

Extracción de señales y ajuste estacional en la CNTR: Estudio de un caso¹

**Jesús Bouso
Enrique M. Quilis**

Instituto Nacional de Estadística

¹ Los autores agradecen los comentarios de Juan Bógalo. Las opiniones expuestas no representan, de forma necesaria, las del Instituto Nacional de Estadística.

Contenido

1. Introducción
 2. Modelización univariante
 - 2.1. Análisis preliminar
 - 2.2. Modelización ARIMA
 - 2.3. Diagnóstico y validación del modelo
 3. Extracción de señales
 - 3.1. Preprocesamiento
 - 3.2. Componentes estocásticos
 - 3.3. Serie desestacionalizada final
- Referencias

1. Introducción

Una de las tareas críticas en la compilación de la Contabilidad Nacional Trimestral (CNTR) es la extracción de señales y, en particular, la desestacionalización y la estimación de la tendencia de las series del sistema de CNTR. En INE (2002) se describe con detalle la metodología general aplicada.

El objetivo de este trabajo es exponer, a través del estudio pormenorizado de una serie particular, el proceso de extracción de señales aplicado en la CNTR, con el fin de difundir y documentar la metodología aplicada.

La estructura del trabajo es la siguiente. En la segunda sección se describe el proceso de especificación, estimación y diagnóstico de un modelo ARIMA con análisis de intervención (AI) que sirve de base para diseñar los filtros de estimación de los componentes subyacentes de la serie objeto de estudio. Se presta especial atención a los métodos de especificación –tanto desde el dominio del tiempo como desde el de la frecuencia– y al diagnóstico y validación del modelo. La extracción de señales es descrita en la tercera sección. Se ofrecen los resultados del preprocesamiento –fundamentalmente vinculados con los efectos de calendario– y de la estimación de los componentes estocásticos básicos. Finalmente se examinan las propiedades estocásticas de la serie desestacionalizada que se deriva de la anterior descomposición.

2. Modelización univariante

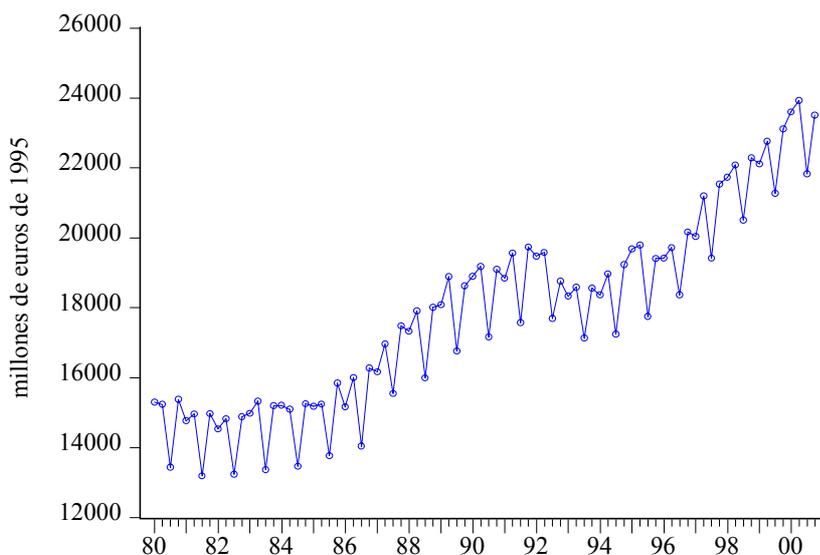
En esta sección se exponen los resultados de la identificación, estimación y diagnóstico de un modelo ARIMA-AI para la serie de la CNTR correspondiente al Valor Añadido Bruto a precios básicos de las ramas industriales no energéticas. La serie está valorada a precios constantes de 1995 y abarca el período 1980:1 – 2000:IV. Los programas empleados son el TRAMO-SEATS (Gómez y Maravall, 1996, 1998a, 1998b), el SCA (Liu y Hudak, 1995) y aplicaciones específicas en Matlab (MathWorks, 1998).

2.1 Análisis preliminar

Antes de pasar a un estudio más formal de la serie, comencemos por exponer los resultados de un conjunto de métodos, en su mayoría gráficos, que nos permiten una primera aproximación a su estructura. Estas técnicas, de naturaleza exploratoria, pueden aportar mucha información útil para la modelización.

El gráfico 1 nos muestra que el Valor Añadido Bruto de la Industria no energética, medido en millones de euros constantes de 1995, está caracterizado por una tendencia globalmente ascendente si bien bastante volátil, de forma que se alternan fases expansivas, contractivas y períodos de estabilidad. Asimismo, se detecta un claro patrón estacional, que se traduce, sobre todo, en acusados descensos de nivel en los terceros trimestres, niveles que se recuperan con rapidez en los últimos períodos de cada año.

**Gráfico 1: VAB industrial no energético.
Niveles**

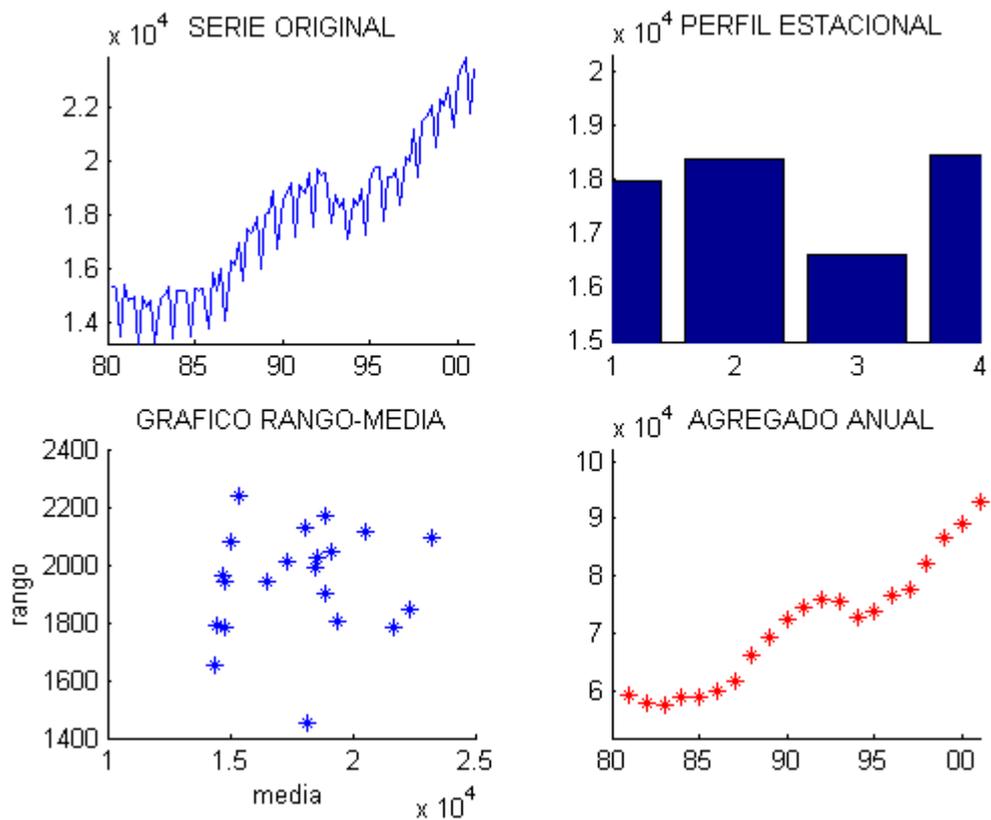


Después de esta primera toma de contacto, veamos cómo algunas agregaciones de los valores de la serie en niveles pueden proporcionar más información sobre sus distintos componentes.

La suma promediada por trimestres nos permite obtener una idea aproximada de la aportación relativa a la estacionalidad de la serie de cada uno de ellos. Las barras en el diagrama de perfil estacional del gráfico 2 cuya altura es muy distinta a la de las demás, reflejan el impacto estacional del período correspondiente. En nuestro caso, es fácil confirmar, como se apreciaba a la vista del gráfico 1, que el tercer período es el más influyente con diferencia en este aspecto. Por su parte, la agregación anual y su representación gráfica vuelven a incidir en la naturaleza de la tendencia que apuntábamos a la vista de la serie en niveles.

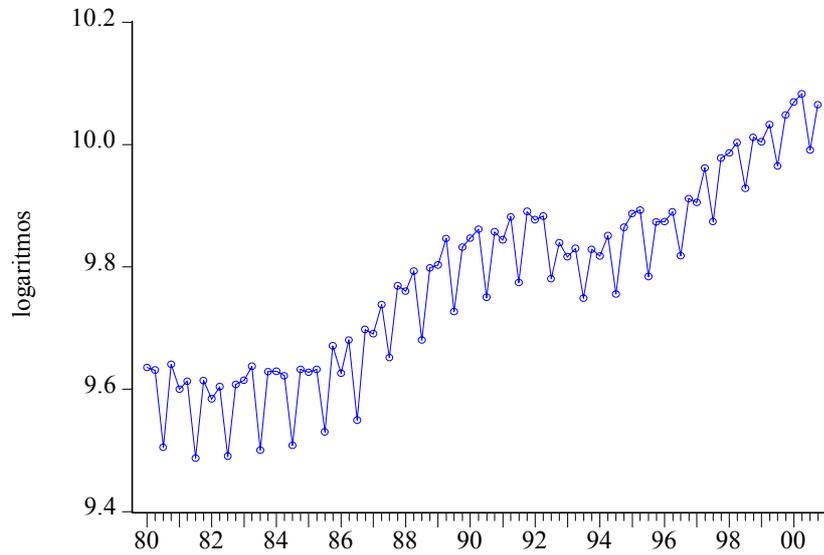
Por otro lado, la mera observación del gráfico 1 no deja clara la conveniencia o no de transformar la variable original con el objeto de homogeneizar la varianza de la serie. No se aprecian en dicha representación aumentos o disminuciones de la varianza en el tiempo que mantengan un mínimo de continuidad. Intentando aclarar este aspecto, recurrimos al estudio de la relación entre el rango y la media por tramos anuales en busca de posibles dependencias entre ambas. En el gráfico 2, obtenemos un diagrama rango-media que no deja entrever con claridad la existencia para esta serie de una relación entre ellas, como confirma su coeficiente de correlación (0.04). No parece, por lo tanto, que exista un patrón de interacción entre nivel y volatilidad, por lo que no es indispensable recurrir a la transformación logarítmica.

**Gráfico 2: VAB industrial no energético.
Análisis preliminar**



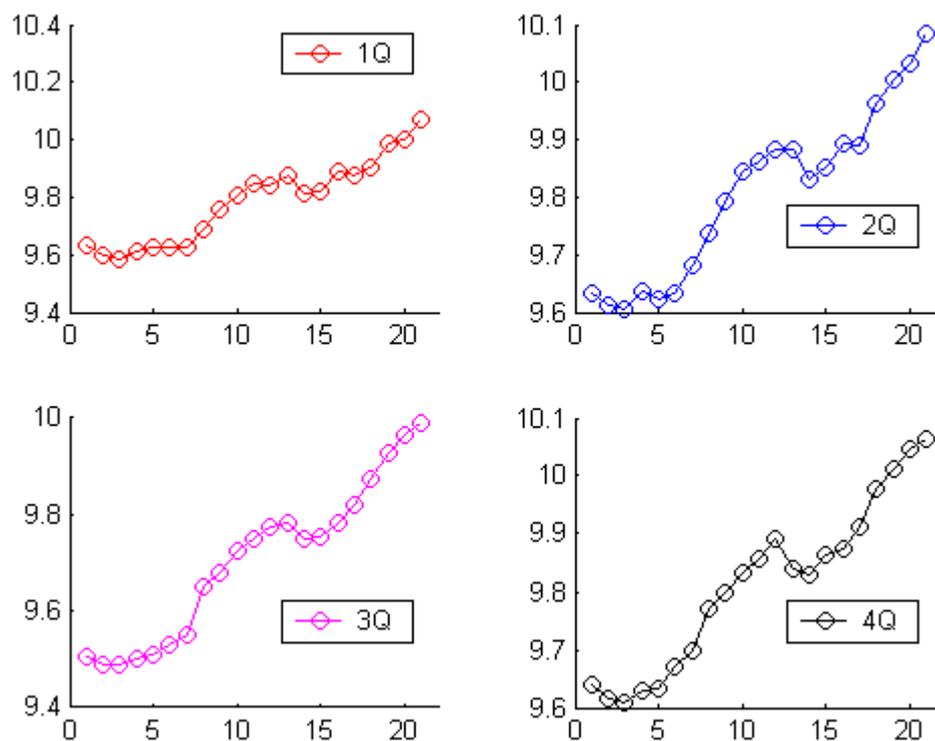
Aunque del análisis rango-media no se desprende la necesidad de tomar logaritmos, hemos decidido aplicarlos dada su conveniencia como herramienta estabilizadora, cuyo uso suele dotar a los residuos de un mayor grado de normalidad. Asimismo, se facilita la interpretación del modelo ARIMA. Tengamos también en cuenta, en este aspecto, que las consecuencias negativas que pueden derivarse de transformar la variable innecesariamente son leves, mientras que no hacerlo cuando es preciso sí puede repercutir adversamente sobre la calidad del modelo estimado. En el gráfico siguiente se presenta la serie transformada.

**Gráfico 3: VAB industrial no energético.
Niveles en logaritmos**



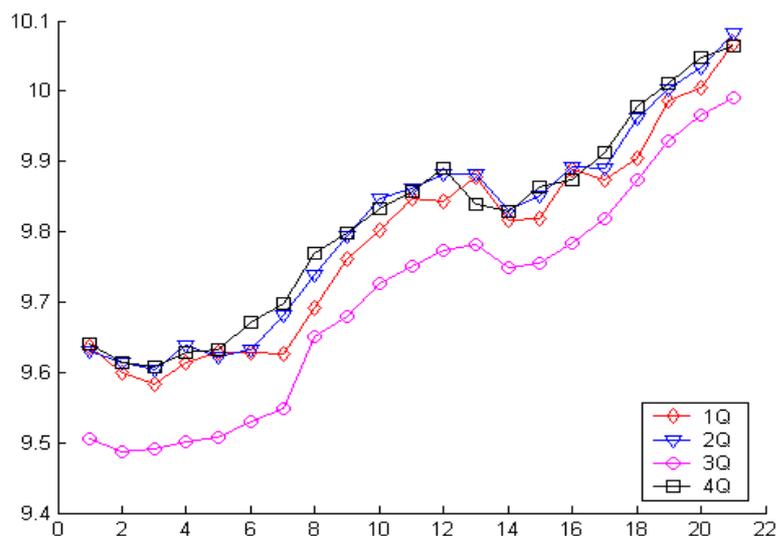
En el gráfico 4 aparece representado el logaritmo de la serie en niveles por trimestres (donde iQ denota el trimestre i ésimo). Se aprecia con nitidez un patrón tendencial cualitativamente similar, hecho que aumenta nuestra convicción acerca de la importancia de este componente en el caso en estudio.

**Gráfico 4: VAB industrial no energético.
Niveles por trimestres en logaritmos**



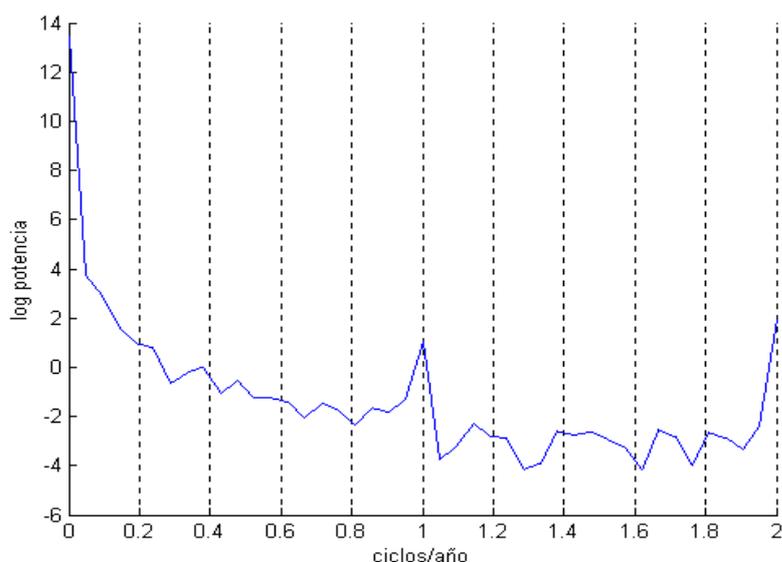
Por su parte, la representación conjunta de las series anteriores, corrobora la impresión inicial acerca de la concentración de la estacionalidad en los terceros trimestres de los años observados, en los que toma valores muy por debajo de los medidos en los demás.

Gráfico 5: VAB industrial no energético.
Superposición de niveles por trimestres en logaritmos



Continuamos este análisis preliminar obteniendo información acerca de la estructura de la serie y sus componentes estudiándola desde el dominio de la frecuencia. El gráfico 6 nos permite examinar el log-periodograma de la serie del VAB de la industria no energética. Los altos valores que éste toma para frecuencias próximas a cero indican que la serie está dotada de un fuerte componente tendencial. Asimismo, el pico que presenta la función en la frecuencia $\pi/2$ (oscilaciones anuales), es claro síntoma de la existencia de estacionalidad anual. También en la frecuencia π (oscilaciones semianuales) se observa este mismo fenómeno, por lo que cabe concluir que la serie posee un patrón intraanual claramente discernible. El área que queda por debajo de la curva cuando nos alejamos de las frecuencia $\pi/2$, es atribuible al componente irregular, como analizaremos más adelante al descomponer la serie.

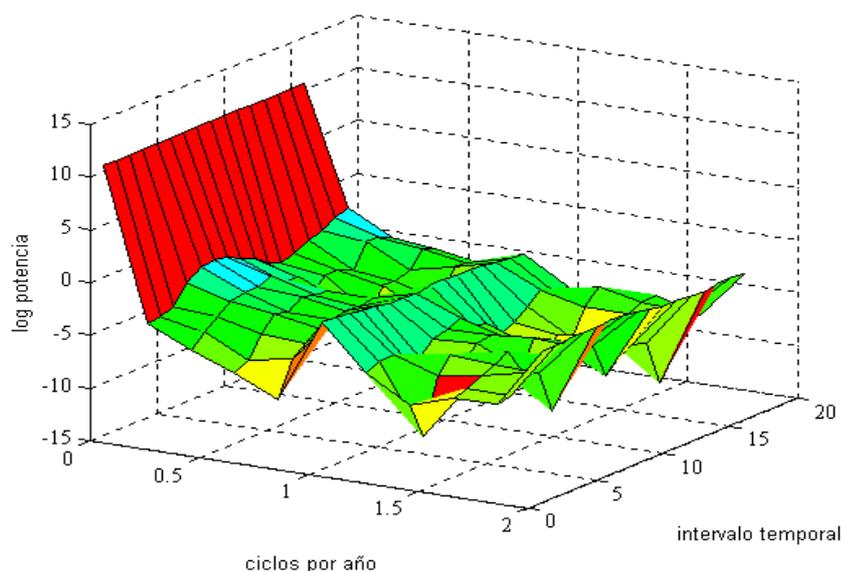
**Gráfico 6: VAB industrial no energético.
Log-periodograma**



Asimismo, podemos representar la evolución del log-periodograma a lo largo del tiempo de observación de la serie, detallando nuestro análisis en el dominio de la frecuencia. Para ello, calculamos los log-periodogramas sobre subseries solapadas de cinco años, que se van desplazando en el tiempo un año en cada iteración, como si se tratara de una “ventana temporal” móvil a la que se ciñe el análisis. De esta manera, examinamos la estabilidad en el tiempo de las propiedades frecuenciales de la serie, discerniendo las fundamentales de las accidentales.

Observamos, en el gráfico 7, cómo las frecuencias muy bajas se mantienen en unos niveles muy similares al avanzar la serie en el tiempo, lo que refleja una homogeneidad en el peso de la tendencia a lo largo del período observado. Se aprecia también un moderado descenso en los valores próximos a las frecuencias de ciclo anual, es decir, un suave descenso de importancia en el componente estacional anual. No ocurre así con las oscilaciones de ciclo semestral, que se mantienen en unos niveles muy parecidos durante la etapa considerada en este estudio. Finalmente, tampoco se observa que el componente irregular adquiera o pierda protagonismo con el tiempo de forma notoria.

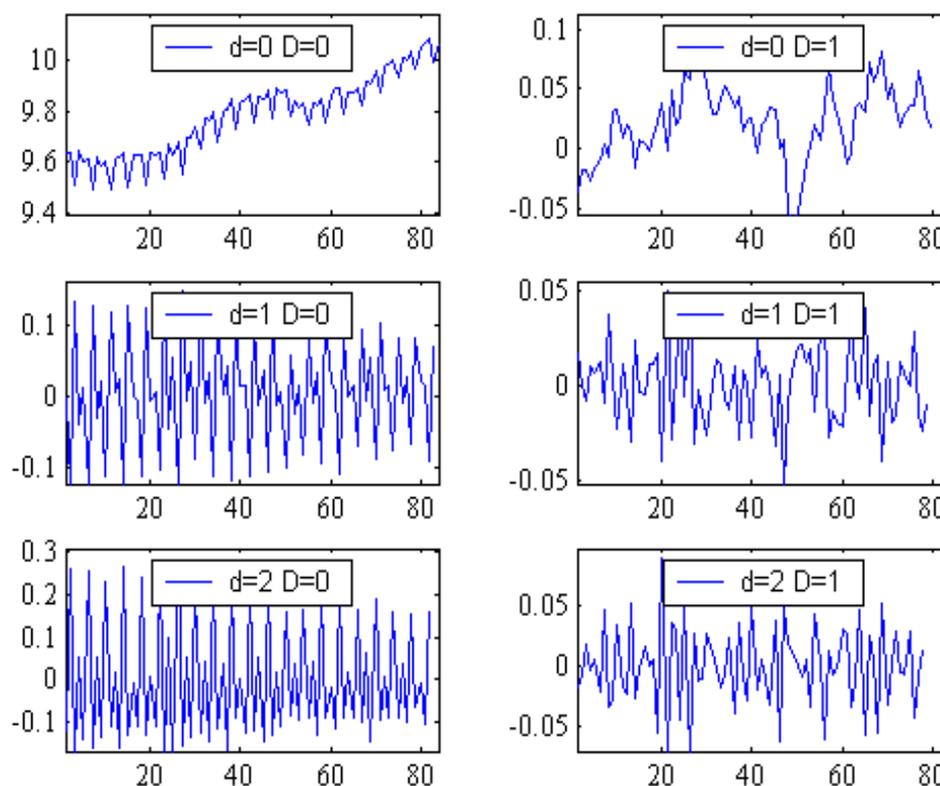
**Gráfico 7: VAB industrial no energético
Log-periodograma móvil**



Otro aspecto que es muy útil analizar antes de proceder de modo formal a la identificación de un modelo ARIMA adecuado, es el concerniente al grado de diferenciación que sería conveniente aplicar a la variable en logaritmos para convertirla en estacionaria. El gráfico 8 muestra la serie diferenciada d veces regularmente y D veces estacionalmente, donde d puede tomar los valores 0, 1 y 2 y D los valores 0 y 1. Comentemos brevemente el grado de estacionariedad al que conduce cada combinación de valores de d y D .

Tanto para el logaritmo de la serie original ($d=0$, $D=0$) como para éste diferenciado una vez estacionalmente ($d=0$, $D=1$), apreciamos en la gráfica un comportamiento que dista bastante de la estacionariedad: ni la esperanza ni la varianza parecen comportarse de modo estable, al tiempo que, en algunos intervalos se detecta una intensa autocorrelación. Diferenciando sólo regularmente, una o dos veces ($d=1$, $D=0$ ó $d=2$, $D=0$) nos encontramos con una cierta homogeneización de la esperanza, pero la varianza sigue adoleciendo de un grado considerable de volatilidad. Observamos, por último, que es con una diferencia estacional y una o dos regulares ($d=1$, $D=1$ y $d=2$, $D=1$) cuando las series asemejan más su comportamiento al estacionario.

Gráfico 8: VAB industrial no energético
Serie diferenciadas regular (d) y estacionalmente (D)



La tabla 1 cuantifica la información anterior, al mostrar los momentos de segundo orden de las series diferenciadas. Combinando ambos elementos, consideramos que una diferenciación de grado uno, tanto regular como estacional, es la más apropiada para inducir estacionariedad en media y varianza en la serie analizada.

También el criterio de diferenciación de Titterton confirma este parecer, pues el grado de diferenciación mencionado minimiza la varianza de la serie diferenciada, estando sujeto a un t-ratio de la media que se mantiene con holgura en unos límites de confianza aceptables para la hipótesis de que ésta es nula.

**Tabla 1: Series diferenciadas
Momentos de segundo orden**

D	D	σ^2	μ	$t(\mu)$
0	0	0.0240	9.7777	578.0510
1	0	0.0061	0.0052	0.6025
2	0	0.0201	0.0010	0.0614
0	1	0.0009	0.0224	6.5350
1	1	0.0004	0.0007	0.2822
2	1	0.0011	-0.0003	-0.0925

Hemos mostrado que el criterio de Titner nos sugiere elegir un orden de diferenciación 1 tanto para la parte regular como para la estacional; dicho de otro modo, la serie para la que intentaremos buscar un modelo ARMA adecuado es:

$$Z_t = (1-B) (1-B^4) \log(X_t),$$

Factoricemos el polinomio en B anterior de modo que quede más fácilmente interpretable en términos de los componentes subyacentes de la serie:

$$(1-B) (1-B^4) = \nabla^2 U(B), \quad \text{con } U(B) = 1+B+B^2+B^3 = (1+B)(1+B^2)$$

Sabemos que, en la extracción de señales, el factor ∇^2 se incorpora a la tendencia, mientras que U(B) se asocia al componente estacional. Esto da pie a intentar aislar los componentes subyacentes a partir de filtrados parciales.

En el gráfico 9 aparecen, dispuestas por filas, las series filtradas de forma selectiva y sus correspondientes log-periodogramas. Así, en la primera fila, se aprecia cómo la aplicación del filtro ∇^2 genera una serie con dos picos frecuenciales vinculados con las oscilaciones de período anual y semianual. Por tanto, existe estacionalidad una vez que la tendencia ha sido eliminada.

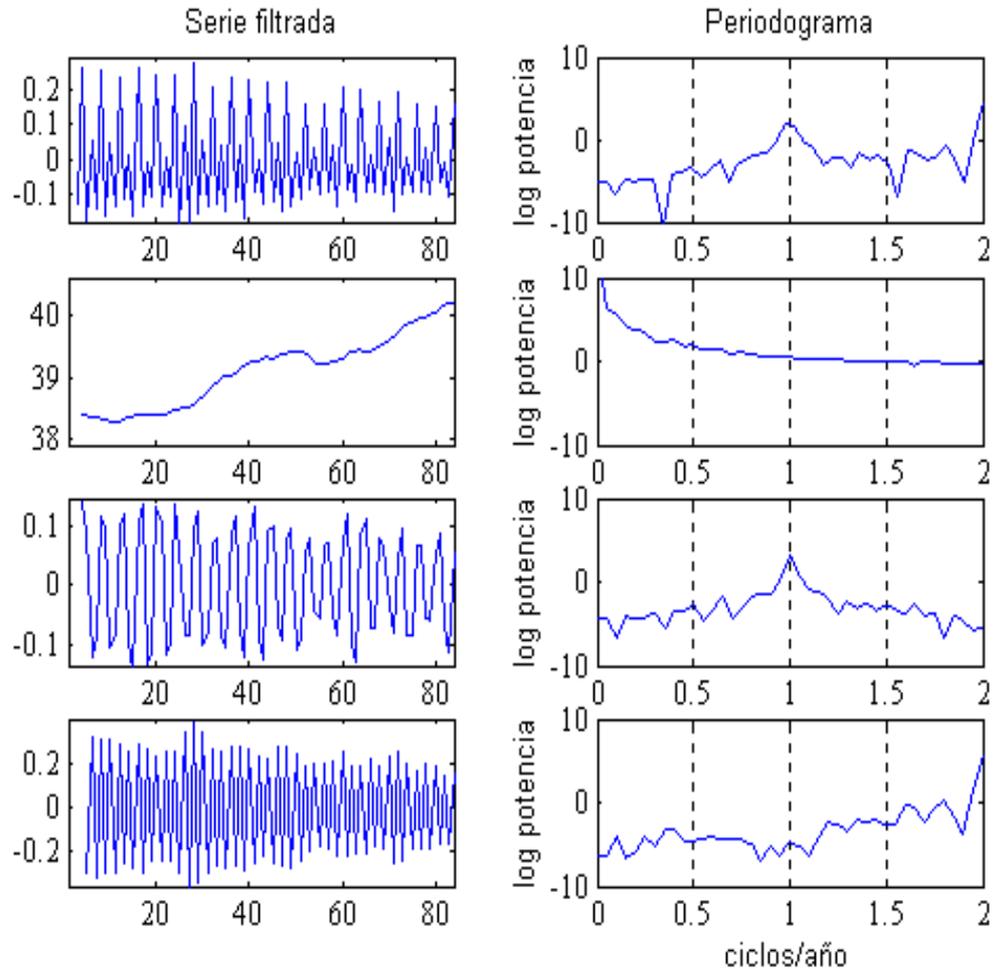
Análogamente, en la segunda fila, se comprueba cómo el filtro U(B) “desestacionaliza” la serie, dando lugar a otra con un acusado patrón tendencial, hecho observable tanto desde el dominio del tiempo como desde el de la frecuencia.

La tercera fila, en la que se ofrecen los resultados del filtrado por $\nabla^2 (1+B)$, da lugar a una serie con acusados movimientos de periodicidad anual. En el mismo sentido, el filtrado a través de $\nabla^2 (1+B^2)$, genera oscilaciones semestrales, como se aprecia tanto en la serie como, especialmente, en el log-periodograma correspondiente.

Considerando de manera conjunta todos esos gráficos se concluye que la serie posee información en las frecuencias cero (tendencial), $\pi/2$ (estacionalidad anual) y π

(estacionalidad semianual), por lo que la transformación $\nabla\nabla_4$ no es sobrediferenciadora.

Gráfico 9: Filtrado selectivo



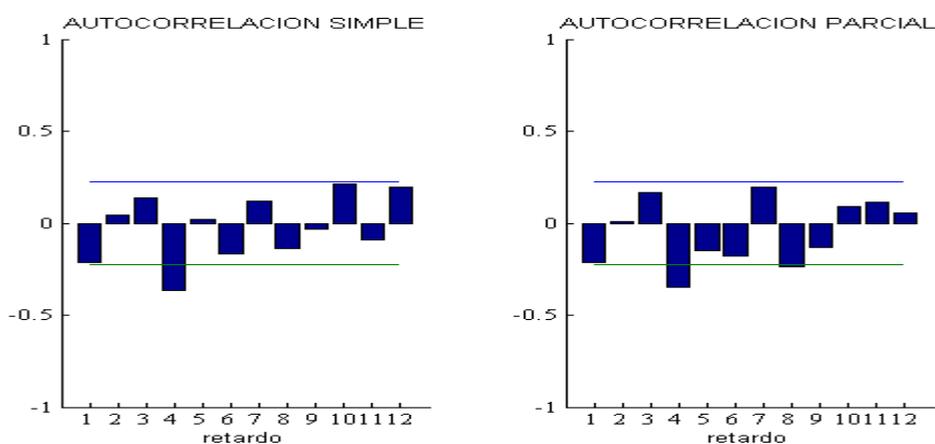
Nota: En las respectivas filas se aplican los siguientes filtros: $\nabla^2=(1-B)^2$, $U(B)=1+B+B^2+B^3$, $\nabla^2(1+B)$ y $\nabla^2(1+B^2)$.

2.2 Modelización ARIMA

Hemos hallado en el apartado anterior claros indicios de que el grado de diferenciación adecuado a aplicar a la transformación logarítmica de la variable VAB industrial no energético en aras de lograr su estacionaridad es uno, tanto para la parte regular como para la estacional. Asumamos –de momento- que éste es el grado elegido. El siguiente paso conducente a la identificación de un modelo ARIMA para la serie pasa por encontrar un modelo ARMA adecuado para la serie estacionaria, esto es, para $Z_t = (1-B)(1-B^4) \log(X_t)$.

Usaremos para lograr ese objetivo algunos programas de modelización, como el SCA y, principalmente el TRAMO, pero antes de presentar e interpretar sus resultados, enfoquemos el problema de identificación de la estructura ARMA con las herramientas clásicas de la metodología Box-Jenkins. Entre ellas, destaca el examen de las funciones de autocorrelación simple y parcial de la serie estacionaria, del que se pueden extraer conclusiones estructurales, bien es verdad que no sin reservas, dada la dificultad que conlleva este tipo de análisis salvo en casos puros (modelos AR o MA).

Gráfico 10: Autocorrelación simple y parcial de la serie estacionaria



En el gráfico 10 aparecen las funciones de autocorrelación simple y parcial (fas y fap respectivamente, en adelante) de Z_t , representadas hasta el duodécimo retardo. Por una parte, la presencia de valores significativos en el retardo 4 de la fas y en los retardos cuarto y octavo de la fap, sugieren la presencia de un término MA(1) estacional. Por otro lado, la existencia de valores significativos en ambas funciones en el primer retardo y la ausencia de una estructura nítida dificulta la identificación de la parte regular que, en todo caso, sería de orden uno. Adicionalmente, los “satélites” de la fas (retardos 3 y 5) no permiten decantarse por una estructura MA frente a una AR.

Seguidamente procederemos, por tanto, a la identificación y estimación de un modelo ARIMA con análisis de intervención para el logaritmo de la serie temporal en estudio utilizando el programa TRAMO. Su funcionamiento se detalla en Gómez y Maravall (1996,1998a).

La expresión del modelo es la siguiente:

$$[1] \quad \log(X_t) = TD_t + E_t + O_t + N_t,$$

expresión en la cual los tres primeros términos son deterministas y el cuarto estocástico, concretamente:

- a) TD_t denota el efecto del ciclo semanal. Representamos este efecto formalmente por:

$$TD_t = \beta D_t,$$

siendo $D_t = (\text{número de lunes, martes, miércoles, jueves y viernes en el trimestre } t) - (\text{número de sábados y domingos en el trimestre } t) \cdot (5/2)$. Se utiliza el factor 5/2 para homogeneizar restando y sustrayendo en D_t . La modelización de esta clase de efectos puede encontrarse en Hillmer (1982), Bell y Hillmer (1983), Hillmer *et al.* (1983) y Salinas y Hillmer (1987), entre otros.

- b) E_t es el efecto de la Pascua móvil, que representamos por el término:

$$E_t = \gamma P(\tau)_t,$$

donde $P(\tau)_t$ cuantifica la proporción de días de Pascua en el trimestre t , considerando que su efecto se percibe durante los τ días anteriores al Domingo de Resurrección. Este tipo de efectos se puede encontrar analizado con detalle en Liu (1980, 1983) y en Hillmer *et al.* (1983). Asumimos en el presente trabajo que τ puede tomar valores entre 1 y 9.

- c) O_t modeliza los efectos derivados de la presencia de observaciones atípicas. Su expresión formal, derivada del análisis de intervención (Box y Tiao, 1975), es:

$$O_t = \sum_{h=1}^k V_h(B) I_t^{T_h},$$

donde $I_t^{T_h}$ es un indicador que toma el valor 1 en la observación T_h y 0 en los restantes, siendo T_h la observación en que se presenta el valor atípico. El filtro $V_h(B)$, que recoge los efectos dinámicos asociados a la observación extraordinaria toma la forma

$$V_h(B) = \frac{V_h}{1 - \delta B} \quad 0 \leq \delta \leq 1$$

En este trabajo se consideran dos posibilidades:

-atípicos aditivos: el efecto de la observación anómala es inmediato y dura sólo un período ($\delta=0$);

-atípicos transitorios: el efecto de la observación atípica persiste durante algún tiempo, pero sin llegar a hacerse permanente ($0 < \delta < 1$).

Los valores anómalos cuyo efecto es permanente ($\delta=1$), no se recogen en el presente análisis debido a que los atípicos permanentes se asignan finalmente al componente de ciclo-tendencia, lo que dificulta considerablemente la estimación de los ritmos de variación y la extracción de la señal cíclica.

N_t es el componente estocástico, que supondremos que sigue un modelo ARIMA estacional multiplicativo $(p,d,q) \times (P,D,Q)_4$. Formalmente:

$$N_t = \frac{\theta_q(B)\Theta_Q(B^4)}{\phi_p(B)\Phi_P(B^4)(1-B)^d(1-B^4)^D} a_t,$$

donde $\phi_p(B)$ y $\theta_q(B)$ son polinomios, de orden p y q respectivamente, en el operador de retardos B , y $\Phi_P(B^4)$ y $\Theta_Q(B^4)$ son polinomios de orden P y Q en B^4 . Los factores $(1-B)^d$ y $(1-B^4)^D$ son operadores de diferenciación regular y estacional controlados por los parámetros enteros d y D , respectivamente. Por último, a_t es una secuencia de ruido blanco gaussiano con esperanza nula y desviación típica constante σ_a .

Una vez situado el marco en el cual utilizar el programa TRAMO, procedemos a la identificación automática y estimación de los cuatro términos anteriores.

Con un valor crítico de detección de atípicos bajo ($VA=3$ en lugar de 4, valor por defecto en el TRAMO) y permitiendo al programa la búsqueda de outliers de carácter permanente, TRAMO localiza una observación anómala en el cuarto trimestre del año 1992, cuyo efecto se perpetúa en el tiempo, y cuya presencia altera la normalidad de los residuos. A efectos de no despreciar factores deterministas relevantes, introducimos en el modelo un regresor externo que recoja la influencia de esta observación, que, por las razones antes señaladas, trataremos como atípico transitorio.

Una vez decidido el tratamiento de outliers y del ciclo semanal, TRAMO considera los efectos de calendario (ciclo semanal y Pascua móvil) significativos, a la vez que no detecta ningún valor atípico aditivo o transitorio (con $VA=4$ y una vez introducido el regresor externo). Para fijar la duración del efecto de Pascua, elegimos el valor de τ entre 1 y 9 que minimice σ_a , la desviación típica de los residuos del modelo identificado por el programa. La tabla 2 recoge esta información, de la que concluimos que, según el criterio expuesto, el valor óptimo para τ es 4.

Tabla 2: Desviación típica de los residuos y duración de la Pascua móvil

τ	1	2	3	4	5	6	7	8	9
$\sigma_a * 10^{-3}$	15.08	15.08	14.74	14.69	14.75	14.88	15.09	15.28	15.44

En estas condiciones, el modelo que TRAMO identifica y estima viene dado por $p=P=q=0$ y $Q=d=D=1$, es decir que diferencia la serie en logaritmos una vez regular y otra estacionalmente e introduce un factor MA estacional, resultados coherentes con el análisis preliminar del apartado anterior y con nuestro análisis de las funciones de autocorrelación. Formalmente -con la notación precedente- la parte estocástica identificada tiene la siguiente estructura:

$$N_t = \frac{(1 - \theta_4 B^4)}{(1 - B)(1 - B^4)} a_t$$

La estimación conjunta de los parámetros incluidos en los cuatro sumandos de [1] por máxima verosimilitud exacta, arroja los siguientes resultados:

Tabla 3: Estimación de los parámetros del modelo ARIMA. Parte determinista y parte estocástica

Variable	Parámetro	Estimación	Desviación típica	t-ratio
Ciclo semanal	β	0.0022	0.0007	2.97
Pascua	γ	-0.0149	0.0028	-5.31
Atípico TC 1992-IV	ρ	-0.0320	0.0118	-2.72
Coeficiente MA	θ_4	-0.5573	0.0934	-5.97
Desv.Típ. residuos	σ_a	0.0147	-	-

Del análisis de la tabla 3, podemos deducir que el efecto de ciclo semanal es positivo y bastante significativo, si bien no tanto como el efecto negativo de la Pascua móvil, que además es de mayor magnitud. El parámetro ρ correspondiente al regresor introducido para corregir el efecto de la observación atípica antes mencionada, toma un valor negativo relativamente elevado, resultando estadísticamente significativo.

En cuanto al componente estocástico, la estimación del parámetro θ_4 arroja un valor intermedio que denota la presencia de un componente estacional evolutivo, claramente no determinista.

Introducida la serie corregida de efectos de calendario en el programa SCA, éste arroja un resultado virtualmente idéntico al del TRAMO, tanto en lo que se refiere a la identificación del modelo, el cual coincide en ambos programas, como a la estimación de su coeficiente MA, muy similar también para los dos. El SCA tampoco detecta outliers, para el mismo valor crítico que ha sido utilizado en el TRAMO. A continuación procedemos a la validación del modelo a través del análisis de sus residuos.

2.3 Diagnóstico y validación del modelo

Una vez identificado y estimado el modelo para la serie temporal, procedemos a su diagnóstico realizando un análisis pormenorizado de los residuos del mismo. Esto supone verificar que a_t , las perturbaciones del modelo ARIMA son ruido blanco gaussiano; es decir, debemos comprobar que se verifican las siguientes hipótesis:

- Media nula: $E(a_t) = 0 \quad \forall t$
- Varianza constante: $\text{Var}(a_t) = \sigma_a^2 \quad \forall t$
- Ausencia de correlación serial: $E(a_t a_s) = 0 \quad \forall t, s \quad t \neq s$
- Normalidad: $a_t \sim \text{iid } N(0, \sigma_a^2) \quad \forall t$

A continuación examinamos secuencialmente si los residuos del modelo estimado verifican estas propiedades.

a) Media nula: $E(a_t) = 0 \quad \forall t$

Podemos comprobar, en la tabla 4, que la media de los residuos toma un valor próximo a cero, aproximadamente a una distancia del origen de una desviación típica. Bajo la hipótesis de perturbaciones de media nula, el cociente entre la media y la desviación típica de los residuos ha de aproximarse a una $N(0,1)$. El valor 0.99 del estadístico permite, pues, aceptar sin problemas la hipótesis de media nula sobre las perturbaciones.

Tabla 4: Media, desviación típica de la media y t-ratio de los residuos

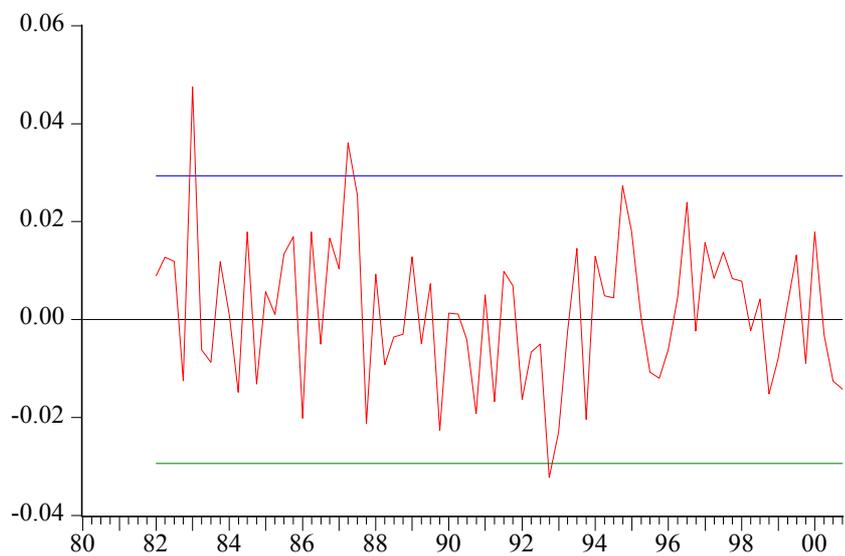
$\mu(\hat{a})$	$\sigma_{\mu(\hat{a})}$	t-ratio
0.00164	0.00166	0.99

b) Varianza constante: $\text{Var}(a_t) = \sigma_a^2 \quad \forall t$

En el gráfico 11 se hallan representados los residuos de la serie, así como también las bandas de confianza asociadas a dos veces la desviación típica. A simple vista, se aprecia una cierta evolución en su volatilidad. Así, el nivel de fluctuación de la variable es más alto en los primeros años observados.

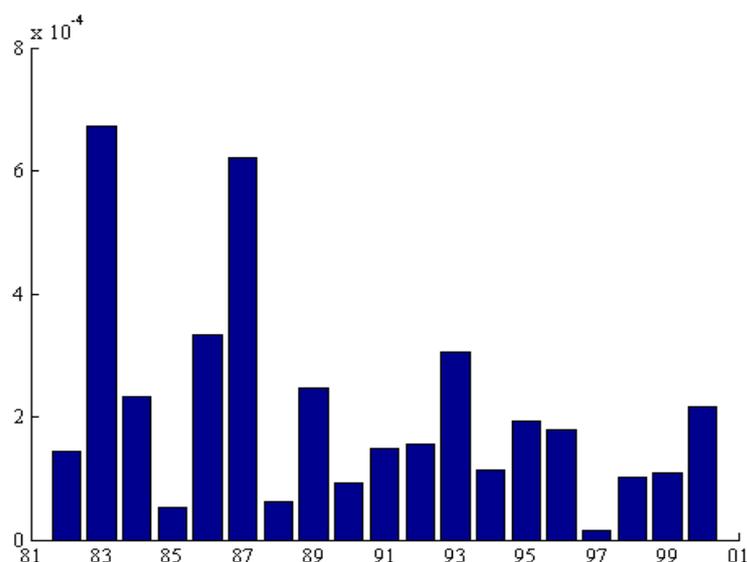
Por otra parte, hay tres observaciones que se encuentran fuera de la banda de dos desviaciones típicas, número razonable teniendo en cuenta que existen 76 valores residuales y que los límites de confianza representan teóricamente al 95 por ciento de la muestra.

Gráfico 11: Residuos



Si representamos la varianza de la serie por tramos anuales, apreciamos con mayor precisión la atenuación de la volatilidad de las innovaciones en el tiempo. Vemos cómo en algunos de los primeros años de la muestra, la varianza alcanza niveles muy altos en comparación con los de los años subsiguientes.

Gráfico 12: Varianza de los residuos por tramos anuales

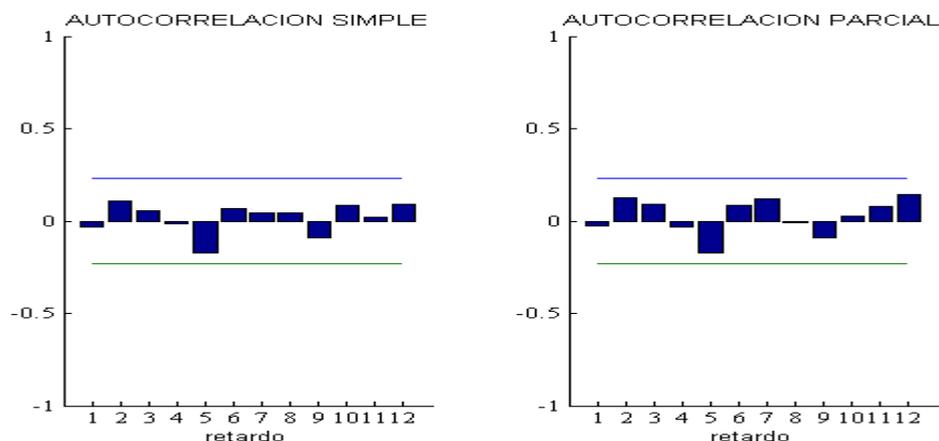


Aplicando el test ARCH (*Autoregressive Conditional Heteroskedasticity*) propuesto por Engle (1982) a los residuos al cuadrado con los cuatro primeros retardos como regresores, confirmamos que las fluctuaciones que acabamos de detectar en la varianza de los residuos no son óbice para que la varianza de las perturbaciones sea constante. El estadístico nR^2 , donde n es el número de residuos y R^2 el coeficiente de determinación de la regresión del test ARCH, toma en nuestro caso el valor 0.76, muy lejos de 9.49, valor crítico al 95% para una χ^2 con 4 grados de libertad. También el resultado de este contraste nos anticipa que los residuos al cuadrado gozan de un elevado grado de independencia serial.

c) Ausencia de correlación serial: $E(a_t a_s) = 0 \quad \forall t, s \quad t \neq s$

Para el análisis de la independencia de las perturbaciones usaremos de varios contrastes sobre los residuos. Así, las funciones de autocorrelación simple y parcial de los residuos muestran una ausencia de estructura bastante clara en los mismos. Por otra parte, ambas funciones se mantienen dentro de un intervalo de confianza centrado en el origen y de radio dos veces la desviación típica como se aprecia en el gráfico 13. Por tanto, el análisis directo de las autocorrelaciones de los residuos indica que existe independencia serial.

Gráfico 13: Autocorrelación simple y parcial de los residuos



Los resultados del análisis SCAN (*Smallest Canonical Correlation Analysis*) propuesto por Tsay y Tiao (1985) muestran una pauta compatible con la hipótesis de ruido blanco, corroborando los resultados de las funciones de autocorrelación simple y parcial antes comentados. La siguiente tabla muestra estos resultados:

Tabla 5: Análisis SCAN de los residuos

		q												
		0	1	2	3	4	5	6	7	8	9	10	11	12
p	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	0	0	0	0	0	0	0	0	0
	5	0	0	0	0	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	0	0

Los valores que toma el estadístico de Ljung-Box para los retardos $h=4, 8$ y 12 , indican que la hipótesis nula de independencia de las perturbaciones no es rechazada por la muestra, como podemos verificar a la luz de la tabla 6, en la que hemos incluido los P-valores para los retardos correspondientes.

Tabla 6: Estadístico Q de Ljung y Box

Retardo: h	4	8	12
Q(h)	2.32	5.03	6.88
P-valor	0.51	0.66	0.81

Finalmente, el contraste de rachas, realizado tanto sobre los residuos como sobre su función de autocorrelación simple, nos ofrece los resultados que recoge la tabla 7. Los t-ratios resultantes sugieren la aceptación de la hipótesis de independencia.

Tabla 7: Contraste de rachas

	Residuos	Autocorrelación
Nº de rachas	42	20
t-ratio	0.6929	0.3382

d) Normalidad: $a_t \sim \text{iid } N(0, \sigma_a^2) \quad \forall t$

El contraste de normalidad de Jarque-Bera nos ofrece unos resultados que confirman la normalidad de los residuos, como podemos comprobar en la tabla 8:

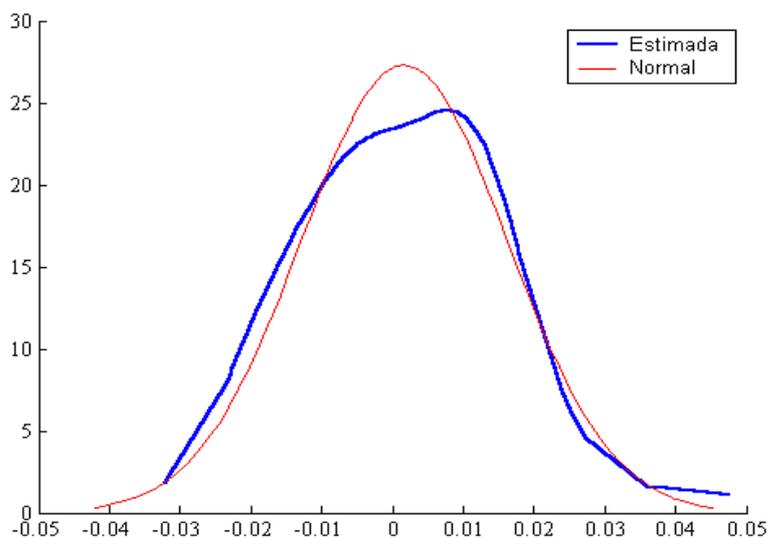
Tabla 8: Contraste de normalidad de Jarque y Bera

Jarque-Bera	1.2773
Asimetría	0.2826
Curtosis	3.2896

Bajo la hipótesis de normalidad, el estadístico de Jarque-Bera se distribuye como una χ^2 con dos grados de libertad. Esta distribución concentra el 95% de su masa de probabilidad antes del valor 5.99; el valor estimado en este caso, deja a su derecha un 52.8% de su densidad. Por otro lado, los intervalos de confianza, al 95 por ciento, para los estadísticos de asimetría y curtosis son, respectivamente: [-0.562, 0.562] y [1.876, 4.124]. Queda claro, pues, que la volatilidad evolutiva antes comentada no resulta lo suficientemente intensa para dislocar la curtosis ni el test de normalidad.

Si aproximamos el histograma de los residuos a una densidad continua mediante un método de kernel, nos encontramos con una elevada similitud a una normal, como se puede comprobar en el gráfico 15, en el cual aparecen tanto la aproximación continua como la normal con media y desviación típica iguales a la media y a la desviación típica muestrales de los residuos.

Gráfico 15: Densidad kernel de los residuos y densidad normal asociada



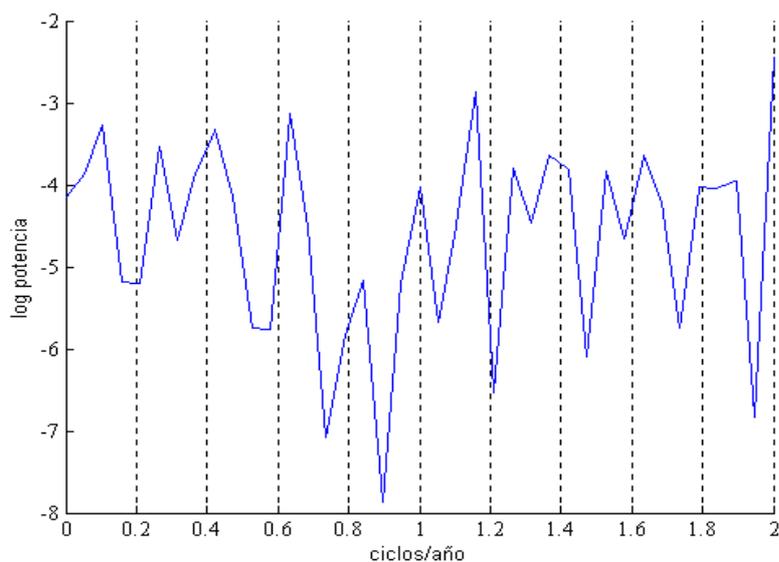
El comportamiento del estadístico de Ljung y Box para los residuos al cuadrado es consistente con la hipótesis de linealidad. En la tabla 9 figuran sus resultados y la masa de probabilidad que queda a la derecha de la estimación en la distribución del estadístico, bajo la hipótesis nula, para los desfases 4, 8 y 12.

Tabla 9: Estadístico de Ljung-Box para los cuadrados de los residuos

Retardo: h	4	8	12
Q(h)	0.81	0.97	2.7
P-valor	0.85	1.00	0.99

Completemos este análisis de los residuos del modelo con un examen de su periodograma. En el gráfico 16 observamos que no hay una pauta de comportamiento asociada con el peso de las frecuencias de una amplitud determinada, sino que la función sigue una trayectoria bastante errática pero con un perfil globalmente plano, como corresponde al espectro empírico de un ruido blanco.

Gráfico 16: Periodograma de los residuos



De todo el estudio anterior, cabe concluir que el comportamiento de los residuos en este modelo encaja casi a la perfección con la hipótesis de que tales residuos son estimaciones de unas perturbaciones distribuidas como ruido blanco gaussiano. Tanto la hipótesis de media nula como la de independencia, superan con holgura todos los tests propuestos. Por su parte, la normalidad de las perturbaciones resulta una hipótesis razonable a la luz de los resultados del test de Jarque-Bera y de los métodos de aproximación de densidades continuas de tipo kernel.

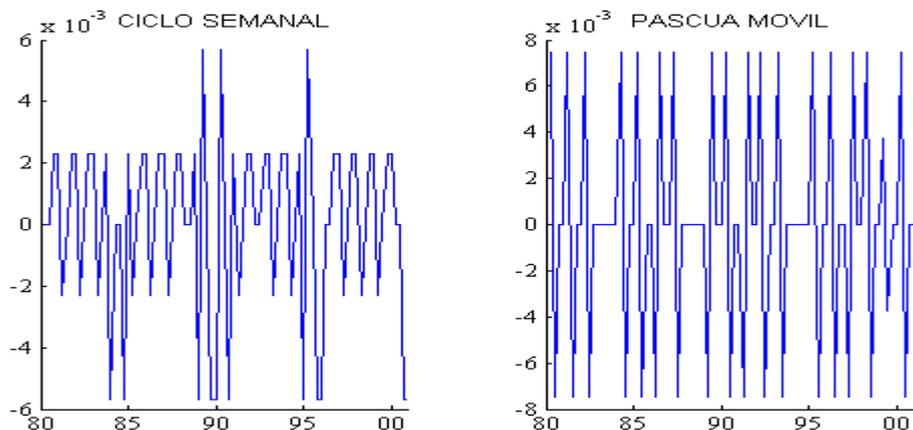
3. Extracción de señales

En esta sección procedemos a descomponer la serie observada en sus componentes subyacentes, mediante la aplicación de la metodología de extracción de señales basada en modelos ARIMA desarrollada por Burman (1980), Hillmer y Tiao (1982), Hillmer et al. (1983), Maravall (1987, 1990, 1993a, 1993b, 1994), Maravall y Pierce (1987) y Gómez y Maravall (1998b, 1998c), entre otros.

3.1 Preprocesamiento

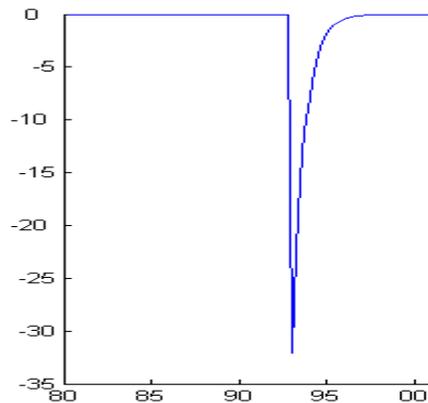
En el epígrafe anterior ya hemos hecho en realidad una primera descomposición de la serie, al dividirla en tres componentes deterministas y uno estocástico. Dos de los componentes deterministas se hallan representados en el gráfico 17. Se trata de los correspondientes a los efectos de calendario. Los valores en ordenadas son las aportaciones en tanto por uno de ambos efectos a los valores de la serie en niveles. Observamos que la contribución del ciclo semanal se sitúa, habitualmente, en torno al 0.2 por ciento, mientras que la Pascua móvil representa alrededor del 0.8 por ciento del valor de la serie. Se trata de valores de una intensidad moderada pero no desdeñables, en especial si se tiene en cuenta su presencia permanente en toda la muestra.

Gráfico 17: Efectos de calendario



Por el contrario, el tercer elemento determinista que se ha estimado está asociado a una observación atípica y presenta, por lo tanto, una acusada concentración temporal acompañada por un efecto de un orden de magnitud más intenso que los de calendario, como puede apreciarse en el gráfico siguiente:

Gráfico 18: Atípico transitorio de 1992.IV (x 10⁻³)



La presencia de este atípico está asociada, al menos parcialmente, a la alteración transitoria e intensa de las condiciones usuales de comportamiento de esta serie debidas a la recesión de 1992-93.

3.2 Componentes estocásticos

El modelo ARIMA para N_t que hemos identificado, estimado y contrastado en el epígrafe 2, nos permite realizar una descomposición de la serie original observada en sus componentes subyacentes de tendencia, estacionalidad e irregularidad, usando los principios de descomposición canónica basada en modelos ARIMA de forma reducida. Utilizamos para tal fin el programa SEATS. Por consiguiente, la descomposición que se va a aplicar es:

$$N_t = P_t + S_t + I_t,$$

siendo P la ciclo-tendencia, S la estacionalidad e I la irregularidad. Naturalmente, N_t es estimado detrayendo a la serie observada (en logaritmos) los elementos deterministas que acaban de comentarse en el apartado 3.1. Seguidamente presentamos un estudio minucioso de cada uno de los componentes extraídos por dicho programa.

(a) Estacionalidad

La aplicación del principio de descomposición canónica permite identificar, de manera única, modelos ARIMA para los componentes teóricos compatibles con el modelo

ARIMA para la serie observada. En nuestro caso, el modelo para el componente estacional viene dado por:

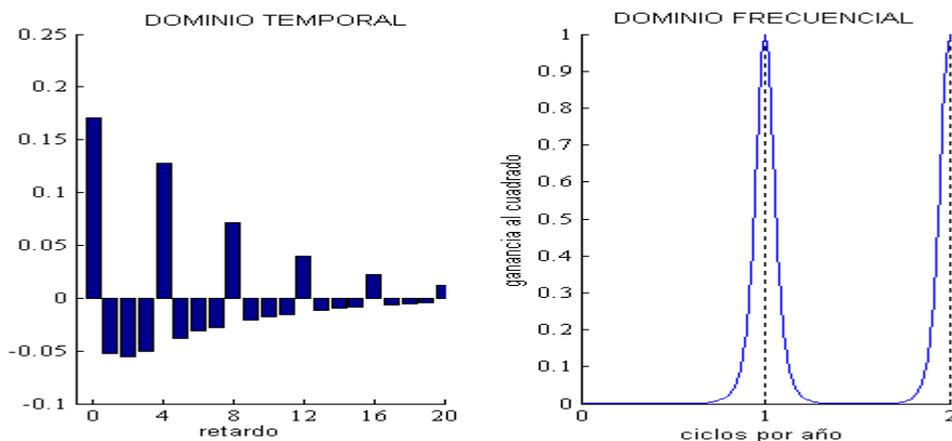
$$(1 + B + B^2 + B^3)S_t = (1 + 0.9961B + 0.3381B^2 - 0.4559B^3)a_{st}$$

La varianza correspondiente a las pseudo-innovaciones a_{st} toma el valor 0.02, medida en unidades de varianza de a_t . Se trata de un modelo ARMA(3,3) equilibrado, no estacionario y no invertible, como resultado de la aplicación del principio de descomposición canónica. Este tipo de modelos consideran que la agregación anual del componente estacional debe ser nula en promedio, pudiendo estar dotada de cierta estructura si bien, en virtud del requisito canónico, no debe contener información tendencial.

Puesto que desconocemos los valores del componente inobservable S_t , el siguiente paso, una vez obtenidos los modelos teóricos para los componentes, consiste en proceder a su estimación a partir de los datos observados en la serie corregida de efectos deterministas N_t . Usaremos para ello los filtros de Wiener-Kolmogorov (W-K). Se trata de filtros ARMA, simétricos y de cola infinita derivados de la minimización del error cuadrático medio entre el componente teórico y su estimador, véase Maravall (1987) para una derivación completa.

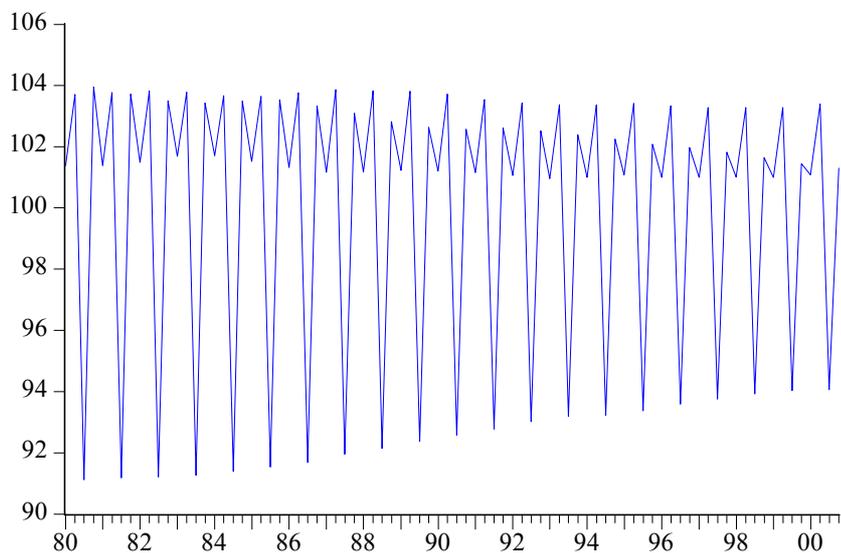
En el gráfico siguiente podemos observar tanto las ponderaciones como la función de ganancia al cuadrado del filtro de W-K aplicado a N_t para obtener la estimación del componente estacional. En la figura, hemos incluido solamente los veinte primeros retardos dado que las ponderaciones son despreciables a partir de ese horizonte. La perspectiva en el dominio de la frecuencia queda recogida en la parte derecha del gráfico. La ganancia al cuadrado del filtro ilustra el peso que adquieren las diversas frecuencias en la serie filtrada en comparación con el que tenían en la serie original. Comprobamos cómo este filtro mantiene el peso en las frecuencias $\pi/2$ y π correspondientes a las oscilaciones anuales o semianuales, esto es, las responsables de la estacionalidad en una serie trimestral-, mientras que elimina toda la contribución de la serie que corresponda a frecuencias lejanas del entorno de las anteriores. De este modo consigue aislar el componente estacional.

Gráfico 19: Filtro de Wiener-Kolmogorov para estimar el componente estacional



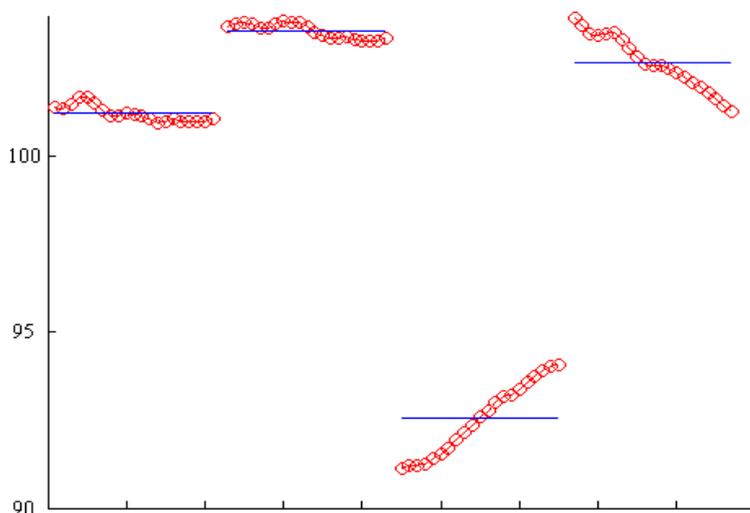
El gráfico 20 nos muestra que el componente estacional de la serie analizada, registra adecuadamente las pronunciadas caídas que en los terceros trimestres de cada año se producen en la serie a lo largo del período observado. Estos descensos pueden llegar a hacer caer el nivel en, aproximadamente un 8 por ciento con respecto al valor medio de la serie y en torno a un 10 por ciento de la media de la variable excluyendo las terceras observaciones de cada año. También recoge las rápidas recuperaciones que el agregado experimenta durante los últimos trimestres, así como las leves variaciones que, en virtud de la estacionalidad se producen durante la primera mitad de cada año. Hemos de notar que, cualitativamente, la pauta de comportamiento estacional posee un alto grado de homogeneidad a lo largo del tiempo. Sin embargo, cuantitativamente, hay que reseñar una cierta disminución en el tamaño de la variabilidad estacional a medida que avanza el período de observación.

Gráfico 20: VAB industrial no energético: componente estacional



Si reordenamos la serie anterior, agrupando las observaciones correspondientes a cada trimestre por orden anual, podemos apreciar con más claridad la evolución de la estacionalidad en cada trimestre. Comprobamos en el gráfico 21 cómo en los dos primeros trimestres, la contribución a la estacionalidad es escasamente volátil, al contrario de lo que sucede con los dos últimos. Con respecto a los terceros trimestres, observamos un menor descenso estacional a medida que avanza el período cuantificado, hecho que se compensa con un menor nivel de recuperación en las cuartas mediciones de cada año. La combinación de ambos efectos da lugar a la menor amplitud de las oscilaciones estacionales antes comentada.

Gráfico 21: Factores estacionales agrupados



En la tabla 10 figuran los cuatro primeros retardos de la función de autocorrelación simple del componente estacional teórico, de su estimador teórico y de su estimación empírica. También figuran las varianzas correspondientes, expresadas tomando como unidad la varianza de los residuos de la modelización ARIMA de la componente estocástica N_t . Se cumple que la varianza de la componente teórica es mayor que la del estimador. Asimismo, la varianza del estimador y la de la estimación tienen valores muy cercanos entre sí. Esta proximidad garantiza que el truncado del filtro de Wiener-Kolmogorov no ha conllevado pérdidas apreciables de información.

Tabla 10: Componente estacional (transformación estacionaria). Autocorrelación simple y su varianza

Retardo	Componente	Estimador	Estimación
1	0.509	-0.016	-0.199
2	-0.050	-0.730	-0.439
3	-0.197	-0.251	-0.223
4	0.000	0.722	0.685
Varianza* σ_a	0.045	0.006	0.004

(b) Ciclo-tendencia

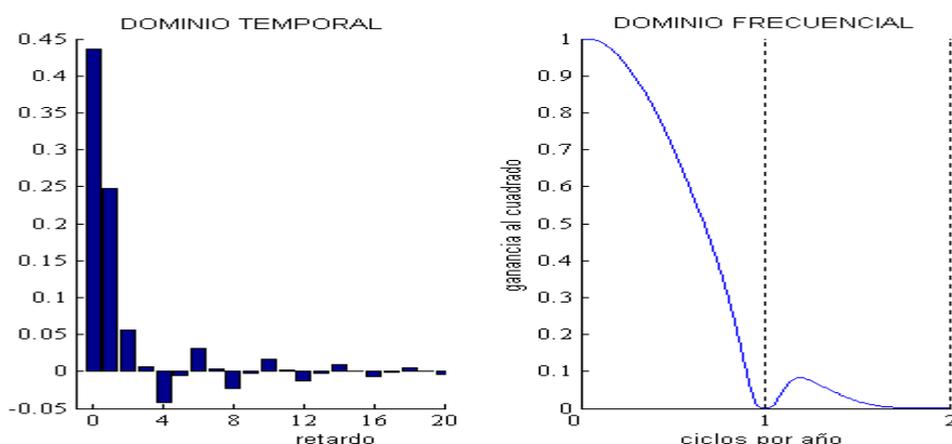
El modelo teórico para el componente de ciclo-tendencia identificado mediante el principio de descomposición canónica es:

$$(1 - B)^2 P_t = (1 + 0.1356B - 0.8644B^2) a_{pt}$$

es decir, un modelo IMA(2,2) equilibrado, no estacionario y no invertible. Las pseudo-innovaciones $a_{p,t}$ tienen una varianza de 0.16, medida en unidades de varianza de a_t . Teniendo en cuenta que el operador MA puede descomponerse como $(1+B)(1-0.87B)$, el modelo puede interpretarse como un paseo aleatorio con deriva volátil, véase Maravall (1990).

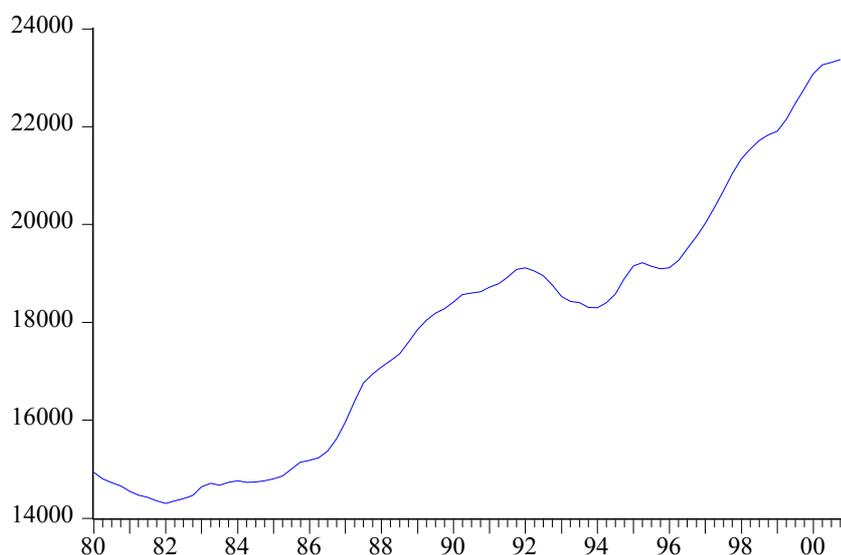
En el gráfico 22 figuran las ponderaciones y la función de ganancia al cuadrado del filtro de Wiener-Kolmogorov aplicado a N_t para estimar la ciclo-tendencia. Como ocurría con la estacionalidad, son los primeros pesos del filtro los de mayor valor absoluto. Observamos en la parte derecha del gráfico cómo es mantenido el peso en la frecuencia cero mientras que en el resto de frecuencias hasta $\pi/2$, dicha ponderación es progresivamente atenuada hasta hacerse nula. Asimismo, el descenso a partir de la frecuencia cero se produce de forma progresiva, por lo que este filtro también preserva una buena parte de las oscilaciones cíclicas. Entre $\pi/2$ y π la ganancia experimenta una pequeña joroba forzada por las raíces del filtro en las frecuencias estacionales.

Gráfico 22: Filtro de Wiener-Kolmogorov para estimar la ciclo-tendencia



Durante el período en estudio, la variable ha mantenido una trayectoria globalmente ascendente, puntuada por episodios contractivos de intensidad variable. Este hecho se aprecia con claridad al examinar la señal de ciclo-tendencia, representada en el gráfico 23.

Gráfico 23: VAB industrial no energético: componente de ciclo-tendencia



A la vista de la función de autocorrelación simple de la ciclo-tendencia teórica, de su estimador y de su estimación comprobamos que, como ocurría con el componente estacional, la varianza del componente teórico es mayor que la del estimador y la estimación; teniendo estas últimas valores muy similares.

Tabla 11: Ciclo-tendencia. Autocorrelación simple y su varianza (transformación estacionaria)

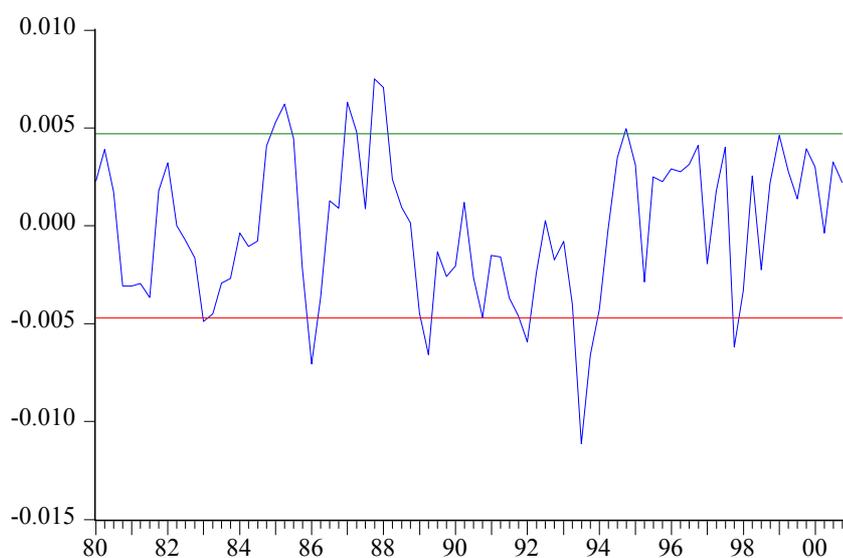
Retardo	Componente	Estimador	Estimación
1	0.010	0.331	0.298
2	-0.490	-0.350	-0.224
3	0.000	-0.289	-0.047
4	0.000	-0.215	-0.335
<hr/>			
Varianza* σ_a	0.294	0.114	0.090

Las pseudo-innovaciones del componente ciclo-tendencial, por razones de estimación, distan bastante de ser ruido blanco, como puede apreciarse a simple vista, en el gráfico 24. La varianza no parece ser constante y se detecta una estructura de autocorrelación nada despreciable. Las bandas de confianza situadas simétricamente a 2 veces la desviación típica del origen, recogen en su interior a la gran mayoría de las observaciones. La innovación más destacable en este aspecto es la que se produce en torno a finales de 1992, fecha del atípico transitorio antes comentado.

También la observación del gráfico nos informa acerca de cómo las pseudo-innovaciones de la ciclo-tendencia son indicativas del signo de la evolución de la

variable en niveles. Se aprecian picos positivos y negativos en las innovaciones coincidentes con épocas de bonanza y depresión económica, respectivamente. En este sentido, con la cautela debida a su estructuración temporal, las pseudo-innovaciones de la tendencia constituyen un elemento potencialmente útil para el análisis de la coyuntura.

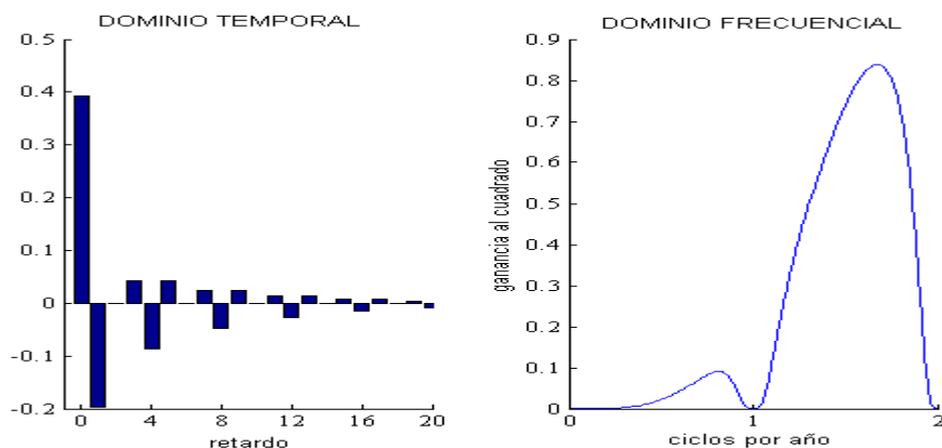
Gráfico 24: Ciclo-tendencia: Pseudo-innovaciones



(c) Componente irregular

El componente irregular teórico es ruido blanco; sin embargo, no ocurre lo mismo en general con el modelo para su estimador, que suele tener estructura.

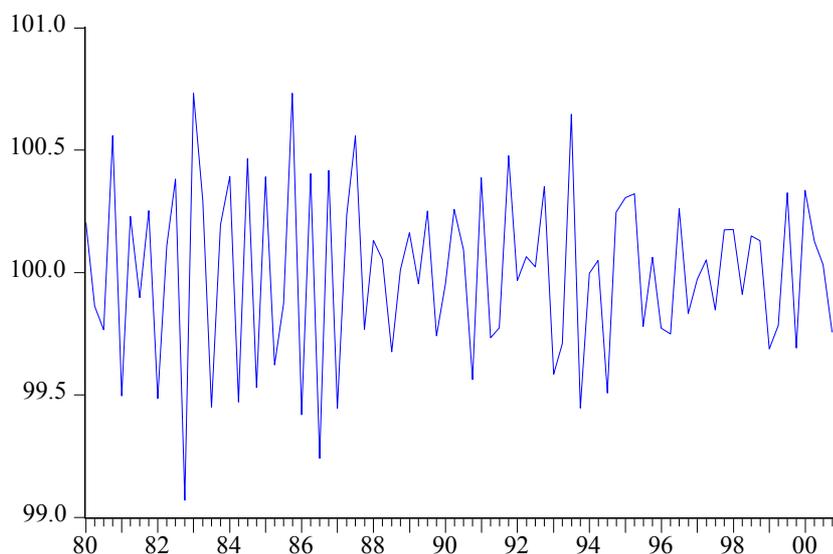
Gráfico 25: Filtro de Wiener-Kolmogorov para estimar el componente irregular



Observamos en el gráfico anterior cómo el filtro de Wiener-Kolmogorov para la irregularidad otorga especial protagonismo al instante actual y a los dos adyacentes. La ganancia al cuadrado del filtro mantiene las oscilaciones de período mayor que semestral y menor que anual, principalmente y exhibe sendos ceros en las frecuencias tendencial y estacional.

Examinando gráficamente el componente irregular estimado, se aprecia claramente la dependencia serial de su estimación así como la evolución de su varianza, habida cuenta de su progresiva reducción desde 1989. Por otra parte, la aportación del componente al nivel, en ningún momento supera el uno por ciento, resultando por tanto relativamente modesta.

Gráfico 26: VAB industrial no energético: componente irregular



La tabla 12 nos muestra cómo el componente irregular teórico tiene autocorrelaciones nulas, como corresponde a un ruido blanco. Sin embargo, el estimador y la estimación tienen cierta estructura de correlación, tal como comentábamos al observar el gráfico del componente. Reparemos también en que las autocorrelaciones respectivas para el estimador y la estimación toman valores muy similares. En lo que se refiere a las varianzas, nuevamente la del componente teórico tiene mayor valor, mientras que la del estimador y la estimación son prácticamente idénticas.

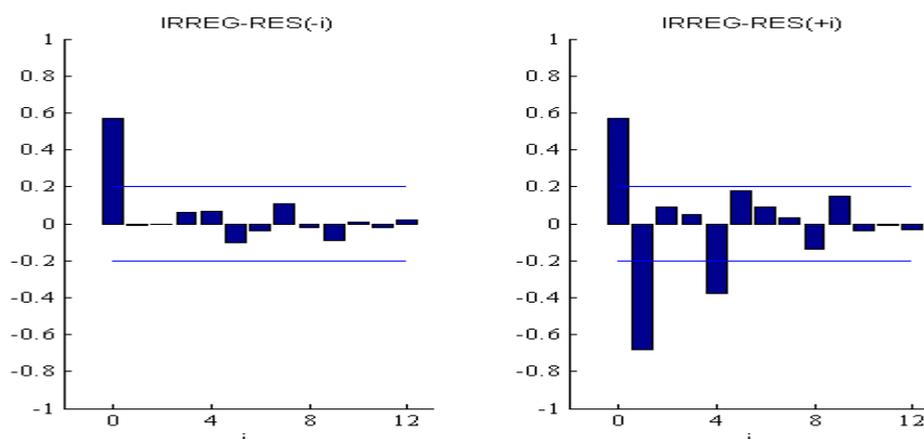
Tabla 12: Irregularidad: Autocorrelación simple y su varianza (transformación estacionaria)

Retardo	Componente	Estimador	Estimación
1	0.000	-0.500	-0.561
2	0.000	0.000	0.034
3	0.000	0.111	0.202
4	0.000	-0.221	-0.223
<hr/>			
Varianza* σ_a	0.153	0.060	0.059

La componente irregular teórica y las perturbaciones del modelo ARIMA, son ambas ruido blanco. Sin embargo, la irregularidad estimada y los residuos del modelo, sus estimaciones respectivas, proceden de la misma información muestral, con lo que cabe esperar una notable correlación entre ambas. El gráfico 27 da cuenta de este hecho; en él aparecen las correlaciones cruzadas entre irregularidad y residuos

hasta el duodécimo retardo y adelanto. La correlación contemporánea entre ambas variables es de 0.57, por otra parte, el lado derecho del gráfico nos permite apreciar una correlación aún mayor en valor absoluto (0.68) entre la irregularidad y los residuos adelantados un período. Recordemos que el filtro de Wiener-Kolmogorov utilizado para estimar la componente irregular está dotado de una elevada ponderación en el primer retardo -y, por simetría, adelanto-. Este hecho es debido a que el modelo del estimador teórico es ruido blanco interpretado retrospectivamente (*backward*) y estructurado según la función representada en el gráfico 27 si se lo examina en sentido extrapolativo (*forward*). En consecuencia, la relación existente entre el componente irregular y los residuos ARIMA es relativamente compleja y, en todo caso, no especialmente intensa de forma contemporánea. Por lo tanto, el uso del componente irregular para el análisis de la coyuntura debe realizarse con prudencia, empleándose de forma preferente los residuos asociados al modelo ARIMA para estimar los *shocks* que recibe la serie.

Gráfico 27: Correlaciones cruzadas entre el componente irregular y los residuos ARIMA



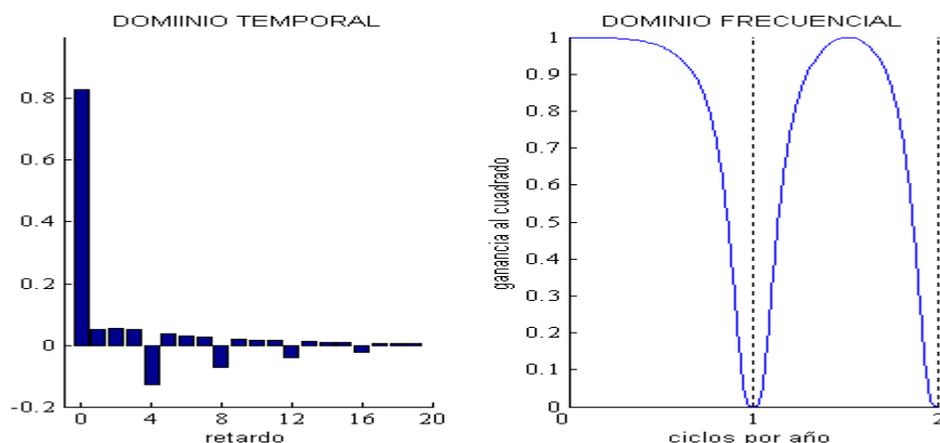
3.3 Serie desestacionalizada final

Si a la serie corregida de efectos deterministas (o linealizada) le descontamos su componente estacional estocástico, obtenemos la serie desestacionalizada (SA, *Seasonally Adjusted*):

$$SA = N - S = P + I$$

Las ponderaciones y la ganancia al cuadrado del filtro de Wiener-Kolmogorov utilizado para la estimación de dicha serie se presentan en el siguiente gráfico:

Gráfico 29: Filtro de Wiener-Kolmogorov para estimar la serie desestacionalizada



Como se aprecia con nitidez, el filtrado otorga la mayor parte del peso al período actual, del que son descontados los retardos múltiplos de cuatro para eliminar la estacionalidad, ponderados cada vez en menor valor absoluto. Los demás retardos juegan un papel secundario en la construcción del filtro. Teniendo en cuenta la simetría del filtro, esta menor dependencia de los valores desplazados con respecto al filtro utilizado para estimar la ciclo-tendencia (véase el gráfico 22) implican un menor nivel de revisiones a medida que la estimación concurrente va transformándose en la histórica.

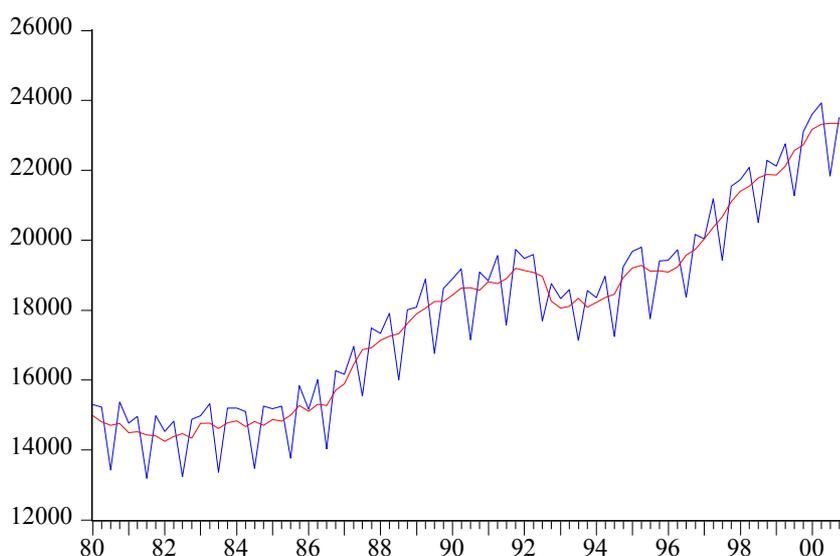
La función de ganancia exhibe una constancia bastante estricta en las bajas frecuencias y posee sendos ceros en las frecuencias estacionales $\pi/2$ y π . Asimismo, debe notarse la apertura relativa de ambas muescas (*notchs*) debido al carácter evolutivo de la estacionalidad que ya ha sido comentado. Por otra parte, el nivel de esta función en la banda cíclica es algo mayor que el que se aprecia para la tendencia (véase el gráfico 22), si bien esta mayor nitidez cíclica es virtualmente anulada por la mayor irregularidad que presenta la serie desestacionalizada con respecto a la señal tendencial.

La serie desestacionalizada final es la que se conoce como “serie desestacionalizada y corregida de efectos de calendario” (SAC, *Seasonally Adjusted and Calendar corrected*) esto es:

$$SA^F = X - TD - E - S = P + I + O = SA + O = SAC$$

En el gráfico 30 aparecen representadas conjuntamente la serie original en niveles y la SAC; de este modo, podemos apreciar con claridad cómo esta última representa el nivel de soporte de la serie a largo plazo, distorsionado localmente por la presencia del componente irregular.

Gráfico 30: Serie bruta y serie desestacionalizada final



Referencias

Bell, W.R. y Hillmer, S.C. (1983) "Modeling time series with calendar variation", *Journal of the American Statistical Association*, vol. 78, n. 383, p. 526-534.

Box, G.E.P. y Tiao, G.C. (1975) "Intervention analysis with applications to economic and environmental problems", *Journal of the American Statistical Association*, vol. 70, n. 349, p. 177-193.

Box, G.E.P. y Jenkins, G.M. (1976) *Time series analysis, forecasting and control*, Holden Day, San Francisco, U.S.A.

Burman, J.P. (1980) "Seasonal adjustment by signal extraction", *Journal of the Royal Statistical Society*, series A, n. 143, p. 321-337.

Engle, Robert F. (1982) "Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of U.K. Inflation," *Econometrica*, 50, 987-1008.

Gómez, V. y Maravall, A. (1996) "Programs TRAMO and SEATS", Documento de Trabajo n. 9628, Banco de España.

Gómez, V. y Maravall, A. (1998a) "Guide for using the programs TRAMO and SEATS", Documento de Trabajo n. 9805, Banco de España.

Gómez, V. y Maravall, A. (1998b) "Automatic modeling methods for univariate series", Documento de Trabajo n. 9808, Banco de España.

Gómez, V. y Maravall, A. (1998c) "Seasonal adjustment and signal extraction in economic time series", Documento de Trabajo n. 9809, Banco de España.

Hillmer, S.C. (1982) "Forecasting time series with trading day variation", *Journal of Forecasting*, vol. 1, p. 385-395.

Hillmer, S.C. y Tiao, G.C. (1982) "An ARIMA model-based approach to seasonal adjustment", *Journal of the American Statistical Society*, vol. 77, n. 377, p. 63-70.

Hillmer, S.C., Bell, W. y Tiao, G.C. (1983) "Modeling considerations in the seasonal adjustment of economic time series", en Zellner, A. (Ed.) *Applied time series analysis of economic data*, U.S. Department of Commerce, Bureau of the Census, Washington, U.S.A.

INE (2002) "Ajuste estacional y extracción de señales en la Contabilidad Nacional Trimestral", *Boletín Trimestral de Coyuntura*, n. 84, p. 129-151.

INE (2002) "Ajuste estacional y extracción de señales en la Contabilidad Nacional Trimestral", Banco de España, Documento de Trabajo n. 0210.

Liu, L.M. (1980) "Analysis of time series with calendar effects", *Management Science*, vol. 26, n. 1, p. 106-112.

Liu, L.M. (1983) "Identification of time series models in the presence of calendar variation", SCA Corporation, Working Paper n. 102.

Liu, L.M. y Hudak, G.B. (1995) *The SCA Statistical System.*, SCA Corp., Oak Ridge, Illinois, U.S.A.

Maravall, A. (1987) "Descomposición de series temporales. Especificación, estimación e inferencia", *Estadística Española*, vol. 29, n. 114, p. 11-69.

Maravall, A. (1990) "Análisis de un cierto tipo de tendencias", *Cuadernos Económicos de ICE*, n. 44, p. 124-146.

Maravall, A. (1993a) "Stochastic linear trends. Models and estimators", *Journal of Econometrics*, n. 56, p. 5-37.

Maravall, A. (1993b) "Short-term analysis of macroeconomic time series", European University Institute, Working Paper ECO n. 95/9.

Maravall, A. (1994) "Unobserved components in economic time series", en Pesaran, H., Schmidt, P. y Wickens, M. (Eds.) *The handbook of applied econometrics*, vol. 1, Basil Blackwell, Oxford, U.K.

Maravall, A. y Pierce, D.A. (1987) "A prototypical seasonal adjustment model", *Journal of Time Series Analysis*, n. 8, p. 177-193.

MathWorks (1998) *Matlab: User's Manual*, The MathWorks Co., Natick, Massachusetts, USA.

Salinas, T.S. y Hillmer, S.C. (1987) "Multicollinearity problems in modeling time series with trading-day variation", *Journal of Business and Economic Statistics*, vol. 5, n. 3, p. 431-436.

Tsay, R.S. y Tiao, G.C. (1985) "Use of canonical analysis in time series model identification", *Biometrika*, vol. 72, p. 299-315.

