

XIV Conferencia Latinoamericana de Informática
17avas. Jornadas Argentinas de Informática
e Investigación Operativa
Buenos Aires, Setiembre 1988.

Nuevas Técnicas en el Análisis de Series de Tiempo Discretas: Aplicación en Modelos Económicos

Oscar Liberman
Fernando Tohme
Departamento de Economía
Universidad Nacional del Sur
Bahía Blanca

Introducción

Los motivos que llevaron a la realización de este trabajo, pueden ser clasificados en motivos operativos y en motivos históricos. De estas dos categorías surge entonces un replanteo de la actual teoría de series de tiempo.

Desde el punto de vista de los motivos operativos, puede verse hoy en día que la ciencia, y la economía en especial, no ha obtenido resultados satisfactoriamente operativos a través de las series de tiempo. Las situaciones por las cuales las series de tiempo discretas no manifestaron operatividad son principalmente tres: Requerimiento de excesiva cantidad de observaciones, Amplio margen de error en el corto y mediano plazo, Falta de relación con la causalidad de los fenómenos. Con respecto a los motivos históricos, ha existido a lo largo de la historia de la investigación de las series de tiempo una fuerte tendencia a seguir las corrientes de lo investigado por la teoría del sonido. Claros ejemplos de esto son la existencia de términos como ruido blanco o filtros. Actualmente en aplicaciones de la teoría del sonido, los especialistas se han apartado en forma sustancial de sus métodos anteriores, lo que nos lleva a pensar si no puede ser necesario, por analogía, replantear la forma de trabajar con las series de tiempo.

Estas dos justificaciones son tratadas con mayor detalle en la primer parte de este trabajo. La segunda parte del mismo contiene el desarrollo teórico del modelo y las posibles aplicaciones prácticas tanto en el análisis explicativo, como en lo que respecta a causalidad y predicción. La tercer parte del trabajo consta de un ejemplo práctico de como utilizar estos nuevos conceptos y de la forma en que aparecen las limitaciones del mismo.

PARTE I: "Por qué un nuevo método de Series de Tiempo ?"

Motivo Operativos: Tres problemas se manifestaron siempre en el trabajo con series de tiempo discretas :

- 1 - Requerimiento de gran cantidad de observaciones.
- 2 - Amplio margen de error en el mediano y corto plazo.
- 3 - Falta de relación con la causalidad de los fenómenos.

1 - Requerimiento de gran cantidad de observaciones:

La teoría de series de tiempo vigente tiene una gran restricción, presente tanto en los métodos robustos como en los no robustos. [1] Esta limitación reside en la necesidad de conseguir alrededor de 150 observaciones para poder realizar una aproximación satisfactoria. Este hecho es de por sí limitante, ya que es sólo podremos conseguir, en general, datos de corto y mediano plazo (frecuencias diarias y semanales; eventualmente anuales con mayores restricciones de información). Como se verá en el próximo punto, no es precisamente en este tipo de plazos donde los métodos de series de tiempo evidencian mayor grado de certeza.

En este trabajo se mostrará que para solucionar esta situación se trabaja sobre la base de modelos ajustables dinámicamente, donde la cantidad de observaciones no es una variable de trascendencia fundamental. Se verá en el ejemplo que los módulos de ajuste del modelo dinámico utilizado constan entre 20 y 40 observaciones habiéndose registrado experiencias con una cantidad inferior, obteniéndose muy buenos resultados explicativos.

[1] Por métodos robustos se entiende aquellos que filtran los picos de las funciones, mientras que no robustos son aquellos métodos que estiman una tendencia considerando todos sus puntos.

2 - Amplio margen de error en el corto y mediano plazo:

Los resultados tradicionalmente obtenidos mediante los métodos de series de tiempo son en general sólo tendencias. Esto implica un margen de error en el corto y mediano plazo. Conviene recordar que esto se debe a la intención de suavizar los picos de la función, ya sea mediante la absorción de los saltos o la separación de la componente aleatoria de la no aleatoria. Además desde el punto de vista explicativo se han dado siempre en las aproximaciones clásicas problemas que van desde la falta de significatividad hasta la aparición de multicolinealidad debido a la presencia de variables aleatorias.

Una de las corrientes más recientes propone realizar un preblanqueo de las variables antes de ajustarla por mínimos cuadrados. [2]

De esta forma se eliminaría la componente aleatoria de cada variable, pero surge el problema del amplio margen de error característico de los métodos estimadores de tendencias. En este trabajo se utiliza el método de incorporar ecuaciones que expliquen "por sí mismas" a las variables con fuerte presencia de componente aleatorio, pero sin necesidad de preblanquear la serie. [3]

[2] La idea del preblanqueo consiste en agregar al modelo ecuaciones de series de tiempo que separen la componente aleatoria de una variable convirtiendo a ésta la expresión de su tendencia. De esta forma se evitan posibles problemas en los resultados que pueden no haberse previsto en el modelo, como así mismo revelar modelos que presentaron en el pasado problemas de ajuste. [Granger & Newbold- bib. 4]

[3] Con la frase "explicación por sí misma" de la variable quiere significarse que sin dejar de lado la incidencia que esta puede tener sobre otras variables, se reconoce la existencia de una componente aleatoria tan fuerte a través del tiempo que produce perturbaciones sobre el ajuste final. Esto impide considerar otra causa del comportamiento de la variable que su propia conducta. Esta situación se da frecuentemente en los modelos de retroalimentación.

3 - Falta de relación causal entre los fenómenos:

Si nos remontamos a los orígenes del estudio de las series de tiempo, es posible ver que la justificación de utilizar sus métodos no radica precisamente en la posibilidad de dar cuenta de la causalidad de los fenómenos, sino por el contrario en la hipótesis de la ausencia de relaciones causales en los mismos. Con esto se quiere resaltar el hecho de que es tan grande la componente aleatoria de la variable, que si estudiamos su evolución a través del tiempo, se verá una presencia frecuente de ruido blanco. Así es que se sugiere entonces encontrar una estimación de la tendencia de la variable en el tiempo sin tener en cuenta sus relaciones causales.

Si bien esto no es falso ni erróneo, también conviene recordar que esta solución parece la única recomendable, ya que los métodos de ajuste conocidos y utilizados que detectan relaciones de causalidad entre fenómenos verifican problemas ante la presencia de aleatoriedad y en última instancia terminan realizando transformaciones de variables bastante similares a las estimaciones de tendencia. [4]

Lo que ahora se propone es conseguir aproximaciones más rigurosas y realistas a las series de tiempo. Si bien no se puede exigir estricta rigurosidad en modelos que, para estimar tendencias, filtran o absorben las observaciones que se alejan demasiado de la variación media, si es importante evitar la pérdida de significatividad de posibles observaciones. Aplicando los métodos tradicionales de series de tiempo se han evitado o absorbido saltos que no siempre eran de origen aleatorio sino que seguramente estaban inducidos por otra variable que, al presentar los mismos problemas de aleatoriedad, no permitían verificar una correlación entre ambas.

[4] Pulido San Román - [bib. 1]

Se puede decir que la componente aleatoria de una variable es fuerte si estudiando la evolución de la variable en el tiempo, se detectan oscilaciones bruscas que se aproximan al ruido blanco. Cuando se analizan variables de origen natural, como temperaturas a una misma hora todos los días, es bastante lógico que en los comportamientos diarios se observen componentes aleatorias, y que los cambios de estación sólo eleven o disminuyan el nivel general de la tendencia. Pero si las variables obedecen a causas determinadas por factores humanos, como por ejemplo la cotización de un activo financiero, la situación es completamente diferente. En el enfoque tradicional se parte de aceptar que el comportamiento de corto plazo es aleatorio y que hay una tendencia distinguible y en cierto modo anticipable. Pero conviene estudiar el proceso más cuidadosamente en cada uno de los instantes y así recorrer la oscilación de una variable en el tiempo desde el origen de la medición. Al llegar al primer salto importante se infiere que existió alguna causa que determinó ese cambio. Se ve que cada uno de estos casos será absorbido como aleatorio por los métodos tradicionales quedando luego una tendencia que indique la participación ponderada de estos saltos. De aquí podemos ver claramente que si se quiere obtener relaciones de causalidad entre variables, estos métodos no representan la situación real sino que sólo dan una idea global del comportamiento de las mismas.

Como ejemplo conviene observar dos series en las que sabemos a priori que puede existir relación causal, y tomar dos observaciones consecutivas y desfasadas en cada una de las series. Es probable que a simple vista se pueda distinguir como una variación en una de las variables es seguida por una variación en la otra. Esta situación probablemente pase desapercibida en un análisis clásico.


Motivos Históricos:

La circunstancia que llevó a plantear este trabajo, tiene que ver en cierto modo con la existencia de un paralelismo histórico entre la ingeniería de sonido y el análisis de series temporales. En un primer momento los diseñadores de los diferentes métodos de series, buscaron sus fuentes en el análisis de ondas sonoras. Más específicamente, existió un paralelismo entre la programación analógica de sintetizadores de sonido y la obtención de tendencias en series de tiempo. Para obtener sonidos mediante un sintetizador analógico, el proceso consiste en generar una onda básica con un oscilador, y mediante el uso de filtros y envolventes conseguir onda final deseada. A la inversa los analistas de series de tiempo, parten de una onda final obtenida a través de observaciones y mediante el uso de filtros y envolventes se llega a separar la onda fundamental de la onda de ruido. Hasta este punto, ambos métodos llevaron caminos paralelos, pero los desarrollos posteriores en síntesis digital marcan un techo bastante rígido en el horizonte de la síntesis sonora. Hay que tener en cuenta que toda esta evolución se debió principalmente a la imposibilidad de los ingenieros de sonido de tomar la muestra de la onda y reproducirla. En cambio los analistas de series no mostraron interés en estimar la forma original en un sentido riguroso, sino que tratan de filtrar esa onda hasta obtener la fundamental.

Si comparamos las metodologías tradicionales en ambos campos, existe un punto de contacto : los dos enfoques se enfrentan a la onda, pero evitan representarla en forma rigurosa. La diferencia reside en que los ingenieros de sonido tomaron esta decisión por falta de medios mientras que los analistas de series lo hicieron por considerar necesario separar la componente aleatoria.

Todo este proceso histórico, se encuentra ahora en un periodo de transición debido a la aparición de los "SAMPLERS", que son generadores de sonido, que como su nombre lo indica (sampler significa en inglés muestreador), toman una muestra de un determinado sonido y tratan de imitarlo rigurosamente. Un sampler trabaja efectuando una transformada rápida de Fourier. Cabe preguntarse si en el trabajo de series de tiempo no ha llegado la hora de tomar también este camino de la reproducción rigurosa.

La siguiente figura esquematiza este paralelismo histórico entre ambos procesos.



PARTE II - "Desarrollo del Modelo"

El modelo planteado está dirigido a obtener dos tipos de estimaciones: explicativas y predictivas.

En el primer caso, el proceso puede sintetizarse de la siguiente manera:

- 1 - Ingresar observaciones de una variable para un determinado periodo de tiempo .
- 2 - Estimar la función muestreada a través de la transformada de Fourier.
- 3 - Introducir en el modelo de ajuste la nueva función obtenida, evitando así los tradicionales problemas producidos en los ajustes por las variables aleatorias y poder crear así un modelo explicativo que incluye a estas variables.

La segunda aplicación del modelo requiere de los siguientes pasos:

- 1 - Estimación de posibles funciones causales, desfazadas tantos periodos como retardos existan, pero utilizando idéntica cantidad de observaciones.
- 2 - Determinar la relación existente entre las funciones estimadas, quedando de esta manera la variable tiempo absorbida como núcleo de relación.
- 3 - Ingresar una nueva observación para la función que anticipa, obteniendo así una tercera función similar a la primera pero desfazada un periodo.
- 4 - Mediante la función de relación y la nueva serie estimada, inferir un nuevo valor par la segunda función.

Aplicación explicativa

Estimación de la serie observada: en ingeniería de sonido, las diferentes fabricantes de samplers utilizaron algoritmos que de una u otra manera contienen la transformada rápida de Fourier. Las diferencias algorítmicas dependen de la capacidad de proceso del sampler y del tipo de sonido que se quiere realzar. En este modelo se utiliza la transformada de Fourier directamente. La fórmula que estima

la serie es:

$$F(t) = \frac{1}{2} a_0 + \sum_{j=1}^k a_j \cos\left(\frac{2\pi j t}{T+1}\right) + b_j \sin\left(\frac{2\pi j t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(k+1)2\pi t}{T+1}\right)$$

donde:

T: cantidad de observaciones en el tiempo.

k: es T/2 si T es par.

(T-1)/2 si T es impar.

ϕ : 0 si T es par.

1 si T es impar.

y los vectores a_j y b_j se obtienen de la siguiente forma:

$$a_j = \frac{2}{T+1} \sum_{i=0}^T X_i \cos\left(\frac{2\pi j i}{T+1}\right)$$

$$b_j = \frac{2}{T+1} \sum_{i=0}^T X_i \sin\left(\frac{2\pi j i}{T+1}\right)$$

Las observaciones abarcan el periodo 1 a T, con iteración 1. En la función $F(t)$ se encuentran todos los puntos de la variable comprendidos entre 1 y T. Hipotéticamente si las observaciones son diarias, medidas a las 0.00 Hs. de cada día, podemos inferir la observación al mediodía del tercer día estimando $F(3.5)$. Si bien de esta manera se puede explicar la variable para un periodo en forma continua, nos queda por resolver el problema de la periodicidad, ya que si estimamos $F(T+1)$, el valor obtenido coincidirá con $F(1)$, y así sucesivamente lo que seguramente no representa una situación real.

Esta situación se resolverá en la segunda aplicación del modelo, o sea en el desarrollo de predicción de cualquier forma, se puede ver que si ahora introducimos esta función obtenida en cualquier método clásico de ajuste, se resolverán los problemas de aleatoriedad confiéndole al modelo un grado más de multiecuacionalidad. Luego sólo resta aplicar algún método de resolución adecuado para modelos multiecuacionales.

Como se verá nuevamente en la aplicación siguiente, cada vez que ingresamos una nueva observación, eliminamos la primera. Esto significa que siempre tenemos T observaciones. Obteniendo la función de transformación entre cada una de éstas estimaciones, podemos derivar la tendencia de la serie.

Aplicación del modelo al análisis causal y a la predicción

Como se vió anteriormente, el principal problema que presentan las estimaciones obtenidas por el modelo es el de la periodicidad. Este supuesto debe ser solucionado debido a que suponer periodicidad en series de tiempo en general puede resultar una hipótesis alejada de la realidad.

Para corregir esta situación, conviene recordar el propósito inicial del trabajo y establecer un sistema de ajuste por etapas. El método a seguir consta de las siguientes etapas :

- a) Estimación de dos funciones correspondientes a dos variables que observen causalidad, y de una tercera que relacione a ambas.
- b) Ingresar un nuevo dato para la función "causa" y reestimarla.
- c) Inferir el nuevo valor de la función "efecto", utilizando la relación entre ambas funciones.

Con respecto a la estimación, se utiliza el mismo método ya visto para la aplicación explicativa. En cambio en la segunda etapa, de reestimación se realiza eliminando siempre la primera observación de la serie y agregándole un nuevo valor. De esta forma se trabaja en módulos de T observaciones, con $T-1$ grados de superposición. Es visible que entre dos funciones consecutivas de una misma variable, no existirá gran diferencia. Por otra parte las diferencias se presentarán en los vectores a_j y b_j , ya que en última instancia la forma de la función utilizada es la misma.

Precisamente aquí es donde se soluciona el obstáculo de la periodicidad, ya que cada nueva función absorbe el dato en $T+1$ que de otro modo significaría el comienzo de un nuevo ciclo.

Con respecto a la continuidad de la serie, de donde se inferiría la tendencia, si se relacionan todas las sucesivas estimaciones de una misma variable, podrá derivarse la tendencia.

Analíticamente, el proceso es el siguiente:

Supongamos dos variables X_1 y X_2 , tal que existe o al menos creemos que existe una ley causal tal que X_1 anticipa en relación directa a X_2 un periodo. De otro modo se puede decir que si se observa un aumento en X_1 del periodo 1 al 2, cabe esperar que X_2 también aumente en forma equiproporcional del periodo 2 al 3.

De esta forma tomamos en el instante $t+1$ dos muestras de t observaciones periódicas de X_1 y X_2 . Los datos de la variable X_1 van desde 1 a t , mientras que los de X_2 de 2 a $t+1$. Matricialmente podemos representar a los datos de X_1 y X_2 como:

$$[X_1] = [X_{11} \dots X_{1t}]$$

$$[X_2] = [X_{22} \dots X_{2t+1}]$$

Utilizando el método que denominamos "sampler", estimamos dos funciones $F(t)$ y $G(t)$, correspondiendo $F(t)$ al vector $[X_1]$ y $G(t)$ a $[X_2]$. Obsérvese que la explicatividad de $F(t)$ abarca el periodo 1..t, mientras que la de $G(t)$ el periodo 2..t+1.

Ambas funciones son idénticas, variando sólo en el valor de los correspondientes vectores a_j y b_j . Definimos entonces como a_{j0} y b_{j0} a vectores correspondientes a $F(t)$ y a_{j1} y b_{j1} a los vectores de la función $G(t)$. En forma matricial tenemos ahora las matrices $[a_{j0}, b_{j0}]$ y $[a_{j1}, b_{j1}]$ de $k+2$ filas por dos columnas. [5]

Si relacionamos $F(t)$ y $G(t)$, podemos obtener una función $H(t)$, que actúe como función de transferencia intertemporal entre X_1 y X_2 .

$$\text{Luego: } H(t) = G(t)/F(t)$$

[5] Los vectores a_j y b_j abarcan de $j=1$ hasta $j=k$, pero como en general también se deben utilizar a_j para $j=0$ y $j=k+1$, entonces la matriz $[a_j, b_j]$ tiene $k+2$ filas, siendo $[a_0, b_0]$ y $[a_{k+1}, b_{k+1}]$ nulos en b_j .

Al ingresar el dato de X_1 para el periodo $T+1$, eliminamos la observación X_1 en el periodo 1 y estimamos una nueva función $F^*(t)$ de T observaciones que abarcan del periodo 2 al $T+1$.

Podemos estimar ahora $G^*(t)$ abarcando el periodo 3... $t+2$ e inducir así el valor esperado de X_2 .

La función $G^*(t)$ se estimará así:

$$G^*(t) = G(t) / F(t) \cdot F^*(t)$$

Si reemplazamos las funciones analíticas aquí vistas en la transformada de Fourier, las funciones estimadas para $[X_1]$ y $[X_2]$, $F(t)$ y $G(t)$ resultan:

$$F(t) = \frac{1}{2} a_0 + \sum_{j=1}^K a_{j1} \cos\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + b_{j1} \sin\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(K+1)2\pi \cdot t}{T+1}\right) \quad \text{con } t: 1 \dots T$$

$$G(t) = \frac{1}{2} a_{01} + \sum_{j=1}^K a_{j1} \cos\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + b_{j1} \sin\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(K+1)2\pi \cdot t}{T+1}\right) \quad \text{con } t: 2 \dots T+1$$

Y los respectivos vectores a_j , b_j para cada función son:

$$a_{j0} = \frac{2}{T+1} \sum_{i=0}^t X_{1i} \cdot \cos\left(\frac{2\pi \cdot j \cdot i}{T+1}\right)$$

$$a_{j1} = \frac{2}{T+1} \sum_{i=0}^t X_{2i} \cdot \cos\left(\frac{2\pi \cdot j \cdot i}{T+1}\right)$$

$$b_{j0} = \frac{2}{T+1} \sum_{i=0}^t X_{1i} \cdot \sin\left(\frac{2\pi \cdot j \cdot i}{T+1}\right)$$

$$b_{j1} = \frac{2}{T+1} \sum_{i=0}^t X_{2i} \cdot \sin\left(\frac{2\pi \cdot j \cdot i}{T+1}\right)$$

para $F(t)$

para $G(t)$

Al ingresar el nuevo valor de X_1 , es decir para el periodo $t+1$, obtenemos $F^*(t)$:

$$F^*(t) = \frac{1}{2} a_{02} + \sum_{j=1}^K a_{j2} \cos\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + b_{j2} \sin\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(K+1)2\pi \cdot t}{T+1}\right) \quad \text{con } t: 2 \dots T+1$$

Finalmente la función de transferencia intertemporal $H(t)$ resulta:

$$H(t) = \frac{G(t)}{F(t)} \quad \text{es decir:}$$

$$H(t) = \frac{\frac{1}{2} a_{01} + \sum_{j=1}^K a_{j1} \cos\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + b_{j1} \sin\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(K+1)2\pi \cdot t}{T+1}\right)}{\frac{1}{2} a_{00} + \sum_{j=1}^K a_{j0} \cos\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + b_{j0} \sin\left(\frac{2\pi \cdot j \cdot t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(K+1)2\pi \cdot t}{T+1}\right)}$$

$$G^*(t) = \frac{\frac{1}{2} a_{01} + \sum_{j=1}^k a_{j1} \cos\left(\frac{2\pi_j t}{T+1}\right) + b_{j1} \sin\left(\frac{2\pi_j t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(k+1)2\pi_j t}{T+1}\right)}{\frac{1}{2} a_{00} + \sum_{j=1}^k a_{j0} \cos\left(\frac{2\pi_j t}{T+1}\right) + b_{j0} \sin\left(\frac{2\pi_j t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(k+1)2\pi_j t}{T+1}\right)} \\ \dots \frac{\frac{1}{2} a_{02} + \sum_{j=1}^k a_{j2} \cos\left(\frac{2\pi_j t}{T+1}\right) + b_{j2} \sin\left(\frac{2\pi_j t}{T+1}\right) + \frac{\phi}{2} \cos\left(\frac{(k+1)2\pi_j t}{T+1}\right)}{\dots}$$

De esta manera, los valores obtenidos para $G^*(t)$ pueden contrastarse en el intervalo $3..t+1$, y así obtener un desvío entre la función $G^*(t)$ y $G(t)$ con $t:3...t+1$.

El valor del desvío puede ser de utilidad para verificar causalidad. Debe destacarse que la relación intertemporal $H(t)$, representa $t-1$ periodos y solo permite inferir uno. Es decir que es razonable ver la evolución del desvío entre $G^*(t)$ y $G(t)$ y si éste se torna muy grande, podemos inferir que la causalidad supuesta no verifica, porque la estimación ha perdido trascendencia en el dominio de superposición temporal entre las variables.

Consideraciones especiales sobre la función de transferencia

En el modelo aquí planteado, se trabajó directamente sobre la transformada de Fourier. Cabe destacar en este punto que como se vió anteriormente, las funciones utilizadas $F(t)$, $G(t)$ y $F^*(t)$ son similares variando sólo los coeficientes a_j y b_j . Por lo tanto al estimar $H(t)$ como cociente de funciones similares, se trata de abarcar un caso general. Esto no es excluyente, ya también se puede trabajar directamente sobre una matriz de relación $[c_{j1} \ c_{j2}]$, que establezca transferencia a_{j0} y a_{j1} y b_{j0} y b_{j1} .

Por ejemplo en el caso de verificarse posibles transferencias lineales, se sugiere trabajar con una matriz $[c_{j1} \ c_{j2}]$ tal que tal que $c_{j1}=a_{j1}/a_{j0}$ y $c_{j2}=b_{j1}/b_{j0}$ de $k+2$ filas por dos columnas.

Estimando luego los $[a_{j2}, b_{j2}]$ de $F^*(t)$, podemos inferir una matriz $[a_{j3}, b_{j3}]$ correspondiente a $G^*(t)$, de manera tal que finalmente los vectores de $G^*(t)$ resultan:

$$[a_{j3}, b_{j3}] = [c_{j1} \ c_{j2}] \cdot [a_{j2} \ b_{j2}]$$

Para este caso la transferencia se supuso lineal y constante en los a_j, b_j . Pero esto no significa que sea la única transformación posible, sino que indica el camino a seguir por sucesivas investigaciones.

Una recomendación que surge de las distintas experiencias prácticas realizadas para este trabajo es el de distinguir un dominio de error más restringido cuando se trabaje directamente sobre los a_j y b_j .

Los vectores a_j y b_j de cada función estimada, pueden sugerir transformaciones lineales, pero dentro de los cuales cualquier margen de error puede transformar en algo completamente impredecible a la transferencia esperada.

En otros términos, lo que quiere destacarse es la mayor amplitud posible de errores en las observaciones en los vectores a_j y b_j .

Si estimamos dos funciones de una misma serie con alguna modificación en una o algunas observaciones, probablemente estas modificaciones no alteren en forma sustancial el resultado final. Mientras que si variamos algún valor de los vectores a_j, b_j arbitrariamente, es posible que al reestimar la función nos quede un resultado muy alejado de la función original.

De cualquier forma, aún teniendo en cuenta estas restricciones, es recomendable continuar experimentando con estos vectores.

PARTE III - Aplicaciones prácticas del modelo

Un caso de predicción causal entre activos financieros

De todas las aplicaciones con que se ha experimentado al desarrollar este trabajo, puede resultar bastante ejemplificador este sencillo modelo de predicción entre activos financieros, por modelar un caso real además por abarcar todas las posibilidades del método (análisis causal, predicción, explicatividad).

Desde el punto de vista técnico, se prepararon tres programas de computación, realizados en una computadora IBM PC/AT. El primero de ellos es el programa de estimación general, que calcula la función de Fourier para una serie dada, grafica ambas (observada y estimada), y nos crea un archivo que contiene los vectores a_j y b_j de cada estimación. El segundo programa relaciona dos funciones desfasadas tantos periodos como periodos de retardo causal existan, calcula la función de transferencia intertemporal y una vez ingresada la nueva observación de la variable "causa", estima los valores máximo y mínimo esperado de la variable efecto [6]. El último programa es un actualizador de archivos que al ingresar la nueva observación de una variable de una variable, borra la primera y anexa esta última. De esta forma se mantienen T observaciones en el archivo.

Variables utilizadas en el modelo

El análisis causal que se explica en este ejemplo es la relación existente entre el dolar financiero y el bonex 82 bursátil contado. En economía es bastante conocido el hecho de que el precio de cierre del dólar influye sobre el precio de apertura del bonex al día siguiente.

[6] Para estimar la función de transferencia intertemporal se utilizaron varios métodos. En aquellos que se trabajó directamente sobre los vectores a_j y b_j se obtuvieron resultados diferentes, dependiendo de la relación considerada. Los resultados aquí publicados no son los exactos pero si los más generales por utilizar Fourier directamente.


El inconveniente para estimar predicción en este caso, era la falta de un método adecuado y exacto. Suponiendo un día de retardo en la causalidad, los datos observados y estimados de ambas variables fueron:

Fecha	Dolar	Bonex	Dol Est	Bon Est	Dvio	Dol	Dvio	Bon
11-Abr	671,00	538,00	680,00	-	0,013412	-	-	-
12-Abr	679,00	535,00	688,42	536,84	0,013874	0,003442	0,003442	0,003442
13-Abr	678,00	520,00	685,28	521,05	0,013701	0,002023	0,002023	0,002023
14-Abr	675,00	520,00	684,21	521,05	0,013647	0,002023	0,002023	0,002023
15-Abr	690,00	524,00	700,00	535,79	0,014491	0,003352	0,003352	0,003352
18-Abr	699,50	547,00	710,00	549,47	0,015012	0,004521	0,004521	0,004521
19-Abr	708,00	551,00	718,95	553,69	0,015461	0,004872	0,004872	0,004872
20-Abr	715,00	555,00	726,32	557,90	0,015826	0,005216	0,005216	0,005216
21-Abr	725,00	559,00	736,84	562,11	0,016333	0,005554	0,005554	0,005554
22-Abr	732,00	564,00	744,21	567,37	0,016680	0,005971	0,005971	0,005971
25-Abr	728,00	567,00	740,00	570,53	0,016483	0,006218	0,006218	0,006218
26-Abr	734,00	577,00	746,32	581,05	0,016777	0,007024	0,007024	0,007024
27-Abr	739,00	581,00	751,58	585,26	0,017023	0,007337	0,007337	0,007337
28-Abr	745,00	598,00	757,89	603,16	0,017306	0,008627	0,008627	0,008627
29-Abr	749,00	590,00	762,11	594,74	0,017496	0,008027	0,008027	0,008027
02-May	735,00	579,00	747,37	583,16	0,016827	0,007181	0,007181	0,007181
03-May	736,00	584,00	748,42	588,42	0,016876	0,007570	0,007570	0,007570
04-May	742,00	595,00	754,74	600,00	0,017167	0,008403	0,008403	0,008403
05-May	742,00	598,00	754,74	603,16	0,017164	0,008625	0,008625	0,008625
06-May	757,00	595,00	770,53	600,00	0,017867	0,008403	0,008403	0,008403
09-May	772,00	621,00	786,32	627,37	0,018544	0,010254	0,010254	0,010254
10-May	782,50	635,00	797,37	642,11	0,019000	0,011190	0,011190	0,011190
11-May	789,00	641,00	804,21	648,42	0,019277	0,011577	0,011577	0,011577
12-May	804,00	651,00	820,00	658,95	0,019899	0,012207	0,012207	0,012207
13-May	810,00	642,00	826,32	648,47	0,020143	0,011640	0,011640	0,011640
16-May	823,00	659,00	840,00	667,37	0,020657	0,012698	0,012698	0,012698
17-May	837,00	663,50	854,74	672,11	0,021191	0,012970	0,012970	0,012970
18-May	834,00	657,00	851,58	665,28	0,021077	0,012576	0,012576	0,012576
19-May	843,00	663,00	861,05	671,58	0,021415	0,012938	0,012938	0,012938
20-May	877,00	694,00	896,84	704,21	0,022624	0,014713	0,014713	0,014713
23-May	883,00	700,00	903,16	710,53	0,022828	0,015037	0,015037	0,015037
24-May	906,00	707,00	927,37	717,90	0,023584	0,015410	0,015410	0,015410
26-May	893,00	706,00	913,68	716,84	0,023162	0,015356	0,015356	0,015356
27-May	906,00	707,50	927,37	718,42	0,023588	0,015436	0,015436	0,015436
30-May	915,00	721,00	936,84	732,63	0,023871	0,016133	0,016133	0,016133
31-May	920,00	722,00	942,11	733,68	0,024027	0,016182	0,016182	0,016182
01-Jun	934,00	726,00	956,84	737,90	0,024457	0,016384	0,016384	0,016384
02-Jun	940,00	727,00	963,16	738,95	0,024635	0,016434	0,016434	0,016434
03-Jun	997,00	764,00	1023,16	777,89	0,026235	0,018185	0,018185	0,018185
06-Jun	1006,00	774,00	1035,16	788,42	0,028983	0,018631	0,018631	0,018631
07-Jun	1015,00	780,00	-	795,22	-	0,019511	0,019511	0,019511

Fuente: "Ambito Financiero"


Evolucion Dolar — Bonex

(11-Abril / 08-Junio)



Desvios de las estimaciones

(11-Abril / 08-Junio)



Los vectores estimados para las funciones de Dólar y Bónex son:

Funcion Dolar			Funcion Bonex	
k	aj	bj	aj	bj
0	11343,00	0,000	5030,000	0,000
1	194,108	-1850,56	70,912	-1572,03
2	-422,849	-977,682	-164,133	-737,903
3	-220,806	-697,929	-98,422	-579,585
4	-248,381	-412,018	-56,129	-307,759
5	-199,897	-424,334	-95,463	-413,733
6	-264,272	-317,766	-96,831	-280,081
7	-347,627	-281,140	-99,378	-189,267
8	-284,832	-202,200	-110,798	-175,008
9	-274,930	-197,990	-113,530	-220,144
10	-345,998	-210,985	-199,499	-75,498
11	-339,529	-183,961	-167,816	-112,251
12	-331,112	-140,315	-157,868	-86,461
13	-326,493	-162,642	-215,322	-46,722
14	-347,690	-83,215	-139,907	-45,086
15	-320,103	-100,341	-172,537	-60,7368
16	-311,667	-109,851	-166,702	-4,987
17	-373,802	-69,097	-180,861	-24,400
18	-379,180	-32,305	-129,625	13,233
19	-360,901	8,747	-137,574	-5,183
20	-331,000	0,009	-167,000	0,004

Las series estimadas observaron un desvio standard de 0,00787 para la del dólar, mientras que para la serie del bonex fue de 0,00860.

Cuando se ingresó en el programa de predicción el valor del dólar para el 6 de Junio, correspondiendo 1006, la predicción nos entregó un valor esperado para el bonex mínimo de 778,1668 y un máximo de 780,5550. Es interesante observar que la variación entre los límites máximo y mínimo estimados en T+1 es un intervalo que abarca el tres mil del valor del bonex en T (0,0030855).

Interpretación de los resultados

Es evidente en este caso que para el 7 de Junio se espera un ascenso en el precio el bonex. Pero ha sucedido también en anteriores experiencias que el precio esperado esté contenido en un entorno de la última observación, lo que significa que no se sabe si el precio

subirá o bajará. Por eso es fundamental la interpretación que se le dará al resultado obtenido.

Volviendo al problema específico, la decisión a tomar se interpretó de la siguiente manera:

El bonex aumentará de precio para el 7 de Junio con un valor comprendido entre 778,1668 y 780,5550, pero dado que el dólar se muestra creciente, no sólo en este último paso sino en general en la serie completa, y que en la última semana se observa un salto atenuado, es muy probable que el precio se ubique muy cerca del límite superior.

Por lo tanto puede interpretarse el resultado con un valor esperado levemente inferior a los 780,5550.

El 7 de Junio el precio del bonex fue de 780 australes.

Es posible que pueda creerse este resultado un poco casual, o por lo menos que se dude de su continuidad predictiva, pero debido al carácter dinámico del modelo, al ingresar otro nuevo valor del dólar (7 de Junio) de 1015 y actualizar y reajustar el modelo, los resultados fueron los siguientes:

Valores esperados para el precio del bonex en el día 8 de junio, mínimo: 804,0223 y máximo: 806,4106.

Con respecto a la interpretación de resultados, en este tramo más aún se refuerza la idea de ubicarse cerca del límite superior, ya que el salto del dólar es significativo.

El 8 de junio, el bonex se cotizó a 806 australes.

Una consideración especial merece el nivel de retardo con que se trabajó. Si bien los resultados obtenidos realmente son confiables, en base a varias experiencias realizadas para diferentes momentos históricos, se encontró que existen periodos donde el dólar anticipa al

bonex en dos días. Por lo tanto el consejo para este tipo de experiencias es estimar la serie con un retardo, luego con dos, y luego con dos retardos pero saltando un valor de dólar, es decir si el intervalo de dólar abarca de 1 a T, y el de bonex de 3 a T+2, ingresar el valor de dólar en T+2.

Comparando los resultados obtenidos con uno y con dos retardos, podemos detectar si el retardo actual es de dos periodos. El factor de comparación resulta de la tercer alternativa, ya que ésta nos da una tendencia de corto plazo, y podemos comparar que estimación se aproxima más a ella.

Restricciones y utilidades del modelo

Para el caso de este ejemplo, existe una restricción fundamental, que está dada por el nivel de información del total de los operadores. Si todos los operadores o un número significativo de ellos conocen la confiabilidad y el resultado de este sistema, mañana seguramente elevarán o disminuirán el nivel de oferta o demanda de bonex de forma tal que el precio esperado caiga o se eleve. Por eso la restricción principal del modelo es que el monto total de operaciones o la cantidad de operadores que actúan según lo indica el modelo no alteren el nivel de equilibrio esperado. En caso de suceder así una posible utilidad está dada en plantear modelos de retroalimentación de forma tal que cuando todos los operadores ubiquen el precio fuera del equilibrio, ésta situación altere el precio de otro activo, y que los poseedores de un grado más de información trabajen en realidad sobre este último activo. De cualquier forma el modelo queda abierto a nuevas experiencias, algunas de las cuales ya se están realizando, como puede ser el caso de modelos de causalidad simultánea entre más de dos activos financieros.

BIBLIOGRAFIA:

- 1- Pulido San Román, Antonio - Modelos Económicos-, Ed. Pirámide, Madrid, 1983.
- 2- Wallis, K. F. -Some Recent Developments in Applied Econometrics: Dynamic Models and Simultaneous Equation Systems -, Journal of Economic Literature. Vol. VII No 3.
- 3- Moreno Otero, J. M. -Lógica y Limitaciones de la Econometría - ,Ediciones ICE.
- 4- Granger C.W.J. & Newbold - The Time Series Approach to Econometric Model Building - En Sims C. (ed) New Methods of Business Cycle Research Federal Reserve Bank of Minneapolis.
- 5- Fontao, Rafael - Apuntes sobre dinámica de sistemas y simulación por computadora -, inédito, sobre seminario dictado en la Universidad Nacional del Sur, 1987.
- 6- Sims, Cr - Money, Income and Causality - American Economic Review, 1972, Vol 62, pp 540-562
- 7- Zellner, A. - Causality and Econometrics .En A. Zellner: Basic Issues in Econometrics, Univ. of Chicago Press.