



***Evaluación del proceso de cambio comportamental mediante el modelo de Glass, Willson y Gottman***

José Ramón Escudero García y Guillermo Vallejo Seco  
e-mail: jrescudero@correo.cop.es  
Departamento de Psicología. Universidad de Oviedo

**RESUMEN.**

En las Ciencias Sociales y del Comportamiento, es de capital importancia verificar si una intervención convenientemente planificada provoca algún cambio de estado en un sistema social u orgánico medido en términos de una serie temporal. Con el fin de constatar si los patrones de cambio van más allá de lo que sería de esperar por simple azar, la técnica ARIMA, y en particular la adaptación que de la misma realizaron Glass, Willson y Gottman (1975) resulta fundamental. Bajo el enfoque de estos autores, los datos son transformados en series independientes con la finalidad de que justifiquen los requerimientos del modelo lineal general. En el presente trabajo se ilustra la evaluación del impacto mediante el enfoque de Glass et al (1975) pero identificando el modelo de dependencia serial desde los errores de la serie.

**Palabras Clave:** Series temporales, modelos ARIMA, autocorrelación, diseños cuasi-experimentales.

**ABSTRACT.**

In the Social and Behavioral Sciences, it is of capital importance to verify if a conveniently planned intervention causes some change of state in a social or organic system measured in terms of a time series. With the purpose of verifying if the patterns of change go beyond what would be expected by random, the ARIMA technique and, in particular, the adaptation carried out by Glass, Willson and Gottman (1975) is fundamental. Under these authors' approach, the data are turned into independent series to verify the requirements of the general lineal model. The evaluation of the impact by means of the approach of Glass et al. (1975) is illustrated in this work but identifying the model of serial dependence from the errors of the series.

**Key words:** Time series, ARIMA models, autocorrelation, quasi-experimental designs.



## 1.- Introducción.

En la actualidad existe un amplio consenso entre los investigadores interesados por las cuestiones aplicadas en considerar a los diseños de series temporales interrumpidas, no sólo como los más utilizados, sino también entre los más poderosos diseños cuasi-experimentales de cuantos existen. Sin embargo, a nuestro juicio, de su empleo se derivan tres problemas fundamentales que ningún investigador debiera pasar por alto a la hora extraer inferencias. El primero es de carácter estrictamente metodológico y reside en el hecho de que al carecer de un principio básico similar al acto físico de la aleatorización (la correcta aplicación del citado principio implica conocer la probabilidad que tiene cada punto de la serie de asignarse a una u otra condición de tratamiento, dicho de otro modo, que el tratamiento pueda introducirse o retirarse aleatoriamente a lo largo de los diferentes puntos temporales) no existe un adecuado grado de control sobre algunas de las principales amenazas que atentan contra la validez interna y, muy en especial, del factor historia. Consecuentemente, uno puede formular la hipótesis rival de que el efecto del tratamiento puede deberse a la acción de otros eventos que han ocurrido al mismo tiempo y que son de hecho los verdaderos responsables de los cambios observados. Como es obvio, la posibilidad de que esta explicación rival prospere dependerá, en buena medida, de lo cuidadoso que sea el investigador a la hora de verificar la existencia de factores extraños, de lo complejo que sea el diseño que se elija y del número de puntuaciones que efectúe, este último aspecto determina críticamente la habilidad del investigador para captar la fuente de inestabilidad de los datos.

El segundo problema es de carácter estrictamente estadístico. Los procedimientos estadísticos tradicionales, tales como la prueba  $t$  de Student o el análisis de la varianza de Fisher, han jugado un importante papel durante bastantes décadas a la hora de estimar y probar cambios entre las medias de diferentes grupos. Sin embargo, como han resaltado Box y Tiao (1975), estas pruebas solamente son válidas si las observaciones registradas con anterioridad y con posterioridad al evento de interés varían en torno a las medias de las respectivas fases no sólo, normalmente y con varianza constante, sino también independientemente. Ahora bien, por lo general, los datos registrados sucesivamente a lo largo del tiempo carecen de la gracia que habitualmente confiere la aleatorización, y son usualmente dependientes y frecuentemente no estacionarios. Consecuentemente, todos aquellos procedimientos estadísticos, tanto paramétricos como no paramétricos, que requieren para su correcta aplicación el supuesto de independencia no deberían emplearse, pues la presencia de autocorrelación puede distorsionar sustancialmente los resultados de las pruebas que no le tienen en cuenta.

Durante bastantes años se ha operado como si la presencia de dependencia serial encontrada en los diseños de series temporales interrumpidas sólo tuviera implicaciones negativas para los análisis estadísticos convencionales, sobre todo, a raíz de que Scheffé (1959) pusiera de relieve cómo la presencia de correlación serial positiva convertía a la prueba de  $F$  en excesivamente liberal, mientras que la presencia de correlación serial negativa la volvía excesivamente conservadora, pero no para los clásicos análisis visuales, pues existía la creencia de que éstos eran más conservadores que los análisis estadísticos y, por ende, los analistas sólo responden a efectos de gran tamaño. No obstante, Matyas



y Greenwood (1990), tras llevar a cabo varios experimentos y una exhaustiva revisión de la literatura existente en torno a la técnica de análisis visual, presentan datos originales en los que demuestran cómo la técnica del trauma ocular, alias acertadamente empleado por Kazdin (1984), además de no ser fiable, es en exceso liberal. En concreto, los autores citados descubrieron que los analistas visuales reivindicaban en numerosas ocasiones intervenciones significativas cuando de hecho no se habían producido; por el contrario, raramente fallaban en detectar efectos verdaderos, aunque el tamaño de tales efectos fuese relativamente modesto. Más aún, si la autocorrelación está presente en la serie temporal, los problemas con los que usualmente se encuentran los partidarios de los análisis visuales no sólo no permanecen estables, sino que la evidencia existente se ha encargado de poner de manifiesto que, generalmente, éstos se suelen acentuar (Matyas y Greenwood, 1990, 1991). Por consiguiente, este descubrimiento debilita enormemente la postura de aquellos investigadores que abogan por utilizar rutinariamente la técnica visual a la hora de evaluar el impacto ocasionado por una intervención planificada.

A raíz de las críticas surgidas con la aplicación rutinaria de las técnicas visuales y con los intentos de aplicación de las pruebas estadísticas convencionales, a lo largo de las dos últimas décadas han aparecido diversos métodos estadísticos tendientes a paliar los problemas reseñados. Con todo, debemos manifestar que la solución más prometedora y también más practicada en el campo de las ciencias socio-comportamentales ha consistido en la adaptación efectuada por Glass, Willson y Gottman (1975) de la técnica de las series temporales, desarrollada inicialmente por Box y Tiao (1965) y Box y Jenkins (1976). Este enfoque se basa en la adaptación e integración dentro de una teoría comprensiva del análisis espectral utilizado en las ciencias físicas con datos de carácter continuo al análisis de datos de corte longitudinal, pero de carácter discreto. En los trabajos de estos autores, además de presentarse las aportaciones más novedosas en torno al tratamiento estocástico de las series temporales, se propone una metodología que permite llegar a modelar adecuadamente la estructura que sigue la parte sistemática (parte responsable de la dependencia serial) del componente estocástico de la serie bajo estudio. Modelamiento que se encuadra dentro de una clase paramétrica de procesos estocásticos lineales y discretos formados por los denominados *autorregresivos*, *integrados* y *de medias móviles*; procesos que reciben el nombre genérico de modelos *ARIMA*.

El tercero es de carácter epistemológico, ya que se trata del problema de la inducción y de la evaluación de la generalidad. Nos podemos preguntar ¿hasta que punto los resultados experimentales obtenidos con un único sujeto son representativos de los logrados con otros sujetos?. Nosotros coincidimos con Cowles (1989) en que la representatividad es un asunto de carácter conductual más que lógico y, por tanto, es un problema de constatar hechos; es decir, se trataría de añadir vigor al rigor mediante algún programa de replicación sistemática. Pues bien, en vez de efectuar replicas adicionales mediante diseños de series temporales simples podemos utilizar diseños transversales, como por ejemplo, el series temporales interrumpidas con replicaciones intercambiadas.



## 2.- Utilización del modelo ARIMA que siguen los residuales de regresión en el enfoque de Glass et al.

En el modelo de regresión se admite que todos los factores que influyen en una variable dependiente ( $y$ ) pueden dividirse en dos clases: la primera incluye a una variable explicativa, independiente ( $x$ ) que se supone no aleatoria y conocida al observar ( $y$ ); la segunda se refiere a un conjunto de factores cada uno de los cuales influye en pequeña magnitud que se engloba en el concepto de término de error ( $\epsilon$ ).

El modelo de regresión supone las siguientes hipótesis para el término de error:

a) El error tiene esperanza nula:

$$E(\epsilon_i) = 0$$

b) La varianza del error es constante, es decir, es una variable homocedástica:

$$Var(\epsilon_i) = \sigma^2$$

c) El error sigue una distribución normal

d) Los errores son independientes entre sí:

$$E(\epsilon_i \epsilon_j) = 0 \quad i \neq j$$

En la aproximación de Glass, Willson y Gottman (1975), los datos originales son transformados en series independientes con el fin de que cumplan el modelo lineal general eliminando la dependencia serial. La fórmula de transformación de los datos se obtiene a partir del modelo ARIMA que siguen los datos.

Si en realidad lo que nos interesa es remover la dependencia serial de los errores, se podría utilizar el modelo ARIMA que siguen estos últimos, en lugar de estimar el modelo que siguen los datos. Una consecuencia interesante de esta aproximación sería la menor transformación de los datos, con la consiguiente menor pérdida de información, con la misma efectividad en la consecución de la eliminación de la dependencia serial de los errores.

En el siguiente caso se presenta una ejemplificación de este modo de proceder.



### 3.- Una clase de educación infantil incontrolable.

En un aula de educación infantil formada por 17 alumnos de cuatro años de edad, una maestra sustituye a otra con baja por maternidad. A los pocos días de trabajo en el aula acude a la Jefatura de Estudios aduciendo falta de capacidad para hacerse con la clase. Los alumnos se levantan continuamente de sus pupitres, y alborotan continuamente produciendo mucho ruido con lápices, sillas etc.

#### 3.1.- Hipótesis de trabajo.

Se trata de un problema generado por la falta de experiencia de la maestra y la carencia de recursos para dominar la clase.

#### 3.2.- Estrategia de intervención.

Se definen las conductas disruptivas que se van a registrar:

*No estar sentado correctamente.* Abandonar el sitio, levantarse, tener la cabeza debajo de la mesa.

*Alborotar.* Dar voces, hablar a destiempo y sin permiso.

*Hacer mucho ruido.* Golpear con los lápices, los pies, la silla etc.

No se hace distinción entre los tres tipos de conductas. Para el registro se elabora un plano del aula con el nombre de cada alumno y cada vez que realizan una conducta disruptiva se pone una cruz en su recinto.

Fecha: \_\_\_\_\_ Periodo: \_\_\_\_\_

Yoana	Javier
Laura	Borja

Pedro	Vanesa
Cristina	Pablo

Verónica	Jesús
Lara	Gema
Jaime	

Aitor	Alfredo
Graciela	Tatiana

Total de conductas: \_\_\_\_\_



Para la obtención de la línea base, debido a lo apremiante de la situación para la profesora, se establecieron periodos media hora de observación cada día durante nueve días. Debido a actividades del centro durante dos días sólo se realizaron dos periodos de observación, con lo que se obtienen 25 medidas para la línea base.

### **3.3.- Tratamiento.**

1° Se explica a los niños que a partir ahora podrán ganar unos vales que posteriormente podrán canjear por la elección de actividades de tiempo libre, como dibujar, montar un rompecabezas otras actividades diversas de las que disponen en el aula.

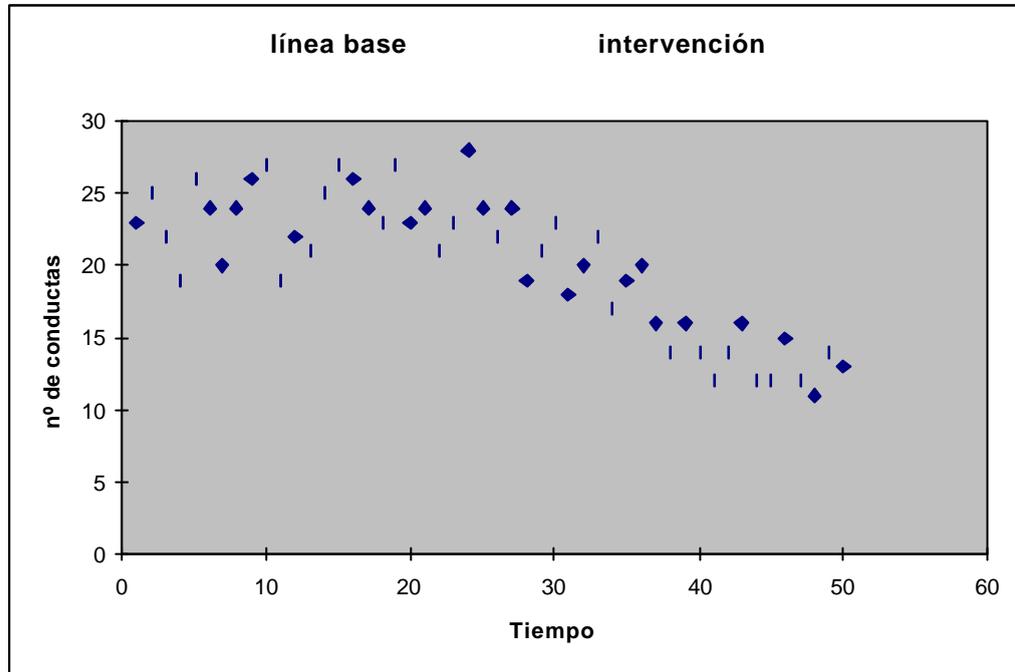
2° Cada vez que se terminaba una tarea se revisaba y se permitía elegir una actividad libre previo pago de un vale.

3° Cuando se reparten los vales, se alaba a los niños que los ganan por estar sentados y no vociferar ni hacer ruidos.

4° Las conductas disruptivas son ignoradas, dentro de lo posible, para evitar su refuerzo

### **3.4.- Tratamiento estadístico.**

La fase de intervención se realizó durante 25 sesiones, para equipararlo a la línea base, pero cada día sólo se realizaba una sesión de registro de media hora. Los datos registrados aparecen en la Figura 1,



**Figura 1.** Serie temporal correspondiente a las conductas controladas del grupo

Para comprobar si el tratamiento ha sido efectivo a nivel estadístico, realizamos un análisis de regresión simple utilizando como variable dependiente, las puntuaciones obtenidas, y como variable independiente la variable tratamiento definida de la siguiente forma: 0,0,...,0 para la línea base y 1,1,...,1, para la fase de intervención.

En la Tabla 1 pueden observarse, las dos variables aludidas anteriormente, así como la pendiente y la ordenada en el origen estimados, los valores predichos y los errores del modelo de regresión.



Y	X	valores predichos	residuales	Y	X	valores predichos	residuales
23	0	23,72	-0,72	22	1	16,64	5,36
25	0	23,72	1,28	24	1	16,64	7,36
22	0	23,72	-1,72	19	1	16,64	2,36
19	0	23,72	-4,72	21	1	16,64	4,36
26	0	23,72	2,28	23	1	16,64	6,36
24	0	23,72	0,28	18	1	16,64	1,36
20	0	23,72	-3,72	20	1	16,64	3,36
24	0	23,72	0,28	22	1	16,64	5,36
26	0	23,72	2,28	17	1	16,64	0,36
27	0	23,72	3,28	19	1	16,64	2,36
19	0	23,72	-4,72	20	1	16,64	3,36
22	0	23,72	-1,72	16	1	16,64	-0,64
21	0	23,72	-2,72	14	1	16,64	-2,64
25	0	23,72	1,28	16	1	16,64	-0,64
27	0	23,72	3,28	14	1	16,64	-2,64
26	0	23,72	2,28	12	1	16,64	-4,64
24	0	23,72	0,28	14	1	16,64	-2,64
23	0	23,72	-0,72	16	1	16,64	-0,64
27	0	23,72	3,28	12	1	16,64	-4,64
23	0	23,72	-0,72	12	1	16,64	-4,64
24	0	23,72	0,28	15	1	16,64	-1,64
21	0	23,72	-2,72	12	1	16,64	-4,64
23	0	23,72	-0,72	11	1	16,64	-5,64
28	0	23,72	4,28	14	1	16,64	-2,64
24	0	23,72	0,28	13	1	16,64	-3,64

**Tabla 1.** Matriz de datos obtenidos en la investigación

En la Figura 2 podemos observar los residuales del modelo de regresión que muestran una clara estructura rectilínea en los datos de la fase de intervención, lo que nos indica que no se trata de ruido blanco, supuesto imprescindible del modelo.

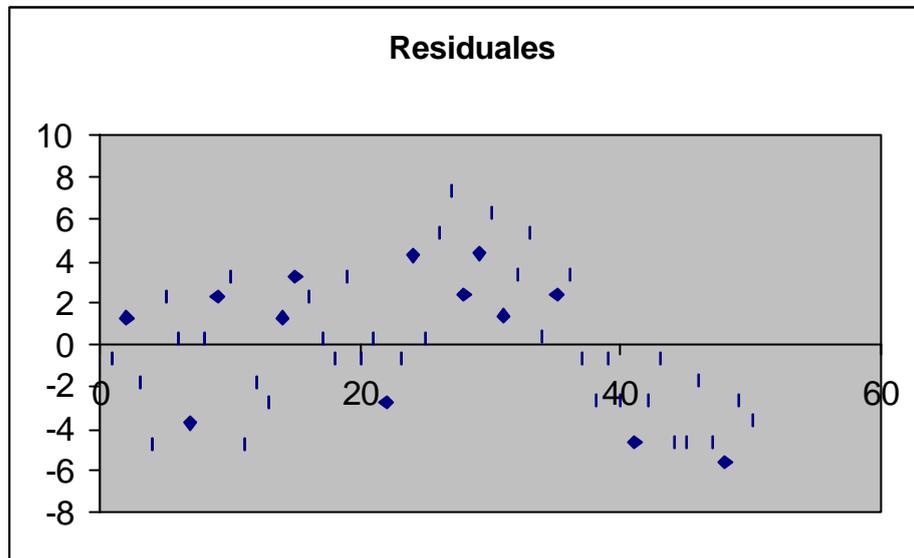


Figura 2. Residuales del modelo sin filtro

Analizando los residuales observamos que están fuertemente correlacionados siguiendo una modelo ARIMA (3) con los siguientes coeficientes autorregresivos  $f_1=0,37$ ,  $f_2=0$  y  $f_3=0,44$

El análisis de regresión que se ha realizado, equivalente a una diferencia de medias de las dos fases, supone hipotetizar un cambio abrupto y permanente del efecto intervención.

---

Esto puede observarse con claridad en la Figura 3 donde se representa la serie original junto con los valores predichos.

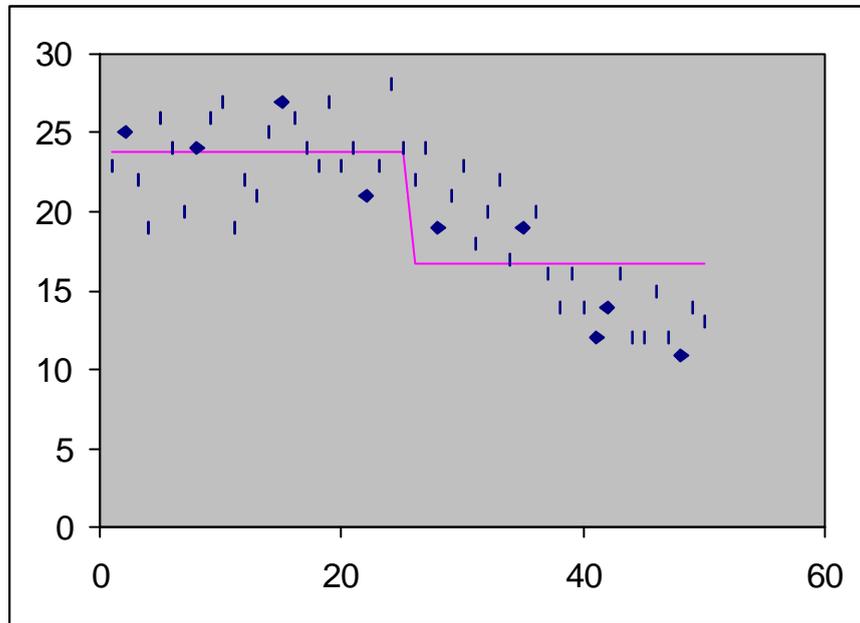
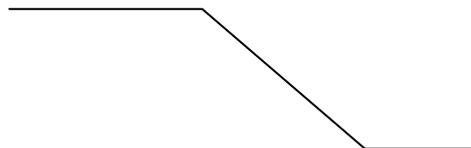


Figura 3. Serie original y valores predichos

A la vista de la Figura 3 se deduce que esta no sería la mejor estrategia, sino que se adaptaría mejor una hipótesis de un efecto gradual y permanente que se estabiliza al final.



En este caso, la variable tratamiento se modeliza de la siguiente forma, 0,0....., para la línea base y 0.05, 0.1, 0.15, ....., 1, 1,.... para la fase de intervención.

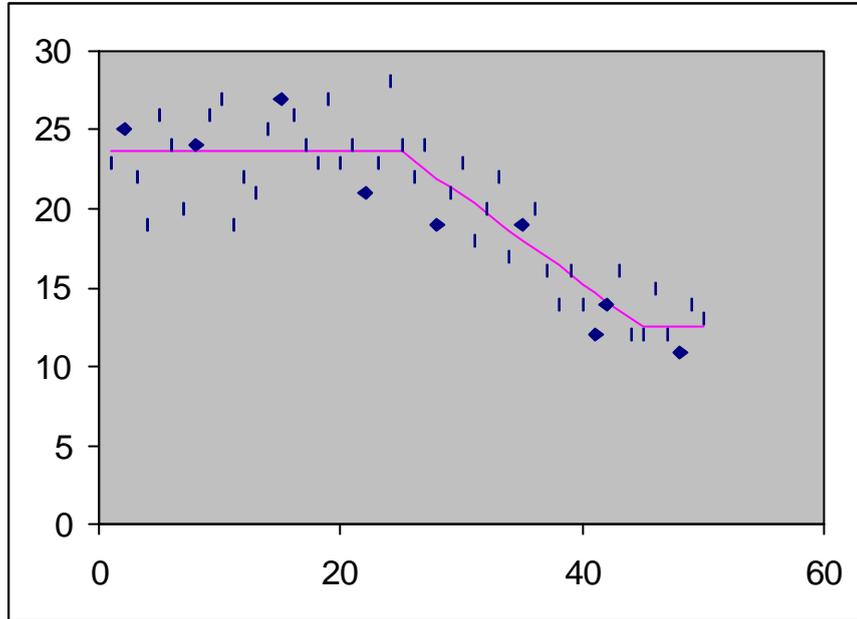
En la Tabla 2 pueden observarse los datos de la regresión realizada con la nueva estrategia.



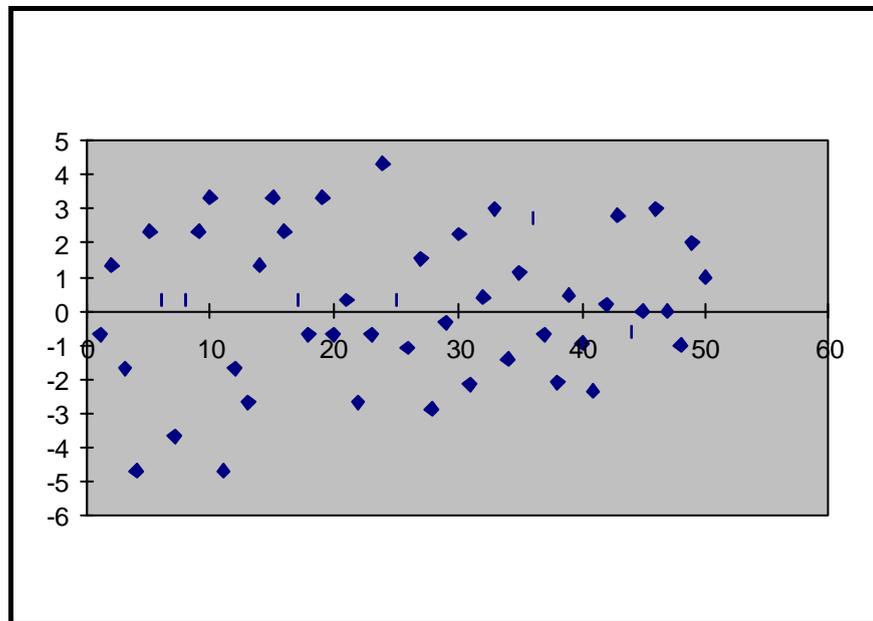
Y	X	valores predichos	residuales	Y	X	valores predichos	residuales
23	0	23,64	-0,64	22	0,05	23,0595	-1,0595
25	0	23,64	1,36	24	0,1	22,479	1,521
22	0	23,64	-1,64	19	0,15	21,8985	-2,8985
19	0	23,64	-4,64	21	0,2	21,318	-0,318
26	0	23,64	2,36	23	0,25	20,7375	2,2625
24	0	23,64	0,36	18	0,3	20,157	-2,157
20	0	23,64	-3,64	20	0,35	19,5765	0,4235
24	0	23,64	0,36	22	0,4	18,996	3,004
26	0	23,64	2,36	17	0,45	18,4155	-1,4155
27	0	23,64	3,36	19	0,5	17,835	1,165
19	0	23,64	-4,64	20	0,55	17,2545	2,7455
22	0	23,64	-1,64	16	0,6	16,674	-0,674
21	0	23,64	-2,64	14	0,65	16,0935	-2,0935
25	0	23,64	1,36	16	0,7	15,513	0,487
27	0	23,64	3,36	14	0,75	14,9325	-0,9325
26	0	23,64	2,36	12	0,8	14,352	-2,352
24	0	23,64	0,36	14	0,85	13,7715	0,2285
23	0	23,64	-0,64	16	0,9	13,191	2,809
27	0	23,64	3,36	12	0,95	12,6105	-0,6105
23	0	23,64	-0,64	12	1	12,03	-0,03
24	0	23,64	0,36	15	1	12,03	2,97
21	0	23,64	-2,64	12	1	12,03	-0,03
23	0	23,64	-0,64	11	1	12,03	-1,03
28	0	23,64	4,36	14	1	12,03	1,97
24	0	23,64	0,36	13	1	12,03	0,97
<b>PENDIENTE</b>		<b>-11,1858887</b>	<b>INTERSECCIÓN</b>	<b>23,6476255</b>			

**Tabla 2.** Matriz de datos para el input modelado de forma gradual.

En la Figura 4 se representan los datos originales y los valores predichos y en la Figura 5 los residuales del nuevo modelo de regresión



**Figura 4.** Puntuaciones originales y valores predichos sin filtrar con input gradual



**Figura 5.** Residuales de la serie sin filtrar utilizando input gradual

Como podemos observar ha desaparecido la estructura rectilínea que tenían los datos en la fase de intervención y a simple vista semejan ruido blanco.



Analizamos los residuales mediante el paquete estadístico BMDP (2T) y estimamos las funciones de autocorrelación y autocorrelación parcial recogidos en el Cuadro 1.

FAC		-1.0	-0.8	-0.6	-0.4	-0.2	0.0	0.2	0.4	0.6	0.8	1.0	
LAG	CORR.	+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+											
							I						
1	-0.055					+	XI					+	
2	-0.353						XX+XXXXXXXXI					+	
3	0.130					+	IXXX					+	
4	-0.026					+	XI					+	
5	-0.125					+	XXXI					+	
6	0.061					+	IXX					+	
7	0.014					+	I					+	
8	-0.140					+	XXXXI					+	
9	0.166					+	IXXXX					+	
10	0.149					+	IXXXX					+	
11	-0.054					+	XI					+	
12	-0.210					+	XXXXXI					+	

FACP		-1.0	-0.8	-0.6	-0.4	-0.2	0.0	0.2	0.4	0.6	0.8	1.0	
LAG	CORR.	+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+											
							I						
1	-0.055					+	XI					+	
2	-0.358						XX+XXXXXXXXI					+	
3	0.096					+	IXX					+	
4	-0.161					+	XXXXI					+	
5	-0.060					+	XI					+	
6	-0.028					+	XI					+	
7	-0.040					+	XI					+	
8	-0.137					+	XXXI					+	
9	0.152					+	IXXXX					+	
10	0.074					+	IXX					+	
11	0.115					+	IXXX					+	
12	-0.221						+XXXXXI					+	

**Cuadro 1.** Funciones de autocorrelación y autocorrelación parcial

Consecuentemente con la previsión hecha a partir de la representación gráfica de los residuales, vemos que existe cierto grado de autocorrelación. Solamente el segundo coeficiente de autocorrelación y de autocorrelación parcial es significativamente distinto de cero. Postulamos un proceso AR(2) con el primer coeficiente autorregresivo ( $f_1$ ) igual a cero.



La estimación del modelo mediante el BMDP aparece en el Cuadro 2.

PARAMETRO	VARIABLE	TIPO	FACTOR	ORDEN	ESTIMACION	ERR. ST.	RAZON-T
1	AZUCAR	AR	1	2	-0.3611	0.1379	-2.62
SUMA DE CUADRADOS RESIDUAL =				199.146133			
GRADOS DE LIBERTAD =				47			
MEDIA DE CUADRADOS RESIDUAL=				4.237152			

**Cuadro 2.** Estimación del modelo

FAC		-1.0	-0.8	-0.6	-0.4	-0.2	0.0	0.2	0.4	0.6	0.8	1.0
LAG	CORR.	+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
							I					
1	-0.031					+	XI					+
2	-0.044					+	XI					+
3	0.062					+	IXX					+
4	-0.140					+	XXXXI					+
5	-0.099					+	XXI					+
6	-0.015					+	I					+
7	0.032					+	IX					+
8	-0.116					+	XXXI					+
9	0.234					+	IXXXXXX+					
10	0.045					+	IX					+
11	0.003					+	I					+
12	-0.198					+	XXXXXI					+
FACP		-1.0	-0.8	-0.6	-0.4	-0.2	0.0	0.2	0.4	0.6	0.8	1.0
LAG	CORR.	+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
							I					
1	-0.031					+	XI					+
2	-0.045					+	XI					+
3	0.059					+	IX					+
4	-0.139					+	XXXI					+
5	-0.103					+	XXXI					+
6	-0.039					+	XI					+
7	0.038					+	IX					+
8	-0.130					+	XXXI					+
9	0.215					+	IXXXXX					+
10	0.024					+	IX					+
11	0.050					+	IX					+
12	-0.276						XXXXXXXXI					+

**Cuadro 3.** Funciones de autocorrelación y autocorrelación parcial



Como vemos las funciones de autocorrelación y autocorrelación parcial del modelo ARIMA estimado tienen todos sus valores dentro de las bandas de no significación.

Los residuales del modelo de regresión siguen, por tanto, el siguiente modelo:

$$X_t = -0.36 X_{t-2} + e_t$$

A continuación filtramos las variables de la regresión  $Y(23,25,22,\dots,14,13)$  y la variable  $X(0,0,0,\dots,1,1,1)$  mediante las expresiones:

$$Y_t^* = Y_t + 0,36Y_{t-2} \quad X_t^* = X_t + 0,36X_{t-2}$$

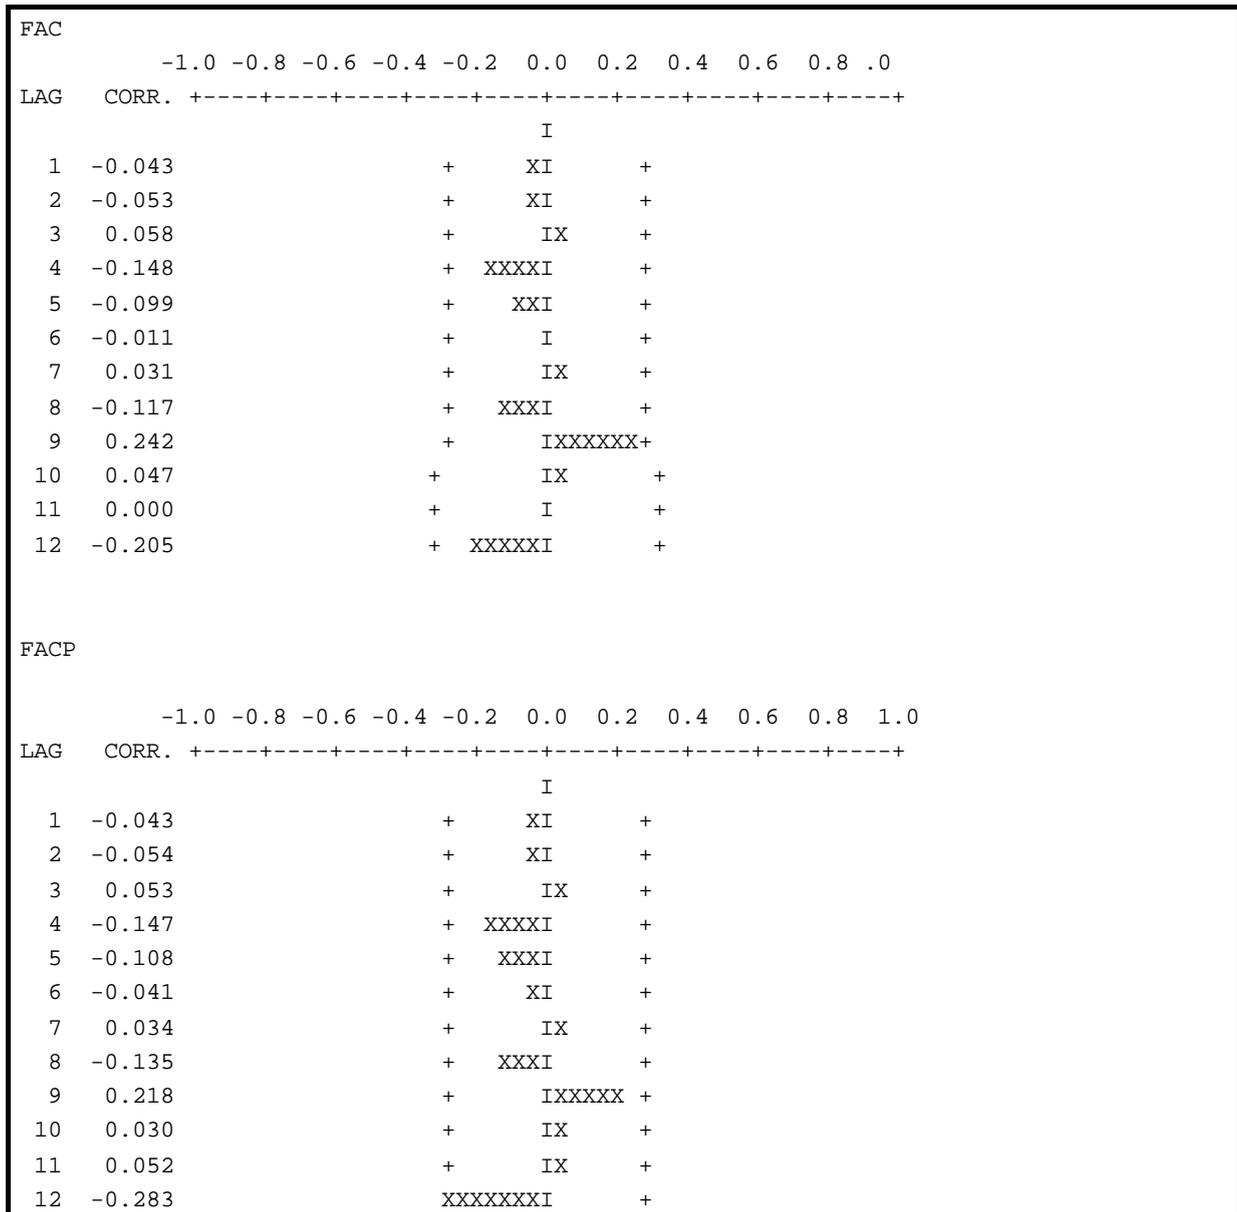
Finalmente realizamos la regresión con las variables filtradas.

Y(filtrada)	X(filtrada)	residuales	Y(filtrada)	X(filtrada)	residuales
23			32,08	0,05	0,434
25			32,64	0,1	1,558
30,28	0	-1,93	26,92	0,168	-3,39496
28	0	-4,21	29,64	0,236	0,09208
33,92	0	1,71	29,84	0,304	1,05912
30,84	0	-1,37	25,56	0,372	-2,45384
29,36	0	-2,85	28,28	0,44	1,0332
32,64	0	0,43	28,48	0,508	2,00024
33,2	0	0,99	24,2	0,576	-1,51272
35,64	0	3,43	26,92	0,644	1,97432
28,36	0	-3,85	26,12	0,712	1,94136
31,72	0	-0,49	22,84	0,78	-0,5716
27,84	0	-4,37	21,2	0,848	-1,44456
32,92	0	0,71	21,76	0,916	-0,11752
34,56	0	2,35	19,04	0,984	-2,07048
35	0	2,79	17,76	1,052	-2,58344
33,72	0	1,51	19,04	1,12	-0,5364
32,36	0	0,15	20,32	1,188	1,51064
35,64	0	3,43	17,04	1,256	-1,00232
31,28	0	-0,93	17,76	1,324	0,48472
33,72	0	1,51	19,32	1,342	2,24776
29,28	0	-2,93	16,32	1,36	-0,5492
31,64	0	-0,57	16,4	1,36	-0,4692
35,56	0	3,35	18,32	1,36	1,4508
32,28	0	0,07	16,96	1,36	0,0908

Tabla 4.



La ecuación de regresión sería  $Y = -11,27613 X + 32,208978$



**Cuadro 4.** Funciones de autocorrelación y autocorrelación parcial de los residuales

Las funciones de autocorrelación y autocorrelación parcial de los residuales tienen todos sus valores dentro de las bandas de no significación



Una vez comprobado que se cumplen las hipótesis del modelo podemos pasar a realizar la prueba de significación del efecto intervención.

Se aplica la prueba **t** a ambos estimadores mediante los estimadores  $\frac{\hat{L} - L}{S_E \sqrt{c^{jj}}} \approx t_{N-2}$  y  $\frac{\hat{I} - I}{S_E \sqrt{c^{jj}}} \approx t_{N-2}$  donde  $S_E$  es la raíz cuadrada de la varianza residual y  $c^{jj}$  es el j-ésimo elemento de la diagonal de la matriz  $(X^*{}' X^*)^{-1}$ .

Para el primer parámetro  $t = -13,32$  y para el segundo el parámetro  $t = 18,50$ . Como  $t_{(>30,01)} = 2,57$  se acepta la significatividad de ambos parámetros

#### 4.- Conclusión.

En la aproximación de Glass et al. las series originales son transformadas con el objetivo de que cumplan los requisitos del modelo lineal general. Toda transformación lleva consigo la pérdida de información, por una parte la información no deseada, pero por otra parte puede perderse información pertinente. En el presente trabajo se ha ilustrado un modo de proceder para reducir en lo posible la pérdida de información buscando la menor transformación posible de los datos para hacer que cumplan con los requisitos del modelo lineal general.

#### 5.- Referencias.

- BMDP Statistical Software (1990). *Health Sciences Computing Facility*. Department of Biomathematics, Los Ángeles: University of California Press.
- Box, G.E.P. y Tao, G.C. (1975). Intervention analysis with applications to economic and environmental problems. *Journal of American Statistical Association*, 70, 70-79.
- Box, G.E.P. y Jenkins, G.M. (1976). *Time Series Analysis. Forecasting and Control*. Revised Edition. Oakland. California: Holden Day.



- Box, G.E.P. y Tiao, G.C. (1965). A change in level of nonstationary time series. *Biometrika*, 52, 181-192.
- Cowles, M. (1989). *Statistic in Psychology. An Historical Perspective*. Hillsdale, New Jersey: LEA.
- Glass, G.V., Willson, V.L. y Gottman, J.M. (1975). *Design and analysis of time-series experiments*. Boulder, CO: Colorado Associated University Press.
- Kazdin, A.E. (1984). Statistical analysis for single-case experimental designs. En D. Barlow y H. Hersen (Eds.): *Single-Case Experimental Designs: Strategies for Studying Behavior Change*. 2ª ed. pp. 265-316. Nueva York: Pergamon Press.
- Matyas, T.A. y Greenwood, K.M. (1990). Visual analysis of single-case time-series: Effects of variability, serial dependence, and magnitude of intervention effect. *Journal of Applied Behavior Analysis*, 23, 341-351.
- Matyas, T.A. y Greenwood, K.M. (1991). Problems in the estimation of autocorrelation in brief time series and some implications for behavioral data. *Behavioral Assessment*, 13, 137-157.
- Scheffe, H. (1959). *The Analysis of Variance*. New York: Willey.