

# Ensayos Económicos

---

**Uso de flujos de información de alta frecuencia para pronósticos de corto plazo de la actividad económica en Argentina**

Laura D'Amato, Lorena Garegnani, Emilio Blanco

**Marco fiscal ruso: pasado, presente y futuro. ¿Es necesario un cambio?**

Sergey Vlasov

**Sobre la "ciencia" de la política monetaria: apuntes metodológicos**

Horacio A. Aguirre

***Premio Raúl Prebisch 2010***

**Historia de la creación del Banco Central de la República Argentina**

Patricio Catriel Liddle, Juan José Pita

64

Octubre - Diciembre de 2011



*ie* | BCRA  
INVESTIGACIONES ECONÓMICAS

# Uso de flujos de información de alta frecuencia para pronósticos de corto plazo de la actividad económica en Argentina\*

**Laura D'Amato**

**Lorena Garegnani**

**Emilio Blanco**

Banco Central de la República Argentina

## Resumen

En este trabajo utilizamos un amplio conjunto de indicadores diarios y mensuales del ciclo económico para generar una predicción dentro del trimestre (*Nowcast*) del crecimiento del PIB real. Realizamos las predicciones en base a un *pooling* de pronósticos bivariados que utilizan esos indicadores como predictores (*Nowcast* con *pooling*). También lo hacemos a partir de la estimación de factores subyacentes a un subgrupo de esos indicadores (*Nowcast* con *factores*). Al comparar la capacidad predictiva del *Nowcast* con *pooling* y con factores con la de un modelo AR(1), sólo el *Nowcast* con *pooling* supera en desempeño al AR(1), lo que indica que el uso de la información publicada dentro del trimestre ayuda a mejorar la predicción del PIB. Por consiguiente, la metodología ofrece un enfoque alentador y valioso para brindar información oportuna para la toma de decisiones.

*Clasificación JEL:* C22, C53, E17.

*Palabras clave:* *pooling* de pronósticos, pronóstico usando un amplio conjunto de datos, *Nowcast*, modelos de factores.

---

\* Deseamos agradecer a Hildegart Ahumada y a Pablo Pincheira por sus valiosos comentarios y sugerencias. Agradecemos también a comentaristas y participantes de diversos seminarios donde se expusieron versiones previas del trabajo. Las opiniones expresadas en este trabajo corresponden a los autores y no necesariamente reflejan las opiniones del Banco Central de la República Argentina o de sus autoridades. Emails: ldamato@bcra.gov.ar, lgaregnani@bcra.gov.ar, emilio.blanco@bcra.gov.ar.

# Using the Flow of High Frequency Information for Short Term Forecasting of Economic Activity in Argentina

**Laura D'Amato**

**Lorena Garegnani**

**Emilio Blanco**

Central Bank of Argentina

## Summary

We exploit the richness of a large data set of daily and monthly business cycle indicators by pooling them to produce *Nowcast* of contemporaneous real GDP growth. We conduct predictions based on a pooling of bivariate forecasts which uses these indicators as predictors of GDP (*Nowcast* with pooling). We also conduct a *Nowcast* exercise with factors for a restricted subset of business cycle indicators. When comparing the predictive accuracy of *Nowcast* with pooling and with factors with that of an AR(1) model, only the *Nowcast* with pooling outperforms the AR(1), indicating that the use of information released within the quarter helps to improve GDP growth prediction. The methodology then offers an encouraging and valuable approach to provide timely information for policy decision making.

*JEL*: C22, C53, E17.

*Key words*: forecast pooling, forecast using a large dataset, nowcast, factor models.

## I. Introducción

Si bien la evaluación en tiempo real de las condiciones cíclicas de la economía y su pronóstico son clave para la conducción de la política monetaria, la principal fuente de información sobre la actividad económica proviene de las cuentas nacionales, cuya frecuencia es trimestral. Se dispone, sin embargo, de un gran número de indicadores del ciclo de frecuencia más alta a la trimestral, que potencialmente podrían aprovecharse para generar predicciones de la actividad económica dentro del trimestre en curso.

Los últimos avances en la literatura de pronóstico, focalizados en trabajar en un entorno rico en datos, podrían ser muy útiles para hacer predicciones con datos de alta frecuencia dentro del trimestre.<sup>1</sup> Esta literatura desarrolló dos estrategias para aprovechar la disponibilidad de un gran número de indicadores del ciclo económico con el fin de mejorar el pronóstico: los modelos de factores y la combinación o *pooling* de pronósticos (ver Stock y Watson, 2006). Ambas estrategias han mostrado buenos resultados en términos de capacidad predictiva.

El uso de datos de alta frecuencia para generar predicciones de datos de menor frecuencia se conoce en la literatura como *Nowcasting*. Se trata de un enfoque en tiempo real, que permite actualizar la predicción de una variable para el período en curso utilizando el flujo de información de más alta frecuencia a medida que se dispone de nuevos datos. En el caso de Argentina, contar con un pronóstico anticipado del PIB es especialmente importante si tenemos en cuenta que las cifras oficiales se publican 10 semanas después de finalizado el trimestre.

Utilizando un gran conjunto de indicadores diarios, semanales y mensuales del ciclo económico, construimos un *pooling* y realizamos un ejercicio de *Nowcast* para el PIB. Adicionalmente, realizamos un ejercicio de *Nowcast* con factores utilizando un subconjunto de indicadores seleccionados del ciclo económico. Estimamos los factores mediante la técnica de componentes principales tal como sugieren Stock y Watson (2002a). Estudiamos la mejora que genera la utilización de indicadores de alta frecuencia para el pronóstico del PIB trimestral. Evaluamos su desempeño secuencialmente a medida que la información se halla disponible dentro del trimestre. Comparamos el desempeño del *Nowcast* con un modelo AR(1), utilizado como *benchmark*.

---

<sup>1</sup> En este sentido, ver Timmerman (2006).

Finalmente, utilizamos el test de Clark y West (2007) para evaluar la significatividad estadística de las diferencias en capacidad predictiva fuera de la muestra del *Nowcast* con *pooling* y del *Nowcast* con factores respecto del modelo AR(1).

El trabajo está organizado del siguiente modo: en la Sección II, describimos brevemente los avances recientes en la literatura de pronóstico en un entorno rico en datos. La Sección III incluye una descripción del enfoque empírico adoptado y los resultados obtenidos. En la Sección IV, realizamos un ejercicio de pronóstico fuera de la muestra. Finalmente, la Sección V presenta las conclusiones.

## II. Pronóstico en un entorno rico en datos

En los últimos años la literatura de pronóstico ha avanzado en el desarrollo de técnicas que permiten utilizar el contenido informativo de grandes conjuntos de datos. Estas técnicas se pueden clasificar en dos grupos:

- (i) El *pooling* de pronósticos, que combina un número considerable de modelos utilizando diferentes criterios de ponderación.
- (ii) Los modelos de factores, que permiten encontrar medidas resumen de la variabilidad de un gran número de indicadores.

En el primer caso, la estrategia de estimación apunta a preservar los modelos causales y eventualmente lograr mejores pronósticos expandiendo el número de predictores. En el segundo, se considera un conjunto grande de indicadores y, mediante técnicas estadísticas multivariadas, se extrae un número reducido de factores subyacentes a esas series que explican una porción significativa de su variabilidad.

El *pooling* o combinación de pronósticos consiste en combinar dos o más pronósticos derivados de modelos que utilizan diferentes predictores. Esta técnica fue desarrollada originalmente por Bates y Granger (1969) y la idea básica es la siguiente:<sup>2</sup>

---

<sup>2</sup> Es posible encontrar una descripción detallada de las técnicas de *pooling* de pronósticos y los principales avances de esta literatura en Stock y Watson (2006), y también en Timmerman (2006).

Consideremos que  $\{Y_{i,t+h}^h, i=1, \dots, n\}$  es un panel de  $n$  pronósticos. El pronóstico combinado o *pool* de pronósticos estará dado por la combinación lineal:

$$Y_{t+h/t}^h = w_0 + \sum_{i=1}^n w_{it} Y_{i,t+h/t}^h$$

donde  $w_{it}$  es el ponderador del pronóstico  $i$  en el período  $t$ .

Bates y Granger (1969) muestran que los ponderadores óptimos (aquellos que minimizan el error cuadrático medio - RMSE por sus siglas en inglés) están dados por la proyección a la población de  $Y_{i,t+h/t}^h$  en una constante y los pronósticos individuales.

En la práctica, las ponderaciones óptimas no son viables porque las matrices de varianzas y covarianzas son desconocidas. Granger y Ramanathan (1984) proponen estimar los ponderadores utilizando mínimos cuadrados ordinarios (MCO) o mínimos cuadrados restringidos, si se impone  $w_0 = 0$  y  $\sum_{i=1}^n w_{it} = 1$ . Si  $n$  es grande, cabe esperar que las estimaciones sean malas sencillamente porque al estimar un número grande de parámetros, se agrega incertidumbre a la muestra. Adicionalmente, si  $n$  es proporcional al tamaño de la muestra, el estimador de MCO no es consistente y las combinaciones que lo utilizan no son asintóticamente óptimas. Por esta razón, la literatura se ha focalizado en proponer distintas estructuras de ponderación para la combinación de pronósticos. Entre los diversos criterios sugeridos, utilizamos en este trabajo los dos siguientes:

(i) *Ponderaciones basadas en el poder explicativo relativo dentro de la muestra* ( $R^2$ ): combina los pronósticos de acuerdo con el ajuste de cada modelo.<sup>3</sup>

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

donde  $j=1, \dots, n$  es el pronóstico generado por cada uno de los modelos considerados.

---

<sup>3</sup> Ver Kitchen y Monaco (2003).

(ii) *Ponderadores basados en el desempeño fuera de la muestra (RMSE)*: en este caso, el ponderador se basa en la inversa del RMSE del pronóstico individual.

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

Como se subraya en la literatura, el *pooling* de pronósticos presenta ventajas destacables:

(i) *Diversificación*: intuitivamente, cuando hay una función de pérdida cuadrática, aun cuando uno de los modelos supere a otro en términos de poder predictivo, una combinación lineal de ellos es siempre preferida.<sup>4</sup>

(ii) Tal como afirman Clements y Henry (2006), el *pooling* de pronósticos puede ser una solución frente a la presencia de quiebres estructurales (cambios en media y en tendencia determinística). En general, la velocidad a la cual los modelos se adaptan a los cambios estructurales suele diferir. En ese sentido, combinar modelos con diferente adaptabilidad a los cambios podría mejorar el pronóstico de un modelo individual.

(iii) La combinación de pronósticos puede ser una forma de generar pronósticos robustos a sesgos de especificación y errores de medición de las variables de los modelos individuales. Si dos pronósticos tienen sesgos en direcciones opuestas, una combinación de ambos podría mejorar el pronóstico.

Otra manera de aprovechar la riqueza de un gran conjunto de datos para pronóstico es estimando modelos con factores subyacentes a ellos, tal como proponen Giannone, Reichlin y Small (2005).

Los modelos de factores dinámicos se basan en la idea de que la covarianza entre un gran número de  $n$  series de tiempo con sus adelantos y rezagos puede representarse mediante un número reducido de factores  $q$  no observables, donde  $n > q$ . En este contexto, las perturbaciones de estos factores podrían representar *shocks* sobre la oferta o demanda agregada.

---

<sup>4</sup> Para una visión detallada de las ventajas de combinar pronósticos, véase Hendry y Clements (2002), Marcellino (2002) y Timmermann (2006).

La idea detrás de los modelos dinámicos de factores (*MDF*) es que la covarianza entre las series del ciclo en sus adelantos y rezagos puede ser descrita mediante unas pocas variables inobservables, a las que llamamos factores. Las innovaciones a esos factores reflejarían los *shocks* macroeconómicos de demanda y oferta que afectan a la economía. De ese modo, los *MDF* expresan el vector de las  $i$  variables del ciclo  $X_{it}$  como:

$$X_{it} = \lambda_i(L)'F_t + u_{it} \quad (1)$$

donde  $F_t$  es un vector  $q \times 1$  de factores inobservables,  $\lambda_i$  es un vector  $q \times 1$  de polinomios de rezagos denominados *factor loadings* y  $u_{it}$  son las perturbaciones idiosincrásicas, que podrían estar correlacionadas serialmente. Se supone que los factores y las perturbaciones idiosincrásicas no estarían correlacionados entre sí en todos sus rezagos y adelantos, es decir  $E(f_i u_{is}) = 0$  para todo  $i, s$ .

Esta medida de la variabilidad conjunta de las  $X_{it}$  (los factores que reflejan la incidencia de los *shocks* comunes a esas variables) puede ser utilizada para pronosticar agregados macroeconómicos del ciclo  $Y_t$ , como el PIB, de acuerdo a:

$$Y_{t+1} = \beta(L)'F_t + \varepsilon_{t+1} \quad (2)$$

Donde  $F_t = [f_t, f_{t-1}, \dots, f_{t-p+1}]$  es un vector de los factores y sus rezagos, y  $\beta$  es un vector de parámetros de los rezagos en los factores. Stock y Watson (2002a) muestran que si los polinomios de rezagos  $\lambda_i(L)$  y  $\beta(L)$  son de orden finito los factores  $f_t$  pueden ser estimados por el método de componentes principales.

### III. Resultados empíricos

#### III.1. Nowcast utilizando pooling

Producir *Nowcast* de una variable económica  $y_t$  implica actualizar su predicción contemporánea a medida que están disponibles nuevos flujos de información. En un entorno rico en datos, es posible utilizar una amplia variedad de indicadores  $x_t$  para generar predicciones contemporáneas de  $y_t$  aprovechando el contenido informativo de datos de una frecuencia más alta.

En el caso de un *pooling* o combinación de pronósticos se puede usar una ecuación puente (*bridge equation*) que relacione las variables de más alta frecuencia disponibles contemporáneamente con la variable de más baja frecuencia que se quiere predecir. Estos pronósticos individuales se combinan utilizando diferentes criterios de ponderación para obtener así una predicción de  $y_t$ .

El ejercicio realizado consiste en: (i) seleccionar los datos disponibles más recientes por indicador, (ii) estimar la ecuación bivariada sobre la base de los datos disponibles más recientes por indicador, (iii) producir un pronóstico por indicador y (iv) combinar los pronósticos individuales de acuerdo con su poder explicativo. Uno de los beneficios de este enfoque es que las regresiones no utilizan pronósticos de las variables independientes.

Para producir el *Nowcast*, estimamos modelos bivariados autorregresivos de rezagos distribuidos como:

$$y_t = \alpha_0 + \sum_{i=1}^4 \alpha_i y_{t-i} + \sum_{i=0}^4 \beta_i x_{jt-i} + \varepsilon_t$$

donde  $y_t$  es el crecimiento del PIB real y  $x_j$  corresponde al indicador  $j$  convertido a la frecuencia del PIB (trimestral).

Los modelos fueron especificados de modo de obtener residuos ruido blanco, homoscedásticos y normales. Aunque simples, los modelos ajustan muy bien a los datos.<sup>5</sup> Ésta es una propiedad promisoría a los fines de pronóstico.

Dada la diversidad en los rezagos de publicación de los diferentes indicadores, las series se agrupan en tres categorías. Una vez convertidas a frecuencia trimestral se actualiza la predicción secuencialmente obteniendo así sucesivos *Nowcast* dentro del trimestre.

Los datos abarcan un conjunto amplio de 55 indicadores económicos que incluyen desde indicadores financieros hasta datos de recaudación impositiva, encuestas cualitativas de actividad industrial, datos desagregados sobre la producción industrial, uso de la energía y ventas de automóviles.<sup>6</sup> La muestra utilizada para estimar

---

<sup>5</sup> Ver la Tabla A.2 en el Anexo para más detalles sobre los modelos.

<sup>6</sup> Ver la Tabla A.1 en el Anexo para más detalles.

los modelos comprende el período 1993:1 a 2004:1. Realizamos el ejercicio de *Nowcast* y el pronóstico fuera de la muestra para el período 2004:2 a 2007:4.

Las series fueron transformadas en logaritmos, desestacionalizadas y se eliminó su tendencia cuando resultó necesario.

El Instituto Nacional de Estadísticas y Censos (INDEC) publica las cifras oficiales del PIB trimestral 10 semanas después de terminado el trimestre respectivo. La Tabla 1 describe el esquema de actualización secuencial de los indicadores mensuales utilizados para la predicción y del PIB trimestral. Tal como se observa en la tabla, 6 semanas después del comienzo del trimestre es posible producir el primer *Nowcast* del PIB trimestral. El *Nowcast* se actualiza con la información entrante cada 15 días.

### **III.2. Resultados**

En la Tabla 2 presentamos las sucesivas actualizaciones del pronóstico del crecimiento del PIB y su valor observado. También reportamos la capacidad predictiva del *Nowcast* medido por el valor absoluto de la diferencia entre los valores observados y los estimados. Se aprecia que el *Nowcast* tiene un muy buen desempeño, aunque éste no necesariamente mejora a medida que se agrega información. De hecho, la predicción del primer mes supera, en algunos casos, a la que utiliza el conjunto completo de información para el trimestre en curso. El conjunto de variables disponibles al final del primer mes, que se utiliza para producir este pronóstico, incluye indicadores monetarios y financieros tales como tasas de interés, precios de las acciones, agregados monetarios, además de ingresos fiscales, ventas de automóviles, producción de acero y cemento Portland y demanda de energía, entre otros.

Comparamos la capacidad predictiva del *Nowcast* con la de un modelo AR(1) tomado como *benchmark*. La comparación se realiza considerando la estimación de tres meses del *Nowcast* (que incluye el conjunto completo de información) con el pronóstico trimestral a un paso del AR(1).

Los resultados, que se muestran en la Tabla 3, indican que el *Nowcast* supera al modelo AR(1) en 13 de los 15 trimestres considerados. El resultado es sorprendente, dada la excelente capacidad predictiva que muestran los modelos AR(1) para pronósticos a corto plazo, tal como se resalta en la literatura de pronóstico.

**Tabla 1 / Esquema de actualización secuencial de los indicadores mensuales y el PIB**

Fecha	15/2/07	28/2/07	15/3/07	31/3/07	15/4/07	30/4/07	15/5/07	31/5/07	15/6/07
Datos Disponibles	Grupo 1 (ene obs) Grupo 2 (dic obs) Grupo 3 (dic obs)	Grupo 1 (ene obs) Grupo 2 (ene obs) Grupo 3 (dic obs)	Grupo 1 (feb obs) Grupo 2 (ene obs) Grupo 3 (ene obs)	Grupo 1 (feb obs) Grupo 2 (feb obs) Grupo 3 (ene obs)	Grupo 1 (mar obs) Grupo 2 (feb obs) Grupo 3 (feb obs)	Grupo 1 (mar obs) Grupo 2 (mar obs) Grupo 3 (feb obs)	Grupo 1 (abr obs) Grupo 2 (mar obs) Grupo 3 (mar obs)	Grupo 1 (abr obs) Grupo 2 (abr obs) Grupo 3 (abr obs)	Grupo 1 (may obs) Grupo 2 (abr obs) Grupo 3 (abr obs)
Nowcast	I 2007	I 2007 II 2007	II 2007	II 2007					
Comunicados Oficiales									<b>Comunicado Oficial 1er. Trim.</b>

**Tabla 2 / Desempeño del Nowcast**

Actualización secuencial de las predicciones del crecimiento del PIB							
Fecha	Observado	A 15 días	A 1 mes	A 45 días	A 2 meses	A 75 días	A 105 días
2004:2	0,01092	0,01452	0,01458	0,01717	0,01711	0,01802	0,01698
2004:3	0,02306	0,01092	0,00924	0,00938	0,01025	0,01044	0,01150
2004:4	0,02668	0,02638	0,02649	0,02311	0,02314	0,02411	0,02362
2005:1	0,02240	0,01457	0,01818	0,01600	0,01538	0,01683	0,01871
2005:2	0,02375	0,01506	0,01650	0,01439	0,01418	0,01478	0,01588
2005:3	0,01914	0,01960	0,02174	0,02051	0,01922	0,01781	0,01893
2005:4	0,01906	0,01649	0,01931	0,01766	0,01752	0,01605	0,01544
2006:1	0,02146	0,00991	0,01264	0,01435	0,01411	0,01782	0,01759
2006:2	0,01952	0,01934	0,01934	0,01988	0,02005	0,02006	0,01882
2006:3	0,02372	0,02048	0,01794	0,01706	0,01757	0,01664	0,01661
2006:4	0,01741	0,02385	0,02036	0,01934	0,02005	0,01869	0,01870
2007:1	0,01716	0,01770	0,01685	0,01287	0,01396	0,01341	0,01778
2007:2	0,02322	0,01807	0,02080	0,01660	0,01643	0,01782	0,01714
2007:3	0,01927	0,02222	0,01897	0,01632	0,01756	0,02112	0,01929
2007:4	0,02379	0,02301	0,02296	0,02369	0,02387	0,02127	0,02023

**Tabla 2 / Desempeño del Nowcast (continuación)**

Fecha	Observado	Actualización secuencial: evolución del desempeño predictivo							
		A 15 días	A 1 mes	A 45 días	A 2 meses	A 75 días	A 3 meses	A 105 días	
2004:2	0,01092	0,00361	0,00366	0,00625	0,00619	0,00711	0,00728	0,00607	
2004:3	0,02306	0,01214	0,01381	0,01367	0,01281	0,01262	0,01173	0,01156	
2004:4	0,02668	0,00031	0,00019	0,00358	0,00355	0,00258	0,00257	0,00307	
2005:1	0,02240	0,00783	0,00422	0,00640	0,00702	0,00558	0,00524	0,00370	
2005:2	0,02375	0,00869	0,00726	0,00937	0,00958	0,00897	0,00908	0,00788	
2005:3	0,01914	0,00046	0,00260	0,00137	0,00008	0,00133	0,00029	0,00021	
2005:4	0,01906	0,00256	0,00025	0,00140	0,00153	0,00301	0,00329	0,00362	
2006:1	0,02146	0,01154	0,00881	0,00711	0,00735	0,00363	0,00292	0,00386	
2006:2	0,01952	0,00018	0,00018	0,00037	0,00053	0,00054	0,00034	0,00069	
2006:3	0,02372	0,00323	0,00577	0,00665	0,00615	0,00708	0,00688	0,00710	
2006:4	0,01741	0,00644	0,00295	0,00193	0,00264	0,00128	0,00129	0,00129	
2007:1	0,01716	0,00054	0,00031	0,00429	0,00320	0,00375	0,00062	0,00062	
2007:2	0,02322	0,00515	0,00242	0,00661	0,00679	0,00539	0,00542	0,00607	
2007:3	0,01927	0,00294	0,00030	0,00295	0,00171	0,00185	0,00173	0,00002	
2007:4	0,02379	0,00079	0,00084	0,00011	0,00008	0,00253	0,00250	0,00357	

**Tabla 3 / Comparación *Nowcast-benchmark***

Fecha	Observado	Pronóstico		Performance Predictiva Relativa	
		AR (1)	<i>Nowcast</i>	Obs. vs. AR	Obs. vs. <i>Nowcast</i>
2004:2	0,01092	0,01899	0,01698	-0,00807	<b>-0,00607</b>
2004:3	0,02306	0,00834	0,01150	0,01472	<b>0,01156</b>
2004:4	0,02668	0,01698	0,02362	0,00971	<b>0,00307</b>
2005:1	0,02240	0,01984	0,01871	<b>0,00256</b>	0,00370
2005:2	0,02375	0,01699	0,01588	<b>0,00676</b>	0,00788
2005:3	0,01914	0,01816	0,01893	0,00098	<b>0,00021</b>
2005:4	0,01906	0,01497	0,01544	0,00409	<b>0,00362</b>
2006:1	0,02146	0,01502	0,01759	0,00643	<b>0,00386</b>
2006:2	0,01952	0,01689	0,01882	0,00263	<b>0,00069</b>
2006:3	0,02372	0,01559	0,01661	0,00812	<b>0,00710</b>
2006:4	0,01741	0,01879	0,01870	-0,00138	<b>-0,00129</b>
2007:1	0,01716	0,01427	0,01778	0,00289	<b>-0,00062</b>
2007:2	0,02322	0,01356	0,01714	0,00966	<b>0,00607</b>
2007:3	0,01927	0,01894	0,01929	0,00033	<b>-0,00002</b>
2007:4	0,02379	0,01786	0,02023	0,00593	<b>0,00357</b>

En la subsección siguiente verificaremos si las diferencias en capacidad predictiva son estadísticamente significativas.

### **III.3. Evaluación de la capacidad predictiva del *Nowcast***

Tomando en cuenta que el *Nowcast con pooling* incluye o anida al modelo AR(1), evaluamos la significatividad estadística de las diferencias en capacidad predictiva entre ambos modelos utilizando el test de Clark y West (2007) para modelos anidados. Bajo la hipótesis nula, el modelo autorregresivo es el proceso generador de datos (PGD). Por lo tanto, se supone que el modelo más amplio introducirá ruido porque su pronóstico requiere la estimación de parámetros poblacionales que se supone son cero bajo la hipótesis nula. El test propuesto por Clark y West evalúa la capacidad predictiva del modelo parsimonioso (en nuestro caso, el AR(1)) con la del modelo más amplio que lo anida (el *Nowcast*), controlando por el ruido que este último introduce.

La hipótesis nula es que el modelo 1 (AR(1)) tiene la misma capacidad predictiva que el modelo 2 (*Nowcast*). La hipótesis alternativa es que el modelo 2 tiene mejor capacidad predictiva que el modelo 1 (test a una sola cola).

El test compara el RMSE del modelo 1 con el del modelo 2 ajustado por la diferencia de los pronósticos de los dos modelos elevada al cuadrado.

$$\hat{f}_{t+1} = (y_{t+1} - \hat{y}_{1t,t+1})^2 - \left[ (y_{t+1} - \hat{y}_{2t,t+1})^2 - (\hat{y}_{1t,t+1} - \hat{y}_{2t,t+1})^2 \right]$$

En la práctica, el test consiste en correr una regresión de  $f_{t+1}$  en una constante y evaluar su significatividad utilizando el estadístico  $t$  para la hipótesis nula de un coeficiente 0. Rechazar la hipótesis nula implica que el RMSE del modelo parsimonioso es significativamente mayor que el del modelo más amplio.

La evidencia indica que se podría rechazar la hipótesis nula de igual capacidad predictiva. El estadístico  $t$  es 5,985 con un valor  $p$  de 0,000, rechazándose la hipótesis nula a un nivel del 1%, lo que indica que el *Nowcast* supera al *benchmark* en desempeño.

#### **III.4. Nowcast utilizando pooling vs. factores**

También realizamos un ejercicio de *Nowcast* utilizando tanto el *pooling* como el modelo de factores y comparamos su desempeño predictivo con el del AR(1).

Los factores fueron obtenidos a partir de un subconjunto de 17 series del conjunto total de indicadores del ciclo utilizado para construir el *pooling*. La razón para restringir el número de series es que los factores estimados con el conjunto completo de indicadores explican una pequeña porción de la varianza del conjunto multivariado de indicadores del ciclo económico. Como sugieren Boivin y Ng (2006), este resultado puede deberse al hecho de que los errores idiosincrásicos de la ecuación (1) pueden estar correlacionados o a que un subconjunto de las series de tiempo consideradas sea “ruidoso”. En este caso, Boivin y Ng muestran que podría ser mejor restringir el conjunto de datos para estimar los factores.

Estimamos los factores utilizando el método de componentes principales, de acuerdo a lo sugerido por Stock y Watson (2002a).

Para producir el *Nowcast* con los factores y obtener factores trimestrales  $f_t^Q$ , definimos al PIB trimestral como el promedio de las observaciones mensuales latentes  $y_t^Q = (y_t + y_{t-1} + y_{t-2})/3$  utilizando la siguiente ecuación puente:

$$\hat{y}_t^Q = \beta(L)' f_t^Q$$

Pronosticando los valores faltantes mediante el uso de modelos autorregresivos univariados resolvemos el problema de contar con un panel desequilibrado de indicadores mensuales.

Las 17 series utilizadas para construir los factores fueron seleccionadas de acuerdo con criterios simples de  $R^2$ . De las 55 series disponibles, mantuvimos aquellas con un  $R^2$  superior a 0,75 en una regresión de MCO para el período 1993-2007.<sup>7</sup> En la Tabla 4 se muestran los resultados de este ejercicio. Como se observa, el *Nowcast* con factores tiene un buen desempeño y, una vez más, no resulta claro que agregar información mejore la capacidad predictiva.

Adicionalmente hicimos un ejercicio de *Nowcast* con *pooling* en base a las 17 series seleccionadas para construir los factores.

En la Tabla 5 se comparan la capacidad predictiva del *Nowcast* con *pooling* para las 55 series, del conjunto restringido de 17 series y del *Nowcast* con factores con la del AR(1). En la mayor parte de los casos, el *Nowcast* supera al autorregresivo.

También evaluamos la significatividad estadística de las diferencias en capacidad predictiva de los *Nowcast* respecto del AR(1) utilizando el test de Clark y West. Los resultados muestran que la hipótesis nula de igual capacidad predictiva no puede rechazarse al 1%. El  $t$  estadístico es 1,033 con un valor  $p$  de 0,3042, lo que indica que el *Nowcast* con factores no supera al *benchmark*, a diferencia de lo que hallamos para el *Nowcast* con *pooling*. En el caso del *Nowcast* con *pooling* reducido, el estadístico  $t$  es 4,812, con un valor  $p$  de 0,0000, siendo este modelo superior al AR(1).

Los resultados indican que el uso de indicadores de alta frecuencia es valioso para generar predicciones del PIB.

---

<sup>7</sup> Ver el Anexo para una descripción de las series de tiempo incluidas en el subconjunto.

**Tabla 4 / Desempeño del Nowcast con factores**

Actualización secuencial de las predicciones del crecimiento del PIB con factores							
Fecha	Observado	A 15 días	A 1 mes	A 45 días	A 2 meses	A 75 días	A 3 meses
2004:2	0,01092	0,01318	0,01119	0,03634	0,03851	0,03635	0,03639
2004:3	0,02306	0,01338	0,01250	0,02329	0,02363	0,02337	0,02364
2004:4	0,02668	0,02381	0,02364	0,02501	0,02534	0,02270	0,02263
2005:1	0,02240	0,00960	0,01041	0,00434	0,00418	0,01511	0,01486
2005:2	0,02375	0,01147	0,01099	-0,00779	-0,00796	-0,00034	-0,00033
2005:3	0,01914	0,00795	0,00809	0,03054	0,03052	0,02338	0,02336
2005:4	0,01906	0,02378	0,02384	0,03657	0,03642	0,02184	0,02192
2006:1	0,02146	0,00041	0,00037	-0,05577	-0,05639	0,03403	0,03378
2006:2	0,01952	0,01337	0,01348	0,03561	0,03566	0,03398	0,03377
2006:3	0,02372	0,02975	0,03035	0,02912	0,02910	0,02254	0,02242
2006:4	0,01741	0,02841	0,02854	0,03619	0,03629	0,03239	0,03243
2007:1	0,01716	0,02784	0,00816	-0,01819	-0,01742	-0,01992	0,02929
2007:2	0,02322	0,01209	0,01254	0,00751	0,00751	0,02347	0,02337
2007:3	0,01927	0,01452	0,01446	-0,01234	-0,01308	0,03381	0,03360
2007:4	0,02379	0,01304	0,02089	0,07484	0,07447	0,03758	0,03768

**Tabla 4 / Desempeño del Nowcast con factores (continuación)**

Actualización secuencial: evolución del desempeño predictivo						
Fecha	Observado	A 15 días	A 1 mes	A 45 días	A 2 meses	A 3 meses
2004:2	0,01092	0,00226	0,00028	0,02543	0,02759	0,02544
2004:3	0,02306	0,00968	0,01056	0,00023	0,00058	0,00058
2004:4	0,02668	0,00288	0,00304	0,00168	0,00135	0,00398
2005:1	0,02240	0,01281	0,01200	0,01806	0,01822	0,00729
2005:2	0,02375	0,01229	0,01276	0,03154	0,03171	0,02409
2005:3	0,01914	0,01119	0,01105	0,01140	0,01138	0,00424
2005:4	0,01906	0,00472	0,00478	0,01752	0,01736	0,00278
2006:1	0,02146	0,02104	0,02109	0,07722	0,07784	0,01257
2006:2	0,01952	0,00615	0,00604	0,01610	0,01614	0,01446
2006:3	0,02372	0,00604	0,00663	0,00541	0,00538	0,00117
2006:4	0,01741	0,01100	0,01113	0,01878	0,01888	0,01498
2007:1	0,01716	0,01068	0,00900	0,03535	0,03458	0,03708
2007:2	0,02322	0,01113	0,01068	0,01570	0,01570	0,00025
2007:3	0,01927	0,00475	0,00481	0,03161	0,03235	0,01454
2007:4	0,02379	0,01075	0,00291	0,05105	0,05068	0,01378

Tabla 5 / Comparación Nowcast con pooling / factores-benchmark

Fecha	Observado	Pronóstico			Performance Predictiva Relativa				
		AR (1)	Nowcast con Pooling con Factores	Nowcast con Pooling 17 series	Obs. vs. AR	Obs. vs. Nowcast con Pooling	Obs. vs. Nowcast con Factores	Obs. vs. Nowcast con Pooling 17 series	
2004:2	0,01092	0,01899	0,01698	0,03639	0,02057	-0,00807	<b>-0,00607</b>	-0,02548	-0,00965
2004:3	0,02306	0,00834	0,01150	0,02364	0,01219	0,01472	0,01156	-0,00058	0,01087
2004:4	0,02668	0,01698	0,02362	0,02263	0,02670	0,00971	0,00307	0,00405	<b>-0,00002</b>
2005:1	0,02240	0,01984	0,01871	0,01486	0,01883	<b>0,00256</b>	0,00370	0,00754	0,00357
2005:2	0,02375	0,01699	0,01588	-0,00033	0,01273	<b>0,00676</b>	0,00788	0,02408	0,01102
2005:3	0,01914	0,01816	0,01893	0,02336	0,01895	0,00098	0,00021	-0,00422	<b>0,00019</b>
2005:4	0,01906	0,01497	0,01544	0,02192	0,01570	0,00409	0,00362	-0,00286	0,00336
2006:1	0,02146	0,01502	0,01759	0,03378	0,02344	0,00643	0,00386	-0,01233	<b>-0,00198</b>
2006:2	0,01952	0,01689	0,01882	0,03377	0,02161	0,00263	<b>0,00069</b>	-0,01425	-0,00209
2006:3	0,02372	0,01559	0,01661	0,02242	0,01672	0,00812	0,00710	0,00130	0,00700
2006:4	0,01741	0,01879	0,01870	0,03243	0,02066	-0,00138	<b>-0,00129</b>	-0,01502	-0,00325
2007:1	0,01716	0,01427	0,01778	0,02929	0,01811	0,00289	<b>-0,00062</b>	-0,01213	-0,00095
2007:2	0,02322	0,01356	0,01714	0,02337	0,01629	0,00966	0,00607	<b>-0,00016</b>	0,00693
2007:3	0,01927	0,01894	0,01929	0,03360	0,02317	0,00033	<b>-0,00002</b>	-0,01433	-0,00390
2007:4	0,02379	0,01786	0,02023	0,03768	0,02660	0,00593	0,00357	-0,01388	<b>-0,00281</b>

#### IV. Pronóstico del crecimiento del PIB fuera de la muestra

También evaluamos el desempeño de los diferentes modelos descriptos en las secciones anteriores para el pronóstico fuera de la muestra y comparamos su capacidad con la del *benchmark*. Consideramos horizontes de pronóstico de 3, 6, 12 y 18 meses para el período 2004-2007.

En la Tabla 6, mostramos el desempeño de todos los modelos para los diferentes horizontes en términos de su RMSE. La combinación basada en el número reducido de series tiene, sin duda, la mejor capacidad predictiva para todos los horizontes.

**Tabla 6 / Desempeño predictivo del pronóstico fuera de la muestra (RMSE)**

Horizonte	AR(1)	Pooling	Pooling 17 series	Factores
3 meses adelante	0,00604	0,00004	<b>0,00000</b>	0,00008
6 meses adelante	0,00560	0,00006	<b>0,00001</b>	0,00006
1 año adelante	0,00593	0,00006	<b>0,00001</b>	0,00004
18 meses adelante	0,00573	0,00005	<b>0,00002</b>	0,00002

#### V. Conclusiones

Si bien la evaluación en tiempo real de la actividad económica es crucial para la toma de decisiones en materia de política monetaria, las cifras del PIB se publican trimestralmente y con un rezago de 10 semanas. Sin embargo, es posible aprovechar la disponibilidad de un gran número de indicadores del ciclo de frecuencia más alta a la trimestral para generar predicciones de la actividad económica dentro del trimestre en curso.

Utilizando un gran conjunto de indicadores mensuales del ciclo económico realizamos un ejercicio de *Nowcast* para el PIB de Argentina. Utilizamos dos metodologías para aprovechar el contenido informativo de esos indicadores: (i) combinarlos en un *pooling* de pronósticos (*Nowcast* con *pooling*) y (ii) extraer los factores subyacentes a ellos, que explican una alta porción de su variabilidad conjunta (*Nowcast* con factores).

Evaluamos el contenido informativo de estos indicadores en términos de las mejoras que generan en la capacidad predictiva cuando se los agrega de modo secuencial al conjunto de información utilizado para estimar el crecimiento del PIB.

Para evaluar el desempeño predictivo del *Nowcast* con *pooling* consideramos como *benchmark* un modelo AR(1). Los resultados indican que el *Nowcast* con *pooling* tiene un mejor desempeño en 13 de los 15 trimestres considerados.

Al evaluar la significatividad estadística de las diferencias en capacidad predictiva entre ambos modelos, el test de Clark y West confirma que el *Nowcast* con *pooling* tiene mejor capacidad predictiva que el AR(1).

También evaluamos el desempeño predictivo del *Nowcast* con factores para un subconjunto de los indicadores del ciclo. En este caso, no encontramos diferencias significativas en relación al *benchmark*. Por el contrario, el *Nowcast* con *pooling* incluyendo el mismo subconjunto restringido de indicadores supera en desempeño al modelo AR(1).

Un ejercicio de pronóstico fuera de la muestra utilizando estos modelos, indica que el *pooling* basado en un número reducido de series tiene, sin duda, la mejor capacidad predictiva.

Los resultados son promisorios si tenemos en cuenta que, de acuerdo a la literatura, el modelo AR(1) ha mostrado empíricamente ser el de mejor desempeño para pronósticos a corto plazo.

La metodología de *Nowcast* tiene una aplicación amplia a distintas variables macroeconómicas. También permite contar con información en tiempo para la toma de decisiones de política.

## Referencias

**Angelini, E., G. Camba-Méndez, D. Gianonni, G. Rünstler, y L. Reichlin (2008).** “Short-term forecast of Euro Area GDP”, European Central Bank Working Paper N° 949.

**Bates, J. M. y C. W. I. Granger (1969).** “The combination of forecasts”, *Operations Research Quarterly* 20, pp. 451-468.

**Boivin, J. y S. Ng (2006).** “Are more data always better for factor analysis?”, *Journal of Econometrics*, Elsevier, Vol. 132(1), pp. 169-194, mayo.

**Clark, T. y K. West, (2007),** “Approximately normal tests for equal predictive accuracy in nested models, *Journal of Econometrics*, Vol. 138, N° 1, pp. 291-311.

**Clements, M. y D. Hendry (2006).** “Forecasting with breaks”, en *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann (eds.), Chapter 12, Vol. 1, North-Holland.

**Croushore, D. (2006).** “Forecasting with real-time macroeconomic data”, en *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann (eds.), Chapter 17, Vol. 1, North-Holland.

**D’Amato, L., L. Garegnani, y E. Blanco (2008).** “Forecasting Initiation in Argentina: Individual Models or Forecast Pooling?”, Documento de Trabajo del BCRA N° 35.

**Diebold, F. X. y R. S. Mariano (1995).** “Comparing Predictive Accuracy”, *Journal of Business & Economic Statistics*, N° 13, pp. 253-263.

**Drechsel, K. y L. Maurin (2008).** “Flow of Conjectural Information and Forecast of Euro Area Economic Activity”, European Central Bank Working Paper N° 925.

**Granger y Ramanathan (1984).** “Improved methods of forecasting”, *Journal of Forecasting*, 3, pp. 197-204.

**Hendry, D. F. y M. P. Clements (2002).** “Pooling of forecasts”, *Econometrics Journal*, 5, pp. 1-26.

**Kitchen, J. y R. Monaco (2003).** “Real-Time Forecasting in Practice”, *Business Economics*, Department of the US Treasury, octubre.

**Marcellino, M. (2002).** “Forecasting pooling for short time series of macroeconomic variables”, *Oxford Bulletin of Economics and Statistics*, N° 66, pp. 91-112.

**Rünstler, G. y F. Sédillot (2003).** “Short-term estimates of Euro Area real GDP by means of monthly data”, European Central Bank Working Paper N° 276.

**Stock, J. y M. Watson (2002a),** “Macroeconomic Forecasting using diffusion indexes”, *Journal of Business and Economic Statistics*, 20, pp. 147-162.

**Stock, J. y M. Watson (2006).** “Forecasting with many predictors”, en *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann (eds.), Chapter 10, Vol. 1, North-Holland.

**Timmermann, A. (2006).** “Forecast Combination”, en *Handbook of Economic Forecasting*, Elliot, G., C. Granger y A. Timmermann (eds.), Vol. 1, North-Holland.

**Watson, M. (2001).** “Macroeconomic Forecasting Using Many Predictors”, en *Advances in Economics and Econometrics, Theory and Applications*, M. Dewatripont, L. Hansen y S. Turnovsky (eds.), Eight World Congress of the Econometric Society, Vol. III, pp. 87-115.

## Anexo A

Las series utilizadas fueron ajustadas estacionalmente (cuando resultó necesario) utilizando el programa X-12 ARIMA y luego estandarizadas, ya sea diferenciándolas (dif) o sustrayendo una tendencia lineal (tend). La Tabla A.1 muestra la totalidad de las series.

**Tabla A.1 / Conjunto de datos**

<b>Serie No.</b>		<b>Frecuencia</b>	<b>Estacionaria</b>
<b>Grupo 1: 15 días de retraso</b>			
1	Producción Nacional de Vehículos	mensual	dif
2	Exportación de Vehículos	mensual	dif
3	Ventas a Concesionarios	mensual	dif
4	Ventas a Concesionarios de Vehículos Nacionales	mensual	dif
5	Despachos provisorios de Cemento	mensual	dif
11	Recaudación Tributaria por Impuesto a las Ganancias	mensual	tend
12	Recaudación Tributaria por Impuesto a las Ganancias DGI	mensual	tend
13	Recaudación Tributaria por Impuesto a las Ganancias DGA	mensual	dif
14	Recaudación Tributaria por Impuesto al Valor Agregado bruto	mensual	tend
15	Recaudación Tributaria por Impuesto al Valor Agregado bruto DGI	mensual	dif
16	Índice MERVAL promedio	diaria	dif
17	Índice MERVAL último día	mensual	dif
54	M2 privado*	diaria	tend
55	Tasa de interés depósitos a plazo 30-59 días*	diaria	dif
<b>Grupo 2: 1 mes de retraso</b>			
6	Hierro Primario	mensual	dif
7	Acero Crudo	mensual	dif
8	Laminados en Frío	mensual	dif
9	Laminados en Caliente - No Planos	mensual	dif
10	Laminados en Caliente - Planos	mensual	dif
18	Energía Demandada	mensual	dif
<b>Grupo 3: 2 meses de retraso</b>			
19	Encuesta Industrial - nivel de stocks industria manufacturera	mensual	dif
20	Encuesta Industrial - nivel de stocks bienes de consumo no durables	mensual	dif
21	Encuesta Industrial - nivel de stocks bienes de consumo durables	mensual	dif

**Tabla A.1 / Conjunto de datos (continuación)**

<b>Serie No.</b>		<b>Frecuencia</b>	<b>Estacionaria</b>
<b>Grupo 3: 2 meses de retraso</b>			
22	Encuesta Industrial - nivel de stocks bienes de capital	mensual	dif
23	Encuesta Industrial - nivel de stocks bienes de uso intermedio	mensual	dif
24	Encuesta Industrial - perspectiva próximos meses industria manufacturera	mensual	dif
25	Encuesta Industrial - perspectiva próximos meses bienes de consumo no durables	mensual	dif
26	Encuesta Industrial - perspectiva próximos meses bienes de consumo durables	mensual	dif
27	Encuesta Industrial - perspectiva próximos meses bienes de capital	mensual	dif
28	Encuesta Industrial - perspectiva próximos meses bienes de uso intermedio	mensual	dif
29	Encuesta Industrial - situación general industria manufacturera	mensual	dif
30	Encuesta Industrial - situación general bienes de consumo no durables	mensual	dif
31	Encuesta Industrial - situación general bienes de consumo durables	mensual	dif
32	Encuesta Industrial - situación general bienes de capital	mensual	dif
33	Encuesta Industrial - situación general bienes de uso intermedio	mensual	dif
34	Encuesta Industrial - tendencia de demanda industria manufacturera	mensual	dif
35	Encuesta Industrial - tendencia de demanda bienes de consumo no durables	mensual	dif
36	Encuesta Industrial - tendencia de demanda bienes de consumo durables	mensual	dif
37	Encuesta Industrial - tendencia de demanda bienes de capital	mensual	dif
38	Encuesta Industrial - tendencia de demanda bienes de uso intermedio	mensual	dif
39	Índice de Producción Industrial - nivel general	mensual	dif
40	Índice de Producción Industrial - bienes de consumo no durables	mensual	dif
41	Índice de Producción Industrial - bienes de consumo durables	mensual	dif
42	Índice de Producción Industrial - bienes de uso intermedio	mensual	dif
43	Índice de Producción Industrial - bienes de capital	mensual	dif
44	Índice de Producción Industrial - alimentos y bebidas	mensual	dif
45	Índice de Producción Industrial - cigarrillos	mensual	dif
46	Índice de Producción Industrial - insumos textiles	mensual	dif

**Tabla A.1 / Conjunto de datos (continuación)**

<b>Serie No.</b>		<b>Frecuencia</b>	<b>Estacionaria</b>
<b>Grupo 3: 2 meses de retraso</b>			
47	Índice de Producción Industrial - pasta y papel	mensual	dif
48	Índice de Producción Industrial - combustible	mensual	dif
49	Índice de Producción Industrial - químicos y plásticos	mensual	dif
50	Índice de Producción Industrial - minerales no metálicos	mensual	dif
51	Índice de Producción Industrial - siderurgia	mensual	dif
52	Índice de Producción Industrial - metalmecánica	mensual	dif
53	Índice de Producción Industrial - automóviles	mensual	dif

\*las cifras mensuales se obtienen promediando datos diarios.

**Tabla A.2 / Resumen de los modelos**

<b>Serie N°</b>	<b>Variables Dummy incluidas</b>	<b>R<sup>2</sup></b>
1	D1995T1 - D1995T2 - D2000T1 - D2001T3 - D2001T4	<b>0,8185</b>
2		0,6493
3	D2001T3 - D2001T4 - D2002T1	0,7406
4		0,6042
5	D1999T2	0,7487
6		0,6328
7	D1995T2 - D2000T1	<b>0,7507</b>
8		0,6086
9	D1995T2 - D2001T3 - D2003T1 - D2001T4 - D1996T1 - D1996T2	0,7407
10	D1995T2	0,6367
11		0,5547
12		0,5551
13	D1995T1 - D1995T2 - D1996T1 - D1996T2 - D2001T3 - D2004T2	<b>0,8580</b>
14	D1995T1 - D1995T2 - D1996T2 - D2004T2 - D1999T4 - D2001T2	0,6688
15	D1996T1 - D1996T2 - D2001T3	0,6570
16	D2000T1 - D2001T3 - D2002T1	<b>0,7935</b>
17	D2001T3 - D1995T1 - D2002T1 - D1995T2 - D2000T1 - D2001T4 D2003T1 - D1996T2 - D2004T2 - D2004T2	<b>0,8792</b>
18		0,5570
19		0,5456
20		0,5428
21		0,6208
22	D1995T1 - D1995T2 - D2001T4	0,6981
23		0,5811
24	D1995T1 - D1995T2 - D2001T3 - D1999T4	0,7148

**Tabla A.2 / Resumen de los modelos (continuación)**

<b>Serie N°</b>	<b>Variables <i>Dummy</i> incluidas</b>	<b>R<sup>2</sup></b>
25	D1995T1 - D1995T2 - D2001T3	<b>0,8013</b>
26		0,5791
27		0,5904
28	D1995T1 - D1995T2 - D2001T3 - D2001T4 - D1996T1 - D1996T2 D1999T4	<b>0,8090</b>
29		0,6093
30		0,5464
31		0,5511
32		0,5648
33		0,5659
34		0,6460
35		0,5991
36	D1995T1 - D1995T2 - D2001T3 - D2001T4 - D1999T4 - D1996T1 D1996T2	<b>0,7776</b>
37		0,5807
38		0,5653
39	D1995T1 - D2001T3 - D2000T1 - D2001T4 - D2003T4	<b>0,8629</b>
40	D1995T1 - D1995T2 - D2001T3 - D2001T4 - D1996T2	<b>0,7566</b>
41	D1996T2 - D2003T4	<b>0,8366</b>
42	D1995T1 - D2001T3 - D2000T1 - D1999T2	<b>0,7935</b>
43	D1995T1 - D1995T2 - D2001T4	<b>0,7865</b>
44	D1995T1 - D1995T2 - D2001T3 - D2001T4 - D1999T4 - D1998T3 D1998T4 - D1996T2	<b>0,8054</b>
45	D1995T1 - D1995T2 - D2001T3	0,6917
46		0,6417
47	D1995T1 - D1995T2 - D2001T3 - D1996T1 - D1996T2 - D2001T4 D1998T3 - D1998T4 - D2003T1 - D2003T1	<b>0,8489</b>
48	D2001T3 - D1996T1 - D1996T2	0,7457
49		0,6306
50		0,6288
51	D1995T1 - D1995T2 - D2000T1	0,7248
52		0,6881
53	D1995T1 - D1995T2 - D2001T3 - D2000T1 - D2001T4	<b>0,8187</b>
54	D2002T1 - D2003T1 - D2004T2 - D1999T4	0,6828
55	D2002T2	<b>0,75178</b>

Nota: las cifras sombreadas indican un R<sup>2</sup> superior a 0,75.

**Tabla A.3 / Series Seleccionadas para construir los factores**

<b>Serie No.</b>	<b>Descripción</b>	<b>R<sup>2</sup></b>
1	Producción Nacional de Vehículos	0,8185
7	Producción de Acero Crudo	0,7507
13	Recaudación Tributaria por Impuesto a las Ganancias DGA	0,8580
16	Índice Merval promedio	0,7935
17	Índice Merval último día	0,8792
25	Encuesta Industrial - perspectiva próximos meses bienes de consumo no durables	0,8013
28	Encuesta Industrial - perspectiva próximos meses bienes de uso intermedio	0,8090
36	Encuesta Industrial - tendencia de demanda bienes de consumo durables	0,7776
39	Índice de Producción Industrial - nivel general	0,8629
40	Índice de Producción Industrial - bienes de consumo no durables	0,7566
41	Índice de Producción Industrial - bienes de consumo durables	0,8366
42	Índice de Producción Industrial - bienes de uso intermedio	0,7935
43	Índice de Producción Industrial - bienes de capital	0,7865
44	Índice de Producción Industrial - alimentos y bebidas	0,8054
47	Índice de Producción Industrial - pasta y papel	0,8489
53	Índice de Producción Industrial - automóviles	0,8187
55	Tasa de interés depósitos a plazo 30-59 días	0,7518