

**DETECCIÓN Y CORRECCIÓN AUTOMÁTICA DE
OUTLIERS CON TRAMO: UNA APLICACIÓN AL IPC
DE BIENES INDUSTRIALES NO ENERGÉTICOS**

*Victor Gómez
David Taguas*

D-95006

Noviembre 1995

Trabajo presentado en el VIII Seminario sobre Validación y Especificación de Modelos Econométricos. Departamento de Análisis Económico. Universidad de Zaragoza, 2-3 Noviembre de 1995.

Agradecemos los comentarios del Profesor Agustín Maravall, Regina Kaiser y Ángel Sánchez.

Los Documentos de Trabajo de la Dirección General de Planificación no representan opiniones oficiales del Ministerio de Economía y Hacienda. Los análisis, opiniones y conclusiones aquí expuestos son los de los autores, con los que no tiene que coincidir, necesariamente, la Dirección General de Planificación. La Dirección General de Planificación considera, sin embargo, interesante la difusión del trabajo para que los comentarios y críticas que suscite contribuyan a mejorar su calidad.

Resumen

El programa TRAMO dispone de 1) un método de especificación automática de modelos ARIMA para series temporales, basado en estimar primero las raíces unitarias y utilizar después el criterio BIC para especificar un modelo ARMA a la serie diferenciada, y 2) un procedimiento para tratar cuatro tipos de outliers que, de forma automática, identifica la situación y el tipo de anomalía y corrige su efecto en la serie. Los outliers se van obteniendo uno a uno, estimándose cada vez conjuntamente los parámetros del modelo y los efectos de todos los outliers obtenidos hasta ese momento. Mediante regresiones múltiples, se eliminan los posibles efectos de enmascaramiento. Las estimaciones, tanto para la especificación automática de modelos como para el tratamiento automático de outliers, se pueden obtener utilizando solo técnicas de regresión lineal, por lo que se reduce sustancialmente el tiempo empleado en hacer los cálculos.

PALABRAS CLAVE: Series Temporales, Outliers, Modelización Automática, Modelos ARIMA, Filtro de Kalman.

1. Introducción

TRAMO ("Time Series Regression with ARIMA Noise, Missing Observations, and Outliers") y SEATS ("Signal Extraction in ARIMA Time Series") son dos programas escritos en Fortran para grandes ordenadores y ordenadores personales bajo MsDos, desarrollados por Gómez y Maravall (1994a) y Maravall y Gómez (1994).

El programa TRAMO puede ser utilizado independientemente de SEATS, como un programa para el análisis detallado de series temporales, ya que permite la estimación, predicción e interpolación de modelos de regresión con observaciones ausentes y errores ARIMA, en presencia de varios tipos de outliers. Las variables de regresión pueden ser incluídas por el usuario (tales como variables económicas que se piensa están relacionadas con la serie), o generadas por el programa, como es el caso del efecto de día laborable, el efecto Pascua y variables de intervención del tipo impulso, escalón, o, en general, cualquier posible secuencia de ceros y unos.

TRAMO elimina de la serie los efectos especiales, identifica y elimina automáticamente los efectos de varios tipos de outliers e interpola las observaciones ausentes. También dispone de un módulo de identificación automática de modelos que puede ser muy útil, tanto para los expertos en series temporales, a los que releva de tareas monótonas, como para los que no lo son, poniendo a su alcance las técnicas de los modelos ARIMA, que hasta hace poco sólo podían ser utilizadas por personal especializado. El procedimiento de modelización automática está basado en estimar primero las raíces unitarias y utilizar después el criterio BIC para especificar un modelo ARMA a la serie diferenciada.

Utilizados conjuntamente, TRAMO y SEATS constituyen una alternativa a filtros ad-hoc,¹ para obtener la tendencia y el ciclo de una serie temporal, entre otros componentes no observados.

TRAMO y SEATS entran dentro de la categoría de los llamados métodos basados en modelos ARIMA para descomponer una serie temporal en sus

¹ Como, por ejemplo, el profusamente utilizado filtro de Hodrick-Prescott.

componentes no observados (es decir, para extraer de una serie sus distintas señales). El método utilizado en SEATS fue diseñado originalmente para desestacionalizar series temporales (es decir, para eliminar la señal estacional), y las referencias básicas son Cleveland y Tiao (1976), Box, Hillmer y Tiao (1978), Burman (1980), Hillmer y Tiao (1982), Bell y Hillmer (1984) y Maravall y Pierce (1987). El programa descompone una serie que sigue un modelo ARIMA en varios componentes. La descomposición puede ser aditiva o multiplicativa. Los componentes considerados en SEATS son: tendencia, componente estacional, ciclo y componente irregular.

La tendencia representa la evolución a largo plazo de la serie y presenta un pico en la frecuencia 0. El componente estacional recoge los picos espectrales en las frecuencias estacionales y el ciclo recoge la fluctuación periódica con período mayor que un año, y tiene un pico espectral en la frecuencia asociada, entre 0 y $(2\pi/s)$, donde s es el número de estaciones en el año. También puede incorporar desviaciones estacionarias con respecto a la tendencia. Finalmente, el componente irregular recoge el comportamiento errático, del tipo ruido blanco, y tiene por tanto un espectro plano. Los componentes vienen determinados y se deducen plenamente de la estructura del modelo ARIMA (agregado) de la serie observada, que puede ser identificado directamente a partir de los datos.

La descomposición parte de la hipótesis de la ortogonalidad de los componentes, que a su vez siguen modelos ARIMA. Para identificar los componentes, se requiere que (excepto para el irregular) estén limpios de ruido blanco. Esta es la llamada propiedad "canónica", que implica que no se pueda extraer ruido blanco de los componentes distintos del irregular. De este modo, se maximiza la varianza de este último y, al contrario, la tendencia, el componente estacional y el ciclo son tan estables como sea posible (de acuerdo con la estructura estocástica del modelo ARIMA seguido por la serie temporal).

El modelo tratado por SEATS es el de una serie integrada lineal con innovaciones gaussianas. Como esta hipótesis puede que no se cumpla y siempre es necesario un modelo, SEATS ha sido diseñado para ser usado conjuntamente con el programa TRAMO, que ha sido descrito más arriba. Como ambos programas pueden tratar de forma rutinaria un

gran número de series, proporcionan una alternativa totalmente basada en modelos a REGARIMA y X11ARIMA, que constituyen el nuevo procedimiento X12 de la Oficina del Censo de los EEUU.

2. Detección y corrección automática de outliers

Cuando se analizan los datos de series temporales, es corriente encontrar atípicos que tienen su origen en intervenciones incontroladas o inesperadas, como huelgas, determinadas medidas de política económica, ocurrencia de desastres, errores en la transcripción de datos, etc. Como los modelos ARIMA que se utilizan frecuentemente en series temporales están diseñados para recoger la información de procesos que tienen una cierta homogeneidad, los outliers y los cambios estructurales influyen en la eficiencia y la bondad del ajuste de dichos modelos.²

El enfoque tradicional para tratar el problema de los outliers, suponiendo que se ha especificado correctamente un modelo ARIMA para la serie, consiste en identificar primero la posición y el tipo de la anomalía y utilizar, a continuación, el análisis de intervención propuesto por Box y Tiao (1975). Esto requiere que una persona experta examine los datos y, con la ayuda de algún programa informático de tratamiento de series temporales, analice las funciones de autocorrelación simple y parcial de los residuos, gráficos de la serie y los residuos, etc... Por esta razón, es interesante buscar algún procedimiento que trate de automatizar lo más posible todo este proceso de localización y corrección de atípicos. Entre los primeros intentos en esta dirección cabe citar los de Chang, Tiao y Chen (1988), Hillmer, Bell y Tiao (1983), y Tsay (1988). Estos procedimientos funcionan bien cuando se trata de detectar y estimar los efectos de outliers de gran relevancia y aislados, pero no resuelven el problema debido a que:

- (a) La presencia de outliers puede hacer que el modelo no se especifique adecuadamente.

² Ver, por ejemplo, Abraham y Box (1979), Chen y Tiao (1990), Tsay (1986), y Guttman y Tiao (1978).

- (b) Incluso si el modelo está adecuadamente especificado, los outliers pueden producir sesgos importantes en los estimadores de los parámetros.
- (c) Puede que no se identifiquen algunos outliers debido a un efecto de enmascaramiento.

El método de Tsay (1986) constituye una aportación muy importante para resolver el problema de la especificación de modelos en presencia de outliers. Por otra parte, Chen y Liu (1993), proponen un método de tratamiento de outliers para resolver los problemas b) y c), que funciona de forma bastante satisfactoria, aunque presenta algunas deficiencias, entre las que cabe destacar las siguientes: 1) se estima varias veces por máxima verosimilitud exacta, lo que es costoso, 2) no utiliza residuos exactos, 3) el algoritmo es excesivamente complicado y 4) las regresiones múltiples no se hacen filtrando los datos y las columnas de la matriz de regresión por un filtro "exacto", como el filtro de Kalman, sino que se utiliza un filtro condicional.

El método que utiliza el programa TRAMO para la detección y la corrección de outliers, aborda la solución de los problemas b) y c) de forma que se intentan subsanar las deficiencias del procedimiento de Chen y Liu (1993), como se verá a continuación. Además, si se utiliza de una forma secuencial, junto con el procedimiento de especificación automática, constituye un procedimiento alternativo al de Tsay (1986) para resolver el problema de la especificación automática en presencia de outliers, que completa y puede mejorar mucho dicho procedimiento.

Considérese en primer lugar el caso en que no hay efectos de regresión para extender posteriormente los resultados al caso general. Supóngase, pues, que la serie $\{z(t)\}$ sigue el modelo ARIMA(p, d, q) dado por:

$$\phi(B)\delta(B)(z(t) - \mu) = \theta(B)a(t), \quad (1)$$

donde $\phi(B) = 1 + \phi_1 B + \dots + \phi_p B^p$, $\delta(B) = 1 + \delta_1 B + \dots + \delta_d B^d$ y $\theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q$ son polinomios en el operador de retardos

B de grados p, d y q , $\{a(t)\}$ es una sucesión de variables aleatorias i.i.d. $N(0, \sigma^2)$ y μ es la media del proceso. Se supone que las raíces de $\delta(B)$ están todas en la circunferencia unidad y que las de $\phi(B)$ están fuera del círculo unidad, de forma que $w(t) = \delta(B)z(t)$ sigue un proceso estacionario ARMA(p, q). Las series económicas en su mayoría siguen procesos estacionales multiplicativos, donde

$$\begin{aligned}\delta(B) &= \nabla^a \nabla_s^b \\ \phi(B) &= \phi_r(B) \phi_s(B^s) \\ \theta(B) &= \theta_r(B) \theta_s(B^s),\end{aligned}$$

s es el número de observaciones por año, $\nabla^a = (1-B)^a$ y $\nabla_s^b = (1-B^s)^b$. Para las series económicas, en la práctica se verifica $0 \leq a \leq 2$, $0 \leq b \leq 1$. En el resto de este epígrafe se utiliza, para simplificar, la notación dada por (1) haciendo referencia al caso estacional multiplicativo cuando convenga. Igualmente se supone, por simplicidad, que $\mu = 0$.

Para modelizar el efecto de un outlier, se considera el modelo:

$$z^*(t) = z(t) + \omega \nu(B) I_t(T), \quad (2)$$

donde $\nu(B)$ es un cociente de polinomios en B , $\{z(t)\}$ es la serie libre de outliers, $I_t(T) = 1$ si $t = T$ e $I_t(T) = 0$ en otro caso, es una función indicadora que hace referencia al momento en que tiene lugar el outlier y ω representa su magnitud. El procedimiento utilizado por TRAMO considera cuatro tipos de outliers, que son:³

$$\text{IO: } \nu(B) = \theta(B) / (\delta(B) \phi(B)),$$

$$\text{AO: } \nu(B) = 1,$$

$$\text{TC: } \nu(B) = 1 / (1 - \delta B),$$

$$\text{LS: } \nu(B) = 1 / (1 - B).$$

³ Las siglas utilizadas están tomadas del inglés y corresponden a atípico innovacional (IO), atípico aditivo (AO), cambio temporal (TC) y cambio de nivel (LS).

El valor de δ se considera fijo e igual a 0.7. Para una discusión más tallada sobre la naturaleza y la motivación de estos tipos de atípicos, ver Chen y Tiao (1990), Fox (1972), Hillmer, Bell y Tiao (1983), y Tsay (1988).⁴

2.1 Estimación y ajuste del efecto de un outlier

Supóngase que los parámetros del modelo (1) son conocidos, que la serie observada es $z^* = (z^*(1), \dots, z^*(N))'$, que la serie libre del efecto de outliers es $z = (z(1), \dots, z(N))'$ y designese $Y = (\nu(B)I_1(T), \dots, \nu(B)I_N(T))'$. Entonces, (2) se puede escribir como el modelo de regresión con errores ARIMA:

$$z^* = Yw + z. \quad (3)$$

Para simplificar, se supone que z en (3) sigue un modelo ARMA o, lo que lo mismo, que $\delta(B) = 1$ en (1). En caso contrario, se trabajaría con las series obtenidas al diferenciar z^* , z e Y en (3). Sea $Var(z) = \sigma^2\Omega$ y $\Omega = LL'$, con L matriz triangular inferior, la descomposición de Cholesky de Ω . Multiplicando (3) por L^{-1} , se obtiene el modelo de regresión lineal simple:

$$L^{-1}z^* = L^{-1}Yw + L^{-1}z. \quad (4)$$

Haciendo $r = L^{-1}z$, se verifica $Var(r) = \sigma^2I_N$, por lo que el vector r es el vector de residuos de la serie (no observados). Si se denomina $r^* = L^{-1}z^*$ a los residuos estimados y se hace $X = L^{-1}Y$, (4) se puede escribir de la forma:

$$r^* = Xw + r. \quad (5)$$

Si en (3) el vector Y fuera 0, entonces el modelo sería $z^* = z$ y, si se aplicara el filtro de Kalman a este modelo, se obtendría $L^{-1}z^*$. Este resultado, que es un resultado estándar de la teoría de control, permite ver el filtro de Kalman como un algoritmo que, aplicado a un vector cualquiera v en lugar de a los datos z^* , produce $L^{-1}v$. Por tanto, el filtro de Kalman, aplicado al vector de observaciones z^* y al vector Y , permite pasar de (3) a (4) o, lo que es lo mismo, de de (3) a (5).

⁴ Estas cuatro clases de outliers corresponden a diversos tipos simples de atípicos. Los casos más complicados se pueden aproximar normalmente mediante combinaciones de estos cuatro tipos.

En (5), se puede estimar ω por MCO, obteniendo:

$$\tilde{\omega} = (X'X)^{-1}X'r^*, \quad (6)$$

siendo la varianza del estimador $Var(\tilde{\omega}) = (X'X)^{-1}\sigma^2$. Para contrastar la hipótesis nula de que no hay anomalía en $t = T$ frente a la hipótesis alternativa de que sí la hay, se utiliza el estadístico:

$$\tau = (X'X)^{1/2}\tilde{\omega}/\sigma, \quad (7)$$

que, bajo la hipótesis nula, tiene una distribución $N(0, 1)$.

En la práctica, lo normal es que no se conozcan los parámetros del modelo (1) y que haya que estimarlos. En estas condiciones, lo que se hace es estimar primero los parámetros del modelo (1) por máxima verosimilitud exacta, como si no hubiera outliers, y luego utilizar, en lugar de (6) y (7), sus homólogos

$$\hat{\omega} = (\hat{X}'\hat{X})^{-1}\hat{X}'\hat{r}^*, \quad \hat{\tau} = (\hat{X}'\hat{X})^{1/2}\hat{\omega}/\hat{\sigma},$$

obtenidos sustituyendo en (6) y (7) los parámetros desconocidos por sus estimaciones. Se puede demostrar que $\hat{\tau}$ es asintóticamente equivalente a τ .⁵ La forma de la matriz X y, por tanto, la de $X'X$, depende de cada tipo de outlier.

Para ver si hay un outlier en $t = T$, se calculan los cuatro estimadores $\hat{\omega}_{IO}(T)$, $\hat{\omega}_{AO}(T)$, $\hat{\omega}_{TC}(T)$ y $\hat{\omega}_{LS}(T)$ y sus correspondientes estadísticos $\hat{\tau}_{IO}(T)$, $\hat{\tau}_{AO}(T)$, $\hat{\tau}_{TC}(T)$ y $\hat{\tau}_{LS}(T)$, donde el subíndice hace referencia al tipo de outlier. Entonces, como proponen Chang, Tiao y Chen (1988), se utiliza el estadístico $\lambda_T = \max\{|\hat{\tau}_{IO}(T)|, |\hat{\tau}_{AO}(T)|, |\hat{\tau}_{TC}(T)|, |\hat{\tau}_{LS}(T)|\}$. Si $\lambda_T > C$, donde C es un valor crítico predeterminado, entonces existe la posibilidad de que haya un outlier del tipo dado por el subíndice del estadístico $\hat{\tau}$ para el cual se alcanza el máximo.

Como el instante $t = T$ en que ocurre el outlier es desconocido en la práctica, el criterio del cociente de verosimilitudes⁶ conduce a repetir

⁵ Ver Chang, Tiao y Chen (1988), pg. 196.

⁶ Véase, a este respecto, Chang y Tiao (1983).

la anterior operación para cada $t = 1, \dots, N$ y calcular $\lambda = \max_t \lambda_t = |\hat{r}_{tp}(T)|$, donde tp puede ser IO, AO, TC o LS. Si $\lambda > C$, entonces hay un outlier de tipo tp en T .

Conocido el tipo de un outlier en $t = T$, se puede corregir su efecto en la serie y en los residuos utilizando (2) y (5), respectivamente.

En todo lo anterior, se ha supuesto que r^* y X se calculan con un filtro "exacto", que es el filtro de Kalman. Esto es lo correcto, ya que el número de observaciones en una serie temporal es siempre finito y, por esta razón, no se puede utilizar el filtro semiinfinito, dado por el inverso del modelo de la serie, $\pi(B) = 1 + \pi_1 B + \pi_2 B^2 + \dots = \phi(B)\delta(B)/\theta(B)$, para aplicarlo a (2) y obtener

$$\pi(B)z_t^* = \omega[\pi(B)\nu(B)I_t(T)] + a(t), \quad t = 1, \dots, N,$$

en lugar de (4). En la práctica, lo que se suele hacer es truncar el filtro $\pi(B)$ y prescindir de algunas observaciones al principio de la serie.⁷ En el procedimiento utilizado por TRAMO lo que se hace es filtrar exactamente los residuos, es decir, obtener r^* , y utilizar $\pi(B)$ para filtrar el vector Y en (3).

2.2 Tratamiento de outliers múltiples

Cuando existen outliers múltiples, en lugar de (2) se debe considerar el modelo:

$$z^*(t) = z(t) + \sum_{i=1}^k \omega_i \nu_i(B) I_i(t_i). \quad (8)$$

Como se muestra en Chen y Liu (1993), los estimadores de los ω_i obtenidos simultáneamente, utilizando (8), pueden ser muy distintos de los obtenidos por un procedimiento iterativo utilizando los resultados del epígrafe anterior (es decir, obtener primero $\hat{\omega}_1$, luego $\hat{\omega}_2$, etc...). Por esta razón, es importante que todo algoritmo de detección de outliers efectúe en algún momento determinadas regresiones múltiples para detectar los falsos atípicos y corregir los sesgos que se producen en los estimadores obtenidos secuencialmente.

⁷ Ver Chen y Liu (1993), pg. 285.

Para estimar los parámetros de las regresiones múltiples, suponiendo conocidos los parámetros del modelo ARIMA (1), el algoritmo que utiliza TRAMO aplica primero el filtro de Kalman como en el paso de (3) a (4). Después, los estimadores de los ω_i y sus correspondientes estadísticos se calculan como en (6) y (7), aunque de una forma eficiente, utilizando el algoritmo QR^8 con transformaciones ortogonales de Housholder. Una descripción más detallada se verá posteriormente, en la tercera sección.

2.3 Estimación de la desviación típica de los residuos σ

Cuando existen outliers en la serie, el estimador muestral usual puede sobreestimar σ . Por esta razón, es conveniente utilizar un estimador robusto, que en TRAMO es el MAD, cuya expresión es

$$\hat{\sigma} = 1'483 \times \text{mediana}\{|r^*(t) - \tilde{r}^*|\},$$

donde \tilde{r}^* es la mediana de los residuos estimados $r^* = L^{-1}z^*$. Aquí se suponen conocidos los parámetros del modelo, pero si éstos fueran desconocidos, como es habitual, se sustituirían en la expresión anterior por sus estimaciones.

2.4 Descripción del procedimiento de TRAMO

Para el tratamiento de outliers, el procedimiento de TRAMO supone que los órdenes (p, d, q) del modelo (1) que sigue la serie son conocidos y procede iterativamente. En la primera etapa, se detectan los atípicos uno a uno y se modifican los parámetros del modelo después de haber detectado cada outlier. Cuando ya no se encuentran más atípicos, se pasa a la segunda etapa, en la que se hace una regresión múltiple, descartándose aquellos outliers que no sean significativos. Después, se vuelve a la primera etapa para iterar.

Hasta ahora, se ha supuesto que no había efectos de regresión, pero todo el esquema anterior es válido también cuando se incluyen dichos efectos. Supóngase, por tanto, que la serie sigue el modelo de regresión con errores

⁸ Véase, por ejemplo, Gill, Murray y Wright (1992).

ARIMA siguiente:

$$z(t) = y'(t)\beta + \nu(t), \quad t = 1, \dots, N, \quad (9)$$

donde $\beta = (\beta_1, \dots, \beta_k)'$ es el vector de los parámetros de regresión, que puede incluir la media en su primera componente, $\{z(t)\}$ es la serie observada, $\{y(t)\}$ son los vectores de las variables de regresión y $\{\nu(t)\}$ sigue el modelo ARIMA (1) con $\mu = 0$. Entonces, el algoritmo de detección y corrección automática de atípicos del procedimiento de TRAMO es, descrito con detalle, el siguiente:

Inicialización

- (a) Si hay variables de regresión en el modelo, incluida la media, se estiman dichos parámetros por MCO y se restan sus efectos de la serie.

Etapa I: Detección y estimación de los outliers uno a uno

- I.1) Se estiman los parámetros del modelo ARIMA mediante el procedimiento de Hannan y Rissanen (1982), utilizando la serie a la que se le han restado todos los efectos de regresión, incluidos los atípicos detectados hasta ese momento.
- I.2) Con las estimaciones de los parámetros del modelo ARIMA obtenidas en I.1, se obtienen nuevas estimaciones de los parámetros de regresión, así como sus estadísticos t , en el modelo (9) por mínimos cuadrados generalizados, utilizando el algoritmo de Morf, Sidhu y Kailath (1974), de filtro de Kalman, y el algoritmo QR. A continuación, se obtienen los residuos estimados del modelo (9).
- I.3) Con los residuos estimados en I.2, se calcula el MAD, que estima de forma robusta la desviación típica de los residuos del modelo (9).
- I.4) Si $x = (x_{d+1}, \dots, x_N)'$, donde d es el grado del polinomio diferenciador $\delta(B)$ en (1), es la serie diferenciada correspondiente a (9),

se calculan para $t = d + 1, \dots, N$ los estadísticos $\hat{r}_{IO}(t)$, $\hat{r}_{AO}(t)$, $\hat{r}_{LS}(t)$ y $\hat{r}_{TC}(t)$, como en el epígrafe 1, utilizando los residuos obtenidos en I.2 y el MAD obtenido en I.3. Sea, para cada $t = d + 1, \dots, N$, $\lambda_t = \max\{|\hat{r}_{IO}(t)|, |\hat{r}_{AO}(t)|, |\hat{r}_{TC}(t)|, |\hat{r}_{LS}(t)|\}$. Si $\lambda = \max_t \lambda_t = |\hat{r}_{tp}(T)| > C$, donde C es un valor crítico predeterminado, entonces hay un posible atípico de tipo tp en T . El subíndice tp puede ser IO, AO, TC o LS. Si no se ha encontrado atípico la primera vez que se pasa por aquí, para, estando la serie libre del efecto de atípicos. Si no se ha encontrado atípico, pero no es la primera vez que se pasa por aquí, entonces va a II.1. Si, por el contrario, se ha encontrado un atípico, entonces se restan todos los efectos de regresión de la serie, utilizando las estimaciones de I.2 y la estimación del último atípico obtenida al calcular λ , y se vuelve a I.1) para iterar.

Etapa II: Regresión múltiple

- II.1) Con los estimadores de los parámetros de regresión múltiple y sus estadísticos t obtenidos la última vez que se pasó por I.2, se comprueba si hay algún atípico cuyo estadístico t sea $< C$, donde C es el mismo valor crítico de I.4. Si no los hay, se para. Si, por el contrario, se ha encontrado alguno, entonces, se eliminan todos los que cumplan esa condición y se vuelve a I.1 para iterar.

Una de las ventajas del algoritmo anterior es que todas las estimaciones de los parámetros del modelo ARIMA se hacen utilizando regresiones lineales y, por tanto, no son costosas de obtener en términos computacionales. Otra mejora consiste en que se utilizan residuos "exactos" frente a residuos aproximados. Finalmente, el uso de regresiones múltiples evita que se detecten falsos *outliers* o se dejen de detectar debido al efecto de enmascaramiento.

En I.2), el filtro de Kalman se aplica a los datos y a las columnas de

la matriz de regresión, para pasar de un modelo de mínimos cuadrados generalizados a uno de MCO. El procedimiento es el mismo que para pasar de (3) a (4).

En I.3), tal y como se explicó al final de la sección 1, se utilizan los residuos "exactos", pero la matriz de regresión para detectar cada *outlier*, que es un vector, se filtra condicionalmente, utilizando el filtro $\pi(B)$ dado por el inverso del modelo de la serie.

3. Aspectos computacionales

El programa TRAMO permite hacer estimaciones por máxima verosimilitud exacta de un modelo ARIMA. Las estimaciones iniciales de los parámetros se obtienen por el método de Hannan y Rissanen (1982). Después, se utiliza el método de Gauss-Marquardt de optimización no lineal. Para evaluar la verosimilitud o, más exactamente, la suma de cuadrados no lineales que hay que minimizar, se utiliza el algoritmo de Morf, Sidhu y Kailath (1974), de filtro de Kalman, descrito por Pearlman (1980), y mejorado por Mélard (1984).

Los parámetros de los modelos de regresión con errores ARIMA, supuesto que se conocen los parámetros autorregresivos y de medias móviles del modelo ARIMA, se estiman de la siguiente manera. Supóngase que la serie observada $z = (z(1), \dots, z(N))'$ sigue el modelo de regresión con errores ARIMA:

$$z = Y\beta + u, \quad (10)$$

donde $\beta = (\beta_1, \dots, \beta_k)'$ es el vector de parámetros de regresión, que puede incluir la media como primera componente, Y es una matriz $N \times k$ de rango completo y u sigue el modelo ARIMA (1) con $\mu = 0$, que se supone conocido. Diferenciando z , las columnas de Y y u en (10), se obtiene

$$y = X\beta + v, \quad (11)$$

donde $y = (y(d+1), \dots, y(N))'$, X es una matriz $(N-d) \times k$, los componentes de $v = (v(d+1), \dots, v(N))'$ siguen el modelo ARMA $\phi(B)v(t) = \theta(B)a(t)$ y se supone que el grado del polinomio diferenciador $\delta(B)$ es d .

Si $Var(v) = \sigma^2\Omega$ y $\Omega = LL'$, con L matriz triangular inferior, es la descomposición de Cholesky de Ω , entonces, multiplicando (11) por L^{-1} , se obtiene

$$L^{-1}y = L^{-1}X\beta + L^{-1}v, \quad (12)$$

que ya es un modelo de MCO. Como se explicó en la sección 1, el filtro de Kalman, aplicado a y y a las columnas de la matriz X permite pasar de (11) a (12). Para estimar β ahora en (12), lo que se hace es aplicar el algoritmo QR . Dicho algoritmo asegura que existe una matriz Q ortogonal tal que $Q'L^{-1}X = (R', 0)'$, con R matriz triangular superior con elementos diagonales no nulos. Particionando $Q' = (Q_1, Q_2)'$ de acuerdo con $(R', 0)'$, se puede pasar de (12) a

$$\begin{aligned} Q_1' L^{-1}y &= R\beta + Q_1' L^{-1}v \\ Q_2' L^{-1}y &= \quad + Q_2' L^{-1}v, \end{aligned}$$

de donde se deduce fácilmente que:

$$\hat{\beta} = R^{-1}Q_1' L^{-1}y$$

$$\hat{\sigma}^2 = y'(L^{-1})'Q_2Q_2'L^{-1}y/(N - d - k)$$

La matriz Q se obtiene en el programa por transformaciones de Housholder.

4. Aplicación al IPC de bienes industriales no energéticos

Para ilustrar la utilización del algoritmo de TRAMO de detección y corrección automática de *outliers*, se analiza el ejemplo del IPC de bienes industriales no energéticos, por ser uno de los componentes del IPC sobre el que los analistas muestran un menor grado de consenso, a pesar del importante peso (32.88 por ciento) que tiene este componente en la actual base del IPC. Por otra parte, el cambio de base llevado a cabo en 1992 no tiene unas consecuencias especialmente relevantes sobre este componente excepto su mayor peso relativo que en la base anterior, por lo que el enlace

con la serie de la base 1983 no plantea especiales dificultades, como es el caso de los alimentos sin elaborar o los servicios.⁹

En primer lugar se ha procedido a una modelización automática de la serie con TRAMO, que a su vez incorpora, como se ha visto anteriormente, un algoritmo de detección y corrección automática de *outliers*.¹⁰ El programa identificó la presencia de dos raíces unitarias en la parte regular de la serie y de una raíz estacional, rechazando, además, la transformación logarítmica de la serie original¹¹, por lo que aplica el polinomio diferenciador $(1-B)^2(1-B^{12})$, contrariamente a los resultados obtenidos por otros analistas.¹² El modelo resultante después de efectuar la modelización automática, seguida por la detección y corrección au-

⁹ Respecto al tema de la relevancia del cambio de base en el IPC de 1992 para analizar la evolución de los precios en la economía española se pueden ver los trabajos de González, Sánchez y Taguas (1994 y 1995).

¹⁰ Cuando no se cuenta con un *a priori* respecto al modelo que pueda seguir una serie y se sospecha que pueda haber outliers, el procedimiento de TRAMO combina secuencialmente pasos de especificación automática del modelo con pasos de detección y corrección automática de outliers, donde se utiliza el algoritmo descrito anteriormente. Normalmente, el programa sólo necesitará dar una vuelta.

¹¹ El test que utiliza TRAMO para contrastar la conveniencia de transformar logarítmicamente la serie es el siguiente: Se divide la serie en tramos de doce observaciones y, para cada uno de esos tramos, se obtiene la media y se ordenan las observaciones. Para protegerse contra la presencia de outliers, se eliminan el máximo y el mínimo de dichas observaciones, obteniéndose el rango de las restantes. A continuación se lleva a cabo una regresión de rangos medias, utilizándose el criterio de la pendiente de ésta regresión. Si es próxima a cero o negativa, no se toman logaritmos y en caso contrario sí.

¹² A este respecto cabe señalar los excelentes trabajos de Matea (1993 y 1994) en los que se concluye que este componente del IPC presenta sólo una raíz unitaria en su parte regular, en contraste con el resto de componentes analizados que son integrados de orden 2, $I(2)$. Igualmente, no se detecta la presencia de una raíz unitaria estacional, aunque el coeficiente estimado para la misma se aproxima bastante al valor unitario, lo que hace que el resultado no sea demasiado concluyente. Por otra parte, se incluye una tendencia determinística sobre el nivel de la serie, indicativa de que el crecimiento a largo plazo de la misma es de carácter determinístico. Por último, los modelos con indicador seleccionados cuentan con variables explicativas que son $I(2)$, lo que hace que el resultado obtenido respecto al grado de integrabilidad de esta serie no sea concluyente sino que, por el contrario, esté sometido a discusión por parte de los analistas.

tomática de *outliers*, bajando el nivel crítico C hasta 2.8, es el siguiente:

$$z(t) = \frac{\omega_1}{1-B}I_t(37) + \frac{\omega_2}{1-B}I_t(133) + \frac{\omega_3}{1-0.7B}I_t(39) \\ + \frac{\omega_4}{1-0.7B}I_t(109) + \omega_5 I_t(34) + \frac{\omega_6}{1-B}I_t(148) + u(t),$$

donde $\{u(t)\}$ sigue el modelo ARIMA:

$$\nabla^2 \nabla_{12} u(t) = (1 + \theta_1 B)(1 + \theta_{12} B^{12})a(t)$$

y los *outliers* corresponden a las siguientes fechas: la observación 37 es enero de 1986, la 133 es enero de 1994, la 39 es marzo de 1986, la 109 es enero de 1992, la 34 octubre de 1985 y la 148 abril de 1995. Los resultados obtenidos al estimar por máxima verosimilitud exacta el modelo anterior, concentrando fuera de la verosimilitud los parámetros de la regresión, son los siguientes:

Parámetro	Valor estimado	Estadístico "t"
θ_1	-0.828	-15.19
θ_{12}	-0.943	-17.30
ω_1	0.823	6.78
ω_2	0.515	4.24
ω_3	0.434	4.03
ω_4	-0.456	-4.20
ω_5	-0.262	-3.21
ω_6	0.344	2.83

El período muestral analizado es el comprendido entre enero de 1983 y septiembre de 1995.¹³ El error standard estimado de los residuos es 0.1239, siendo inferior al de otros modelos alternativos que se han considerado en el proceso de identificación. La media estimada de la serie de residuos no resulta significativamente distinta de cero, el test de normalidad no permite rechazar la hipótesis nula de normalidad de los mismos (0.022 frente a un valor crítico al 95 por ciento de 5.99), el estadístico de *Durbin-Watson* es 2.02, el estadístico de *Ljung-Box* de orden 24 es 21.61 y los tests de rachas sobre los residuos y sobre la función

¹³ En Matea (1994) el período muestral comprende desde enero de 1978 hasta diciembre de 1990.

de autocorrelación no muestran desviaciones sobre la aleatoriedad de los mismos.

Por lo que respecta a las variables de intervención (véanse los gráficos adjuntos), cabe señalar que el cambio de nivel de enero de 1986 y el cambio temporal de marzo del mismo año corresponden a la introducción del IVA en enero de 1986, siendo ambos efectos positivos y claramente significativos, aunque el segundo es de una magnitud que se estima en el cincuenta por ciento, aproximadamente, del escalón de enero.¹⁴ En enero de 1992 se estima un cambio temporal de valor negativo y muy significativo, que se corresponde con la reducción del tipo incrementado del IVA del 33 por ciento al 28 por ciento. En enero de 1994 se detecta un cambio de nivel positivo y muy significativo que está asociado a subidas del automóvil que, aunque retardadas, son consecuencia de las devaluaciones de la moneda de septiembre y noviembre de 1992 y mayo de 1993. Por último, el cambio de nivel estimado en abril del presente año puede interpretarse como el efecto sobre este componente del IPC de los cambios netos en imposición indirecta y cotizaciones sociales llevados a cabo en enero de 1995¹⁵, aunque, por otra parte, es posible que no haya consenso en esta interpretación puesto que también puede deberse a una traslación a los precios finales de las tensiones registradas en la evolución de los precios industriales como resultado del comportamiento negativo de los precios de las materias primas. Como consecuencia, la tasa de crecimiento intermensual de este componente experimentó en abril un incremento del 0.76 por ciento, que supuso casi el doble del valor esperado por los analistas.

Una posibilidad adicional para analizar la serie del IPC de bienes indus-

¹⁴ Los coeficientes estimados suponen un efecto porcentual sobre el nivel de la serie que se cuantifica en un 1.13 por ciento en enero de 1986, siendo de carácter permanente. El efecto de marzo es de carácter transitorio y supone un 0.6 por ciento del nivel de la serie. En Matea (1993) se cuantifican estos efectos en un 1.28 y un 0.66 por ciento respectivamente, aunque el segundo es permanente en este caso. Nótese que en este trabajo la estimación de estos efectos se ha llevado a cabo con el algoritmo de detección y corrección automática de *outliers* de TRAMO.

¹⁵ Una evaluación de los efectos macroeconómicos asociados a la subida de un punto porcentual del IVA y a la reducción de las cotizaciones sociales llevada a cabo en enero de 1995 se puede encontrar en Fernández, Ponz y Taguas (1994 y 1995).

triales no energéticos es proceder a un análisis más desagregado de la misma. En particular resulta de interés analizar la evolución separada del precio de los automóviles y del resto de bienes incluidos en este componente del IPC. Como se puede apreciar en los gráficos adjuntos, el componente de automóviles presenta una mayor volatilidad que el resto de la serie, por lo que parece más que justificado proceder a un análisis separado de ambos componentes, aunque la no disponibilidad de información impide la utilización del mismo período muestral que en el caso del agregado, limitándose el mismo al período comprendido entre enero de 1985 y septiembre de 1995.

En el caso del IPC de automóviles, TRAMO rechaza, igual que en el agregado, la conveniencia de la transformación logarítmica y encuentra que la serie es integrada de orden uno en su componente regular, rechazando la existencia de raíces unitarias estacionales. El modelo resultante de las fases de identificación y estimación es el siguiente:

$$z(t) = \mu + \frac{\omega_1}{1-B} I_t(78) + \frac{\omega_2}{1-B} I_t(102) + \frac{\omega_3}{1-B} I_t(4) + \frac{\omega_4}{1-B} I_t(117) \\ + \frac{\omega_5}{1-B} I_t(111) + \frac{\omega_6}{1-B} I_t(8) + \frac{\omega_7}{1-B} I_t(88) + \frac{\omega_8}{1-B} I_t(21) \\ + \omega_9 I_t(94) + \frac{\omega_{10}}{1-0.7B} I_t(35) + u(t),$$

donde $\{u(t)\}$ sigue el modelo ARIMA:

$$\nabla u(t) = (1 + \theta_1 B + \theta_2 B^2)(1 + \theta_{12} B^{12}) a(t)$$

y las variables de intervención corresponden a las siguientes fechas: la observación 78 es enero de 1992, la 102 enero de 1994, la 4 noviembre de 1985, la 117 abril de 1995, la 111 octubre de 1994, la 8 marzo de 1986, la 88 noviembre de 1992, la 21 abril de 1987, la 35 junio de 1988 y la 94 mayo de 1993. En este caso, a pesar de que en la fase de detección y corrección automática de outliers el nivel crítico se ha fijado en el valor de 3.5, la mayor variabilidad de la serie tiene como consecuencia que el número de outliers encontrados sea superior al del caso agregado analizado anteriormente (véanse a este respecto los gráficos 3 y 4 adjuntos). Los resultados obtenidos al estimar el modelo anterior por máxima verosimilitud exacta son los siguientes:

Parámetro	Valor estimado	Estadístico "t"
θ_1	-0.407	-4.15
θ_2	-0.198	-2.11
θ_{12}	0.429	4.45
μ	0.353	16.82
ω_1	-4.824	-16.16
ω_2	3.047	9.94
ω_3	1.900	5.61
ω_4	2.422	7.39
ω_5	1.999	6.12
ω_6	1.838	5.47
ω_7	1.624	5.40
ω_8	1.790	5.86
ω_9	-1.058	-3.64
ω_{10}	1.367	4.28

El error standard de los residuos estimados es 0.377, el estadístico *Durbin-Watson* 1.88, y los residuos estimados superan con amplitud la batería de tests habitual.¹⁶ Por lo que respecta a los *outliers* estimados, cabe señalar que no aparece el efecto introducción del IVA en enero de 1986, aunque sí aparece en marzo de 1986, siendo en este caso un cambio de nivel de la serie, en lugar de un cambio temporal de la misma como aparecía en el modelo del componente más agregado.¹⁷ Por otra parte, se estima un cambio de nivel en noviembre de 1985 que refleja una subida del precio de las piezas de recambio y accesorios del automóvil (ver Matea (1993)), que supone un incremento del 2.5 por ciento sobre el nivel de la serie. El cambio de nivel de enero de 1992 se muestra muy significativo y parece más acorde con la reducción del tipo incrementado del IVA que el cambio temporal negativo estimado en el caso anterior.¹⁸ El cambio

¹⁶ El test de normalidad ofrece un resultado de 2.945 frente a un valor crítico de 5.99. El estadístico de Ljung-Box es $Q(24) = 12.71$ e igualmente se superan los test de rachas sobre los residuos y sobre la función de autocorrelación (0.96 y 1.69 respectivamente).

¹⁷ El efecto estimado es de carácter permanente y supone un 2.3 por ciento del nivel de la serie. Nótese que en el caso de los automóviles el efecto del IVA pudo retardarse al mes de marzo con la actualización de precios.

¹⁸ El efecto estimado es del 4.9 por ciento que parece muy satisfactorio dado que

de nivel detectado en enero de 1994 ya se había atribuido a una subida del precio de los automóviles, que ahora aparece más nítida. Por otra parte, no se encuentran efectos sobre los precios del Plan Renove I, que estuvo vigente desde abril de 1995 hasta octubre del mismo año, mes en el que se puso en marcha el Plan Renove II que ha continuado hasta el 30 de junio del presente año 1995. El outlier detectado en octubre de 1994 puede atribuirse al Renove y se estima en un incremento del precio del automóvil del 1.7 por ciento.

Como se puede apreciar, en noviembre de 1992 se estima un cambio de nivel positivo en la serie que puede interpretarse como el efecto de las devaluaciones de la peseta llevadas a cabo en septiembre y noviembre de ese año. Este efecto no podía encontrarse en la serie agregada, por lo que a veces el análisis de los precios llevado a cabo con un nivel de agregación demasiado alto no permite apreciar los efectos de algunas medidas de política económica. Por otra parte, como se puede ver en el cuadro anterior, se estima un impulso negativo en mayo de 1993, que es un mes en el que se produjo una tercera devaluación de la moneda. Este efecto es difícil de interpretar, puesto que se estima como un impulso y, además, tiene el signo contrario al que se podría esperar como resultado de una devaluación. Probablemente este resultado puede servir para ilustrar la conveniencia de no extraer conclusiones precipitadas en base a estimaciones como las que aquí se presentan. De hecho, la atonía de la demanda durante el último período recesivo experimentado por la economía española puede no haber permitido una traslación total a precios finales de algunas medidas de política económica, que de haber acaecido en otra fase del ciclo podían haber tenido unos efectos distintos. Nótese que, aunque en mayo de 1993 se detecta una innovación negativa de carácter transitorio en el precio de los automóviles, en enero de 1994 hay una innovación positiva de carácter permanente que se interpretó por los analistas como una traslación retardada a los precios de consumo de las tensiones sobre el tipo de cambio experimentadas durante el primer semestre de 1993.

Por lo que respecta al resto de los bienes industriales no energéticos, TRAMO estima la existencia de una raíz unitaria en la parte regular de

el tipo incrementado del IVA se redujo del 33 al 28 por ciento.

la serie y otra en la parte estacional, por lo que identifica el polinomio diferenciador $\delta(B) = \nabla \nabla_{12}$ procediendo a la fase de detección y corrección automática de outliers, en la que se ha utilizado un valor crítico de 2.8. El modelo finalmente escogido para este componente ha sido:

$$z(t) = \frac{\omega_1}{1-B} I_t(6) + \omega_2 I_t(80) + \frac{\omega_3}{1-B} I_t(2) + \frac{\omega_4}{1-B} I_t(86) + \omega_5 I_t(40) + \omega_6 I_t(114) + u(t),$$

donde $\{u(t)\}$ sigue el modelo ARIMA:

$$(1 + \phi_1 B) \nabla \nabla_{12} u(t) = (1 + \theta_{12} B^{12}) a(t)$$

donde las intervenciones corresponden a las siguientes fechas: la 6 es enero de 1986, la 80 marzo de 1992, la 2 septiembre de 1985, la 86 septiembre de 1992, la 40 noviembre de 1988 y la 114 enero de 1995. Los resultados obtenidos al estimar el modelo por máxima verosimilitud exacta son los siguientes:

Parámetro	Valor estimado	Estadístico "t"
ϕ_1	-0.594	-7.49
θ_{12}	-0.658	-6.98
ω_1	0.915	10.65
ω_2	-0.244	-5.26
ω_3	0.465	4.66
ω_4	0.297	3.77
ω_5	-0.162	-3.49
ω_6	0.154	3.04

Como se puede ver todos los parámetros estimados resultan significativos, siendo el error standard de la regresión 0.099. Por otra parte, el modelo estimado pasa el conjunto de contrastes de especificación y validación comentado anteriormente, por lo que parece cumplir los requisitos mínimos para su utilización. Por lo que respecta a las variables de intervención, cabe resaltar nuevamente el efecto IVA de enero de 1986, que se estima como de carácter permanente, aunque no aparece el efecto encontrado en marzo del mismo año en la serie agregada.¹⁹ Se estima igualmente

¹⁹ Este efecto de marzo de 1986 se ha visto que corresponde a los automóviles. El impacto del IVA se estima en un 1.3 por ciento sobre el nivel de la serie en enero de 1986 y es de carácter permanente.

un efecto de carácter permanente en septiembre de 1992, que se asocia a la primera devaluación de la moneda comentada antes y un efecto transitorio en enero del presente año que cabría asociar a la sustitución de IVA por cotizaciones sociales (véanse los gráficos 5 y 6 adjuntos).

5. Conclusiones

La utilización de TRAMO de forma completamente automática para modelizar series temporales en presencia de *outliers* se muestra bastante eficiente y permite al analista, con un ahorro evidente de tiempo, obtener conclusiones similares a las que llegaría con otros procedimientos más complejos de usar. De hecho, en la modelización de los precios de consumo de bienes industriales no energéticos se llega a modelos similares a los obtenidos anteriormente con otros paquetes.

Por otra parte, los *outliers* detectados y estimados con TRAMO corresponden, en su mayoría, a las conclusiones del análisis de intervención tradicional llevado a cabo con las series originales en el pasado.

La modelización de los precios de consumo de bienes industriales no energéticos pone de manifiesto la importancia de proceder a un análisis más desagregado de las series de precios de consumo, sobre todo cuando se considera un componente poco homogéneo y con un peso importante en la evolución de los mismos. El análisis a un nivel de desagregación superior permite una más correcta evaluación de los efectos asociados a determinadas medidas de política económica sobre los que los analistas no siempre han mostrado un nivel de consenso suficiente.

Finalmente, cabe resaltar que uno de los problemas a los que se enfrentan los analistas ante la evaluación de los efectos de una determinada medida de política suele ser no sólo su cuantificación a corto plazo, midiendo el impacto que ha tenido en un determinado mes, sino que es imprescindible cuantificar el impacto que dicha innovación puede tener sobre la evolución a medio plazo de la variable objeto de estudio, lo cuál no es, en principio una tarea fácil. En este sentido, la disponibilidad de un paquete como

SEATS utilizado conjuntamente con TRAMO resulta extremadamente útil.

6. Referencias

- Abraham, B. y Box, G. E. P., (1979), "Bayesian Analysis of Some Outlier Problems in Time Series", *Biometrika*, **66**, 229-236.
- Akaike, H. (1978), "A Bayesian Analysis of the Minimum AIC Procedure", *Ann. Inst. Statist. Math.*, **30 A**, 9-14.
- Akaike, H. (1979), "A Bayesian Extension of the Minimum AIC Procedure of Autoregressive Model Fitting", *Biometrika*, **66**, 237-242.
- Bell, W.R. and Hillmer, S.C. (1984), "Issues Involved with the Seasonal Adjustment of Economic Time Series", *Journal of Business and Economic Statistics* **2**, 291-320.
- Box, G.E.P., Hillmer, S.C. and Tiao, G.C. (1978), "Analysis and Modeling of Seasonal Time Series", in Zellner, A. (ed.), *Seasonal Analysis of Economic Time Series*, Washington, D.C.: U.S. Dept. of Commerce - Bureau of the Census, 309-334.
- Box, G.E.P., y Jenkins, G.M., (1976), *Time Series Analysis, Forecasting and Control*, Holden-Day, San Francisco.
- Box, G.E.P., y Tiao, G.C., (1975), "Intervention Analysis with Applications to Economic and Environmental Problems", *Journal of the American Statistical Association*, **70**, 70-79.
- Brockwell, P., y Davis, R., (1992), *Time Series: Theory and Methods, Second Edition*, Springer-Verlag, Berlin.
- Burman, J.P. (1980), "Seasonal Adjustment by Signal Extraction", *Journal of the Royal Statistical Society A*, **143**, 321-337.
- Chang, I., Tiao, G.C. (1983), "Estimation of Time Series Parameters in the Presence of Outliers", Technical Report 8, University of Chicago, Statistics Research Center.
- Chang, I., Tiao, G.C. y Chen, C., (1988), "Estimation of Time Series Parameters in the Presence of Outliers", *Technometrics*, **30**, 193-204.
- Chen, C. y Liu, L., (1993), "Joint Estimation of Model Parameters and Outlier Effects in Time Series", *Journal of the American Statistical Association*, **88**, 284-297.
- Chen, C. y Tiao, G. C., (1990), "Random Level Shift Time Series Models, ARIMA Approximation, and Level Shift Detection", *Journal*

- of Business and Economic Statistics*, 8, 170-186.
- Choi, B., (1992), *ARMA Model Identification*, Springer Verlag, New York.
- Cleveland, W.P. and Tiao, G.C. (1976), "Decomposition of Seasonal Time Series: A Model for the X-11 Program", *Journal of the American Statistical Association* 71, 581-587.
- Espasa, A. y Cancelo, J.R. (eds.) (1993), *Métodos Cuantitativos para el Análisis de la Coyuntura Económica*, Alianza Economía.
- Fernández, M.; Ponz, J.M. y Taguas, D. (1994a), "Algunas Reflexiones sobre la Fiscalidad sobre el Factor Trabajo y la Sustitución de Cuotas a la Seguridad Social por Imposición Indirecta", *Documento de Trabajo D-94004* (versión revisada). Dirección General de Planificación. Ministerio de Economía y Hacienda.
- Fernández, M.; Ponz, J.M. y Taguas, D. (1994b), "La Fiscalidad sobre el Factor Trabajo: Un Enfoque Macroeconómico", *Economía y Sociología del Trabajo* 25/26, 161-179.
- Fox, A. J., (1972), "Outliers in Time Series", *Journal of the Royal Statistical Society, Ser. B*, 34, 350-363.
- Gill, P. E., Murray, W. y Wright M. H., (1992) *Practical Optimization*, Academic Press, London.
- Gómez, V. (1994), "Especificación Automática de Modelos Arima en Presencia de Observaciones Atípicas", mimeo, Departamento de Estadística e I.O., Universidad Complutense de Madrid, Junio 1994.
- Gómez, V. and Maravall, A. (1994a), "Program TRAMO - Time Series Regression with Arima Noise, Missing Observations, and Outliers - Instructions for the User", EUI Working Paper ECO No. 94/31, Department of Economics, European University Institute.
- Gómez, V. and Maravall, A. (1994b), "Estimation, Prediction and Interpolation for Nonstationary Series with the Kalman Filter", *Journal of the American Statistical Association*, 89, 611-624.
- González, L.; Sánchez, A. y Taguas, D. (1994), "Análisis de la Inflación de la Economía Española en base a una Homogeneización del IPC" *Documento de Trabajo D-94003*, Dirección General de Planificación. Ministerio de Economía y Hacienda.
- González, L.; Sánchez, A. y Taguas, D. (1994), "La Influencia del Cambio de Base del IPC en la Medición y Análisis de la Inflación"

Información Comercial Española **739**, 143-164

- Guttman, I. y Tiao, G. C., (1978), "Effect of Correlation on the Estimation of a Mean in the Presence of Spurious Observations", *The Canadian Journal of Statistics*, **6**, 229-247.
- Hamilton, D. C. y Watts, D. G., (1978), "Interpreting Partial Autocorrelation Function of Seasonal Time Series Models", *Biometrika*, **65**, 135-140.
- Hannan, E. J. y Rissanen, J., (1982), "Recursive Estimation of Mixed Autoregressive-Moving Average Order", *Biometrika*, **69**, 81-94.
- Hillmer, S.C. and Tiao, G.C. (1982), "An Arima-Model Based Approach to Seasonal Adjustment", *Journal of the American Statistical Association* **77**, 63-70.
- Maravall, A. and Pierce, D.A. (1987), "A Prototypical Season Adjustment Model", *Journal of Time Series Analysis* **8**, 177-193.
- Maravall, A. and Gómez, V. (1994), "Program SEATS - Signal Extraction in Arima Time Series - Instructions for the User", EUI Working Paper ECO No. 94/28, Department of Economics, European University Institute.
- Ljung, G. M. y Box, G. E. P., (1979), "The Likelihood Function of Stationary Autoregressive-Moving Average Models", *Biometrika*, **66**, 265-270.
- Liu, L. M., (1989), "Identification of Seasonal ARIMA Models Using a Filtering Method", *Communications in Statistics*, **18**, 2279-2288.
- Maddala, G.S., (1977), *Econometrics*, New York: McGraw-Hill, Capítulo 12, 280-281.
- Matea, M.de los LLanos (1993), "Análisis de la Inflación en España", en *Métodos Cuantitativos para el Análisis de la Coyuntura Económica*, Espasa y Cancelo (eds.).
- Matea, M.de los LLanos (1994), "Contrastes de Raíces Unitarias para Series Mensuales. Una Aplicación al IPC", *Revista Española de Economía*, **11**, **1**, 7-26.
- Mélard, G., (1984), "A Fast Algorithm for the Exact Likelihood of Autoregressive-Moving Average Models", *Applied Statistics*, **35**, 104-114.
- Morf, M., Sidhu, G.S., y Kailath, T., (1974), "Some New Algorithms for Recursive Estimation on Constant, Linear, Discrete- Time Systems",

- IEEE Transactions on Automatic Control*, **AC-19**, 315-323.
- Pearlman, J.G., (1980), "An Algorithm for the Exact Likelihood of a High-Order-Autoregressive-Moving Average Process", *Biometrika*, **67**, 232-233.
- Tiao, G. C. y Tsay, R. S., (1983), "Consistency Properties of Least Squares Estimates of Autoregressive Parameters in ARMA Models", *The Annals of Statistics*, **11**, 856-871.
- Tsay, R. S., (1984), "Regression Models With Times Series Errors", *Journal of the American Statistical Association*, **79**, 118-124.
- Tsay, R. S., (1986), "Time Series Model Specification in the Presence of Outliers", *Journal of the American Statistical Association*, **81**, 132-141.
- Tsay, R. S., (1988), "Outliers, Level Shifts, and Variance Changes in Time Series", *Journal of Forecasting*, **7**, 1-20.
- Tsay, R. S. y Tiao, G. C., (1984), "Consistent Estimates of Autoregressive Parameters and Extended Sample Autocorrelation Functions for Stationary and Nonstationary ARMA models", *Journal of the American Statistical Association*, **79**, 84-96.
- Zhao-Guo, C., (1985), "The Asymptotic Efficiency of a Linear Procedure of Estimation for ARMA Models", *Journal of Time Series Analysis*, **6**, 53-62.

Gráfico 1: IPC
Bienes Industriales No Energéticos

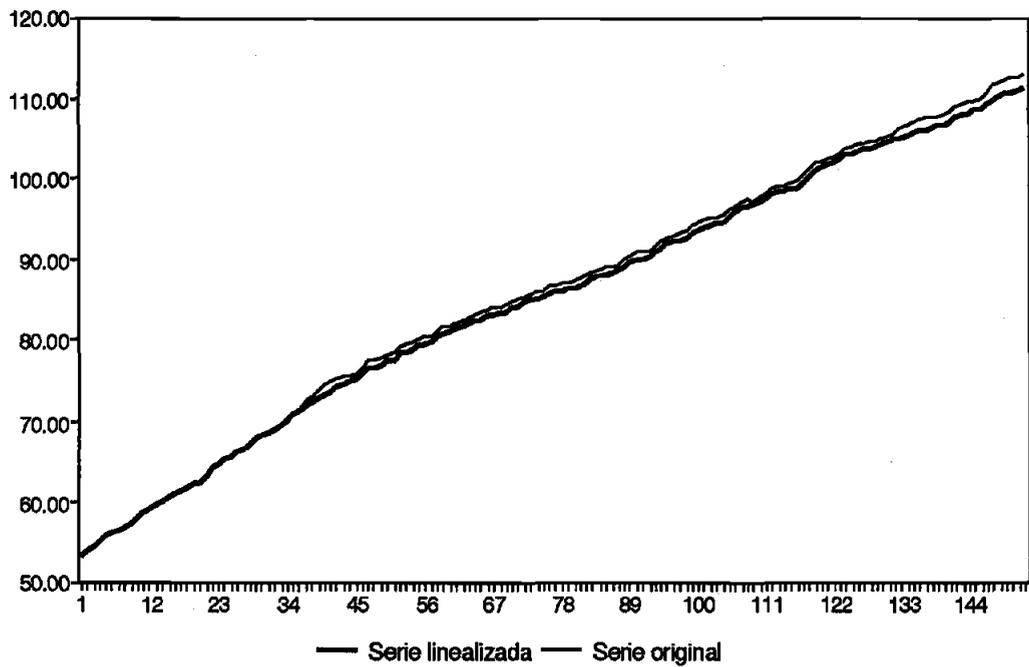


Gráfico 2: IPC
Bienes Industriales No Energéticos

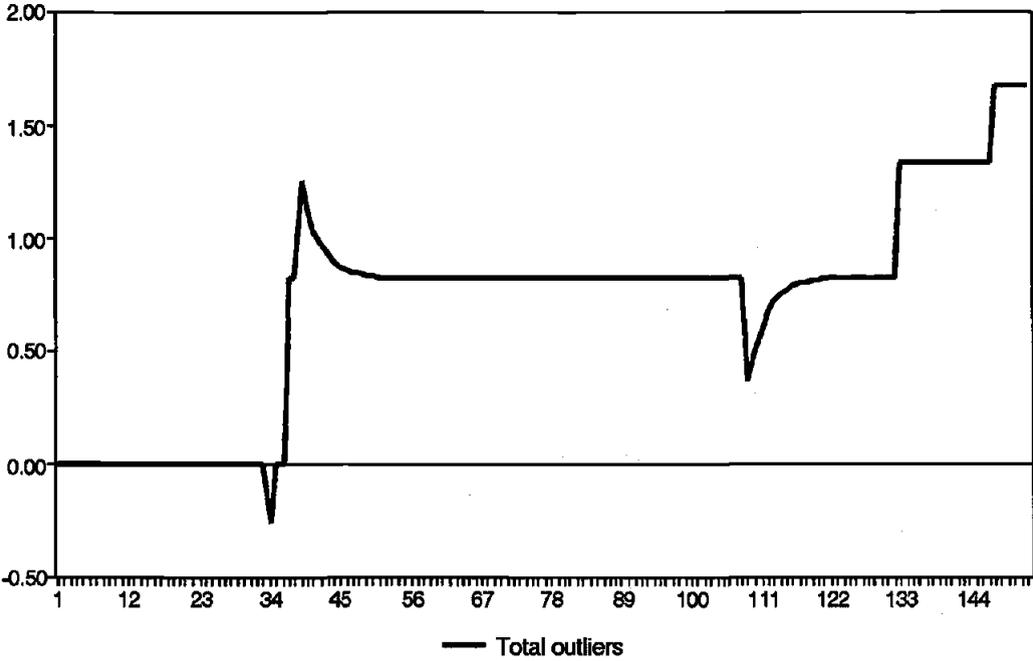


Gráfico 3: IPC
Automóviles

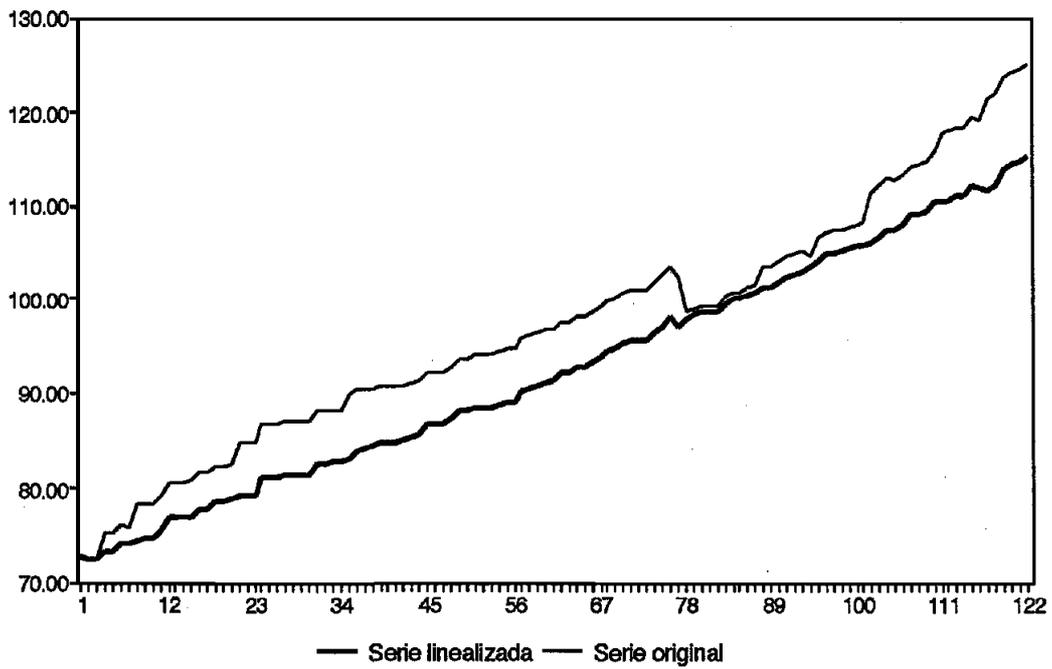


Gráfico 4: IPC
Automóviles

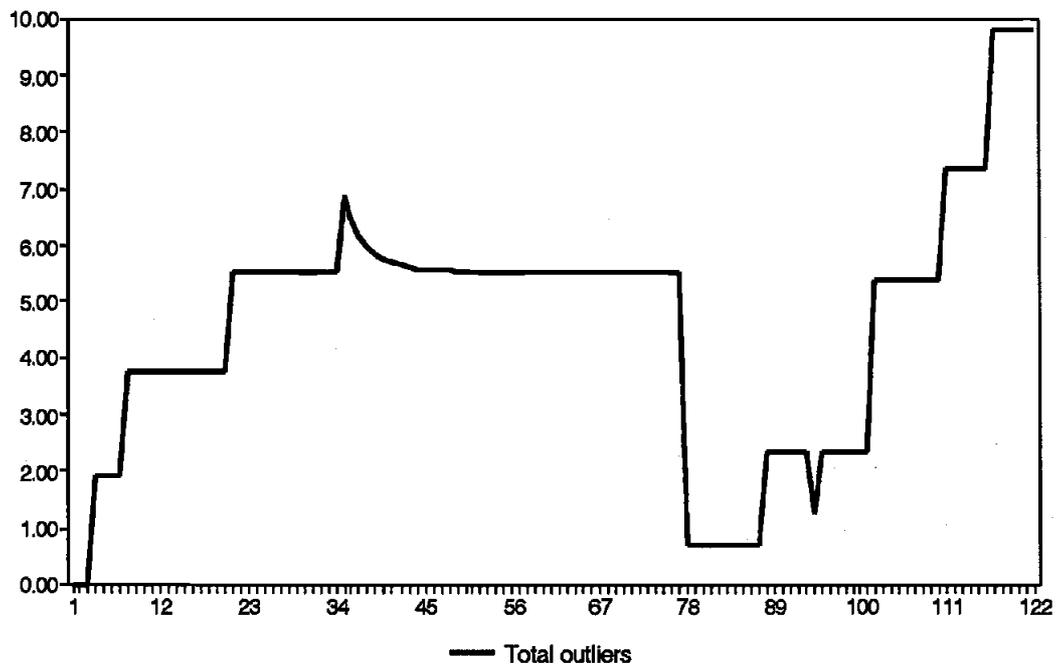


Gráfico 5: IPC
BINE (excluyendo automóviles)

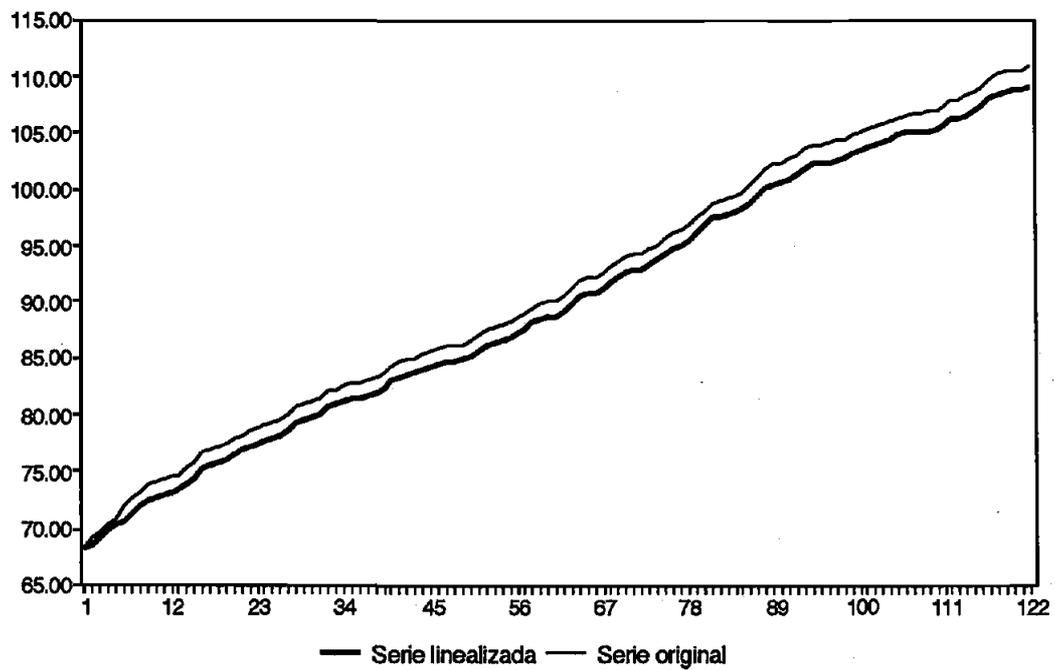


Gráfico 6: IPC
BINE (excluyendo automóviles)

