ciudad de Buenos Aires	0.36	2.40
Expectativa neta de empleo	EIL - Ministerio de Trabajo de la Nación	0.38	2.56
Empresas que realizaron búsqueda de personal	EIL - Ministerio de Trabajo de la Nación	0.31	2.03
IPI - automóviles	FIEL	0.49	3.43
IPI - bienes de capital	FIEL	0.40	2.68
IPI - bienes de consumo durables	FIEL	0.39	2.58
M Q Nivel general	INDEC	0.72	6.38
M Q bienes intermedios	INDEC	0.69	5.83
M Q Piezas y accesorios	INDEC	0.64	5.20
M Q bienes de consumo	INDEC	0.55	4.08
X P PP	INDEC	0.47	3.26
X P MOI	INDEC	0.43	2.98
X P Nivel general	INDEC	0.39	2.61
M Q vehiculos	INDEC	0.36	2.39
X Q MOI	INDEC	0.31	2.01
Ganancias (Total)	MECON	0.31	2.01
ICC-Condiciones Presentes	UTDT	0.51	3.63
ICC - Nivel General	UTDT	0.49	3.45
ICC-SP	UTDT	0.48	3.37
ICC - Nivel General-Capital Federal	UTDT	0.43	2.96
ICC-Expectativas	UTDT	0.31	1.98
ICC-DI	UTDT	0.30	1.93

8.3. Anexo III. Componentes Principales

Factores Grupo 1- Coeficiente: 0.30

Principal Components Analysis

Eigenvalues: (Sum = 36, Average = 1)

Number	Value	Difference	Proportion	Cumulative Value	Cumulative Proportion
1	12.58344	7.038933	0.3495	12.58344	0.3495
2	5.544504	1.981026	0.1540	18.12794	0.5036
3	3.563478	1.502268	0.0990	21.69142	0.6025
4	2.061211	0.142050	0.0573	23.75263	0.6598
5	1.919161	0.327167	0.0533	25.67179	0.7131
6	1.591993	0.396697	0.0442	27.26378	0.7573
7	1.195296	0.112127	0.0332	28.45908	0.7905
8	1.083169	0.165967	0.0301	29.54225	0.8206
9	0.917202	0.175073	0.0255	30.45945	0.8461
10	0.742129	0.044261	0.0206	31.20158	0.8667
11	0.697868	0.070236	0.0194	31.89945	0.8861
12	0.627632	0.081641	0.0174	32.52708	0.9035
13	0.545991	0.089553	0.0152	33.07307	0.9187
14	0.456438	0.035586	0.0127	33.52951	0.9314
15	0.420852	0.076300	0.0117	33.95036	0.9431
16	0.344552	0.097701	0.0096	34.29492	0.9526
17	0.246851	0.004752	0.0069	34.54177	0.9595
18	0.242100	0.028372	0.0067	34.78387	0.9662
19	0.213727	0.015482	0.0059	34.99759	0.9722
20	0.198245	0.026659	0.0055	35.19584	0.9777
21	0.171586	0.040810	0.0048	35.36743	0.9824
22	0.130776	0.031386	0.0036	35.49820	0.9861
23	0.099390	0.000309	0.0028	35.59759	0.9888
24	0.099081	0.023662	0.0028	35.69667	0.9916
25	0.075419	0.012910	0.0021	35.77209	0.9937
26	0.062509	0.007800	0.0017	35.83460	0.9954
27	0.054708	0.018713	0.0015	35.88931	0.9969
28	0.035995	0.012460	0.0010	35.92530	0.9979
29	0.023535	0.001565	0.0007	35.94884	0.9986
30	0.021970	0.010253	0.0006	35.97081	0.9992
31	0.011717	0.002761	0.0003	35.98253	0.9995
32	0.008956	0.003461	0.0002	35.99148	0.9998
33	0.005495	0.003825	0.0002	35.99698	0.9999
34	0.001670	0.000573	0.0000	35.99865	1.0000
35	0.001097	0.000841	0.0000	35.99974	1.0000
36	0.000256	---	0.0000	36.00000	1.0000

Factores Grupo 2- Coeficiente: 0.35

Principal Components Analysis

Eigenvalues: (Sum = 26, Average = 1)

Number	Value	Difference	Proportion	Cumulative Value	Cumulative Proportion
1	9.761444	5.855928	0.3754	9.761444	0.3754
2	3.905517	1.579478	0.1502	13.66696	0.5257
3	2.326038	0.433411	0.0895	15.99300	0.6151
4	1.892627	0.385041	0.0728	17.88563	0.6879
5	1.507586	0.247845	0.0580	19.39321	0.7459
6	1.259741	0.420292	0.0485	20.65295	0.7943
7	0.839449	0.137882	0.0323	21.49240	0.8266
8	0.701567	0.118276	0.0270	22.19397	0.8536
9	0.583292	0.066366	0.0224	22.77726	0.8760
10	0.516926	0.081708	0.0199	23.29419	0.8959
11	0.435218	0.010352	0.0167	23.72941	0.9127
12	0.424866	0.043545	0.0163	24.15427	0.9290
13	0.381321	0.092261	0.0147	24.53559	0.9437
14	0.289061	0.023469	0.0111	24.82466	0.9548
15	0.265592	0.061268	0.0102	25.09025	0.9650
16	0.204325	0.021848	0.0079	25.29457	0.9729
17	0.182476	0.036019	0.0070	25.47705	0.9799
18	0.146457	0.003560	0.0056	25.62351	0.9855
19	0.142897	0.050381	0.0055	25.76640	0.9910
20	0.092516	0.039249	0.0036	25.85892	0.9946
21	0.053267	0.013523	0.0020	25.91219	0.9966
22	0.039744	0.011645	0.0015	25.95193	0.9982
23	0.028099	0.016493	0.0011	25.98003	0.9992
24	0.011605	0.005245	0.0004	25.99163	0.9997
25	0.006361	0.004356	0.0002	25.99800	0.9999
26	0.002005	---	0.0001	26.00000	1.0000

Factores Grupo 3- Coeficiente: 0.40

Principal Components Analysis

Eigenvalues: (Sum = 19, Average = 1)

Number	Value	Difference	Proportion	Cumulative Value	Cumulative Proportion
1	7.807496	4.051372	0.4109	7.807496	0.4109
2	3.756123	1.983448	0.1977	11.56362	0.6086
3	1.772676	0.457612	0.0933	13.33629	0.7019
4	1.315064	0.265941	0.0692	14.65136	0.7711
5	1.049123	0.375372	0.0552	15.70048	0.8263
6	0.673751	0.130484	0.0355	16.37423	0.8618
7	0.543267	0.116622	0.0286	16.91750	0.8904
8	0.426645	0.045551	0.0225	17.34414	0.9128
9	0.381094	0.034525	0.0201	17.72524	0.9329
10	0.346568	0.084160	0.0182	18.07181	0.9511
11	0.262408	0.016564	0.0138	18.33421	0.9650
12	0.245844	0.075366	0.0129	18.58006	0.9779
13	0.170478	0.054172	0.0090	18.75054	0.9869
14	0.116306	0.051215	0.0061	18.86684	0.9930
15	0.065091	0.033324	0.0034	18.93193	0.9964
16	0.031767	0.009933	0.0017	18.96370	0.9981
17	0.021834	0.009876	0.0011	18.98553	0.9992
18	0.011958	0.009450	0.0006	18.99749	0.9999
19	0.002508	---	0.0001	19.00000	1.0000

8.4. Anexo IV. Estimaciones

Nowcast G1

Dependent Variable: INVERSION

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.005149	0.003855	1.335846	0.1910
INVERSION(-1)	0.138296	0.074182	1.864291	0.0715
PC1_1	0.012301	0.001274	9.657935	0.0000
DMAR08	0.065086	0.006029	10.79553	0.0000
DJUN11	-0.103707	0.007930	-13.07820	0.0000
R-squared	0.783084	Mean dependent var		0.006800
Adjusted R-squared	0.755970	S.D. dependent var		0.058749
S.E. of regression	0.029022	Akaike info criterion		-4.116471
Sum squared resid	0.026952	Schwarz criterion		-3.898780
Log likelihood	81.15472	Hannan-Quinn criter.		-4.039725
F-statistic	28.88071	Durbin-Watson stat		2.007653
Prob(F-statistic)	0.000000			

Nowcast G2

Dependent Variable: INVERSION

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.006614	0.003488	1.896055	0.0665
INVERSION(-1)	0.153518	0.076255	2.013226	0.0521
PC1_2	0.013373	0.001291	10.35517	0.0000
DJUN11	-0.099372	0.006938	-14.32308	0.0000
DMAR08	0.054529	0.005550	9.825579	0.0000
R-squared	0.779750	Mean dependent var		0.007716
Adjusted R-squared	0.753838	S.D. dependent var		0.057321
S.E. of regression	0.028440	Akaike info criterion		-4.162854
Sum squared resid	0.027500	Schwarz criterion		-3.949577
Log likelihood	86.17565	Hannan-Quinn criter.		-4.086332
F-statistic	30.09244	Durbin-Watson stat		2.089489
Prob(F-statistic)	0.000000			

Nowcast G3

Dependent Variable: INVERSION

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.012101	0.004252	2.846172	0.0076
INVERSION(-1)	0.123251	0.080626	1.528668	0.1359
PC1_3	0.014276	0.001548	9.223689	0.0000
DMAR09	-0.080891	0.027689	-2.921415	0.0062
DJUN11	-0.100521	0.025751	-3.903537	0.0004
DSEPT14	-0.065617	0.025298	-2.593824	0.0140
R-squared	0.835708	Mean dependent var		0.007716
Adjusted R-squared	0.810815	S.D. dependent var		0.057321
S.E. of regression	0.024932	Akaike info criterion		-4.404689
Sum squared resid	0.020513	Schwarz criterion		-4.148757
Log likelihood	91.89144	Hannan-Quinn criter.		-4.312863
F-statistic	33.57228	Durbin-Watson stat		2.085440
Prob(F-statistic)	0.000000			

AR

Dependent Variable: INVERSION

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.011753	0.007656	1.535261	0.1337
INVERSION(-1)	0.275602	0.122414	2.251385	0.0307
DDIC08	-0.119750	0.007728	-15.49642	0.0000
DMAR09	-0.143933	0.014898	-9.661175	0.0000
R-squared	0.437406	Mean dependent var		0.007716
Adjusted R-squared	0.389184	S.D. dependent var		0.057321
S.E. of regression	0.044799	Akaike info criterion		-3.276343
Sum squared resid	0.070244	Schwarz criterion		-3.105721
Log likelihood	67.88869	Hannan-Quinn criter.		-3.215125
F-statistic	9.070612	Durbin-Watson stat		1.830677
Prob(F-statistic)	0.000140			