8201

EL COMPORTAMIENTO DE SERIES ECONOMICAS: MOVIMIENTOS ATIPICOS Y RELACIONES A CORTO Y LARGO PLAZO

Antoni Espasa

EL COMPORTAMIENTO DE SERIES ECONOMICAS: MOVIMIENTOS ATIPICOS Y RELACIONES A CORTO Y LARGO PLAZO

Antoni Espasa

INTRODUCCION-RESUMEN

En este trabajo se comenta primero como el tratamiento lineal univariante de series económicas, por ejemplo por medio de modelos ARIMA, lleva con frecuencia a la conclusión de que en la serie examinada existen puntos atípicos que no han sido explicados. Muchas veces una ulterior investigación sobre tales puntos revela que en dichos momentos del tiempo, o en momentos próximos a ellos, ocurrieron fenómenos muy específicos cuyos efectos en la serie difícilmente se pueden captar con variables explicativas reales. En tales circunstancias la cuantificación de dichos efectos se puede llevar a cabo mediante variables artificiales ("dummies") afectadas por un filtro ARMA, que es lo que en la literatura de Series Temporales ha venido denominándose como Análisis de Intervención. Para realizar tal análisis es importante distinguir si el fenómeno en cuestión supone una perturbación permanente del nivel de la serie y/o una perturbación del mismo en un período limitado de tiempo. En el primer caso hablaremos de efectos de largo plazo y en el segundo de corto plazo, pero bien entendido que nuestra definición de largo y corto plazo difiere de la habitual pues se refiere al nivel de la serie y no a los segundos momentos de la misma. Esta distinción nos llevará a decidir si necesitamos una variable escalón y/o una variable impulso. La estructura temporal de la intervención se logrará aplicando sobre dichas variables el filtro ARMA correspondiente. El análisis de intervención es un complemento, con frecuencia indispensable, a un tratamiento univariante de series temporales, pues sirve para captar un determinado tipo de comportamiento no lineal presente en las series económicas que, obviamente, no es considerado por los modelos lineales.

En la segunda parte del documento se extiende la idea de efectos a largo y corto plazo sobre el nivel de una serie en su relación con otras series referentes a otras tantas variables y se expone como la descomposición de las variables explicativas en un componente permanente y otro transitorio, de forma que éste último no tiene ningún efecto a largo plazo sobre la variable dependiente, puede ser útil en la construcción de modelos econométricos cuando existan fundadas sospechas de que los mencionados componentes tienen, sobre la variable dependiente, efectos con una estructura dinámica distinta. Bajo la hipótesis de que la estructura dinámica de los componentes permanentes en el modelo son muy simples, el trabajo concluye apuntando un método para llegar a una especificación inicial del modelo econométrico.

I.- MODELOS UNIVARIANTES: INNOVACIONES Y ANALISIS DE INTERVENCION

I.1 Análisis univariante y modelos ARIMA

El primer paso en el tratamiento de series temporales es explicar cada serie mediante modelos univariantes. En este contexto los modelos ARIMA(*) representan una clase general de modelos que se han mostrado muy eficaces para la predicción. El análisis univariante es muy importante por distintos motivos:

1.- Con frecuencia es el único tipo de análisis que se puede realizar, ya que aunque una serie esté relacionada con otras variables, no siempre éstas se pueden medir aceptablemente y en consecuencia el análisis multivariante no se puede llevar a cabo en la práctica. Por ejemplo, podemos disponer de buenos datos de ventas y malos datos de precios.

2.- Otras veces la relación coste-beneficio no aconseja realizar un análisis multivariante.

3.- El análisis univariante es útil en sí mismo para captar anomalías.

4.- También, si por las razones anteriores, no se pasa a un análisis multivariante los modelos ARIMA se pueden utilizar para descomponer la serie.

5.- Nos da una explicación de la serie que señala el límite mínimo a lograr con un análisis multivariante.

6.- Es un paso necesario para el análisis multivariante.

(*) Véase Box-Jenkins (1970).

Los modelos ARIMA (Autorregresivos, integrados y de medias móviles) tienen la siguiente representación:

$$\Phi_p(L)\ \Delta(L)\ Y_t^{\lambda} = \Theta_q(L)\ a_t \quad (*) \,, \tag{1}$$

donde
$$\Phi_p(L) = (1-\phi_1 L-\phi_2 L^2- \ldots\ldots -\phi_p L^p), \tag{2}$$

$$\Delta(L) = \prod_{j=1}^{j=\kappa} (1-L^{s_j})^{d_j}, \tag{3}$$

$$\Theta_q(L) = (1-\theta_1 L- \ldots\ldots -\theta_q L^q), \tag{4}$$

L es el operador de retardos tal que:

$$L^j\ X_t = X_{t-j}$$

y a_t es un proceso gaussiano del tipo ruido blanco. Un proceso ruido blanco es aquel que tiene media cero, varianza (σ_a^2) constante y la autocovarianza con el retardo k es cero para cualquier valor de k.

En (1) $\Delta(L)$ es un polinomio que permite κ diferenciaciones de la variable Y_t, de forma que la jotésima diferenciación es de grado s_j y se aplica d_j veces. Obsérvese que para el valor $s_j=1$ el operador $(1-L^{s_j})^{d_j}$ toma d_j veces primeras diferencias de la serie Y_t. Ese es el operador que se utiliza para eliminar de Y_t su tendencia regular. La serie Y_t además de la tendencia regular puede tener κ-1 ciclos estacionales de períodos $s_2, \ldots, s_\kappa$. En tal caso, con frecuencia, se requerirá diferenciar la serie con operadores de grado $s_2, \ldots, s_\kappa$. La finalidad del polinomio $\Delta(L)$ es la de que aplicado a la serie original la convierta en estacionaria. Una serie estacionaria es aquélla que su media (esperanza matemática) y varianza son independientes del tiempo y la autocovarianza con el retardo k es función sólo de k pero no del momento inicial. Como ejemplos de transformaciones esta-

(*) Cuando la serie Y_t tiene un componente estacional los polinomios $\Phi_p(L)$ y $\Theta_q(L)$ se suelen poder descomponer en el producto de dos polinomios $(1-\alpha_1 L-\ldots-\alpha_r L^r)$ para la parte regular y $(1-\beta_1 L^{s_j}-\beta_2 L^{2s_j}-\ldots -\beta_s L^{s\,s_j})$ para la parte estacional.

tenemos
cionarias que la serie mensual del índice de producción industrial necesita diferenciaciones de grado 1 y 12 para transformarse en estacionaria; la serie diaria de dinero en manos del público necesita diferenciaciones de grado 1, 6 y 313 (*) para convertirse en estacionaria, etc. Así pues,

$$W_t = \Delta(L)\ Y_t^{\lambda} \tag{5}$$

es la transformación estacionaria de Y_t.

En (5) λ es un parámetro que se introduce para homogeneizar la varianza de Y_t y normalmente tomará valores entre -1 y 1.(+) El valor de 0,5 supone que la desviación estándar de Y_t ($\sigma(Y_t)$) es función de la raíz cuadrada del nivel de la serie(**) y λ=-1 supone que $\sigma(Y_t)$ es función del cuadrado del nivel de la serie. Cuando $\lambda=0$ diremos que la transformación requerida para homogeneizar la varianza es la del logaritmo neperiano y supone que $\sigma(Y_t)$ es función del nivel de la serie.

I.2 Las innovaciones en los modelos ARIMA

De los modelos Arima conviene destacar la importancia de la serie a_t. Para ello escribamos (1) de la forma

$$\Phi_p(L)\ W_t = \Theta_q(L)\ a_t \quad , \tag{6}$$

en donde $\Phi_p(L)$ y $\Theta_q(L)$ tienen todas sus raices mayores que la unidad en valor absoluto. Con ello (6) se puede escribir de la forma

$$\Theta_q(L)^{-1}\ \Phi_p(L)\ W_t = a_t \quad , \tag{7}$$

y de (7)

$$W_t = \bar{W}_{t-1,1} + a_t \quad , \tag{8}$$

(*) Obsérvese que esta serie diaria no incluye los domingos.

(+) Para este tipo de transformaciones véase Box-Cox (1964)

(**) Es decir la varianza de la serie es función del nivel de la misma.

donde $\bar{W}_{t-1,1}$ es la predicción que en el momento t-1 hacemos para W_t, y depende de los valores anteriores de W y de los parámetros de (1). Utilizando (5) obtenemos también:

$$Y_t = \bar{Y}_{t-1,1} + a_t \tag{9}$$

y se puede demostrar que si Y_t viene generada por (1), $\bar{Y}_{t-1,1}$ es una predicción óptima (*). La descomposición que a partir de (1) se hace de Y_t en (9) es muy importante, pues en (9) hemos dividido a Y_t en dos partes $\bar{Y}_{t-1,1}$ que depende de la historia pasada de la serie y es completamente predecible y a_t que es el componente inesperado e impredecible de Y_t. A la serie $\{a_t\}$ se le denomina serie de INNOVACIONES, pues recoge la única información nueva contenida en la observación Y_t respecto al fenómeno Y.

La serie $\{a_t\}$ ha de ser, necesariamente, ruido blanco pues de lo contrario sería, en parte, predecible. Obviamente $\{a_t\}$ no es observable y ha de ser estimada a partir de la serie $\{Y_t\}$. Así dada una serie Y_t a través de un proceso de identificación se postula una estructura del tipo (1) para Y_t y se estiman los parámetros de dicha estructura por el método de la máxima verosimilitud. A partir de (1) conociendo la serie $\{Y_t\}$ y los parámetros estimados del modelo obtenemos la serie $\{a_t\}$. Examinando si la serie estimada $\{a_t\}$ cumple (o no cumple) las características de una serie generada por un proceso ruido blanco aceptaremos (o no aceptaremos) el modelo (1) identificado y estimado para Y_t.

Con frecuencia al examinar $\{a_t\}$ concluímos que excepto en un número determinado y pequeño de puntos, que llamaremos atípicos, la serie $\{a_t\}$ es del tipo ruido blanco. Un punto puede ser atípico porque su valor exceda en más de k veces la desviación estándar (por ejemplo 3 veces la desvia

(*) Por predicción óptima entendemos la que minimiza el error cuadrático medio.

ción estándar en la muestra. En otros casos un conjunto de puntos puede ser atípico, estando sus valores individualmente tomados dentro de unos intervalos de confianza aceptables, por tener los puntos un signo constantemente positivo o negativo. Para el tratamiento de estos puntos es para lo que aplicaremos el análisis de intervención.

La importancia de las innovaciones se mide:

a) $\hat{\sigma}_a$ (estimación de σ_a) en porcentaje (desviación estándar residual porcentual), para ello si el modelo se ha especificado en logaritmos ($\log Y_t$) $\hat{\sigma}_a$ viene expresado en tanto por uno de Y, con lo que multiplicando $\hat{\sigma}_a$ por cien tenemos el $\hat{\sigma}_a$ porcentual. Si el modelo se ha construido sobre la serie original (Y_t) $\hat{\sigma}_a$ viene expresado en unidades de Y y será conveniente formularlo en porcentaje sobre el valor medio muestral de Y_t o sobre el valor medio de Y_t en las últimas observaciones.

b) $$R^2 = 1 - \frac{\hat{Var}\,(\hat{a}_t)}{\hat{Var}\,(W_t)} ,$$

donde $\hat{Var}\,(W_t)$ es la varianza muestral de la serie estacionaria (W_t) y $\hat{Var}\,(\hat{a}_t)$ es $\hat{\sigma}_a^2$. El coeficiente R^2 es un indicador del tanto por uno de varianza de W_t explicado por el modelo. Obsérvese que si denominamos $\hat{W}_t$ a la serie W_t ajustada por el modelo, en general, no se cumple que el coeficiente R^2 definido arriba sea igual a $\hat{Var}\,(\hat{W}_t)/\hat{Var}\,(W_t)$, como ocurre en el modelo de regresión múltiple con término constante.

I.3 El análisis de intervención

El análisis de intervención(*) es una generalización de lo que en Econometría se denomina "análisis con va-

(*) Sobre análisis de intervención véase Box y Tiao (1975) en cuyo articulo están inspirados los comentarios de este trabajo.

riables artificiales". La generalización del análisis de intervención consiste en que en él la variable artificial puede ir afectada por un filtro ARMA (autorregresivo y de medias móviles) del tipo:

$$\frac{\omega_s(L)}{\delta_r(L)} = \frac{\omega_0-\omega_1 L- \;...\; -\omega_s L^s}{1-\delta_1 L- \;.....\; -\delta_r L^r}\,, \tag{10}$$

con lo que la flexibilidad de dicha variable para explicar los movimientos anómalos en las series es muy grande, permitiéndose que sean los datos quienes decidan el tipo de estructura requerida en esos puntos de ruptura mediante la estimación de los parámetros ω y δ .

El análisis de intervención es útil para explicar puntos atípicos en las series debidos a causas muy concretas y conocidas pero difíciles de cuantificar, como por ejemplo,

a.- Errores en la construcción de la serie publicada, así en la confección de una serie mensual en un determinado mes sólo se tuvieron en cuenta parte de los días del mes.

b.- Cambios de definición en la serie publicada, así en una serie agregada a partir de una determinada fecha se le añade o se le quita un componente (Véase por ejemplo Espasa-Pérez (1982),sección I.2).

c.- Medidas o cambios de legislación, como la introducción o cambio de tipo o fecha de recaudación de un impuesto, una devaluación. (Véase por ejemplo Treadway et. al 1978)), etc.

d.- Acontecimientos extraordinarios como huelgas, elecciones, etc.

e.- Fenómenos que afectan a la estacionalidad de la serie pero son mas bien de naturaleza determinística o de carácter excepcional, como Pascua, pagas extraordinarias, arreglos de escaparate, inviernos o veranos excesivamente rigurosos, etc. (Véase Espasa (1982)).

Al realizar un análisis univariante y encontrarnos con puntos atípicos empezaremos siempre examinando si la causa es un error en la transcripción de los datos. Si no lo es convendrá investigar, siempre que sea posible, si hubo algún error en la construcción o elaboración de los datos publicados (*) que puede ser subasanado. Con frecuencia éstas suelen ser las causas de un número importante de puntos atípicos. Si la causa de la anomalía no son errores subsanables en los datos habrá que indagar si es debida a algún acontecimiento especial como los mencionados en el párrafo anterior. Conviene advertir que la anomalía aparezca en el punto correspondiente a la observación j no quiere decir que el acontecimiento especial se tuvo que dar en ese determinado momento del tiempo, pudo ocurrir anteriormente y la anomalía reflejarse con posterioridad debido a que los modelos ARIMA incluyen diferenciaciones (Véase por ejemplo Espasa (1979), sección II). Si tras todo este estudio se identifica para la anomalía una causa tratable mediante variables artificiales tendremos que pasar a recoger información sobre el tipo de efecto que se espera que tenga, sobre la serie en cuestión, dicha causa. Identificado, por la información a priori, el tipo de efecto tenemos que seleccionar un esquema ARMA de los definidos en (10) capaz de captar tal efecto. Para ello pasemos a ilustrar las estructuras en las anomalías que se pueden explicar con determinados filtros ARMA y variables artificiales.

(*) Un ejemplo de este tipo se detecta en el trabajo de Luis Tortosa en la sección IV de Espasa (1979).

I.4 Variables impulso y variables escalón

Comencemos definiendo tres clases de variables artificiales. A la primera la denominaremos variable impulso y la representaremos por D(F). Esta es una variable que tiene siempre el valor cero menos en un determinado punto (F) de la muestra en que toma el valor unidad. A la segunda la denominaremos variable escalón y la representaremos por S(F). Esta es una variable que tiene valores cero hasta el momento F a partir del cual toma el valor unidad. A la tercera le denominaremos variable tendencia y la representaremos por T(F). Esta es una variable que tiene valores cero hasta el momento F y a partir del mismo toma los valores 1, 2, 3,.... La representación gráfica de estas variables es la siguiente:

D(F)

F

G1

S(F)

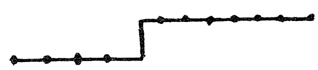

G2

T(F)

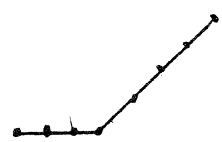

G3

Es interesante observar que si denominamos Δ al operador de primeras diferencias - (1-L) - la inversa de Δ, Δ^{-1}, es el operador de integración. Es decir, Δ^{-1} aplicado a una variable en el momento t (Y_t) nos da la suma de los valores de dicha variable hasta el momento t. Así tenemos que las variables D(F), S(F) y T(F) están relacionadas de la siguiente forma:

$$T(F) = \frac{1}{1-L} S(F) = \frac{1}{1-L} \frac{1}{1-L} D(F) = \frac{1}{(1-L)^2} D(F). \qquad (11)$$

La identidad (11) es de importancia práctica pues, primero permite, necesitando T(F) o S(F), utilizar D(F) multiplicada por Δ^{-2} o Δ^{-1}, respectivamente, con lo que al alargarse la muestra no hay que preocuparse de alimentar la variable artificial con los nuevos valores distintos de cero. Es decir, D(F) es más operativa pues queda definida especificando el número de observaciones de que consta y en cuál de ellas (F) toma el valor unidad. Además (11) nos da la guía para contrastar intervenciones que a priori se haya postulado que necesitan las variables S(F) o T(F), pues en dichos casos podemos utilizar $\frac{1}{1-\delta_1 L}$ D(F) ó $\frac{1}{1-\delta_1 L}$ S(F) en vez de S(F) y T(F) y permitir que los datos informen sobre el valor de δ_1. Si para δ_1 se obtiene un valor muy próximo a la unidad diremos que la intervención con S(F) o T(F) está bien modelada, pero si por el contrario para δ_1 se obtiene un valor significativamente distinto de uno los datos nos estarán indicando que la intervención está mal estructurada. Siempre que se utilice S(F) ó T(F) la realización del test sobre δ_1 es importante. En Espasa-Pérez (1982), sección II se interviene una serie agregada decenal que a partir del 31 de marzo de 1976 tenía un componente menos en el agregado. Dado que el porcentaje del componente en el agregado para la muestra considerada parece bastante constante una intervención del tipo:

$$\omega_0 \text{ S(1}^{a} \text{ decena abril 1976)} = \omega_0 \text{S(1-IV-76)}, \qquad (12)$$

puede ser adecuada. No obstante, al sustituir (12) por

$$\frac{\omega_0}{1-\delta_1 L} \text{ D(1-IV-76)}, \qquad (13)$$

el valor que se obtiene para δ_1 es significativamente distinto de cero. Ante tal resultado en dicho trabajo se prueba la intervención siguiente

$$\frac{\omega_0-\omega_1 L}{1-\delta_1 L}\, D(3\text{-III-}76) = \frac{\omega_0-\omega_1 L}{1-\delta_1 L}\, D(3^{a} \text{ decena marzo } 1976) \qquad (14)$$

para la que se obtiene un valor de δ_1 muy próximo a uno. En este caso, pues, el test ha servido para precisar el punto F. Conviene advertir que verificado que δ_1 tiene un valor próximo a uno, se debe fijar δ_1 en dicho valor, es decir, se debe utilizar (1-L) y no $(1-\delta_1 L)$.

I.5 Filtros ARMA aplicados a variables artificiales

Pasemos ahora a considerar el efecto de distintos filtros ARMA sobre las variables impulso , escalón y tendencia. Señalemos primero que en el filtro ARMA definido en (10) cuando $\delta_r(L)$ es uno, es decir todos los parámetros δ_j $(j=1,\ldots,r)$ son cero, se reduce a $\omega_s(L)$ y se denomina filtro de medias móviles (MA) de orden s. Obsérvese también que un filtro MA de orden cero tiene todavía un parámetro (ω_0) a estimar.

Un filtro MA de orden s aplicado a D(F) tendrá sobre la variable a explicar (Y_t) los siguientes efectos según el orden del filtro y los signos de los parámetros:

s = 0

ω_0 = positivo

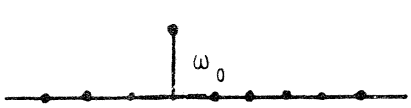

F G4

ω_0 = negativo

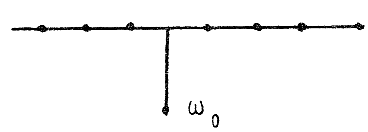

G5

s = 1

ω_0 positivo y ω_1 negativo

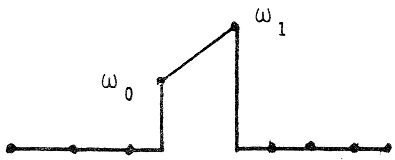

G6

ω_0 y ω_1 positivos

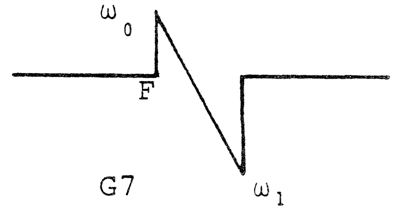

G7

Vemos pues que este tipo de filtros sólo intervienen a Y_t para el período de tiempo que va de F a F+s. El efecto de la intervención sobre Y_t en cada momento F+j (j=1,...,s) vendrá dado por $-\omega_j$ y en el momento F por ω_0. Cuando s es distinto de cero además del efecto en un momento dado se puede hablar del efecto neto o ganancia (G) de la intervención (*). Esta ganancia viene medida por $(\omega_0 - \omega_1 - \ldots\ldots - \omega_s)$.

Para cualquier valor finito de s el efecto de una variable impulso es un efecto de corto plazo, es decir, un efecto localizado en un período de tiempo concreto. En el momento F+s+1 la variable Y_t vuelve a su nivel habitual, que es independiente de la perturbación ocurrida en F. En ese sentido decimos que el fenómeno anómalo no ha tenido un efecto de largo plazo. Obsérvese también que es posible una ganancia distinta de cero con un efecto a largo plazo nulo. Sobre ésto volveremos más adelante.

Consideremos ahora el caso en el que la intervención es con una variable escalón. El efecto sobre Y_t para distintos valores de s son:

s = 0

ω_0 positivo

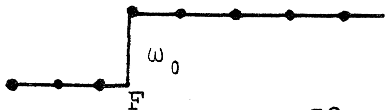

G8

ω_0 negativo

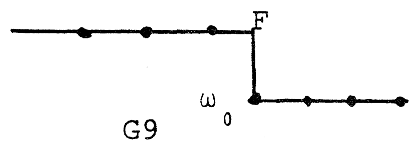

G9

(*) Cuando s=0 la ganancia y el efecto momentáneo coinciden.

$s = 1$

ω_0 positivo y ω_1 negativo

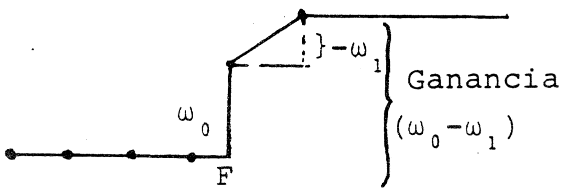

G 10

ω_0 y ω_1 positivos

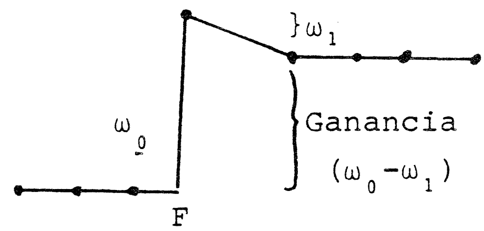

G11

Los gráficos G8 a G11 nos muestran que la intervención con S(F) tiene un efecto permanente o de largo plazo que viene medido por la ganancia y consiste en desplazar el nivel de Y_t de una forma fija.

Si la intervención es con la variable tendencia tendremos:

$s = 0$ ω_0 positivo

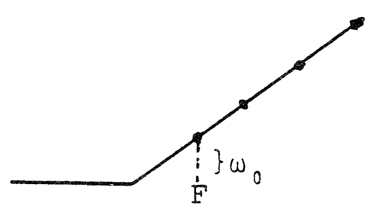

G 12

$s = 1$ ω_0 positivo y ω_1 negativo

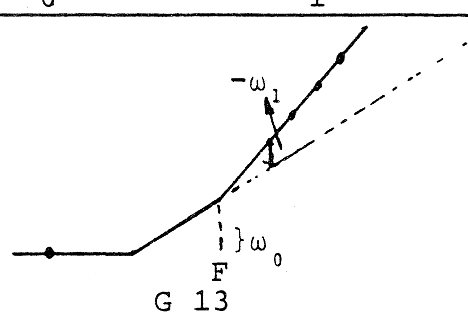

G 13

Los gráficos G12 y G13 muestran que la intervención con T(F) tiene un efecto a largo plazo consistente en desplazar el nivel de Y_t de forma evolutiva. (Véase Espasa (1979,b) pg. 15).

Resumiendo lo expuesto hasta el momento diremos que los impulsos sólo tienen efecto a corto plazo. Los escalores tienen un efecto a largo plazo consistente en desplazar el nivel de forma fija y la magnitud del desplazamiento permanente viene dada por la ganancia. Las tendencias tienen un efecto a largo plazo evolutivo.

Al hablar de la intervención impulso hemos señalado que puede darse una ganancia distinta de cero. La importancia de la ganancia ocasionada por un impulso es muy distinta según sea la variable Y_t stock o flujo. En el caso de una variable stock como reservas en divisas, total de recursos ajenos de una entidad bancaria, etc, la ganancia de la intervención impulso no tiene gran importancia pues tras la perturbación ocasionada por el fenómeno atípico, el nivel de stock ha quedado inalterado respecto al nivel que en F+s+1 hubiese tenido dicha variable si no hubiese existido dicho fenómeno. Por ejemplo, si una Caja de Ahorros anuncia un sorteo de pisos entre los que realicen ingreoss en un determinado período, es de esperar que durante ese período aumenten los recursos ajenos de la Caja, pero si realizado el sorteo no hay ningún efecto de inercia y los clientes de la entidad bancaria vuelven a mantener el nivel de ahorros "habitual", la promoción del sorteo no habrá tenido ningún efecto a largo plazo sobre el nivel de recursos ajenos.

Por el contrario la ganancia en una intervención impulso es importante cuando la variable intervenida es una variable flujo como ventas, tasa de crecimiento de un índice de precios, saldo de la balanza de pagos, etc. La razón es muy sencilla. Designemos por YF_t a una variable flujo, (e.g. incremento de recursos ajenos de una entidad bancaria) y por YS_t a su correspondiente variable stock (total de recursos ajenos). La relación entre ambas variables es:

$$YS_t = \frac{YF_t}{(1-L)} = (1+L+L^2+....)\ YF_t. \tag{15}$$

Si YF_t requiere la intervención de una variable impulso de la forma:

$$YF_t = \omega_s(L)\ D(F)_t + N_t, \tag{16}$$

donde N_t es el resto de YF_t no explicado por la intervención, podemos comprender fácilmente que la correspondiente intervención en YS_t es:

$$YS_t = \omega_s(L)\ \frac{1}{(1-L)}\ D(F)_t + \frac{N_t}{(1-L)} \tag{17}$$

$$= \omega_s(L)\ S(F)_t + \frac{N_t}{(1-L)}\ . \tag{18}$$

Tenemos pues que una intervención impulso en una variable flujo supone una intervención escalón en su correspondiente variable stock, en consecuencia la intervención sobre el flujo no tiene efecto a largo plazo pero sí que lo tiene sobre el stock. Así pues que para hablar de efectos a largo plazo necesitamos que el input, en nuestro caso la variable artificial, sea un escalón y en ese sentido si se realiza una intervención impulso sobre una variable flujo será conveniente trasladarlo, utilizando (15), a su correspondiente stock.

Sin embargo, si realizamos una intervención impulso a una variable stock la forma de ver que la ganancia distinta de cero es meramente momentánea es trasladando el análisis a la variable flujo. Así si el stock requiere

$$YS_t = \omega_0\ D(F)_t + N_t \tag{19}$$

utilizando (15) el flujo requerirá:

$$YF_t = (\omega_0 - \omega_0 L)\ D(F)_t + (1-L)\ N_t, \qquad (20)$$

con lo que claramente se ve que la ganancia en el flujo ha sido cero, aunque el stock ha tenido momentaneamente un nivel superior debido a la intervención. Por supuesto si el stock ya tiene ganancia cero, también es cero ésta en el flujo.

De forma similar una intervención tendencia en el stock supone una intervención escalón en el flujo. En este caso al ser el efecto resultante, de una intervención tendencia, evolutivo parece preferible referir nuestros resultados a la variable flujo a quien le corresponderá un efecto estable en el tiempo.

Con lo dicho tenemos que las intervenciones se reducen a dos tipos, intervenciones impulso de corto plazo e intervenciones escalón de largo plazo. El reconocimiento de estos dos tipos de efectos tan distintos nos conduce a que al realizar una intervención habrá que preguntarse qué efecto se espera que tenga ésta y en el caso de que se esperen ambos habrá que ser conscientes de que hay que introducir dos variables una para captar el efecto a corto plazo (D(F)) y otra para captar el efecto a largo plazo (S(F)). Así, por ejemplo, el anuncio en el momento F de un fuerte impuesto en el precio de un producto para el momento F+1 puede llevar a un aumento de las ventas (V) en F seguido de una caída muy acusada en F+1, mientras que a partir de F+2 la caída se suaviza y estabiliza. Para captar estos efectos necesitaremos una variable escalón que capte la caída permanente en las ventas a partir de F+1 y una variable impulso que capte la subida de ventas en F y la caída excesiva en F+1 debido a la acumulación de stock por parte de los consumidores en F. La modelización será del tipo:

$$V_t = (\omega_0 - \omega_1 L)\ D(F)_t - \omega_0^*\ S(F+1)_t + N_t \tag{21}$$

y la representación gráfica del efecto en las ventas (YF_t) será:

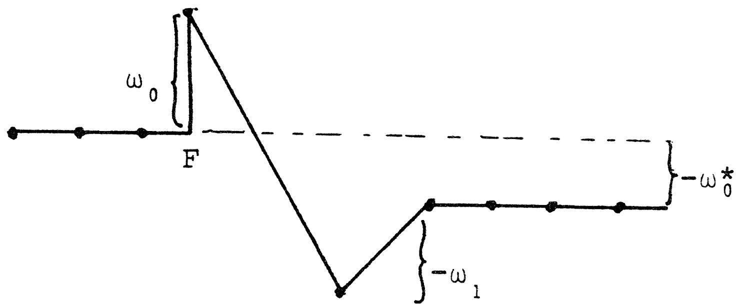

G 14

Como DF no tiene efectos permanentes, el efecto a largo plazo del nuevo impuesto sobre el producto en cuestión vendrá medido por $-\omega_0^*$. Ciertamente (21) no es la única forma de modelar esta intervención. En efecto, utilizando (11) y teniendo en cuenta que

$$L\ S(F)_t = S(F+1)_t, \tag{22}$$

podemos reescribir (21) de la forma:

$$V_t = (\omega_0 - \omega_1 L)(1-L)\ S(F)_t - \omega_0^* L\ S(F)_t + N_t \tag{23}$$

y operando tenemos:

$$V_t = (\alpha_0 - \alpha_1 L - \alpha_2 L^2)\ S(F)_t + N_t \tag{24}$$

donde:

$$\alpha_0 = \omega_0$$

$$\alpha_1 = \omega_0 + \omega_1 + \omega_0^*$$

$$\alpha_2 = -\omega_1.$$

En (24) toda la intervención se realiza con $S(F)_t$ y por tanto la ganancia $G = \alpha_0 - \alpha_1 - \alpha_2 = -\omega_0^*$, será el efecto a largo plazo. El gráfico de la intervención con (24) sería:

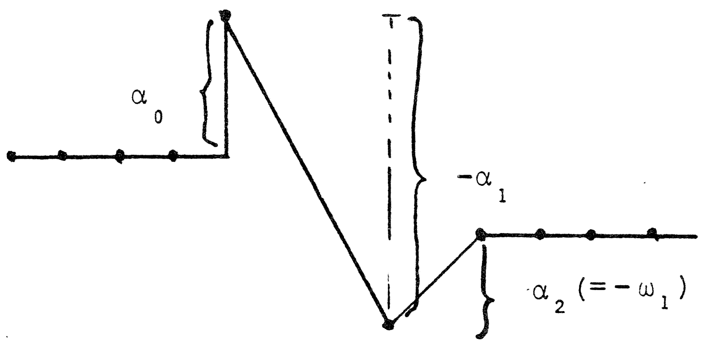

G 15

La comparación de los gráficos G.14 y G.15 nos indica que aunque existen dos formas alternativas de modelar la intervención, (21) lo hace más ortogonalmente que (24) pues en aquél cada coeficiente recoge el efecto específico de cada momento, mientras que en (24) α_1 recoge los tres efectos.

Hasta ahora sólo nos hemos ocupado de intervenciones con filtros MA y es el momento de pasar a considerar filtros ARMA (r,s). Empecemos con el filtro ARMA (1,0) aplicado a un impulso. El modelo será:

$$Y_t = \frac{\omega_0}{1-\delta_1 L} D(F)_t + N_t, \qquad |\delta_1| < 1 \qquad (25)$$

y el efecto de la intervención $\omega_0/1-\delta_1 L$ sobre Y_t se da en G.16 y G.17 para valores de δ positivos o negativos:

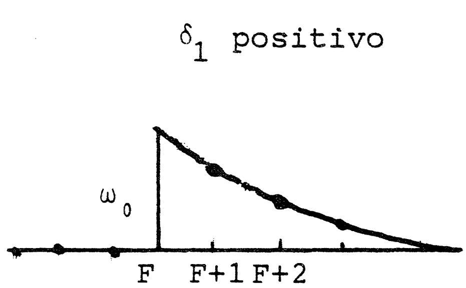

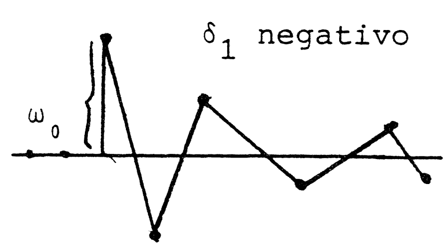

G.16 G.17

En G.16 se ve que para valores positivos de δ_1 el efecto de la intervención consiste en desplazar el nivel de Y_t de acuerdo con ω_0 y en momentos sucesivos este desplazamiento (ω_0) se va reduciendo exponencialmente. Es interesante observar que el filtro ARMA(1,0) se puede aproximar con un filtro MA(s) hasta el grado de precisión deseado dando a s un valor suficientemente alto. Por ejemplo, para un valor de δ_1=0,8, en F+10 el efecto de la intervención sería 0,107 ω_0, con lo que en gran parte de los casos prácticos a partir de F+11 se podrían considerar como extinguidos los efectos de intervención. En efecto, realizando la división polinomial del filtro ARMA(1,0) tenemos:

$$\frac{\omega_0}{1-\delta_1 L} \simeq \omega_0+\omega_0\delta_1+\omega_0\delta_1^2+\ldots.+\omega_0\delta^s=\omega_0+\omega_1+\omega_2+\ldots..+\omega_s. \qquad (26)$$

En (26) vemos que si los s+1 coeficientes de un filtro MA(s) van decayendo exponencialmente el filtro ARMA(1,0) capta el mismo efecto con sólo dos parámetros y por tanto es preferible a MA(s). Obsérvese que estamos suponiendo que δ_1 es en valor absoluto inferior a la unidad, pues de lo contrario la intervención tendría un efecto explosivo en el tiempo, lo cual no es un caso muy real en Economía.

Si δ_1 es negativo el filtro ARMA(1,0) también va reduciendo el efecto inicial de la intervención (ω_0) hasta prácticamente agotarse en F+s, pero en este caso la intervención en cada momento va oscilando de signo. Esto, dicho sea de paso, es un caso bastante infrecuente.

Con el filtro ARMA(1,0) la ganancia del filtro es:

$$G = \omega_0 + \omega_0\delta_1 + \omega_0\delta_1^2 + \ldots.. + \omega_0\delta_1^s+\ldots.. = \frac{\omega_0}{1-\delta_1}. \qquad (27)$$

Consideremos ahora el esquema ARMA(2,0)

$$\frac{\omega_0}{1-\delta_1 L-\delta_2 L^2}. \qquad (28)$$

Denominando π_1 y π_2 a la inversa de las raíces del polinomio autorregresivo tenemos:

$$\frac{\omega_0}{(1-\pi_1 L)(1-\pi_2 L)} = \frac{\sqrt{\omega_0}}{1-\pi_1 L} \cdot \frac{\sqrt{\omega_0}}{1-\pi_2 L} . \qquad (29)$$

Si las raíces son reales el efecto de un ARMA(2,0) consiste en ir reduciendo el impacto inicial ω_0 de forma exponencial, aunque ahora este decrecimiento exponencial viene controlado por dos factores π_1 y π_2 en vez de uno sólo (δ_1) como ocurría con ARMA(1,0). Si las raíces son complejas entonces ARMA(2,0) va reduciendo el impacto inicial pero de forma oscilante sinusoidal. Utilizando (27) y (29) vemos que ahora la ganancia será:

$$G = \frac{\sqrt{\omega_0}}{1-\pi_1} \cdot \frac{\sqrt{\omega_0}}{1-\pi_2} = \frac{\omega_0}{(1-\pi_1)(1-\pi_2)} = \frac{\omega_0}{1-(\pi_1+\pi_2) + \pi_1\pi_2} \qquad (30)$$

y observando que

$$\delta_1 = \pi_1 + \pi_2$$

$$\delta_2 = -\pi_1\pi_2,$$

la ganancia también se puede expresar de la forma:

$$G = \frac{\omega_0}{1-\delta_1-\delta_2} , \qquad (31)$$

y vemos que dicho valor se consigue sustituyendo, simplemente, L por uno en (28).

Para que la intervención con ARMA(2,0) no sea explosiva se necesita (Véase (29)) que π_1 y π_2 sean en valores absolutos (o en módulo) inferiores a uno o, lo que es lo mis mo, que las raíces del polinomio autorregresivo sean en módulo superiores a la unidad.

Filtros ARMA(r,0) con valores de r superiores a dos son raramente necesarios en el análisis de intervención. En cualquier caso conviene decir que todo polinomio autorregresivo de orden r se puede descomponer en el producto de polinomios autorregresivos de orden uno o dos según sean las raíces reales ó complejas. Por tanto para r>2 el problema se puede descomponer, utilizando como componentes los casos anteriores

Consideremos ahora el filtro ARMA(1,1) aplicado a un impulso. Este filtro se puede descomponer de la forma:

$$\frac{\omega_0-\omega_1 L}{1-\delta_1 L} D(F)_t = \frac{\omega_0}{1-\delta_1 L} D(F)_t - \frac{\omega_1}{1-\delta_1 L} LD(F)_t, \quad (32)$$

es decir, como la suma algebraíca de dos filtros ARMA(1,0). Si δ_1 es positivo el efecto de la intervención (32) tendrá la siguiente interpretación gráfica:

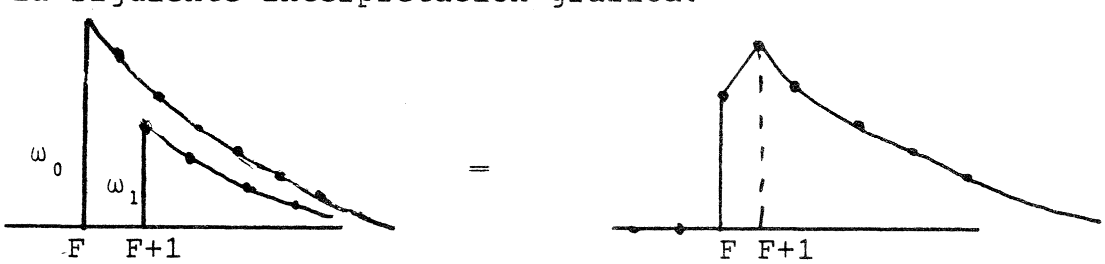

G 18

En G.18 se ve que en el caso de ARMA(1,1) el decrecimiento exponencial ocurre a partir de F+1. En general con un filtro ARMA(1,s) el decrecimiento exponencial empezará a partir de F+s.

En la medida que los filtros ARMA(r,s) se pueden sustituir por filtros MA(s*) podemos decir que estos filtros cuando se aplican a impulsos continúan captando unicamente efecto de corto plazo. No obstante debido a la prolongación en el tiempo que imprime la parte autorregresiva del filtro, ahora el corto plazo será más largo y en algun caso, será quizás útil hablar de ellos como efectos a medio plazo.

Consideremos ahora el filtro ARMA(1,0) aplicado a una variable escalón. El efecto se representa en G.19

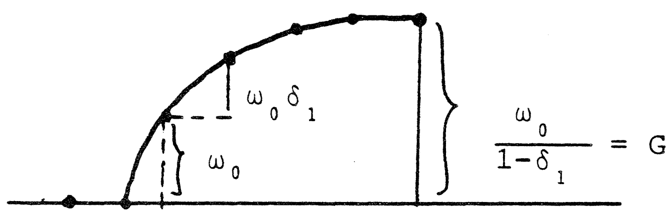

G.19

y vemos que consiste en ir cambiando el nivel de Y_t de forma evolutiva entre F y F+s, momento a partir del cual el nivel de Y_t, prácticamente, se estabiliza en una nueva cuota que viene dada por la ganancia. Al igual que antes ARMA (1,0) produce, en la práctica, el efecto de un filtro MA(s) pero con un número menor de parámetros. Obsérvese que al aplicarse ahora el filtro sobre una variable escalón, la intervención tiene efectos a largo plazo.

Volvamos sobre el ejemplo de la introducción de un nuevo impuesto sobre un producto X en el momento F+1 y postulemos ahora que el tipo de efecto que se espera es una caída permanente de las ventas a partir de F+1 y un aumento de éstas en F debido a un proceso de acumulación de stock por los consumidores y, a su vez, debido a esa acumulación, durante el período F+1 a F+s el descenso de ventas será superior al permanente y ese exceso en el descenso será cada vez menor hasta llegar prácticamente a cero en F+s.

En vez de (21) el modelo que utilizamos ahora es:

$$YF_t = \omega_0 \ D(F)_t + \frac{\bar{\omega}_0}{1-\delta_1 L} \ D(F+1)_t + \omega_0^* \ S(F+1)_t + N_t \qquad (33)$$

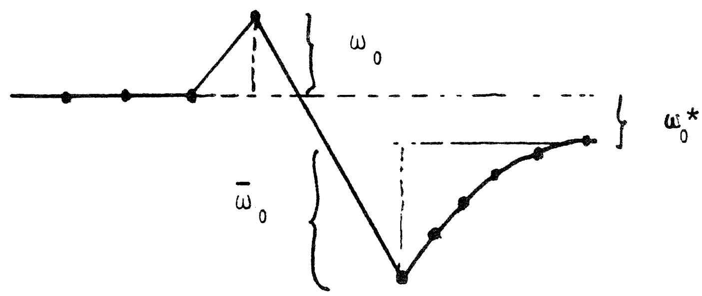

G.20

y en G.20 se da la representación gráfica de la intervención, donde se ve que el efecto a largo plazo viene dado por el coeficiente ω_0^*. Al igual que antes hay formas alternativas de modelar la intervención pero ésta es la más operativa.

Resumiendo lo dicho sobre el análisis de intervención diremos que los filtros ARMA aplicados a variables impulso o escalón son un instrumento muy general para explicar comportamientos atípicos en una serie debido a causas concretas (e.g. elecciones generales) pero difícilmente cuantificables.

Para concluir esta sección señalemos que en ocasiones distintos impulsos $D(F_1)$, $D(F_2)$,..., $D(F_n)$ pueden tener el mismo efecto en la serie, en cuyo caso en vez de introducirlos separadamente en el modelo, crearemos una variable $DM(F) = D(F_1) + D(F_2) + \ldots + D(F_n)$, que será la que consideraremos. Por ejemplo, la Semana Santa suele ser un período de menor actividad que es acusado por distintas series económicas. Tal efecto se puede captar con un análisis de intervención con variables impulso, pero si dicho efecto es aproximadamente el mismo todos los años no necesitamos una variable por año sino que podemos utilizar la variable DM(F) definida arriba.

II.- RELACIONES ENTRE VARIABLES A CORTO Y LARGO PLAZO(*)

En Economía con frecuencia nos encontramos que al intentar explicar una variable (output), Y_t, mediante otra variable (input), X_t, es de esperar que la tendencia, "componente permanente" o evolución a largo plazo de Y_t, Y_t^p, venga explicado por la evolución a largo plazo de X_t, X_t^p, mientras que las desviaciones de Y_t sobre su tendencia ("componente transitorio") o evolución a corto plazo, Y_t^T, vengan explicadas por el componente transitorio de X_t, X_t^{T}(**). Además la relación entre Y_t^p y X_t^p puede ser muy simple y quizás determinística, e.g. del tipo:

$$Y_t^p = k\, X_t^p \quad , \tag{34}$$

ó

$$Y_t^p = \frac{k_1}{1-k_2L}\, X_t^p \quad , \tag{34b}$$

mientras que la relación entre los componentes transitorios puede ser más compleja, por ejemplo:

$$Y_t^T = \frac{\omega_s(L)}{\delta_r(L)}\, \dot{X}_t^T + u_t, \tag{35}$$

donde u_t puede ser un proceso ARMA(p,q).

Teniendo en cuenta que para una variable Z_t se tiene que cumplir que:

$$Z_t = Z_t^p + Z_t^T, \tag{36}$$

(*) Estoy muy agradecido al profesor Jenkins por las conversaciones privadas mantenidas sobre diferentes temas relacionados con él de esta sección. La idea del profesor Jenkins de descomponer las variables explicativas y la utilización de sus componentes como distintos inputs en un modelo econométrico fué el punto de partida en el desarrollo de este epígrafe, en donde se propone una descomposición en un componente permanente o tendencial y un componente resto o transitorio. En Espasa (1981) se desarrolla como estimar ambos componentes.

(**) En este trabajo supondremos que si las variables tienen un componente estacional éste puede incluirse en el componente permanente.

sumando (34) y (35) tenemos:

$$Y_t = k\, X_t^p + \frac{\omega_s(L)}{\delta_r(L)}\, X_t^T + u_t \quad .^{(*)} \qquad (37)$$

En (37) vemos que en la determinación de Y_t el componente permanente de X_t es, en principio, el único factor explicativo no estacionario y por tanto el que define la tendencia de Y_t (**). Los otros dos términos de la parte derecha de (37) servirán para explicar el componente transitorio de Y_t. Lo importante de (37) es que para explicar Y_t mediante X_t se requiere la descomposición de ésta última en X_t^p y X_t^T, pues cada componente afecta de forma distinta a Y_t. Además X_t^p y X_t^T serán factores casi ortogonales entre sí. El modelo (37) se puede reformular de la forma:

$$Y_t = k\, X_t^p + k\, X_t^T + \frac{\omega_s(L)}{\delta_r(L)}\, X_t^T - k\, X_t^T + u_t,$$

$$Y_t = k\, X_t + \frac{\omega_{s'}(L)}{\delta_{r'}(L)}\, X_t^T + u_t \, .^{(***)} \qquad (38)$$

Obviamente, (37) es equivalente a (38) pero aquélla es preferible a ésta pues los inputs son casi ortogonales mientras que en (38) X_t contiene a X_t^T.

Con frecuencia en vez de estimar (37) ó (38) se intenta la estimación de

$$Y_t = \frac{\omega_{\bar{s}}(L)}{\delta_{\bar{r}}(L)}\, X_t + V_t = \pi(L)\, X_t + V_t \qquad (39)$$

con lo que si (38) es cierto el término de error, V_t, en (39) será del tipo:

(*) De forma similar sumando (34 b) y (35) obtendríamos el correspondiente modelo (37 b).

(**) En realidad aunque X_t^T es estacionaria pues está compuesta de impulsos en distintos momentos del tiempo, puede tener un efecto a largo plazo si $\delta_r(L)$ tiene una raiz unitaria, pero por sencillez en la exposición ignoraremos esa posibilidad.

(***) La formulación (38 b) a partir de la (37 b) es inmediata.

$$V_t = u_t - \frac{\omega_{s'}(L)}{\delta_{r'}(L)} X_t^p, \tag{40}$$

con lo que en (39) la señal (X_t) y el ruido (V_t) tendrán una fuerte correlación negativa y con frecuencia observaremos que los resultados son inestables a cambios en el período muestral de la estimación.

Si X_t^T no influye en la determinación de Y_t y se intenta estimar el modelo:

$$Y_t = c\, X_t + \eta_t \tag{41}$$

es todavía importante que en la estimación se tenga en cuenta que η_t seguirá, en general, un proceso ARMA.

Si (37) es cierto y se intenta estimar el modelo:

$$\Delta Y_t = \frac{\omega^*_{s^*}(L)}{\delta^*_{r^*}(L)} \Delta X_t + \varepsilon_t \tag{42}$$

tenemos que si ΔY_t y ΔX_t sirven como aproximaciones de Y_t^T y X_t^T, con (42) estaremos captando principalmente (35) con lo que el componente más importante en la relación entre Y_t y X_t (ecuación (34)) se está ignorando. Obsérvese que (42) se puede formular también como

$$Y_t = \frac{\omega^*_{s^*}(L)}{\delta^*_{r^*}(L)} X_t + \frac{\varepsilon_t}{(1-L)}, \tag{43}$$

donde el término de error es no estacionario, lo que equivale a decir que el componente permanente de Y_t está principalmente determinado por factores desconocidos y eso, muchas veces, puede ser una hipótesis de trabajo bastante mala en Macroeconomía.

Obsérvese que en (39) al utilizar como único input X_t cualquiera de las dos relaciones de Y_t con X_t^p y X_t^T se captarán mal. Pero si modificamos (39) añadiendo valores retardos de Y_t, al estimar la ecuación resultante

$$Y_t = \Pi(L)\ X_t + \alpha(L)\ Y_t + \bar{V}_t, \tag{44}$$

puede ocurrir que sólo $\alpha(L)$ sea significativo y $\Pi(L)$ deje de serlo. Esto puede indicar que $\alpha(L)Y_t$ está aproximando Y_t^p (i.e. k X_t^p) mientras X_t es una mala variable "proxy" de X_t^T y por tanto no es extraño que no aparezca como significativa. Al mismo tiempo este resultado indicaría que $\Pi(L)X_t$ aproxima peor a Y_t^p, debido a la inclusión de X_t^T en el imput, que $\alpha(L)Y_t$. Este tipo de resultados es bastante frecuente en trabajos econométricos pero no siempre se es consciente de que una posible explicación de ellos radica en que se está utilizando una variable explicativa sin depurar de sus componentes transitorios.

Volviendo a (37) diremos que X_t^p es, esencialmente, una variable muy próxima a las del tipo escalón a tendencia tratadas en la sección anterior. Por tanto k medirá su efecto a largo plazo en Y_t.

Por el contrario X_t^T es una variable compuesta de impulsos aleatorios y por tanto la ganancia de $\omega_s(L)/\delta_r(L)$ no tiene efectos a largo plazo sobre Y_t. Obsérvese que en (37) estamos suponiendo que todos los impulsos que componen a X_t^T tienen el mismo efecto sobre Y_t, si se cree lo contrario se puede descomponer X_t^T de la forma

$$X_t^T = X_t^{t_1} + X_t^{t_2} + \ldots\ldots + X_t^{t_n}, \tag{45}$$

de modo que $X_t^{t_1}$ recoja sólo los impulsos de X_t^T entre los momentos 1 y t_1, $X_t^{t_2}$ los comprendidos entre t_1+1 y t_2 y así sucesivamente y luego permitir que cada componente de X_t^T venga afectado por un filtro distinto en la ecuación (37). Si uno de estos componentes X_t^{Tj}, además de un efecto a corto tiene uno a largo habrá que incluir en el modelo como variables explicativas X_t^{Tj} y Δ^{-1} X_t^{Tj} y la ganancia de ésta última será el efecto a largo de dicho impulso. Así pues la formulación general de (37) será:

$$Y_t = k\ X_t^p + \sum_{j=1}^{j=n} \frac{\omega_s^j(L)}{\delta_r^j(L)} X_t^{Tj} + \sum_{j=1}^{j=n} \frac{\bar{\omega}_s^j(L)}{\bar{\delta}_r^j(L)} \frac{1}{(1-L)} X_t^{Tj} + u_t. \quad (*) \qquad (46)$$

En (46) obviamente muchos componentes pueden ser cero. El análisis se puede generalizar a más inputs de forma que unos sólo influyan en la determinación de Y_t^p y otros sólo a los de Y_t^T.

La identificación de (37) se puede realizar de la siguiente forma:

1.- En base al análisis univariante descompóngase X_t en X_t^p y X_t^T; (**)

2.- Con dichos resultados hágase la regresión

$$Y_t = k^*\ X_t^p + W_t; \quad (***)$$

3.- En base al croscorrelograma y croscorrelograma parcial de W_t y X_t^T identifíquese a la Box-Jenkins el filtro $\omega_s(L)/\delta_r(L)$ y el ruido u_t;

(*) Utilizando (34 b) la formulación general se obtendría sustituyendo el primer término de la derecha de (46) por $\frac{k_1}{1-k_2L}$ X_t^p .

(**) Para ello véase Espasa (1981)

(***) Si se supone (34 b) en vez de (34) en este paso tendremos que estimar el modelo:

$$Y_t = \frac{k_1^*}{1-k_2^*L} X_t^p + W_t \quad .$$

4.- Por último, examinando el correlograma y correlograma parcial del ruido identificado en la etapa anterior identifíquese una estructura ARMA para ese ruido.

REFERENCIAS.-

Box, G.E.P. y D.R. Cox, 1964, "An analysis of transformations", Journal of the Royal Statistical Society B, V. 26, nº 2, pgs. 211-42.

Box, G.E.P. y G.M. Jenkins, 1970, Time Series Analysis Forecasting and Control, Holden-Day, San Francisco.

Box, G.E.P. y G.C. Tiao, 1975, "Intervention analysis with applications to economic and environmental problems, Journal of American Statistical Association, V. 70, nº 349, pgs. 70-79.

Espasa, A., 1979, "Modelos ARIMA univariantes, con análisis de intervención para las series de agregados monetarios (saldos medios mensuales) M_3 y M_2", Servicio de Estudios del Banco de España, documento de trabajo nº 7901.

Espasa, A., 1979,b, "Un modelo diario para la serie de depósitos en la banca: primeros resultados y estimación de los efectos de las huelgas de febrero de 1979", Servicio de Estudios del Banco de España, documento de trabajo nº 7905.

Espasa, A., 1981, "Relationships between variables: the short and long run effects", ponencia presentada al Congreso Europero de la "Econometric Society" en Atenas, Septiembre de 1979, de próxima publicación.

Espasa, A., 1982, "El análisis de intervención para la predicción monetaria en momentos de cambios estructurales: el caso español en 1979-80", de próxima publicación en documento de trabajo del Servicio de Estudios del Banco de España.

.../...

.../...

Espasa, A. y J. Pérez, 1982, La predicción decenal de los agregados monetarios y la instrumentación de la política monetaria en España, de próxima publicación en la colección de estudios económicos - del Servicio de Estudios del Banco de España.

Treadway, A.B., J. García-Pardo y A. Carbajo, 1978, Efectos sobre la economía española de una devaluación de la peseta, Fundación Ramón Areces, Madrid.

- - - - - -

DOCUMENTOS DE TRABAJO:

7801 **Vicente Poveda y Ricardo Sanz**: Análisis de regresión: algunas consideraciones útiles para el trabajo empírico.
7802 **Julio Rodríguez López**: El PIB trimestral de España, 1958-1975. Avance de cifras y comentarios **(Agotado)**.
7803 **Antoni Espasa**: El paro registrado no agrícola 1964-1976: un ejercicio de análisis estadístico univariante de series económicas. (Publicado en Estudios Económicos n.º 15).
7804 **Pedro Martínez Méndez y Raimundo Poveda Anadón**: Propuestas para una reforma del sistema financiero.
7805 **Gonzalo Gil**: Política monetaria y sistema financiero. Respuestas al cuestionario de la CEE sobre el sistema financiero español. Reeditado con el número 8001.
7806 **Ricardo Sanz**: Modelización del índice de producción industrial y su relación con el consumo de energía eléctrica.
7807 **Luis Angel Rojo y Gonzalo Gil**: España y la CEE. Aspectos monetarios y financieros.
7901 **Antoni Espasa**: Modelo Arima univariantes, con análisis de intervención para las series de agregados monetarios (saldos medios mensuales) M_3 y M_2.
7902 **Ricardo Sanz**: Comportamiento del público ante el efectivo.
7903 **Nicolás Sánchez-Albornoz**: Los precios del vino en España, 1861-1890. Volumen I: Crítica de la fuente.
7904 **Nicolás Sánchez-Albornoz**: Los precios del vino en España, 1861-1890. Volumen II: Series provinciales.
7905 **Antoni Espasa**: Un modelo diario para la serie de depósitos en la Banca: primeros resultados y estimación de los efectos de las huelgas de febrero de 1979.
7906 **Agustín Maravall**: Sobre la identificación de las series temporales multivariantes.
7907 **Pedro Martínez Méndez**: Los tipos de interés del mercado interbancario.
7908 **Traducción de E. Giménez-Arnau**: Board of Governors of the Federal Reserve System Regulations AA–D–K–L–N–O–Q. **(Agotado)**.
7909 **Agustín Maravall**: Effects of alternative seasonal adjustment procedures on monetary polici.
8001 **Gonzalo Gil**: Política monetaria y sistema financiero español. Respuesta al cuestionario de la CEE sobre el sistema financiero español **(Agotado)**.
8002 **Traducción de E. Giménez-Arnau**: Empresas propietarias del Banco. Bank Holding Company Act-Regulation «Y» **(Agotado)**.
8003 **David A. Pierce, Darrel W. Parke, and William P. Cleveland, Federal Reserve Board and Agustín Maravall, Bank of Spain**: Uncertainty in the monetary aggregates: sources, measurement and policy effects.
8004 **Gonzalo Gil**: Sistema financiero español.
8005 **Pedro Martínez Méndez**: Monetary Control by control of the monetary base: The Spanish Experience (la versión al español se ha publicado como Estudio Económico n.º 20).
8101 **Agustín Maravall, Bank of Spain and David A. Pierce, Federal Reserve Board**: Errors in preliminary money stock data and monetary aggregate targeting.
8102 **Antoni Espasa**: La estimación de los componentes tendencial y cíclico de los indicadores económicos.
8103 **Agustín Maravall**: Factores estacionales de los componentes de m.^{3}. Proyecciones para 1981 y revisiones, 1977-1980.
8104 Normas relativas a las operaciones bancarias internacionales en España.
8105 **Antoni Espasa**: Comentarios a la modelización univariante de un conjunto de series de la economía española.
8201 **Antoni Espasa**: El comportamiento de series económicas: Movimientos atípicos y relaciones a corto y largo plazo.

***Estas publicaciones —que, por su carácter especializado, son de tirada reducida— se distribuyen gratuitamente a las personas o entidades interesadas que las soliciten por correo.*

Información: Banco de España, Servicio de Publicaciones. Alcalá, 50. Madrid-14.