

cinve

Documentos de Trabajo

**Métodos cuantitativos para el análisis y
predicción de la actividad industrial uruguaya**

Fernando Lorenzo
cinve

Bibiana Lanzilotta
cinve

Ignacio Sueiro
cinve

2003

MÉTODOS CUANTITATIVOS PARA EL ANÁLISIS Y PREDICCIÓN DE LA ACTIVIDAD INDUSTRIAL URUGUAYA

Fernando Lorenzo, Bibiana Lanzilotta e Ignacio Sueiro
Centro de Investigaciones Económicas (**cinve**)¹

Resumen

En este trabajo se presenta un conjunto de modelos estadístico-econométricos para el Índice de Volúmen Físico (IVF) de la industria manufacturera uruguaya. Se consideran datos mensuales correspondientes al período comprendido entre 1985 y 2003. Se aportan estimaciones de modelos univariantes de series temporales con Análisis de Intervención y multivariantes de Función de Transferencia en los que se analiza y cuantifica la influencia de la Semana Santa, Semana de Carnaval, el denominado Efecto Calendario, las fiestas nacionales y los paros generales. Se procede a la modelización del índice representativo del total de la industria (excluida la refinería de petróleo) y de una desagregación sectorial elaborada en función del patrón de especialización comercial de cada una de las ramas industriales. Los resultados obtenidos indican que el análisis desagregado permite una mejor comprensión del comportamiento de la actividad industrial y que contribuye a mejorar la precisión de las predicciones.

¹ Centro de Investigaciones Económicas (**cinve**), Uruguay. E-mail: cinve@cinve.org.uy

Indice

| | | |
|-------|--|----|
| I. | Introducción | 3 |
| II. | Los datos sobre actividad industrial | 4 |
| 1. | Caracterización de las series | 4 |
| 2. | Importancia económica del análisis desagregado..... | 4 |
| 3. | Propuesta de desagregación | 5 |
| 4. | Breve caracterización de los grupos | 6 |
| III. | Los datos | 8 |
| IV. | Modelización univariante y extracción de señales..... | 10 |
| 1. | Modelos univariantes..... | 12 |
| 2. | Análisis de intervención en series de actividad industrial..... | 12 |
| | Efecto Pascua | 13 |
| | Efecto de fiestas intrasemanales | 13 |
| | Efecto Calendario..... | 14 |
| | Paros..... | 15 |
| 3. | Resultados de las estimaciones | 15 |
| 4. | Ventajas de la desagregación | 21 |
| V. | Utilización de indicadores..... | 25 |
| 1. | Metodología de las Funciones de Transferencia | 25 |
| 2. | Variables a considerar como indicadores..... | 25 |
| 3. | Resultados de las estimaciones | 26 |
| 4. | Ganancias derivadas del uso de indicadores a nivel desagregado | 32 |
| | Ganancias en precisión..... | 32 |
| | Mejor comprensión del fenómeno | 33 |
| | Consideraciones finales | 33 |
| VI. | Perspectivas actuales de la industria (2003-2004) | 34 |
| VII. | Referencias bibliográficas | 36 |
| VIII. | Anexo 1: Detalle de las variables utilizadas..... | 38 |
| IX. | Anexo econométrico | 39 |

I. Introducción

Este trabajo aborda el estudio de la producción industrial de Uruguay, mediante la aplicación de técnicas estadístico-económicas (univariantes y multivariantes) y evaluando las ventajas e inconvenientes que ofrece el análisis a nivel desagregado del IVF de la industria manufacturera elaborado por el Instituto Nacional de Estadística. El criterio de agrupamiento se apoya en los patrones de especialización productiva e inserción internacional de las diversas ramas industriales.

El enfoque metodológico considerado en este trabajo tiene múltiples antecedentes en la literatura – véanse, por ejemplo, los trabajos de Espasa, Revilla y Rey (1989), Morales y Espasa (1992a) y Morales, Espasa y Rojo (1992b) –. En estos trabajos el análisis se realiza a partir de modelos univariantes ARIMA con Análisis de Intervención (Box y Tiao, 1975). En general, las representaciones estadísticas estimadas permiten identificar un conjunto de regularidades empíricas típicas de las series de actividad industrial, a saber la presencia simultánea de componentes tendenciales y estacionales que no son estrictamente estocásticos y la influencia de un conjunto de acontecimientos especiales que afectan el nivel de las variables analizadas.

A nivel nacional existen pocos estudios en los que se han utilizado métodos cuantitativos al estudio de la actividad industrial. En este sentido, cabe destacar el trabajo de Groskoff *et al.* (1994) que puede considerarse como pionero en la materia para el análisis de la coyuntura industrial. Groskoff *et al.* (1994) realizan una caracterización de algunas series de producción industrial uruguayas. El análisis se focaliza en las divisiones 31 y 32 de la revisión 2 de la Clasificación Industrial Internacional Uniforme (CIIU). En los modelos estimados se incluyen una serie de variables cualitativas para representar la influencia de factores tales como el efecto calendario, la Semana Santa, Carnaval, feriados laborables y no laborables. Los resultados obtenidos permitieron arribar a un conjunto de modelos aceptables en términos explicativos y predictivos, que tienen la virtud de ser una primera aproximación al análisis de la coyuntura industrial.

El trabajo se organiza de la siguiente manera. En la sección II se expone una breve caracterización de las series industriales, se analiza la relevancia de efectuar un análisis desagregado de las series industriales y se presenta la caracterización de la industria con la cual se trabajará en adelante, así como una breve caracterización de esos agregados. En la sección III se presentan los datos correspondientes a los IVF de los grupos industriales de acuerdo a la clasificación anterior. En el apartado IV se exponen los resultados la modelización univariante y en el V el de la modelización multivariante de función de transferencia y se realiza una evaluación de las ventajas de ésta última respecto de la univariante, en términos de precisión y mejor comprensión de los fenómenos agregados. Por último, en la sección VI se exponen las perspectivas de la industria manufacturera para los años 2003-2004.

II. Los datos sobre actividad industrial

1. Caracterización de las series

Las series mensuales de actividad industrial suelen considerarse indicadores “adelantados” para la predicción de variables tales como el Producto Interno Bruto (PIB), especialmente el PIB del sector manufacturero. Dicha cualidad depende obviamente de las prácticas estadísticas de las instituciones que tienen a su cargo la elaboración y publicación de estos indicadores, en particular en lo que refiere a la oportunidad de la publicación de los datos

Las series de producción industrial se caracterizan por exhibir tendencias estocásticas y un marcado comportamiento estacional, con caídas pronunciadas en determinados meses del año que se compensan con niveles de producción superiores a la media anual en otros meses. Como señalan Espasa y Cancelo (1992), el patrón estacional de este tipo de series puede variar en diferentes períodos más o menos extensos y frecuentemente se ve influido por otra serie de factores, tales como la longitud de los meses, la composición de cada mes (número de días lunes, martes, miércoles, etc.), la fecha en la que caen las fiestas de Pascua o el Carnaval y por la ubicación en la semana de días festivos no laborables.

El interés de destacar estas características responde a que las mismas deberán tomarse en cuenta no sólo en el análisis descriptivo de los datos sino porque resulta crucial su adecuado tratamiento a la hora de la especificación de los modelos econométricos y de la generación de predicciones.

2. Importancia económica del análisis desagregado

Una cuestión especialmente relevante al estudiar el comportamiento de las series de actividad industrial es definir si existen razones que justifiquen un análisis desglosado del indicador agregado. El análisis desagregado de la serie de producción industrial permite considerar las características peculiares y específicas de los distintos sectores, evitando que éstas queden diluidas en un único índice escalar. Recogiendo las especificidades de distintos sectores contribuye a clarificar el análisis y a identificar comportamientos heterogéneos cuya comprensión enriquece el diagnóstico.

En definitiva, las especificidades sectoriales se manifiestan en patrones de crecimiento claramente diferenciadas. El análisis agregado no permite considerar la diversidad en la evolución de los diversos grupos industriales atribuible a factores causales que inciden de forma diferenciada sobre el crecimiento de distintos segmentos de la industria manufacturera. Debe tenerse en cuenta, por otra parte, que si se constata que las causas que determinan el crecimiento de distintos sectores industriales difieren, entonces, serán diferentes las reacciones de los mismos ante impulsos provenientes de la política económica o del entorno externo. El reconocimiento de esta diversidad permitirá configurar la situación de la actividad industrial presente, proyectar su futuro con mayor precisión y realizar un diagnóstico más adecuado para cada grupo de sectores industriales industrial. Estos comentarios anteriores indican que, desde el punto de vista económico, los agrupamientos deben construirse a partir de criterios que aseguren que los factores determinantes del crecimiento actúan de manera razonablemente homogénea al interior de cada grupo.

3. Propuesta de desagregación

Siguiendo a Laens y Osimani (2000), se procedió a la desagregación del IVF industrial de acuerdo a su patrón de especialización productiva y comercial. Para ello se toman en cuenta las corrientes de importación y exportación de los bienes pertenecientes a la rama y también la producción nacional de los mismos. Las autoras clasificaron 73 sectores industriales (tomados a 4 dígitos de la CIIU revisión 2), los que representan prácticamente el 100% del sector manufacturero uruguayo.

La agrupación de los sectores industriales en 4 grupos realizada por dichas autoras, se basó en los criterios de especialización. De acuerdo a este criterio se seleccionan aquellos sectores en los que el coeficiente de apertura² es menor al 5%. Estos sectores quedan clasificados dentro del grupo denominado de **Bajo Comercio**. Si dicho coeficiente es mayor al 5% se analiza la presencia de comercio intraindustrial, a través de los correspondientes índices de Grubel y Lloyd,³ si este índice supera el 0,50, se clasifica un segundo grupo de industrias como de **Comercio Intraindustrial o intrarrama**. Finalmente, los sectores con índices de Grubel y Lloyd inferiores a 0,50 y con un coeficiente de apertura superior a 5% fueron clasificados de acuerdo a si su saldo del comercio sectorial era positivo o negativo. Aquéllos con signo positivo conforman el grupo de **Exportadores** y los de signo negativo definen el grupo denominado de **Sustitutos de Importaciones**. Para implementar esa clasificación, Laens y Osimani tomaron como referencia la información de la Encuesta Industrial Anual del año 1996.

Dentro del grupo de Bajo Comercio (BC) quedaron clasificadas un reducido número de ramas. Las más importantes pertenecen a la industria de Alimentos y Bebidas: Pan, Repostería y Pastas, Fabricación de Cerveza, Malta, Industria Vinícola y de Bebidas sin Alcohol. También pertenecen a este grupo las ramas de Minerales no Metálicos: Fabricación de Productos de Arcilla para la Construcción y Cemento, Cal y Yeso. En el grupo denominado de Comercio Intraindustrial (CI) se incluyeron a todas las ramas de la Madera, del Papel y de Minerales no Metálicos (Insumos para la construcción, algunas ramas pertenecientes al sector de Alimentos, de la industria Textil, del Cuero, de la Química y Caucho (Resinas, Pinturas, Cámaras y neumáticos) y de Productos metálicos y maquinaria (Electrodomésticos). El agrupamiento de Sustitutivos de Importaciones (IMP) está compuesto, entre otros, por las industrias como la Fabricación de Vehículos Automotores, los Productos Farmacéuticos, Industria del Tabaco, Plásticos y Sustancias Químicas Industriales Básicas. Finalmente, en el grupo de industrias Exportadoras (EXP) se incluyen la Matanza y Preparación de Carnes y Aves, la rama de Productos Lacteos, los Lavaderos, Hilanderías y Tejedurías, la Fabricación de Prendas de Vestir y Teñido de Pieles, los Molinos Arroceros y Productos Alimenticios Diversos.

² Exportaciones más importaciones como porcentaje de la oferta global.

³ El índice de Grubel y Lloyd se define como:

$$B_{ij} = (X_{ij} + M_{ij} - |X_{ij} - M_{ij}|) / (X_{ij} + M_{ij})$$

donde X_{ij} y M_{ij} , son exportaciones e importaciones del sector i a la región j , respectivamente, X_j y M_j son exportaciones e importaciones de la región j .

4. Breve caracterización de los grupos

Como se mencionó en el apartado anterior, los agrupamientos responden a criterios de especialización e inserción internacional, por lo que para su caracterización se consideraron las corrientes de exportación e importación de las ramas y la producción nacional de los mismos.

En el Cuadro 1 se presentan la participación de cada agrupamiento en el agregado industrial de acuerdo a los datos del Censo Económico Nacional de 1997 realizado por el INE, en función de su peso en el Valor Bruto de Producción (VBP) y en el Valor Agregado Bruto (VAB) correspondientes a la industria manufacturera.

| Cuadro 1 – Participación de los agrupamientos en el VBP y VAB industrial | | |
|---|----------------|----------------|
| Grupos | 1997 | |
| | VBP (%) | VAB (%) |
| Exportadores | 51 | 38 |
| Sustitutivos de Importaciones | 20 | 27 |
| Comercio intra-rama | 10 | 10 |
| Bajo Comercio | 19 | 25 |
| Total Industria | 100 | 100 |

Fuente: CEN 1997, INE.

Puede apreciarse que el grupo de industrias exportadoras es el que realiza la mayor contribución en términos de VBP (más de 50%) y del VAB manufacturero. Su participación es algo menor en el segundo de los indicadores (explica algo menos de 40% del mismo). Los Sustitutivos de Importaciones son responsables de aproximadamente la cuarta parte del VAB y VBP industrial, y, sólo algo menor es la participación del grupo de industrias clasificadas como de Bajo Comercio.

Desde el punto de vista descriptivo, interesa tener en cuenta, además, los cambios ocurridos entre el último Censo Económico (1997) y el anterior que data del año 1988, en la medida en que ofrece información sobre los efectos de la apertura comercial y el avance del proceso de integración regional. De acuerdo a los datos aportados por el Cuadro 2, el único cambio relevante refiere a la pérdida de importancia en términos de VAB, del agrupamiento correspondiente a industrias Sustitutivas de Importaciones, en favor del agrupamiento de industrias de Bajo Comercio.

| Cuadro 2 - Participación de los agrupamientos en el VAB industrial (1997 - 1988) | | |
|---|----------------|-------------|
| Grupos | VAB (%) | |
| | 1997 | 1988 |
| Exportadores | 38 | 35 |
| Sustitutivos de Importaciones | 27 | 37 |
| Comercio intra-rama | 10 | 12 |
| Bajo Comercio | 25 | 16 |
| Total Industria | 100 | 100 |

Fuente: CEN 1988 y 1997, INE.

La estructura de la producción de los cuatro agregados se presenta en el Cuadro 3.

| Cuadro 3 - Estructura productiva según agregado industrial | | | | |
|---|---------------------|----------------------|-----------------------|----------------------|
| | Exportadores | Sust. Import. | Com intrarrama | Bajo comercio |
| VAB | 27.2 | 50.5 | 38.1 | 50.9 |
| Excedente de Explotación | 12.46 | 17.40 | 14.79 | 21.54 |
| Costo laboral | 13.37 | 19.25 | 19.49 | 16.65 |
| Consumo capital fijo | 2.06 | 2.62 | 3.50 | 6.24 |
| Impuestos | -0.70 | 11.20 | 0.27 | 6.47 |
| Cons. Intermedio | 72.8 | 49.5 | 61.9 | 49.1 |
| Mat. Primas Nac | 44.3 | 9.3 | 19.4 | 19.7 |
| Mat. Primas Import | 6.2 | 20.3 | 21.5 | 6.3 |
| Combustibles | 0.8 | 0.4 | 1.9 | 1.6 |
| Otros | 19.2 | 19.3 | 21.1 | 21.1 |
| VBP | 100 | 100 | 100 | 100 |

Fuente: Encuesta Industrial Anual de 1997, INE.

En este cuadro se puede apreciar heterogeneidad entre la estructura productiva de los cuatro agregados. En primer lugar, debe tenerse en cuenta que, tanto en las industrias exportadoras como en las industrias de Comercio Intraindustrial, el VAB representa una menor proporción del VBP que en los dos grupos industriales restantes. En las industrias Exportadoras destaca el fuerte componente de insumos nacionales y la baja proporción de insumos importados.

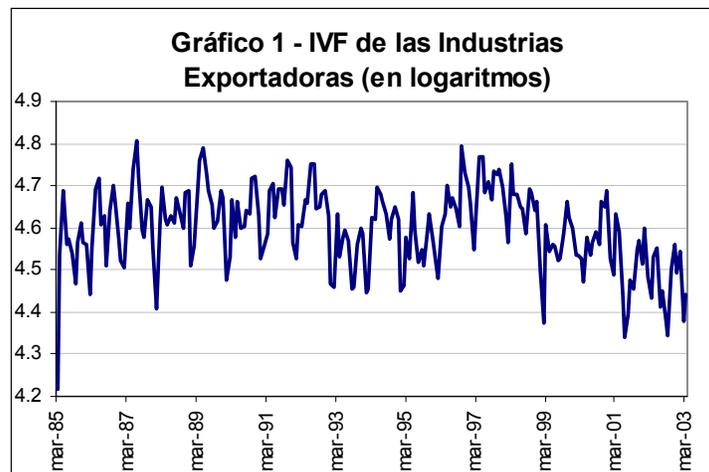
En cuanto a la composición del VAB de este grupo, que representa menos del 30% del total de la producción industrial, cabe señalar que el mismo se integra casi por partes iguales por el componente de costos salariales y de excedente de explotación, lo que implica que en este grupo los costos laborales representan una proporción menos significativa en los costos totales. La estructura productiva del grupo de industrias Sustitutivas de Importaciones se caracteriza por la alta participación de los insumos importados (y la baja proporción de los nacionales) y por el fuerte componente salarial dentro de su valor agregado. En el agregado de industrias con Comercio Intraindustrial, se

destaca también una alta incidencia de los costos laborales. Su consumo intermedio se distribuye por partes casi iguales entre los componentes importados y los nacionales. En el grupo de Bajo Comercio resalta la fuerte incidencia del Excedente de Explotación dentro de su valor agregado, y que es el grupo con mayor componente de consumo de capital fijo. En cuanto al consumo de bienes intermedios de este agrupamiento, el mismo se concentra en materias primas nacionales.

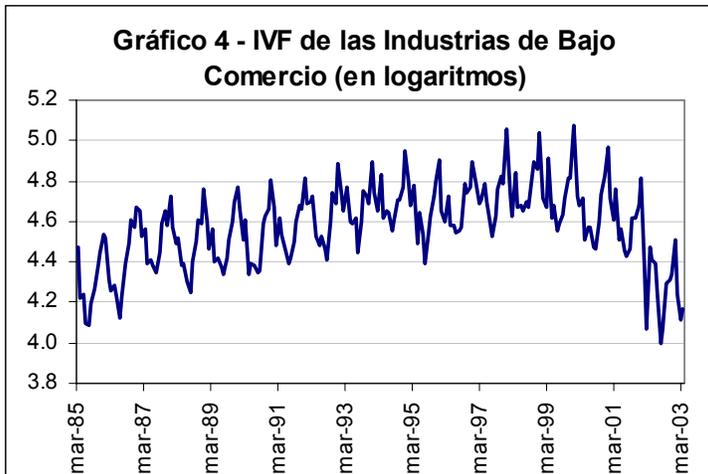
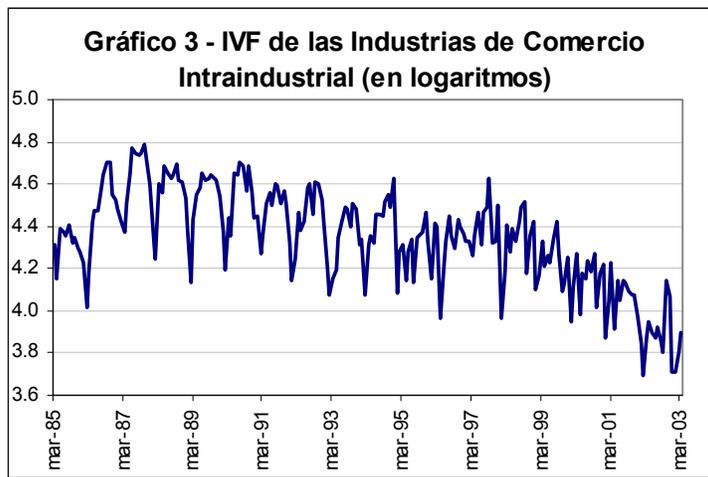
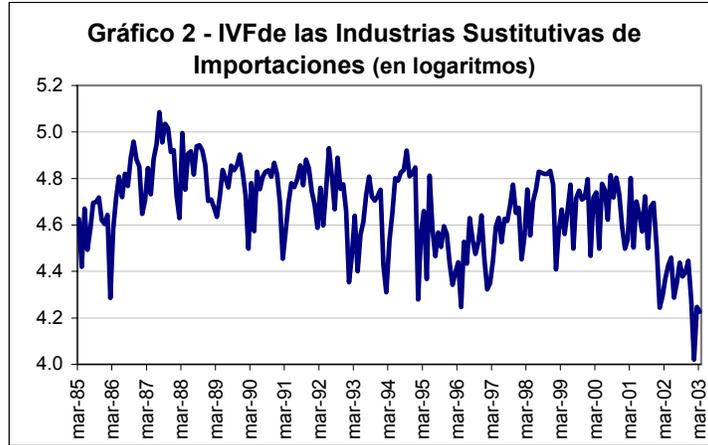
III. Los datos

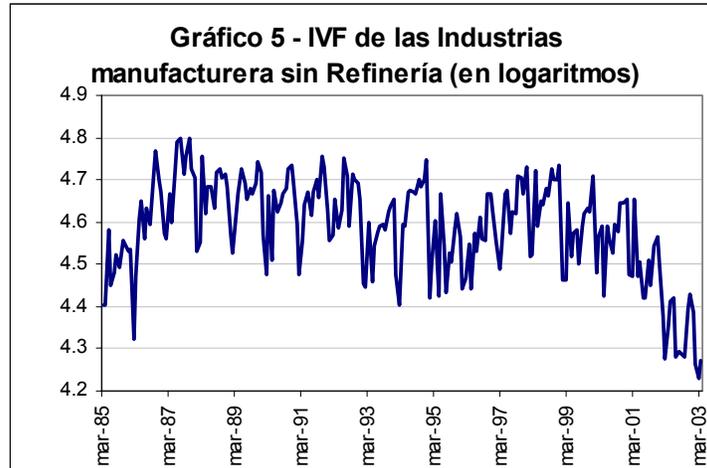
Las series de producción industrial consideradas en este trabajo corresponden al Índice de Volumen Físico de la Industria Manufacturera base 1988 = 100 elaborado por el INE. Dicho indicador tiene como referencia la estructura industrial relevada en el Censo Económico de 1988. En concreto se trabajó con datos mensuales correspondientes al período comprendido entre el mes de Marzo de 1985 y el mes de Marzo de 2003.⁴ Se excluyó del análisis la rama de Refinería de Petróleo (código 353 de la clasificación CIIU revisión 2), cuya evolución se encuentra afectada por interrupciones en la actividad de la refinería por lapsos aperiódicos relativamente prolongados.

Sobre la base de las series industriales correspondientes a las distintas ramas a cuatro dígitos se construyeron los índices de los cuatro agrupamientos industriales descritos anteriormente. En los Gráficos 1 a 5 se presentan los datos correspondientes al logaritmo de las cuatro agrupados industriales, así como al IVF agregado excluida la Refinería de Petróleo.



⁴ Para la extensión del análisis al período anterior a 1993 fue necesario enlazar los datos de la base 1988 = 100 con los correspondientes al IVF con base 1982 = 100. El procedimiento de enlace se aplicó al nivel más desagregado posible (a cuatro dígitos de la CIIU revisión 2).





IV. Modelización univariante y extracción de señales

Como señalan Espasa y Cancelo (1993), resulta deseable que el seguimiento de la coyuntura de un fenómeno económico de interés esté basado en un análisis riguroso de los aspectos esenciales del mismo. Un análisis de este tipo requiere estimar componentes de los datos que no son directamente observables, para lo cuál es necesario disponer de técnicas para extraer las señales de nivel relevantes para el seguimiento del fenómeno.

El análisis clásico de series temporales evalúa la existencia de los siguientes componentes: tendencia, ciclo, estacionalidad e irregular. Este último está constituido por las oscilaciones no sistemáticas, que normalmente tienen una estructura aleatoria predeterminada. El componente de tendencia recoge la parte de la variable que está relacionada principalmente con factores de largo plazo. En tanto, el componente estacional está constituido por las oscilaciones cuasiperiódicas de media nula que tienen periodicidad anual o submúltiplo del año, mientras que el componente cíclico lo constituyen aquellas oscilaciones debidas a la actividad económica; son menos frecuentes y menos sistemáticas que las estacionales.

La agregación de estos cuatro componentes no observables conforma la serie observada de acuerdo a la relación que sigue:

Esquema aditivo:

$$Y_t = T_t + C_t + S_t + I_t$$

Esquema multiplicativo:

$$Y_t = T_t * C_t * S_t * I_t$$

donde Y_t = Serie observada

T_t = Tendencia

C_t = Componente cíclico

S_t = Estacionalidad

I_t = Componente irregular

En el análisis de series de actividad económica es más frecuente el uso de esquemas multiplicativos, en los cuáles los componentes cíclico, estacional e irregular se expresan

como una proporción de la tendencia. En los casos en que una serie original siga este esquema, su transformación logarítmica seguirá un esquema aditivo.

Es bien sabido que la estimación de los componentes no observables puede implementarse a partir de la estimación de modelos ARIMA multiplicativos estacionales, en la medida en que este tipo de representaciones recoge las principales características del fenómeno económico considerado. La depuración de los datos originales permite obtener señales de nivel y del crecimiento (subyacente) que no estén afectadas por perturbaciones cíclicas y cuasi-cíclicas de corto plazo, ni por perturbaciones anómalas y estacionalidad.

1. Modelos univariantes

Si bien la mayor parte de las variables económicas no son estacionarias, en la mayoría de los casos sus crecimientos o sus aceleraciones son al menos aproximadamente estacionarias, condición que implica que este tipo de variables sean procesos integrados. El orden de integración refiere al número de diferenciaciones que se han de efectuar para que el proceso sea estacionario. En general, resulta que:

$\Delta^d \Delta_{12}^D Y_t = W_t$ es estacionario, donde d = orden de diferencias regulares y D es el número de diferencias estacionales.

Si W_t es estacionario, puede representarse mediante un modelo univariante multiplicativo estacional $ARIMA(p, d, q) \times (P, D, Q)$:

$$\phi_p(L)\Phi(L^{12})(1-L)^d(1-L^{12})^D Y_t = \theta_q(L)\Theta(L^{12})e_t$$

donde:

$\phi_p(L) = 1 - \phi_1 L - \dots - \phi_p L^p$: polinomio en el operador de retardo que representa el componente autorregresivo regular (su polinomio característico tiene todas las raíces estrictamente fuera del círculo unitario);

$\Phi(L^{12}) = 1 - \phi_{12} L^{12} - \dots - \phi_{12p} L^{12p}$: polinomio en el operador de retardo que representa el componente autorregresivo estacional (su polinomio característico tiene todas las raíces estrictamente fuera del círculo unitario);

$\theta_q(L) = 1 - \theta_1 L - \dots - \theta_q L^q$: polinomio en el operador de retardo que representa el componente de medias móviles "regular" (su polinomio característico tiene todas las raíces estrictamente fuera del círculo unitario);

$\Theta(L^{12}) = 1 - \theta_{12} L^{12} - \dots - \theta_{12q} L^{12q}$: polinomio en el operador de retardo que representa el componente de medias móviles "estacional" (su polinomio característico tiene todas las raíces estrictamente fuera del círculo unitario);

$(1-L)^d (1-L^{12})^D$: transformación estacionaria (polinomio en el operador de retardo que contiene sólo raíces unitarias);

e_t : proceso estocástico que representa las innovaciones o residuos ruido blanco (independientes, normales, de media nula, varianza constante e idénticamente distribuidos).

2. Análisis de intervención en series de actividad industrial

Siguiendo a García Martos (1994), en las series de actividad económica de periodicidad mensual, además de los componentes inobservables de naturaleza estocástica, suele detectarse la presencia de un conjunto específico de elementos determinísticos, asociados a acontecimientos regulares, con marcado carácter estacional, debido a su condición intraanual, y cuya localización temporal puede variar de unos años a otros. Por sus especiales características, es conveniente considerar dichos elementos de forma explícita en el proceso de especificación de los modelos, ya que, en otro caso, se pueden introducir sesgos en la estimación de los parámetros de los modelos y en los propios componentes inobservables. A este respecto, al comparar información sobre observaciones mensuales "no homogéneas" se puede llegar a conclusiones erróneas acerca del comportamiento real de la variable en cuestión.

Por otra parte, a partir de los modelos se puede detectar, fechar y medir la importancia de valores atípicos en las series de producción industrial. Se consideran valores atípicos aquéllas observaciones cuyos residuos están fuera de un intervalo determinado por un número de veces la desviación estándar residual. Como es habitual en el análisis de series temporales, se han considerado como atípicas las observaciones cuyos residuos se apartan en más tres desviaciones típicas del valor esperado (cero). El análisis de la presencia de valores atípicos puede considerarse como un instrumento para detectar y medir los efectos de acontecimientos especiales sobre las series consideradas. Para el tratamiento de las anomalías se han incluido en los modelos variables cualitativas especialmente adaptadas a las características de cada caso (impulsos, escalones, escalones estacionales, tendencias, tendencias truncadas).

El proceso de producción industrial tiene ciertas características que influyen muy especialmente sobre las características de las series de actividad del sector. La jornada laboral suele estructurarse en turnos de producción que no funcionan los días feriados, ya sean domingos, feriados no laborables o los días de Pascua y Carnaval. Las vacaciones de los trabajadores de la industria suelen concentrarse en determinados meses del año calendario, especialmente en los meses de verano.

Como se expresó anteriormente, las series de actividad industrial suelen verse afectadas por la presencia del efecto calendario, del efecto Pascua y por la presencia del efecto debido a fiestas intrasemanales (véase, Espasa, Revilla, Rey, 1989).

Efecto Pascua

Con este efecto se intenta presentar la influencia que la festividad móvil de la Pascua ejerce sobre la producción industrial. Que la Semana Santa no ocurra siempre en el mismo mes del año (marzo o abril), implica que cuando ocurre esta festividad se produce una caída de la actividad industrial en dicho mes. En este trabajo se ha considerado que la Semana Santa afecta a siete días consecutivos. A fin de evaluar la incidencia de este efecto sobre las series de actividad, se definió la variable "Pascua" que toma valor cero para aquellos meses distintos de marzo y abril, y para estos últimos la cantidad de días de Semana Santa que caen en cada mes.

Efecto de fiestas intrasemanales

Este efecto pretende reflejar la influencia que tiene sobre la producción industrial de un mes determinado el que, en dicho mes, exista una fiesta en un día distinto de sábado y domingo. Sin lugar a dudas, las fiestas existentes en nuestro calendario afectan al volumen de la producción, aunque habitualmente, su incidencia no es tenida en cuenta, por considerarse que su efecto sobre la serie mensual no es estadísticamente significativo. No obstante, tal como se ha comprobado en diversos estudios (Espasa *et al*, 1993), se estima que la incidencia de las fiestas intrasemanales reviste cierta importancia en un amplio volumen de series económicas, y principalmente las ligadas al proceso productivo. Este hecho viene justificado por diversos motivos, entre ellos, el carácter móvil de las fiestas dentro de la semana en años distintos. Aún cuando estos días festivos, distintos de sábados o domingos, sea un fenómeno que se presenta en estrecha relación con el calendario, es preferible tratarlo de forma aislada, dado que no tiene el mismo comportamiento regular que aquél, ya que las fiestas pueden modificarse.

En este trabajo se define la variable “calendario” para cada mes como el número de fiestas intrasemanales que no se celebran ni en sábado ni en domingo.

Efecto Calendario

Este efecto hace referencia al hecho de que se espera un mayor nivel de producción industrial en aquellos meses con mayor número de días laborales. Esto supone tener en cuenta no sólo la distinta longitud de los meses, sino su diferente composición en términos de número de lunes, martes, etc.. Este efecto es resultado tanto de la distinta duración, como de la composición de cada mes (véase, García Martos y Navarro, 1994).

La composición mensual del calendario afecta al nivel de actividad mensual por una doble vía: a) el número de días laborales que tiene cada mes; b) la estructura según días de la semana, en cuanto a la frecuencia relativa de lunes, martes, etc. El tratamiento del ciclo semanal que se sigue en este trabajo es el de Hillmer *et al.* (1983), basado en el modelo determinístico que se expone a continuación.

Se denomina TD_t al efecto asociado al mes t , cuya expresión es la siguiente:

$$TD_t = \delta_1 X_{1t} + \delta_2 X_{2t} + \dots + \delta_6 X_{6t} + \delta_7 X_{7t} = \sum_{i=1}^7 \delta_i X_{it}$$

donde X_{it} son variables tipo *dummy* cuyos valores son el número de lunes, martes, ..., domingos, en el mes t de cada año y δ_i el efecto o peso que tiene cada día de la semana en la variable objeto de análisis, la producción industrial en este caso. Por tanto, cada observación mensual, Z_t , se puede escribir de la siguiente forma:

$$Z_t = TD_t + n_t$$

donde n_t es una variable que recoge la estructura estocástica de Z_t , es decir, el correspondiente modelo ARMA con análisis de intervención de la serie estacionaria así como la variable residual.

Ahora bien, si se estimase el TD_t tal como se ha definido, sin ninguna modificación, se obtendrían estimadores pocos precisos de los δ_i , ya que las X_{it} están muy correlacionadas entre sí y darían lugar a un problema de multicolinealidad. De ahí, que se estime el modelo con el siguiente cambio de variable:

$$td_{it} = X_{it} - X_{7t}, i = 1, \dots, 6$$

$$td_{7t} = \sum_{i=1}^7 X_{it}$$

donde td_{it} representa el número de días de tipo i que tiene el mes t en exceso sobre el número de domingos, tomados como punto de referencia, y td_{7t} , el número total de días del mes t . Sustituyendo se obtiene que:

$$TD_t = \sum_{i=1}^7 \delta_i X_{it} = \sum_{i=1}^7 C_i td_{it}$$

De forma que la relación entre los parámetros viene dada por:

$$\delta_i = C_i + C_7, i = 1, \dots, 6$$

$$\delta_7 = C_7 - \sum_{i=1}^6 C_i$$

La interpretación de los mismos es la siguiente:

$C_7 = \frac{\sum \delta_i}{7}$ es el efecto medio diario, o lo que es lo mismo, el aumento de la producción al añadir un día más al mes t , con independencia de qué día de la semana se trate.

C_i es el efecto diferencial de cada tipo de día respecto al efecto medio C_7 . Estos coeficientes reflejan el coeficiente estacional semanal correspondiente al tipo de día i . Para el domingo, éste se calculará a partir de la relación:

$$C_D = \delta_7 - C_7 = -\sum_{i=0}^6 C_i$$

ya que, por definición, la suma de los coeficientes estacionales ha de ser cero.

Paros

En el análisis de las series de actividad industrial es preciso incluir una variable *dummy* que refleje el número de días laborables en el mes en los cuales la actividad desciende debido a la ocurrencia de medidas de índole gremial. Pueden diferenciarse entre los paros parciales y los totales, y es recomendable también distinguir a los paros que afectan a todos los sectores de actividad o aquellos que involucran sólo al sector de actividad de interés.

3. Resultados de las estimaciones

Los resultados de las estimaciones que surgen de los modelización univariante se presentan en los Cuadros 4 a 8, los cuales corresponden a las estimaciones de los agrupamientos de Bajo Comercio, Comercio Intraindustrial, Exportadores, Sustitutiva de Importaciones y al agregado del conjunto de la industria manufacturera (excluyendo la Refinería de Petróleo).

Cuadro 4 - Modelo univariante para la serie del indicador del IVF de bajo comercio

$$\begin{aligned}
 (1 + 0,5839L)(1 + 0,5110L^{12})\Delta\Delta_{12}LIVFBC_t = & -0,0159\Delta\Delta_{12}PAS_t - 0,0132\Delta\Delta_{12}CAR_t + \\
 & (-7,93) \quad (-7,54) \quad (-7,35) \quad (-5,25) \\
 & -0,0286\Delta\Delta_{12}PAR_t - 0,0396\Delta\Delta_{12}VIE_t + \\
 & (-4,14) \quad (-3,28) \\
 & -0,0001\Delta\Delta_{12}DLU_t - 0,0070\Delta\Delta_{12}DMA_t + \\
 & (-0,01) \quad (-1,00) \\
 & + 0,0051\Delta\Delta_{12}DMI_t + 0,0158\Delta\Delta_{12}DJU_t + \\
 & (0,74) \quad (2,37) \\
 & -0,0012\Delta\Delta_{12}DVI_t - 0,0142\Delta\Delta_{12}DSA_t + \\
 & (-0,19) \quad (-2,10) \\
 & + 0,1437\Delta\Delta_{12}LS8607_t - 0,1245\Delta\Delta_{12}AO9008_t + \\
 & (2,41) \quad (-3,17) \\
 & -0,1281\Delta\Delta_{12}AO9208_t - 0,0832\Delta\Delta_{12}LS9601_t + \\
 & (-3,27) \quad (-2,38) \\
 & + 0,0965\Delta\Delta_{12}AO9604_t + 0,1348\Delta\Delta_{12}AO9903_t + \\
 & (2,47) \quad (3,54) \\
 & -0,1921\Delta\Delta_{12}AO0201_t - 0,3083\Delta\Delta_{12}AO0202_t + \\
 & (-4,59) \quad (-6,85) \\
 & -0,2106\Delta\Delta_{12}LS0207_t + (1 - 0,2770L^2)a_t \\
 & (-4,98) \quad (-3,16)
 \end{aligned}$$

Muestra: Mayo 1987 – Marzo 2003 (191 observaciones)

Número de residuos: 191

$\hat{\sigma}_a = 0,0472$

t-valor de la media de los residuos: -0,0620

Estadísticos de Box-Pierce-Ljung: Q(14)= 15,5

Q(26)= 42,2

Q(38)= 47,4

Residuos superiores a $3\hat{\sigma}_a$:

(t-valores entre paréntesis)

4. Ventajas de la desagregación

Se realizó una evaluación de las predicciones del IVF agregado de la industria a partir de las predicciones generadas por los modelos univariantes estimados para cada componente, y por la estimación del indicador agregado. Se utilizó como criterio de evaluación el cálculo de los errores cuadrático medios de las predicciones.

Tal como se puede apreciar en el Cuadro 9, la estimación del agregado manufacturero a partir de los grupos industriales antes definidos mejora las predicciones respecto de la estimación del agregado industrial.

| Cuadro 9 - Evaluación de desempeño predictivo del IVF sin Refinería | |
|--|-------|
| <i>Predicciones 1995.06-2002.09</i> | |
| <i>Predicciones a un paso del IVF sin Refinería agregado</i> | |
| Raíz del Error Cuadrático Medio (RECM) | 0.038 |
| <i>Predicciones a un paso del IVF sin Refinería a partir de los componentes</i> | |
| Raíz del Error Cuadrático Medio (RECM) | 0.032 |

El análisis univariante de las series de la industria manufacturera realizado anteriormente ha revelado que todas las series admiten las representaciones $I(1,1)$, es decir, con tasas de crecimiento de largo plazo bastante estables.

La existencia o no de factores tendenciales comunes puede analizarse a partir de la teoría econométrica de la cointegración desarrollada originalmente por Engle y Granger (1987). El enfoque de la cointegración ofrece un marco para investigar los vínculos entre series económicas no estacionarias, en particular entre aquéllas cuyo comportamiento se encuentra dominado por la evolución tendencial, como es el caso precisamente de las series analizadas en este trabajo. En términos generales, puede decirse que la identificación de relaciones de cointegración se reduce a determinar la existencia de combinaciones lineales estacionarias –o más generalmente combinaciones lineales de un menor orden de integración que el observado en los datos originales– entre series temporales que individualmente no lo son.

En concreto, se ha utilizado el procedimiento de estimación de máxima verosimilitud gaussiana propuesto por Johansen (1988) para analizar la existencia de relaciones de cointegración entre un vector de series no estacionarias.

Primero, se estima el modelo de corrección del error en primeras diferencias para el conjunto de variables endógenas y se determina el número de vectores de cointegración existentes en los datos a través de los contrastes habituales basados en los estadísticos de traza y de máximo autovalor (Johansen, 1995).

El procedimiento descrito es el que se ha seguido en este trabajo para investigar la existencia de relaciones de cointegración entre las series de los cuatro sectores de la industria manufacturera sin refinería en el periodo comprendido entre noviembre de 1985 y marzo de 2003. Las estimaciones fueron realizadas con el programa PC Fiml versión

9.0. Por su parte, para la modelización de la dinámica de corto plazo se han incluido seis retardos de cada una de las variables endógenas.

Los resultados de las estimaciones se recogen en el Cuadro 10. Se observa que los estadísticos de traza y máximo autovalor no permiten rechazar la hipótesis de que la matriz de largo plazo es de rango cero, o lo que es lo mismo que no existen relaciones de cointegración entre los cuatro sectores de la industria manufacturera y que por lo tanto no existen tendencias comunes entre ellos.

| Cuadro 10 - Resultados de test de Johansen sobre los grupos industriales | | | | | | |
|---|------------------|-------------|--------------|--------------|------------------|--------------|
| Vectores de cointegración normalizados | Variables | | | | Autovalor | Traza |
| | DLBC | DLCI | DLEXP | DLIMP | | |
| (H0: r=0) 1 | 1 | 0.0504 | -0.0077 | -0.14532 | 0.4014 | 325.2** |
| (H0: r<=1) 2 | -0.34326 | 1 | 0.45155 | 0.079938 | 0.38519 | 217.4** |
| (H0: r<=2) 3 | -0.06124 | -0.8742 | 1 | 0.76385 | 0.27781 | 115.3** |
| (H0: r<=3) 4 | 0.06867 | -0.3298 | -1.0810 | 1 | 0.20018 | 46.91** |

(**) Significativo al 1%. De acuerdo al criterio Akaike (AIC), se eligió 6 retardos para la estimación del modelo.

Para intentar aprovechar las interrelaciones existentes entre las secuencias temporales de las innovaciones de los distintos sectores de la industria, a efectos de mejorar la precisión de las predicciones del conjunto de la industria manufacturera sin refinería, puede considerarse la información expuesta en el Cuadro 11. En dicho cuadro se recogen los valores estadísticamente significativos de los coeficientes de correlación cruzada entre los residuos de los modelos ARIMA de cada uno de los cuatro sectores correspondientes a los doce primeros retardos.

En primer término, cabe subrayar que no existen correlaciones estadísticamente significativas entre las innovaciones contemporáneas (residuos) de los distintos componentes. Esto estaría indicando que la matriz de varianzas y covarianzas del vector de innovaciones de los distintos componentes básicos es diagonal, y que las innovaciones contemporáneas no se alejan demasiado de la hipótesis de independencia.

Cuadro 11 - Correlación cruzada entre los residuos de los modelos ARIMA de los agregados industriales

| i \ j | $r_k = corr(e_t^j, e_{t-k}^i)$ | | | |
|-------|--------------------------------|-----------------------------|--------------|----------------------------|
| | BC | CI | EXP | IMP |
| BC | n.c. | $r_7(0.15)$ | $r_2(0.17)$ | $r_2(0.14)$ $r_4(0.13)$ |
| CI | $r_5(-0.14)$ $r_{10}(0.17)$ | n.c. | – | – |
| EXP | $r_3(0.14)$ | $r_{12}(-0.17)$ | n.c. | – |
| IMP | – | $r_1(-0.15)$ $r_6(0.16)$ | $r_9(-0.16)$ | n.c. |

En segundo término, se observa que las correlaciones desfasadas en el tiempo entre las innovaciones de los cuatro sectores presentan pocos valores estadísticamente significativos en los primeros retardos regulares y sólo uno en el primer retardo estacional. Las pocas correlaciones que podrían presentar algún interés a efectos de la formulación de modelos multivariantes de series temporales pueden agruparse en dos categorías. Por un lado, se observa que las innovaciones de BC parecen anticipar a las innovaciones de los otros sectores de la industria manufacturera, y a su vez se ven afectadas por las innovaciones de otros sectores. Sin embargo, un análisis más profundo de estas correlaciones indica que las mismas son de magnitud reducida y de difícil interpretación desde el punto de vista económico.

Es dudoso que el resto de las correlaciones cruzadas señaladas en el Cuadro 11 puedan aprovecharse en la formulación de modelos multivariantes de series temporales. Por otro lado, se observa que las innovaciones del grupo IMP adelantan negativamente en un período y positivamente en seis periodos a las registradas en CI, aunque nuevamente los valores de los coeficientes de correlación son de reducida magnitud.

En los puntos anteriores se concibió la conveniencia de analizar la industria manufacturera de forma desagregada, se planteaba el problema de la posible necesidad de llevar a cabo un estudio multiecuacional conjunto de los diferentes sectores. Los resultados expuestos en esta sección indican que:

- a) La matriz de varianzas y covarianzas contemporáneas de los residuos es casi diagonal. En consecuencia, se obtendrán resultados prácticamente idénticos estimando el sistema conjuntamente o ecuación por ecuación (Zellner, 1979).
- b) La posible omisión de interrelaciones dinámicas entre las innovaciones de las diferentes ecuaciones no es importante y, sobre todo, en dichas interrelaciones aparecen signos de difícil interpretación, como que un movimiento al alza en el momento t en el índice de volumen físico del grupo comercio intraindustrial implique efectos a la baja en el índice de volumen físico de las de bajo comercio en t+5 y a la vez alzas en t+10.

Por otra parte, es importante analizar la relevancia del análisis de intervención, es decir medir la significación que tienen en la formulación de los modelos tanto la utilización de variables *dummies* (escalones, impulsos, etc.) como la de variables que incorporen las características productivas de la industria (efecto calendario, Pascua, etc.).

En el Cuadro 12 se enumeran los errores estándares de los residuos de los modelos estimados sin la utilización del análisis de intervención y con la utilización de éste.

| Cuadro 12 – Residuos de los modelos con y sin intervenciones específicas | |
|---|--------------------------------|
| MODELO | Error Estándar Residual |
| DLIVFBC | 0.073 |
| DLIVFBC con intervenciones | 0.047 |
| DLIVFCI | 0.108 |
| DLIVFCI con intervenciones | 0.075 |
| DLIVFEXP | 0.070 |
| DLIVFEXP con intervenciones | 0.048 |
| DLIVFIMP | 0.112 |
| DLIVFIMP con intervenciones | 0.070 |

Como se puede apreciar en el cuadro, las ganancias por la utilización del análisis de intervención son muy significativas en todos los casos estimados. En promedio, el desvío estándar se redujo un 34% con la incorporación de las variables *dummies* y las de efecto calendario, pascua, etc.

V. Utilización de indicadores

El objetivo de esta sección es la especificación y estimación de modelos econométricos uniecuacionales con indicadores (adelantados) específicos para los cuatro grupos industriales antes definidos y el análisis de las ventajas que podrían derivarse de la utilización de los mismos a efectos de mejorar la precisión de las predicciones y la comprensión de la evolución de la industria manufacturera.

1. Metodología de las Funciones de Transferencia

Los modelos uniecuacionales de Función de Transferencia permiten evaluar la incidencia de los diversos indicadores sobre variables de interés, en este caso el IVF de la industria manufacturera uruguaya. Este tipo de modelos se deben especificar de manera de tener en cuenta la dinámica transitoria de los datos (Hendry, 1995) mediante la incorporación de un número suficiente y apropiado de retardos, tanto de la variable de interés como de las otras variables explicativas.

En la formulación econométrica del modelo lineal general uniecuacional se consideran k variables (x_k) exógenas que tienen información relevante sobre la evolución de la variable de interés y_t . Puede expresarse como:

$$y_t = v(L)x_t + \eta_t$$
$$y_t = \frac{\omega(L).L^b}{\delta(L)}x_t + \frac{\theta(L)}{\phi(L)}\varepsilon_t$$

donde x_t y y_t son transformaciones estacionarias de las series consideradas.

El cociente de polinomios en el operador de retardo aplicado sobre $\Delta x_{t,i}$ aproxima el efecto dinámico de la variable x_i sobre Δy_t , mientras que el segundo término representa una estructura ARMA (p,q) que resume la estructura de dependencia temporal a través de la que las perturbaciones se transmiten a la serie Δy_t . Las raíces del polinomio $\delta_{m,i}(L)$ se encuentran todas estrictamente fuera del círculo unitario, de tal modo que el cociente polinomial puede ser de orden infinito, siendo la suma de sus coeficientes finita.

La utilización de los modelos de función de transferencia con fines predictivos requiere que se verifiquen las condiciones de exogeneidad fuerte. Es decir que la variable de interés no cause en el sentido de Granger a las otras variables y que estas últimas sean además débilmente exógenas. La condición de exogeneidad débil es necesaria para la validez de la inferencia acerca de los parámetros del modelo, mientras que la condición de exogeneidad fuerte implica que no existe retroalimentación desde y_t hacia x_t .

2. Variables a considerar como indicadores

En la elaboración de este trabajo se consideró un conjunto de variables económicas factibles de ser utilizadas como indicadores de las series homogéneas correspondientes a los distintos agregados industriales, en consideración de las especificidades de cada uno de ellos. Para ello se tomó en cuenta que la variable indicador representa un proceso relevante para el análisis del fenómeno económico en cuestión y que lo cuantifique de

manera adecuada. Ello resulta relevante debido a que las metodologías de predicción basadas en indicadores pretenden mejorar la precisión de las predicciones y al mismo tiempo se proponen brindar información útil para el diagnóstico y para la toma de decisiones.

Por otra parte, es fundamental que la relación entre el indicador y el grupo industrial que se trate no dependa de la fase del ciclo macroeconómico considerada, o que en caso de que existiera tal dependencia ésta pudiera modelizarse adecuadamente. Asimismo, es deseable, que el comportamiento de los indicadores no se encuentre dominado por movimientos erráticos que pueden provocar distorsiones importantes, sobre todo en el diagnóstico a corto plazo.

Las variables consideradas fueron:

- Índice de Producción Industrial de Argentina
- Índice de Producción Industrial de Brasil
- Tipo de Cambio Real Bilateral con Brasil
- Tipo de Cambio Real Bilateral con Argentina
- Precios en Dólares de Argentina
- Precios en Dólares de Brasil
- Inflación en Dólares Uruguay
- Ingreso Real de los Hogares de Montevideo

Se tuvo en cuenta además, que las variables indicadores se publicaran con periodicidad mensual o que fuera factible llevarlas a dicha frecuencia, y que la publicación de los datos por parte del organismo productor de la estadística no tuviera un rezago tal que las inhabilitara para operar como indicador adelantado. Por otra parte, se tomó en cuenta que dichas variables no estuvieran sujetas a revisiones importantes con posterioridad a la fecha de publicación, debido a que la revisión de los datos preliminares puede acarrear un deterioro del desempeño predictivo y llevar a conclusiones erróneas sobre las perspectivas de evolución de la industria manufacturera en el futuro.

3. Resultados de las estimaciones

En concreto, se realizaron estimaciones de modelos econométricos uniecuacionales para las series homogéneas correspondientes a los cuatro agrupamientos y para el agregado de los mismos (IVF excluida la Refinería de Petróleo). Además de la inclusión de los indicadores que cumplían con las condiciones exigidas, se incluyeron variables de intervención que recogen los efectos determinísticos detallados en el capítulo anterior, siempre que las mismas tuvieran efectos estadísticamente significativos sobre las variables de interés. Los resultados de las estimaciones se presentan en los Cuadros 13 a 16.⁵ Todos los modelos fueron sometidos a los contrastes de diagnóstico habituales. La pertinencia de la inclusión de los indicadores en modelos uniecuacionales fue evaluada a la luz de los contrastes de exogeneidad débil -test de Hausman-, y fuerte -contraste de causalidad a la Granger-, que se presentan en el Anexo Econométrico, dado que estos modelos serán utilizados, no solo para la explicación de la evolución pasada de la industria manufacturera sino para la predicción de su evolución futura.

⁵ Las salidas completas de las estimaciones respectivas se presentan en el Anexo Econométrico.

Cabe destacar que la inclusión de indicadores en los modelos econométricos estimados supuso, en todos los casos, una reducción del error estándar residual. El aporte de los indicadores resultó especialmente importante en el caso de las ramas Exportadoras y en los agrupamientos de sectores Sustitutivos de Importaciones y Bajo Comercio. En el caso del agrupamiento de Comercio Intraindustrial el aporte de los indicadores se reveló menos importante.

En la especificación del modelo econométrico de función de transferencia para el agrupamiento BC se utilizó como indicador adelantado la tasa de inflación en dólares en Uruguay, cuyo efecto sobre la variable de interés opera positivamente, aunque con bastante retraso (seis meses).

En la función de transferencia estimada para el agrupamiento CI, se utilizó como variable indicador el Índice de Producción Industrial (IPI) de la economía argentina.⁶ La incidencia de este indicador (positiva y muy significativa) ocurre contemporáneamente y con rezago (en el sexto retardo) sobre este grupo de industrias.

Por su parte, en la modelización del agrupamiento de ramas Exportadoras se incluyeron como indicadores el Índice de Producción Industrial de Argentina, la inflación en dólares en Argentina y la inflación en dólares en Uruguay. Las dos primeras variables operan sobre la variable de interés en forma positiva y con dos meses de retraso, mientras que la tercera lo hace con tres meses, y, tal como es de esperar, en forma negativa.

Finalmente, en la modelización del IVF del agrupamiento de ramas Sustitutivas de Importaciones resultó estadísticamente significativa la influencia del ingreso medio de los hogares (medido en términos constantes) y el tipo de cambio real bilateral con Argentina. El primero de los indicadores opera lentamente; la ganancia final del filtro de la función de transferencia se sitúa aproximadamente en 0,7, valor que puede ser interpretado como una elasticidad acumulada. El tipo de cambio real bilateral con Argentina opera (positivamente) con bastante retraso, lo que revela que las ganancias de competitividad respecto este país en este segmento de la industria se traducen en mejoras de la producción con bastante retraso.

⁶ Elaborado por el INDEC (Instituto Nacional de Estadística y Censo).

Cuadro 14 - Modelo de función de transferencia para la serie del indicador del IVF de comercio intraindustrial

$$\begin{aligned}
 \Delta\Delta_{12}LIVFCI_t = & -0,0239\Delta\Delta_{12}PAS_t - 0,0092\Delta\Delta_{12}CAR_t - 0,0835\Delta\Delta_{12}DMES_t + \\
 & \quad (-9,87) \quad \quad \quad (-1,70) \quad \quad \quad (-1,46) \\
 & - 0,0532\Delta\Delta_{12}DLU_t + 0,0170\Delta\Delta_{12}DMA_t - 0,0152\Delta\Delta_{12}DMI_t + \\
 & \quad (-5,30) \quad \quad \quad (1,66) \quad \quad \quad (-1,60) \\
 & + 0,0172\Delta\Delta_{12}DJU_t - 0,0125\Delta\Delta_{12}DVI_t + 0,0355\Delta\Delta_{12}DSA_t + \\
 & \quad (1,65) \quad \quad \quad (-1,40) \quad \quad \quad (3,92) \\
 & - 0,2649\Delta\Delta_{12}AO9303_t + 0,2458\Delta\Delta_{12}AO9412_t - 0,2352\Delta\Delta_{12}AO9507_t + \\
 & \quad (-3,82) \quad \quad \quad (3,62) \quad \quad \quad (-3,52) \\
 & + 0,4095\Delta\Delta_{12}LIPIAR_t + 0,4380\Delta\Delta_{12}LIPIAR(-6)_t + 0,1723\Delta\Delta_{12}AO9412_t + \\
 & \quad (2,30) \quad \quad \quad (2,11) \quad \quad \quad (-6) \quad \quad \quad (2,37) \\
 & - 0,2078\Delta\Delta_{12}AO9501_t + 0,1338\Delta\Delta_{12}AO9511_t + 0,2603\Delta\Delta_{12}AO9602_t + \\
 & \quad (-2,79) \quad \quad \quad (3,04) \quad \quad \quad (3,34) \\
 & + 0,2843\Delta\Delta_{12}AO9607_t + 0,1426\Delta\Delta_{12}TC9701_t + 0,0902\Delta\Delta_{12}LS9709_t + \\
 & \quad (9,12) \quad \quad \quad (3,37) \quad \quad \quad (2,66) \\
 & - 0,3407\Delta\Delta_{12}LS9710_t + 0,2875\Delta\Delta_{12}AO9712_t + 0,1865\Delta\Delta_{12}LS9802_t + \\
 & \quad (-9,30) \quad \quad \quad (7,03) \quad \quad \quad (5,52) \\
 & - 0,2593\Delta\Delta_{12}AO9810_t - 0,2469\Delta\Delta_{12}AO0008_t - 0,1453\Delta\Delta_{12}AO0202_t + \\
 & \quad (-6,70) \quad \quad \quad (-7,91) \quad \quad \quad (-2,82) \\
 & - 0,2159\Delta\Delta_{12}TC0212_t + (1 - 0,5787L)(1 + 0,9131L^2)a_t \\
 & \quad (-2,66) \quad \quad \quad (-5,94) \quad \quad \quad (39,62)
 \end{aligned}$$

Muestra: Agosto 1994 – Marzo 2003 (104 observaciones)

Número de residuos: 104

$\hat{\sigma}_a = 0,0649$

t-valor de la media de los residuos: - 0,0387

| | |
|-----------------------------------|-------------|
| Estadísticos de Box-Pierce-Ljung: | Q(14)= 18,5 |
| | Q(26)= 27,4 |
| | Q(38)= 39,4 |

Residuos superiores a $3\hat{\sigma}_a$: 0

(t-valores entre paréntesis)

4. Ganancias derivadas del uso de indicadores a nivel desagregado

Ganancias en precisión

En primer lugar se analizaron las ganancias de precisión en términos predictivos de los modelos de las funciones de transferencia estimadas. Se efectuó la evaluación de las predicciones generadas por los modelos univariantes y por los modelos econométricos fue realizada a partir del cálculo de la raíz de los errores cuadrático medios (RECM). Este criterio es frecuentemente usado para evaluar el desempeño de los modelos, aunque éste no contempla una correcta evaluación del contenido informativo de las predicciones generadas a través de distintos procedimientos. Como se señaló anteriormente, se realizaron los tests correspondientes a la verificación de la hipótesis de exogeneidad fuerte de los indicadores utilizados.

Para la generación de predicciones a horizontes de predicción alejados en el tiempo es necesario utilizar predicciones de los indicadores. Incluso, en algún caso, la información se conoce con retraso respecto a la fecha de publicación del IVF industrial, por lo que no sólo hay que predecir su futuro, sino su presente, e incluso su pasado aún no observado. Este desfase en la publicación de la información de los indicadores puede provocar una pérdida de precisión de las predicciones, que puede llegar a anular las ganancias derivadas del uso de los mismos. Estas consideraciones podrían alertar sobre las ventajas asociadas al uso de indicadores en la predicción de largo plazo, y hace hipotizar que las mismas se manifiesten exclusivamente a corto plazo, y que las mismas se diluyan por completo cuando el analista se interesa en obtener predicciones a medio y largo plazo.

En el Cuadro 17 se presentan los resultados obtenidos a partir de las estimaciones univariadas y las multivariadas de función de transferencia, respectivamente. Las evaluaciones se han realizado a partir del análisis de los errores muestrales correspondientes al periodo comprendido entre junio de 1995 y setiembre de 2002. El estadístico considerado para evaluar las predicciones es RECM(h).

El análisis de los errores cometidos bajo la hipótesis de que los indicadores son conocidos al momento de generar las predicciones confirma, con absoluta nitidez, que los mismos contienen información fundamental para la predicción del desempeño de la industria manufacturera. La inclusión de indicadores en los modelos econométricos estimados supuso, en todos los casos, una reducción del error estándar residual. El aporte de los indicadores resultó especialmente relevante en el caso de las ramas Exportadoras y en los agrupamientos de sectores Sustitutivos de Importaciones y de Bajo Comercio, mientras que el agrupamiento de Comercio Intraindustrial el aporte de los indicadores se reveló menos importante.

A su vez, se determinó el RECM del agregado industrial sin refinería calculado a partir de la agregación de las predicciones que surgían de las estimaciones univariantes y multivariantes de los cuatro grupos industriales. Tal como se puede apreciar en el Cuadro 17, las predicciones del IVF industrial sin Refinería mejoran significativamente cuando provienen de la agregación de los modelos multivariados de función de transferencia, respecto de los univariantes.

| Cuadro 17 - Evaluación de desempeño predictivo de los cuatro modelos | | | | | |
|---|---------------|---------------|----------------|----------------|--------------------|
| Predicciones 1995.06-2002.09 | IVF BC | IVF CI | IVF EXP | IVF IMP | IVF sin Ref |
| Predicciones a un paso modelos univariados | | | | | |
| Raíz del Error Cuadrático Medio (RECM) | 0.052 | 0.079 | 0.047 | 0.066 | 0.045 |
| Predicciones a un paso modelos multivariados | | | | | |
| Raíz del Error Cuadrático Medio (RECM) | 0.046 | 0.065 | 0.036 | 0.045 | 0.022 |

Mejor comprensión del fenómeno

Además del criterio de optimalidad predictiva, las estimaciones realizadas a partir de los modelos uniecuacionales que incorporan variables exógenas como indicadores del comportamiento de las ramas industriales, permiten una mejor comprensión del comportamiento de la industria, tanto por grupo industrial como a nivel global. Los indicadores ofrecen información de interés para la elaboración del diagnóstico de la evolución pasada de la industria y sus perspectivas de evolución en el futuro. El conocimiento de la contribución de los indicadores al comportamiento de los grupos industriales y el análisis de los errores cometidos en la predicción de los mismos, permite realizar una evaluación más completa de las innovaciones que se van produciendo en los agrupamientos y de la forma en que las mismas repercuten en el desempeño industrial global.

Consideraciones finales

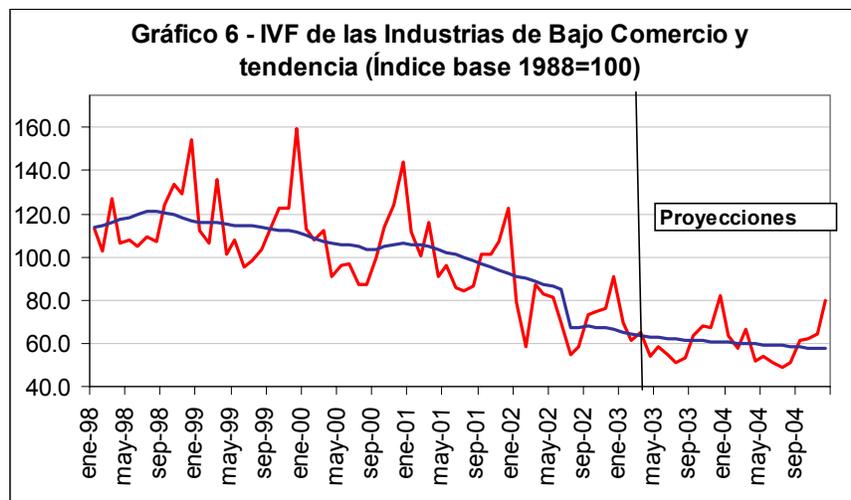
Los resultados expuestos, permiten concluir sobre la conveniencia de analizar y predecir la evolución de la industria manufacturera a partir de su desagregación de acuerdo a los grupos definidos en función de su patrón de especialización y comercio, conjuntamente con la utilización de indicadores adelantados. Tal como se demostró en el apartado IV.4 de este documento, la fundamentación de la desagregación en cuatro grupos industriales se basa en la heterogeneidad que presentan en su comportamiento. Vinculado a ello, son distintos los factores explicativos de su desempeño, y los indicadores adelantados específicos de cada grupo industrial. La evaluación del desempeño predictivo de los modelos econométricos ha puesto en evidencia que una estrategia que combine desagregación e indicadores ofrece ventajas en materia de precisión de las predicciones frente a la alternativa de predicción basada en modelos univariantes para las agrupaciones industriales y a la predicción del IVF industrial agregado.

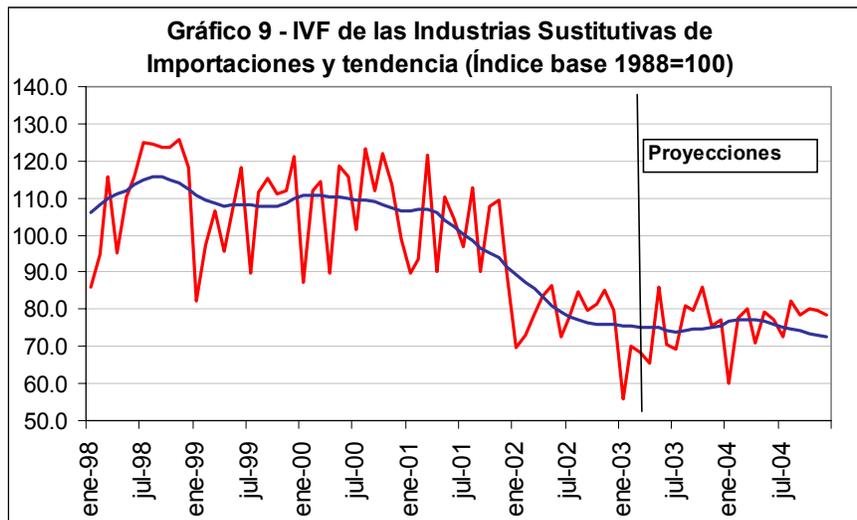
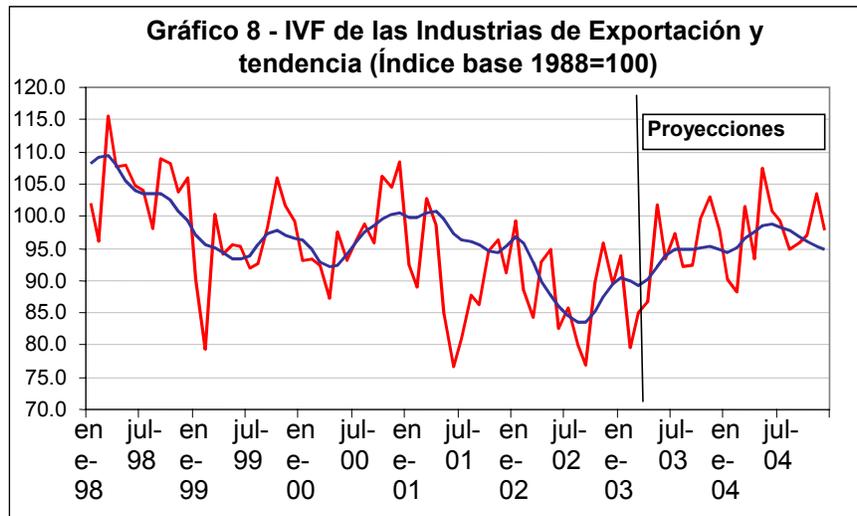
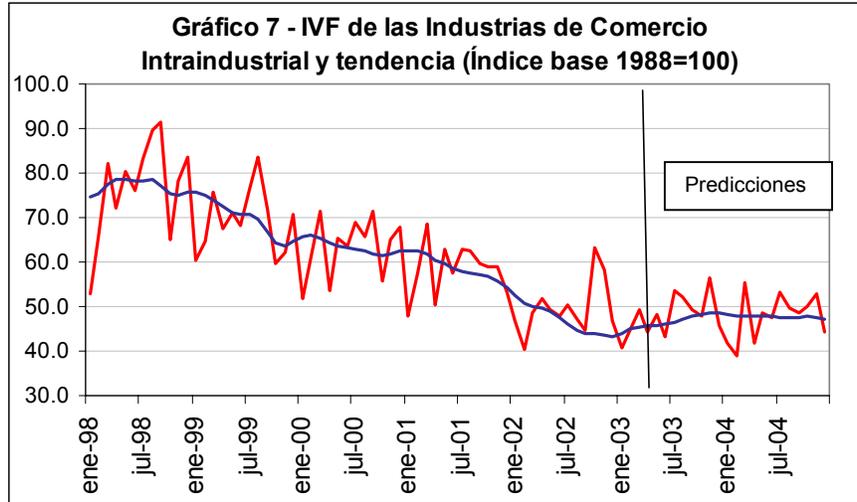
VI. Perspectivas actuales de la industria (2003-2004)

Por último, se presentan las predicciones para los distintos agrupamientos industriales correspondientes al período Abril de 2003 a Diciembre de 2004. Las mismas fueron elaboradas a partir de los modelos multivariantes y la información aportada por los indicadores (sus valores observados y las correspondientes proyecciones).

Los resultados de las estimaciones se presentan en los Gráficos 6 a 9. En ellos se presenta la evolución previsible de los IVF de los distintos grupos industriales, así como las proyecciones del componente de tendencia respectivo. Durante 2003, todos los grupos de industrias experimentarán caídas, salvo el de las exportadoras las cuales expandirán su producción. Las ramas clasificadas como de Bajo Comercio serán las más afectadas y su producción caerá significativamente.

En 2004, el desempeño del conjunto de la industria manufacturera será mejor que en 2003. Tanto el grupo de industrias de exportación como el de las industrias sustitutivas de importaciones experimentarán aumentos de su producción, en tanto que el grupo de industria de comercio intraindustrial caerá, aunque mínimamente.





VII. Referencias bibliográficas

- Box G. y Tiao G. (1975), *Intervention Analysis with Applications to Economic and Environmental Problems*. Journal of the American Statistical Association, vol.70, 70-79.
- Engle R y Granger C. (1987), *Cointegration and error correction. Representation, estimation and testing*. Econometrica, 55, 251-276.
- Espasa A., Rojo M, Morales E. (1990), *Métodos cuantitativos para el análisis de la actividad industrial española*. Investigaciones Económicas (Segunda época) Suplemento, pp 63-70.
- Espasa A y Cancelo J.R. (eds.) (1993), *Métodos cuantitativos para el análisis de la coyuntura económica*. Alianza Económica.
- García Martos D. y Navarro A. (1994), *Incidencia del calendario laboral en las series de producción industrial*. D.G. Previsión y Coyuntura/Síntesis Mensual de Indicadores económicos.
- Grosskoff R., Fernandez A., Selves R., y Villamonte G. (1994), *Caracterización de series de producción industrial en el Uruguay. Utilización de modelos ARIMA con análisis de intervención*. Revista Quantum Vol 1 N° 2 (pp109-127).
- Hamilton, J. (1994), *Time Series Analysis*. Princeton University Press.
- Hendry, D.F. (1995), *Dynamic Econometrics*, Oxford, Oxford University Press.
- Instituto Nacional de Estadística (1996), *Metodología de la Encuesta Industrial Trimestral. Base Año 1988*. INE.
- Johansen S. (1988), *Statistical analysis of cointegration vectors*. Journal of Dynamics and Control, 12,231-254.
- Johansen S. (1995), *Likelihood-based inference in cointegrated vector auto-regressive models*, Oxford, Oxford University Press.
- Laens S y Osimani R. (2000), *Patrones de comercio y desempeño exportador, el caso de Uruguay en los noventa*. CINVE
- Morales E y Espasa A (1992a), *Análisis coyuntural de la actividad industrial en España*.
- Morales E., Espasa A., Rojo M.L. (1992b), *Univariate methods for the analysis of the industrial sector in Spain*. Investigaciones Económicas (Segunda época). Vol. XVI N° 1 (1992), pp. 127-149.
- Revilla P., Rey P, Espasa A., (1989), *Characterization of production in different branches of Spanish industrial activity by means of time series analysis*. Paper presented at the European Meeting of the Econometric Society, Munich.

Zellner A (1979), *Statistical analysis of econometric models* Journal of the American Statistical Association, Vol. 74, 628-651.

Anexo 1: Detalle de las variables utilizadas

Las variables utilizadas al estimar los modelos fueron las siguientes:

LIVFBC: Transformación logarítmica del índice de volumen físico de las industrias de bajo comercio.

LIVFCI: Transformación logarítmica del índice de volumen físico de las industrias de comercio intraindustrial.

LIVFEXP: Transformación logarítmica del índice de volumen físico de las industrias exportadoras.

LIVFIMP: Transformación logarítmica del índice de volumen físico de las industrias sustitutivas de importaciones.

PAS: Variable que incorpora el número de días de Pascua que caen en marzo y/o abril.

CAR: Variable que incorpora el número de días de Carnaval.

PAR: Variable que incorpora el número de paros o huelgas en cada mes.

VIE: Variable *dummy* que representa cuando un feriado cae el día viernes.

DLU, ..., *DSA*: Variables que representan el día lunes, martes, ..., sábado.

MES: Variable que incorpora el número de días de cada mes.

LINFDU: Transformación logarítmica de la inflación en dólares de Uruguay.

LIPIAR: Transformación logarítmica del índice de producción industrial de Argentina.

LPDA: Transformación logarítmica de los precios en dólares de Argentina.

LYHOG: Transformación logarítmica de los ingresos de los hogares de Montevideo en términos constantes.

LTCRAR: Transformación logarítmica del tipo de cambio real bilateral con Argentina.

AO0201: Variable *dummy* representando un impulso en enero del año 2002.

LS0201: Variable *dummy* representando un escalón en enero del año 2002.

TC0201: Variable *dummy* representando un cambio transitorio en enero del año 2002.

VIII. Anexo econométrico

Test de Johansen entre los agregados industriales

Cointegration analysis 1985-04 to 2003-03

| eigenvalue | loglik | for rank |
|------------|---------|----------|
| | 1916.94 | 0 |
| 0.401481 | 1970.84 | 1 |
| 0.385193 | 2021.91 | 2 |
| 0.277807 | 2056.09 | 3 |
| 0.200182 | 2079.54 | 4 |

| Ho:rank=p | -Tlog(1-\mu) | using T-nm | 95% | -T\Sum log(.) | using T-nm | 95% |
|-----------|--------------|------------|------|---------------|------------|------|
| p == 0 | 107.8** | 95.47** | 27.1 | 325.2** | 288** | 47.2 |
| p <= 1 | 102.2** | 90.48** | 21.0 | 217.4** | 192.6** | 29.7 |
| p <= 2 | 68.35** | 60.54** | 14.1 | 115.3** | 102.1** | 15.4 |
| p <= 3 | 46.91** | 41.55** | 3.8 | 46.91** | 41.55** | 3.8 |

standardized \beta' eigenvectors

| DLBC | DLCI | DLEXP | DLIMP |
|-----------|----------|------------|----------|
| 1.0000 | 0.050417 | -0.0077097 | -0.14532 |
| 0.34326 | 1.0000 | 0.45155 | 0.079938 |
| -0.061242 | -0.87420 | 1.0000 | 0.76385 |
| 0.068668 | -0.32986 | -1.0810 | 1.0000 |

standardized \alpha coefficients

| | | | | |
|-------|----------|---------|----------|----------|
| DLBC | -2.5600 | 0.45743 | -0.44480 | 0.64092 |
| DLCI | -1.5061 | -2.0031 | 1.0872 | -0.25091 |
| DLEXP | -0.40816 | -1.0486 | -1.1538 | 0.54355 |
| DLIMP | -1.5218 | -1.0315 | -1.0392 | -1.4926 |

long-run matrix $Po = \alpha * \beta'$, rank 4

| | DLBC | DLCI | DLEXP | DLIMP |
|-------|----------|----------|----------|----------|
| DLBC | -2.3318 | 0.50580 | -0.91138 | 0.70974 |
| DLCI | -2.2775 | -2.9468 | 0.46556 | 0.63830 |
| DLEXP | -0.66012 | -0.23985 | -2.2117 | -0.36227 |
| DLIMP | -1.9147 | 0.29260 | 0.12027 | -2.1477 |

Number of lags used in the analysis: 6

Variables entered unrestricted:

Constant

Modelización univariante

Dependent Variable: D(LOG(IVFBC),1,12)

Method: Least Squares

Sample(adjusted): 1987:05 2003:03

Included observations: 191 after adjusting endpoints

Convergence achieved after 13 iterations

Backcast: 1987:03 1987:04

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|---------------------|-------------|-----------------------|-------------|-----------|
| D(PASCUA,1,12) | -0.015903 | 0.002164 | -7.348361 | 0.0000 |
| D(CARNA,1,12) | -0.013238 | 0.002524 | -5.245546 | 0.0000 |
| D(PAROS,1,12) | -0.028581 | 0.006909 | -4.136863 | 0.0001 |
| D(VIERNES,1,12) | -0.039591 | 0.012058 | -3.283272 | 0.0012 |
| D(DLU,1,12) | -7.50E-05 | 0.007277 | -0.010313 | 0.9918 |
| D(DMA,1,12) | -0.007036 | 0.007052 | -0.997624 | 0.3199 |
| D(DMIE,1,12) | 0.005082 | 0.006847 | 0.742141 | 0.4590 |
| D(DJU,1,12) | 0.015823 | 0.006669 | 2.372751 | 0.0188 |
| D(DVIE,1,12) | -0.001236 | 0.006642 | -0.186047 | 0.8526 |
| D(DSA,1,12) | -0.014200 | 0.006776 | -2.095771 | 0.0376 |
| D(AFE>=198607,1,12) | 0.143719 | 0.059689 | 2.407815 | 0.0171 |
| D(AFE=199008,1,12) | -0.124452 | 0.039250 | -3.170788 | 0.0018 |
| D(AFE=199208,1,12) | -0.128123 | 0.039235 | -3.265564 | 0.0013 |
| D(AFE>=200207,1,12) | -0.210614 | 0.042259 | -4.983912 | 0.0000 |
| D(AFE=200202,1,12) | -0.308311 | 0.044985 | -6.853626 | 0.0000 |
| D(AFE=200201,1,12) | -0.192059 | 0.041851 | -4.589174 | 0.0000 |
| D(AFE=199903,1,12) | 0.134829 | 0.038049 | 3.543550 | 0.0005 |
| D(AFE=199604,1,12) | 0.096470 | 0.039079 | 2.468600 | 0.0146 |
| D(AFE>=199601,1,12) | -0.083204 | 0.034975 | -2.378970 | 0.0185 |
| AR(1) | -0.583887 | 0.073588 | -7.934583 | 0.0000 |
| SAR(12) | -0.510960 | 0.067803 | -7.535892 | 0.0000 |
| MA(2) | -0.277030 | 0.087769 | -3.156354 | 0.0019 |
| R-squared | 0.756100 | Mean dependent var | -0.002144 | |
| Adjusted R-squared | 0.725793 | S.D. dependent var | 0.095702 | |
| S.E. of regression | 0.050114 | Akaike info criterion | -3.041032 | |
| Sum squared resid | 0.424432 | Schwarz criterion | -2.666425 | |
| Log likelihood | 312.4186 | Durbin-Watson stat | 1.962143 | |
| Inverted AR Roots | .91 -.24i | .91+.24i | .67+.67i | .67 -.67i |
| | .24 -.91i | .24+.91i | -.24 -.91i | -.24+.91i |
| | -.58 | -.67 -.67i | -.67 -.67i | -.91+.24i |
| | -.91 -.24i | | | |
| Inverted MA Roots | .53 | -.53 | | |

Dependent Variable: D(LOG(IVFCI),1,12)

Method: Least Squares

Sample(adjusted): 1986:04 2003:03

Included observations: 204 after adjusting endpoints

Convergence achieved after 11 iterations

Backcast: 1985:03 1986:03

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|---------------------|-------------|-----------------------|-------------|------------|
| D(PASCUA,1,12) | -0.022609 | 0.003664 | -6.170927 | 0.0000 |
| D(CARNA,1,12) | -0.017104 | 0.004296 | -3.981093 | 0.0001 |
| D(DLU,1,12) | -0.008734 | 0.011547 | -0.756406 | 0.4504 |
| D(DMA,1,12) | 0.006477 | 0.011599 | 0.558403 | 0.5773 |
| D(DMIE,1,12) | 0.006718 | 0.011835 | 0.567619 | 0.5710 |
| D(DJU,1,12) | 0.010659 | 0.011809 | 0.902650 | 0.3679 |
| D(DVIE,1,12) | -0.003641 | 0.011294 | -0.322412 | 0.7475 |
| D(DSA,1,12) | 0.011837 | 0.011465 | 1.032451 | 0.3032 |
| D(DMES,1,12) | -0.035618 | 0.043406 | -0.820576 | 0.4130 |
| D(AFE=199412,1,12) | 0.245842 | 0.067869 | 3.622278 | 0.0004 |
| D(AFE=199507,1,12) | -0.235241 | 0.066771 | -3.523098 | 0.0005 |
| D(AFE=199602,1,12) | 0.291021 | 0.080222 | 3.627696 | 0.0004 |
| D(TC9604,1,12) | -0.226222 | 0.069835 | -3.239387 | 0.0014 |
| D(AFE=199709,1,12) | 0.243234 | 0.068320 | 3.560202 | 0.0005 |
| D(AFE=199712,1,12) | 0.249367 | 0.070328 | 3.545759 | 0.0005 |
| D(AFE>=199802,1,12) | 0.174696 | 0.065904 | 2.650777 | 0.0087 |
| D(AFE=199810,1,12) | -0.236924 | 0.068050 | -3.481616 | 0.0006 |
| D(AFE=200210,1,12) | 0.321690 | 0.074775 | 4.302089 | 0.0000 |
| D(AFE=199303,1,12) | -0.264890 | 0.069414 | -3.816093 | 0.0002 |
| D(AFE=200211,1,12) | 0.221234 | 0.074084 | 2.986250 | 0.0032 |
| MA(1) | -0.563217 | 0.065703 | -8.572151 | 0.0000 |
| SMA(12) | -0.730497 | 0.052925 | -13.80244 | 0.0000 |
| R-squared | 0.792951 | Mean dependent var | 0.000678 | |
| Adjusted R-squared | 0.769060 | S.D. dependent var | 0.165217 | |
| S.E. of regression | 0.079397 | Akaike info criterion | -2.127144 | |
| Sum squared resid | 1.147302 | Schwarz criterion | -1.769307 | |
| Log likelihood | 238.9686 | Durbin-Watson stat | 1.932486 | |
| Inverted MA Roots | .97 | .84+.49i | .84 -.49i | .56 |
| | .49+.84i | .49 -.84i | .00+.97i | -.00 -.97i |
| | -.49 -.84i | -.49+.84i | -.84 -.49i | -.84+.49i |
| | -.97 | | | |

Dependent Variable: D(LOG(IVFEXP),1,12)

Method: Least Squares

Sample(adjusted): 1987:04 2003:03

Included observations: 192 after adjusting endpoints

Convergence achieved after 11 iterations

Backcast: 1987:03

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|---------------------|-------------|-----------------------|-------------|------------|
| D(PASCUA,1,12) | -0.009852 | 0.001838 | -5.360727 | 0.0000 |
| D(CARNA,1,12) | -0.005703 | 0.002239 | -2.547080 | 0.0117 |
| D(DLU,1,12) | -0.006551 | 0.005824 | -1.124972 | 0.2622 |
| D(DMA,1,12) | 0.010373 | 0.005844 | 1.774933 | 0.0777 |
| D(DMIE,1,12) | 0.009421 | 0.005839 | 1.613518 | 0.1085 |
| D(DJU,1,12) | 0.002515 | 0.005686 | 0.442245 | 0.6589 |
| D(DVIE,1,12) | 0.001885 | 0.005542 | 0.340175 | 0.7341 |
| D(DSA,1,12) | 0.000825 | 0.005598 | 0.147375 | 0.8830 |
| D(DMES,1,12) | 0.045596 | 0.020411 | 2.233859 | 0.0268 |
| D(TC8802,1,12) | 0.156377 | 0.043213 | 3.618713 | 0.0004 |
| D(AFE=199112,1,12) | -0.102190 | 0.034873 | -2.930351 | 0.0038 |
| D(TC9206,1,12) | 0.114843 | 0.038589 | 2.976060 | 0.0033 |
| D(AFE>=200105,1,12) | -0.252354 | 0.040412 | -6.244450 | 0.0000 |
| D(TC0201,1,12) | 0.120092 | 0.041815 | 2.871974 | 0.0046 |
| D(AFE=198704,1,12) | -0.104790 | 0.037642 | -2.783861 | 0.0060 |
| D(AFE>=198808,1,12) | 0.107034 | 0.038995 | 2.744801 | 0.0067 |
| D(AFE>=198812,1,12) | 0.093605 | 0.038571 | 2.426784 | 0.0163 |
| AR(12) | -0.344986 | 0.069779 | -4.943998 | 0.0000 |
| MA(1) | -0.382546 | 0.072911 | -5.246778 | 0.0000 |
| R-squared | 0.687459 | Mean dependent var | -0.000499 | |
| Adjusted R-squared | 0.654940 | S.D. dependent var | 0.086119 | |
| S.E. of regression | 0.050588 | Akaike info criterion | -3.036504 | |
| Sum squared resid | 0.442727 | Schwarz criterion | -2.714147 | |
| Log likelihood | 310.5044 | Durbin-Watson stat | 1.969708 | |
| Inverted AR Roots | .88+.24i | .88 -.24i | .65+.65i | .65 -.65i |
| | .24+.88i | .24 -.88i | -.24 -.88i | -.24+.88i |
| | -.65+.65i | -.65+.65i | -.88+.24i | -.88 -.24i |
| Inverted MA Roots | .38 | | | |

Dependent Variable: D(LOG(IVFIMP),1,12)

Method: Least Squares

Sample(adjusted): 1987:04 2003:03

Included observations: 192 after adjusting endpoints

Convergence achieved after 11 iterations

Backcast: 1987:03

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|---------------------|-------------|-----------------------|-------------|-----------|
| D(PASCUA,1,12) | -0.022123 | 0.002903 | -7.620696 | 0.0000 |
| D(CARNA,1,12) | -0.016285 | 0.003157 | -5.158887 | 0.0000 |
| D(PAROS,1,12) | -0.034412 | 0.009475 | -3.631992 | 0.0004 |
| D(VIERNES,1,12) | -0.041607 | 0.017214 | -2.417038 | 0.0167 |
| D(DLU,1,12) | 0.009875 | 0.009577 | 1.031149 | 0.3039 |
| D(DMA,1,12) | 0.009456 | 0.009341 | 1.012314 | 0.3128 |
| D(DMIE,1,12) | 0.003134 | 0.009122 | 0.343506 | 0.7316 |
| D(DJU,1,12) | 0.024165 | 0.008822 | 2.739287 | 0.0068 |
| D(DVIE,1,12) | 0.006456 | 0.008755 | 0.737482 | 0.4618 |
| D(DSA,1,12) | -0.022353 | 0.009084 | -2.460690 | 0.0148 |
| D(AFE=198812,1,12) | -0.202756 | 0.052196 | -3.884481 | 0.0001 |
| D(AFE>=199404,1,12) | 0.232720 | 0.050391 | 4.618287 | 0.0000 |
|) | | | | |
| D(AFE=199501,1,12) | -0.255839 | 0.052557 | -4.867806 | 0.0000 |
| D(AFE>=199507,1,12) | -0.205638 | 0.049505 | -4.153917 | 0.0001 |
|) | | | | |
| D(AFE=199907,1,12) | -0.206608 | 0.052278 | -3.952137 | 0.0001 |
| D(AFE=198903,1,12) | -0.153436 | 0.054964 | -2.791590 | 0.0058 |
| D(AFE=199308,1,12) | 0.130569 | 0.053367 | 2.446622 | 0.0154 |
| AR(12) | -0.424416 | 0.071353 | -5.948153 | 0.0000 |
| MA(1) | -0.539929 | 0.066551 | -8.113024 | 0.0000 |
| R-squared | 0.822026 | Mean dependent var | -0.002112 | |
| Adjusted R-squared | 0.803508 | S.D. dependent var | 0.159313 | |
| S.E. of regression | 0.070619 | Akaike info criterion | -2.369316 | |
| Sum squared resid | 0.862764 | Schwarz criterion | -2.046959 | |
| Log likelihood | 246.4543 | Durbin-Watson stat | 2.001951 | |
| Inverted AR Roots | .90+.24i | .90-.24i | .66-.66i | .66+.66i |
| | .24+.90i | .24-.90i | -.24+.90i | -.24-.90i |
| | -.66+.66i | -.66+.66i | -.90-.24i | -.90+.24i |
| Inverted MA Roots | .54 | | | |

Modelización multivariante de los agregados

Dependent Variable: D(LOG(IVFBC),1,12)

Method: Least Squares

Sample(adjusted): 1986:10 2003:03

Included observations: 198 after adjusting endpoints

Convergence achieved after 8 iterations

Backcast: 1985:09 1986:09

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|------------------------|-------------|-----------------------|-------------|------------|
| D(PASCUA,1,12) | -0.015139 | 0.001941 | -7.798796 | 0.0000 |
| D(CARNA,1,12) | -0.009650 | 0.002228 | -4.331705 | 0.0000 |
| D(PAROS,1,12) | -0.027927 | 0.006202 | -4.502730 | 0.0000 |
| D(VIERNES,1,12) | -0.035528 | 0.012260 | -2.897970 | 0.0043 |
| D(DLU,1,12) | -0.001371 | 0.006729 | -0.203832 | 0.8387 |
| D(DMA,1,12) | -0.004998 | 0.006534 | -0.764916 | 0.4454 |
| D(DMIE,1,12) | 0.000290 | 0.006360 | 0.045634 | 0.9637 |
| D(DJU,1,12) | 0.017841 | 0.006134 | 2.908380 | 0.0041 |
| D(DVIE,1,12) | 0.000873 | 0.005971 | 0.146167 | 0.8840 |
| D(DSA,1,12) | -0.015109 | 0.006035 | -2.503505 | 0.0132 |
| D(DMES,1,12) | 0.040762 | 0.019488 | 2.091613 | 0.0380 |
| D(LOG(INFDU(-6)),1,12) | 0.255871 | 0.106699 | 2.398059 | 0.0176 |
| D(AFE>=198607,1,12) | 0.139011 | 0.041030 | 3.388014 | 0.0009 |
| D(AFE=199008,1,12) | -0.125322 | 0.035663 | -3.514087 | 0.0006 |
| D(AFE=199208,1,12) | -0.109988 | 0.035318 | -3.114207 | 0.0022 |
| D(AFE=199307,1,12) | -0.085940 | 0.035508 | -2.420281 | 0.0166 |
| D(TC9601,1,12) | -0.106876 | 0.038456 | -2.779198 | 0.0061 |
| D(AFE=199604,1,12) | 0.102751 | 0.037103 | 2.769339 | 0.0062 |
| D(AFE>=199507,1,12) | -0.076699 | 0.036394 | -2.107469 | 0.0365 |
| D(AFE>=199701,1,12) | 0.077632 | 0.036852 | 2.106563 | 0.0366 |
| D(AFE=199801,1,12) | -0.081742 | 0.035838 | -2.280907 | 0.0238 |
| D(AFE=199903,1,12) | 0.148519 | 0.036002 | 4.125267 | 0.0001 |
| D(AFE>=200011,1,12) | 0.076213 | 0.036945 | 2.062841 | 0.0406 |
| D(AFE=200201,1,12) | -0.201806 | 0.038333 | -5.264578 | 0.0000 |
| D(AFE=200202,1,12) | -0.341616 | 0.039026 | -8.753603 | 0.0000 |
| D(AFE>=200207,1,12) | -0.223459 | 0.039318 | -5.683352 | 0.0000 |
| MA(1) | -0.461629 | 0.067168 | -6.872721 | 0.0000 |
| SMA(12) | -0.695265 | 0.049565 | -14.02743 | 0.0000 |
| R-squared | 0.822047 | Mean dependent var | -0.002629 | |
| Adjusted R-squared | 0.793784 | S.D. dependent var | 0.095615 | |
| S.E. of regression | 0.043420 | Akaike info criterion | -3.305456 | |
| Sum squared resid | 0.320493 | Schwarz criterion | -2.840449 | |
| Log likelihood | 355.2402 | F-statistic | 29.08555 | |
| Durbin-Watson stat | 2.058904 | Prob(F-statistic) | 0.000000 | |
| Inverted MA Roots | .97 | .84+.49i | .84 -.49i | .49+.84i |
| | .49 -.84i | .46 | .00+.97i | -.00 -.97i |
| | -.49 -.84i | -.49+.84i | -.84 -.49i | -.84+.49i |
| | -.97 | | | |

Dependent Variable: D(LOG(IVFCI),1,12)

Method: Least Squares

Sample(adjusted): 1994:08 2003:03

Included observations: 104 after adjusting endpoints

Convergence achieved after 30 iterations

Backcast: 1993:07 1994:07

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|------------------------|-------------|-----------------------|-------------|------------|
| D(PASCUA,1,12) | -0.023941 | 0.002426 | -9.868380 | 0.0000 |
| D(CARNA,1,12) | -0.009184 | 0.005391 | -1.703550 | 0.0925 |
| D(DLU,1,12) | -0.053204 | 0.010045 | -5.296542 | 0.0000 |
| D(DMA,1,12) | 0.016986 | 0.010223 | 1.661500 | 0.1007 |
| D(DMIE,1,12) | -0.015205 | 0.009526 | -1.596071 | 0.1146 |
| D(DJU,1,12) | 0.017226 | 0.010428 | 1.651916 | 0.1026 |
| D(DVIE,1,12) | -0.012501 | 0.008899 | -1.404733 | 0.1641 |
| D(DSA,1,12) | 0.035523 | 0.009068 | 3.917589 | 0.0002 |
| D(DMES,1,12) | -0.083471 | 0.057077 | -1.462436 | 0.1477 |
| D(LOG(IPIAR),1,12) | 0.409473 | 0.177986 | 2.300592 | 0.0241 |
| D(LOG(IPIAR(-6)),1,12) | 0.438010 | 0.207706 | 2.108798 | 0.0382 |
| D(AFE=199412,1,12) | 0.172297 | 0.072603 | 2.373120 | 0.0201 |
| D(AFE=199501,1,12) | -0.207839 | 0.074625 | -2.785114 | 0.0067 |
| D(AFE=199511,1,12) | 0.133779 | 0.043938 | 3.044737 | 0.0032 |
| D(AFE=199602,1,12) | 0.260333 | 0.077944 | 3.339984 | 0.0013 |
| D(AFE=199607,1,12) | 0.284250 | 0.031170 | 9.119384 | 0.0000 |
| D(TC9701,1,12) | 0.142614 | 0.042360 | 3.366732 | 0.0012 |
| D(AFE>=199709,1,12) | 0.090213 | 0.033936 | 2.658325 | 0.0095 |
| D(AFE>=199710,1,12) | -0.340743 | 0.036625 | -9.303481 | 0.0000 |
| D(AFE=199712,1,12) | 0.287456 | 0.040867 | 7.033974 | 0.0000 |
| D(AFE>=199802,1,12) | 0.186547 | 0.033818 | 5.516151 | 0.0000 |
| D(AFE=199810,1,12) | -0.259327 | 0.038686 | -6.703458 | 0.0000 |
| D(AFE=200008,1,12) | -0.246894 | 0.031202 | -7.912695 | 0.0000 |
| D(AFE=200202,1,12) | -0.145275 | 0.051586 | -2.816147 | 0.0062 |
| D(TC0212,1,12) | -0.215908 | 0.081026 | -2.664682 | 0.0094 |
| MA(1) | -0.578736 | 0.097417 | -5.940806 | 0.0000 |
| SMA(12) | 0.913115 | 0.023049 | 39.61649 | 0.0000 |
| R-squared | 0.884854 | Mean dependent var | 0.000417 | |
| Adjusted R-squared | 0.845974 | S.D. dependent var | 0.191543 | |
| S.E. of regression | 0.075173 | Akaike info criterion | -2.119398 | |
| Sum squared resid | 0.435128 | Schwarz criterion | -1.432873 | |
| Log likelihood | 137.2087 | Durbin-Watson stat | 1.871773 | |
| Inverted MA Roots | .96+.26i | .96 -.26i | .70+.70i | .70+.70i |
| | .58 | .26 -.96i | .26+.96i | -.26+.96i |
| | -.26 -.96i | -.70 -.70i | -.70 -.70i | -.96 -.26i |
| | -.96+.26i | | | |

Dependent Variable: D(LOG(IVFEXP),1,12)

Method: Least Squares

Sample(adjusted): 1995:06 2003:03

Included observations: 94 after adjusting endpoints

Convergence achieved after 23 iterations

White Heteroskedasticity-Consistent Standard Errors & Covariance

Backcast: 1995:04 1995:05

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|------------------------|-------------|-----------------------|-------------|------------|
| D(PASCUA,1,12) | -0.014440 | 0.002681 | -5.385595 | 0.0000 |
| D(CARNA,1,12) | -0.010211 | 0.003031 | -3.368868 | 0.0012 |
| D(DLU,1,12) | -0.010960 | 0.006417 | -1.708063 | 0.0919 |
| D(DMA,1,12) | 0.005308 | 0.006480 | 0.819072 | 0.4154 |
| D(DMIE,1,12) | 0.011355 | 0.006628 | 1.713071 | 0.0909 |
| D(DJU,1,12) | 0.009754 | 0.006594 | 1.479327 | 0.1434 |
| D(DVIE,1,12) | -0.009673 | 0.007529 | -1.284790 | 0.2029 |
| D(DSA,1,12) | -0.000183 | 0.006627 | -0.027577 | 0.9781 |
| D(DMES,1,12) | 0.046718 | 0.019860 | 2.352406 | 0.0214 |
| D(LOG(IPIAR(-2)),1,12) | 0.234326 | 0.101090 | 2.317992 | 0.0233 |
| D(LOG(PDA(-2)),1,12) | 0.157275 | 0.082804 | 1.899367 | 0.0615 |
| D(LOG(INFDU(-3)),1,12) | -0.353126 | 0.155217 | -2.275052 | 0.0258 |
| D(AFE=199709,1,12) | 0.066297 | 0.025464 | 2.603501 | 0.0112 |
| D(AFE=200012,1,12) | 0.103514 | 0.030150 | 3.433340 | 0.0010 |
| D(AFE>=200105,1,12) | -0.327645 | 0.048352 | -6.776188 | 0.0000 |
| D(TC0201,1,12) | 0.118862 | 0.032127 | 3.699725 | 0.0004 |
| D(AFE=200301,1,12) | 0.142677 | 0.043665 | 3.267550 | 0.0017 |
| AR(1) | -0.341411 | 0.089759 | -3.803640 | 0.0003 |
| AR(2) | -0.681990 | 0.084562 | -8.064995 | 0.0000 |
| SAR(12) | -0.388400 | 0.116157 | -3.343750 | 0.0013 |
| MA(2) | 0.953905 | 0.037580 | 25.38335 | 0.0000 |
| R-squared | 0.828846 | Mean dependent var | 0.000226 | |
| Adjusted R-squared | 0.781954 | S.D. dependent var | 0.087498 | |
| S.E. of regression | 0.040857 | Akaike info criterion | -3.363490 | |
| Sum squared resid | 0.121860 | Schwarz criterion | -2.795307 | |
| Log likelihood | 179.0840 | F-statistic | 17.67580 | |
| Durbin-Watson stat | 1.890845 | Prob(F-statistic) | 0.000000 | |
| Inverted AR Roots | .89 -.24i | .89+.24i | .65+.65i | .65 -.65i |
| | .24+.89i | .24 -.89i | -.17+.81i | -.17 -.81i |
| | -.24 -.89i | -.24+.89i | -.65+.65i | -.65+.65i |
| | -.89+.24i | -.89 -.24i | | |

Dependent Variable: D(LOG(IVFIMP),1,12)

Method: Least Squares

Sample(adjusted): 1990:03 2003:03

Included observations: 157 after adjusting endpoints

Convergence achieved after 14 iterations

Backcast: 1989:01 1990:02

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|------------------------|-------------|-----------------------|-------------|------------|
| D(PASCUA,1,12) | -0.017316 | 0.002032 | -8.521214 | 0.0000 |
| D(PAROS,1,12) | -0.032213 | 0.008373 | -3.847086 | 0.0002 |
| D(VIERNES,1,12) | -0.064346 | 0.018993 | -3.387813 | 0.0009 |
| D(DLU,1,12) | -0.018260 | 0.008611 | -2.120541 | 0.0359 |
| D(DMA,1,12) | 0.042525 | 0.008591 | 4.949814 | 0.0000 |
| D(DMIE,1,12) | -0.018676 | 0.008076 | -2.312435 | 0.0224 |
| D(DJU,1,12) | 0.025599 | 0.008205 | 3.119829 | 0.0022 |
| D(DVIE,1,12) | 0.026999 | 0.008556 | 3.155668 | 0.0020 |
| D(DSA,1,12) | -0.037935 | 0.007955 | -4.768698 | 0.0000 |
| D(DMES,1,12) | 0.096311 | 0.025378 | 3.795073 | 0.0002 |
| D(LOG(YHOGK),1,1) | -0.129260 | 0.022135 | -5.839573 | 0.0000 |
| D(LOG(YHOGK(-1)),1,1) | 0.292688 | 0.069042 | 4.239257 | 0.0000 |
| D(LOG(YHOGK(-4)),1,1) | 0.397423 | 0.099790 | 3.982600 | 0.0001 |
| D(LOG(YHOGK(-7)),1,1) | 0.129579 | 0.078158 | 1.657907 | 0.0998 |
| D(LOG(TCRAR(-6)),1,12) | 0.062365 | 0.033900 | 1.839651 | 0.0682 |
| D(AFE=199208,1,12) | -0.155187 | 0.041402 | -3.748267 | 0.0003 |
| D(TC9307,1,12) | 0.125643 | 0.047861 | 2.625142 | 0.0097 |
| D(AFE>=199404,1,12) | 0.209268 | 0.047371 | 4.417662 | 0.0000 |
| D(AFE=199501,1,12) | -0.409142 | 0.040889 | -10.00623 | 0.0000 |
| D(AFE>=199503,1,12) | -0.200343 | 0.051013 | -3.927282 | 0.0001 |
| D(AFE=199505,1,12) | 0.157654 | 0.047088 | 3.348104 | 0.0011 |
| D(AFE=199607,1,12) | 0.191886 | 0.039048 | 4.914123 | 0.0000 |
| D(AFE=199611,1,12) | 0.123253 | 0.039920 | 3.087469 | 0.0025 |
| D(AFE=199907,1,12) | -0.133857 | 0.040341 | -3.318131 | 0.0012 |
| D(AFE>=200109,1,12) | -0.114626 | 0.048329 | -2.371775 | 0.0192 |
| D(AFE>=200201,1,12) | -0.104777 | 0.047439 | -2.208663 | 0.0290 |
| D(AFE=200210,1,12) | -0.135746 | 0.038105 | -3.562446 | 0.0005 |
| D(TC0212,1,12) | -0.115049 | 0.044126 | -2.607309 | 0.0102 |
| AR(3) | 0.478310 | 0.095900 | 4.987578 | 0.0000 |
| MA(1) | -0.299100 | 0.087339 | -3.424570 | 0.0008 |
| MA(2) | -0.404315 | 0.069244 | -5.838975 | 0.0000 |
| SMA(12) | -0.923078 | 0.019808 | -46.60236 | 0.0000 |
| R-squared | 0.916593 | Mean dependent var | | 0.000217 |
| Adjusted R-squared | 0.895909 | S.D. dependent var | | 0.162061 |
| S.E. of regression | 0.052286 | Akaike info criterion | | -2.884457 |
| Sum squared resid | 0.341731 | Schwarz criterion | | -2.261528 |
| Log likelihood | 258.4299 | Durbin-Watson stat | | 1.942836 |
| Inverted AR Roots | .78 | -.39+.68i | -.39 -.68i | |
| Inverted MA Roots | .99 | .86+.50i | .86 -.50i | .80 |
| | .50+.86i | .50 -.86i | .00+.99i | -.00 -.99i |
| | -.50+.86i | -.50 -.86i | -.50 | -.86 -.50i |
| | -.86+.50i | -.99 | | |

Contrastes de exogeneidad

Exogeneidad débil: test de Hausman

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|------------|-------------|------------|-------------|--------|
| RESIDIPIAR | 0.084294 | 0.104937 | 0.803281 | 0.4244 |
| RESYHK | 0.062702 | 0.098238 | 0.638271 | 0.5246 |

Exogeneidad fuerte: contraste de causalidad a la Granger

| Pairwise Granger Causality Tests | | | |
|---|-----|-------------|-------------|
| Null Hypothesis: | Obs | F-Statistic | Probability |
| Sample: 1986:10 2004:12 | 198 | | |
| Lags: 6 | | | |
| D(LOG(IVFBC),1,12) does not Granger Cause D(LOG(INFDU),1,12) | | 136,863 | 0.22937 |
| Sample: 1986:10 2004:12 | 98 | | |
| Lags: 12 | | | |
| D(LOG(IVFCI),1,12) does not Granger Cause D(LOG(IPIAR),1,12) | | 129,355 | 0.24098 |
| Sample: 1995:06 2004:12 | 102 | | |
| Lags: 8 | | | |
| D(LOG(IVFEXP),1,12) does not Granger Cause D(LOG(IPIAR),1,12) | | 134,832 | 0.23126 |
| Lags: 4 | | | |
| D(LOG(IVFEXP),1,12) does not Granger Cause D(LOG(PDA),1,12) | | 114,229 | 0.338 |
| Sample: 1990:03 2004:12 | 157 | | |
| Lags: 8 | | | |
| D(LOG(IVFIMP),1,12) does not Granger Cause D(LOG(TCRAR),1,12) | | 0.55895 | 0.80991 |
| Lags: 10 | | | |
| D(LOG(IVFIMP),1,12) does not Granger Cause D(LOG(YHOGK),1,1) | | 0.98608 | 0.45857 |