

Tutorial para la estimación de Modelos ARMA

Julio César Alonso C.

No. 24

Septiembre de 2010

APUNTES DE ECONOMÍA

ISSN 1794-029X

No. 24, Septiembre de 2010

Editor

Julio César Alonso C.

jcalonso@icesi.edu.co

Luis Eduardo Jaramillo

Vanessa Ospina López

Asistentes de Edición

Gestión Editorial

Departamento de Economía - Universidad Icesi

Apuntes de Economía es una publicación del Departamento de Economía de la Universidad Icesi, cuya finalidad es divulgar las notas de clase de los docentes y brindar material didáctico para la instrucción en el área económica a diferentes niveles. El contenido de esta publicación es responsabilidad absoluta del autor.

www.icesi.edu.co

Tel: 5552334 ext: 8398. Fax: 5551441

Calle 18 # 122-135 Cali, Valle del Cauca, Colombia

TUTORIAL PARA LA ESTIMACIÓN DE MODELOS ARMA EMPLEANDO EASYREG

Julio Cesar Alonso C¹.

Septiembre de 2010

Resumen

Este documento de carácter pedagógico, discute la estimación de modelos ARMA(p,q) y muestra paso a paso cómo efectuar dicha prueba empleando el paquete estadístico EasyReg International. Este documento está diseñado para estudiantes de un curso introductorio al análisis de series de tiempo. Por su simplicidad, puede ser útil para economistas que estén trabajando con series de tiempo y quieran empezar el estudio de los modelos ARMA. Se supone un conocimiento previo de los conceptos básicos de series de tiempo.

Palabras Clave: EasyReg, ARMA, test de cointegración de Johansen, Cointegración.

Abstract

This tutorial presents a brief introduction to the estimation of ARMA(p,q) models using the statistical package EasyReg International. This document is designed for students in an introductory course on time series analysis. Thanks to its simplicity, the tutorial can be useful for economists who are working with time series and want to begin the study of ARMA models. This tutorial assumes a prior knowledge of the basic concepts of time series.

Keywords: EasyReg, ARMA, Johansen cointegration test, Cointegration

¹ Profesor del Departamento de Economía y Director del Centro de Investigación en Economía y Finanzas (CIENFI) de la Universidad Icesi, jcalonso@icesi.edu.co.

Al terminar este tutorial usted estará en capacidad de:

- Encontrar y hacer inferencia sobre las funciones de Autocorrelación y Autocorrelación parcial de una serie.
- Estimar un modelo ARMA(p,q)

Para este tutorial nos basaremos en el ejemplo presentado por Enders (1995) en la sección 10, capítulo 2 (Página106). En este ejemplo Enders, estudia las propiedades del índice de precios al por mayor de los Estados Unidos (Wholesale Price Index – WPI) para el período 1960:I – 1992:II.

Los datos para este ejercicio serán encontrados en la página Web del curso. Antes de iniciar, cargue los datos en EasyReg International.

1 Gráficos de las series y Transformación de las variables.

El primer paso en el estudio de las características de una serie de tiempo es graficar la serie contra el tiempo. Esto nos permite observar de forma intuitiva si los supuestos de estacionariedad se cumplen o no, v.g., media y varianza constantes en el tiempo y la covarianza no depende del tiempo. Por lo menos, las dos primeras características si pueden ser chequeadas visualmente a partir de un gráfico.


Para graficar la serie de tiempo, emplee la opción “Menu/Data Analysis/Plot time series”.



Como en este momento sólo contamos con una serie (*WPI*), EasyReg la preseleccionará automáticamente. Haga clic en el botón “Continue”.

En la siguiente ventana, tendrá la opción de seleccionar una submuestra ; en este caso emplearemos toda la muestra, así que haga clic en el botón “No” e inmediatamente haga clic en el botón “Continue”². Observará el siguiente gráfico.

Gráfico 1-1. Índice de Precio al por Mayor de los Estados Unidos. (WPI) (1985=100)



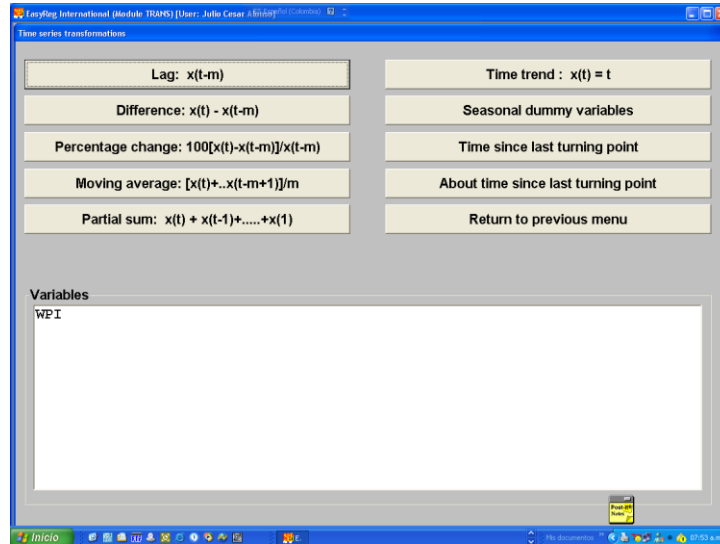
Recuerde que siempre existe una opción de grabar el gráfico dibujado por EasyReg si se hace clic en el botón “Save Picture”. El dibujo queda grabado como un archivo .bmp en el folder *C:\Archivos de Programas\EasyReg International\EASYREG.DAT* o en su defecto en el folder donde usted halla inicializado EasyReg. Los gráficos se pueden consultar rápidamente por el menú “Menu/Output/View bitmap files”. Haga clic en el botón “Done” y luego en “Cancel” para regresar a la ventana inicial.

Como se puede observar en el Gráfico 1-1, la serie tiene una tendencia positiva a crecer, reflejando una media creciente, por tanto no cumple las propiedades de una

² En caso de seleccionar más de una serie para ser graficada, EasyReg ofrecerá la opción de graficar las variables estandarizadas (Standardize variables), o sin estandarizar. Si las variables no están medidas en la misma escala, por lo general, es mejor hacer el gráfico en escala estandarizada. También se puede elegir si queremos tener todas las series en el mismo gráfico o cada una en uno diferente. Habitualmente se observan mejor las relaciones con todas en uno. Si ese es el caso, escogemos “All charts in one box”. También se nos dan varias opciones para el tipo de líneas.

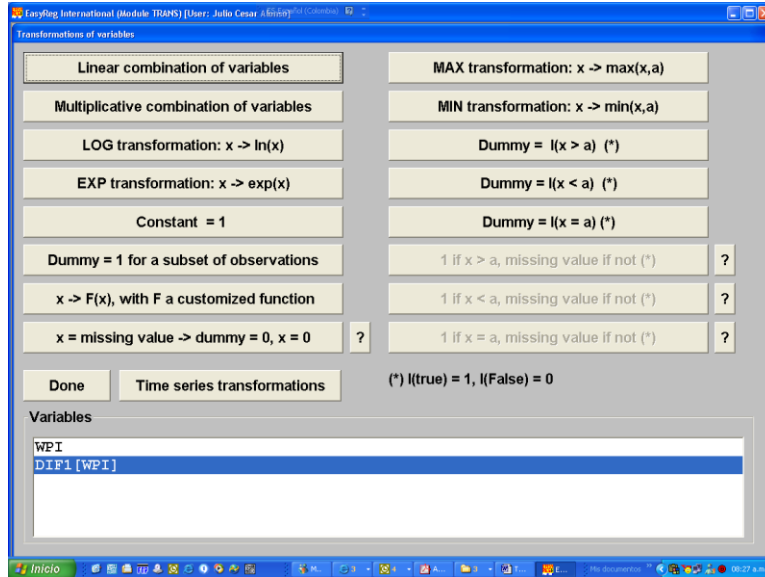
serie estacionaria. Debido a lo anterior, debemos transformar la variable hasta obtener una serie que, por lo menos gráficamente, parezca una serie estacionaria.

Para esto, diferenciamos la serie una vez³. Es decir, creemos la serie $\Delta WPI_t = WPI_t - WPI_{t-1}$. Para crear esta nueva variable, haga clic en “Menu / Input / Transform Variables”. En la siguiente ventana haga clic en el botón “Time Series Transformation”. Observará la siguiente ventana.



En esta ventana EasyReg proporciona la opción de diferentes transformaciones para las series de tiempo: diferenciación, sumas parciales, promedios móviles, cambios porcentuales, etc. Para generar la nueva serie, $\Delta WPI_t = WPI_t - WPI_{t-1} = (1-L)WPI_t$, haga clic en el botón “Difference: $x(t) - x(t-m)$ ”. Con el botón “m-up” y “m-down”, puede seleccionar el orden de diferenciación. Dado que sólo necesitamos las primeras diferencias, haga clic de nuevo en el botón “Difference: $x(t) - x(t-m)$ ”. Como se mencionó anteriormente, sólo tenemos una variable en la base de datos de EasyReg por tanto la serie WPI será preseleccionada. Haga clic en “Continue” y nuevamente en “OK”. La serie ha sido creada. Observará la siguiente ventana.


³ En clase discutimos que está no es la mejor opción, primero deberíamos probar que en efecto la serie contiene una raíz unitaria o se trata de una serie estacionaria alrededor de una tendencia. Aquí, obviaremos este paso. Más adelante aprenderemos como hacer esto. Es importante anotar que si se tratase de una serie estacionaria alrededor de una tendencia, diferenciar la serie no generaría un proceso estacionario.



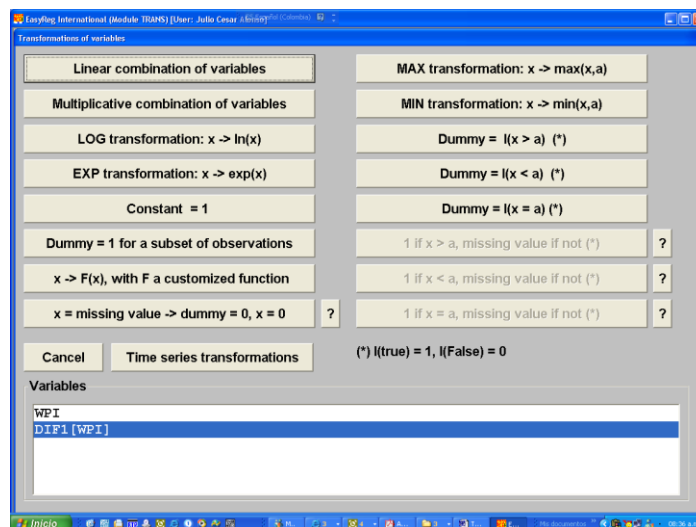
Haga clic en “Done” para regresar a la ventana inicial.

Ahora, veamos el comportamiento de las primeras diferencias del WPI (ΔWPI_t). Con tal fin, grafique esta nueva serie contra el tiempo, siguiendo los pasos descritos arriba. Obtendrá un gráfico como el Gráfico 1-2. En este, se puede observar que si bien la serie parece tener una media constante, la variabilidad de la serie tiende a aumentar con el tiempo. Por tanto, se esperaría que esta serie no sea estacionaria. Debemos entonces considerar otro tipo de transformación de la serie original, en especial, una transformación que establezca la variabilidad.

Gráfico 1-2. Primeras Diferencias del Índice de Precio al por Mayor de los Estados Unidos. (ΔWPI_t)




Una práctica muy común para disminuir la varianza de una serie es considerar el logaritmo de la serie o en su defecto, las primeras diferencias del logaritmo de la serie⁴. Para generar esta nueva serie, seleccione “Menu / Input / Transform Variables”. Observará la siguiente ventana.



⁴ Esta diferencia es aproximadamente igual al cambio porcentual en la serie original. Es decir, $\Delta\%WPI_t = \ln(WPI_t) - \ln(WPI_{t-1})$.

Ahora, haga clic en el botón “LOG transformation: $x \rightarrow \ln(x)$ ” y seleccione la serie WPI, haga clic en “Continue” y nuevamente en “Continue”. La serie ha sido creada. Puede constatar que esta serie no presenta una media constante, por tanto, es necesario transformar la serie de tal forma que tengamos una serie aparentemente estacionaria. Genere la serie $\Delta \ln(WPI_t) = \ln(WPI_t) - \ln(WPI_{t-1})$ y gráfiquela. Obtendrá la siguiente gráfica.

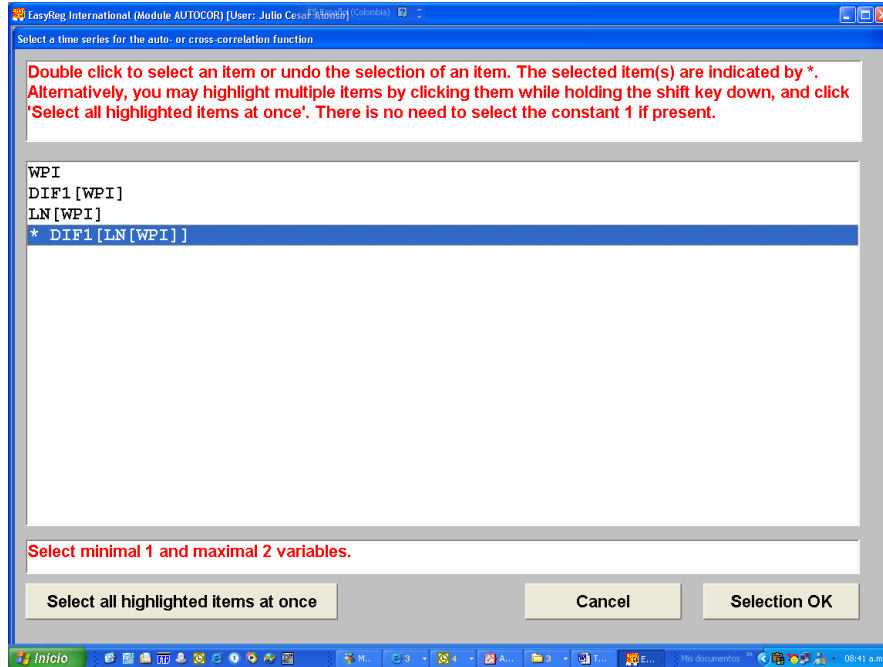
Gráfico 1-3 Primeras Diferencias del Logaritmo del Índice de Precio al por Mayor de los Estados Unidos. ($\Delta \ln(WPI_t) = \ln(WPI_t) - \ln(WPI_{t-1})$)



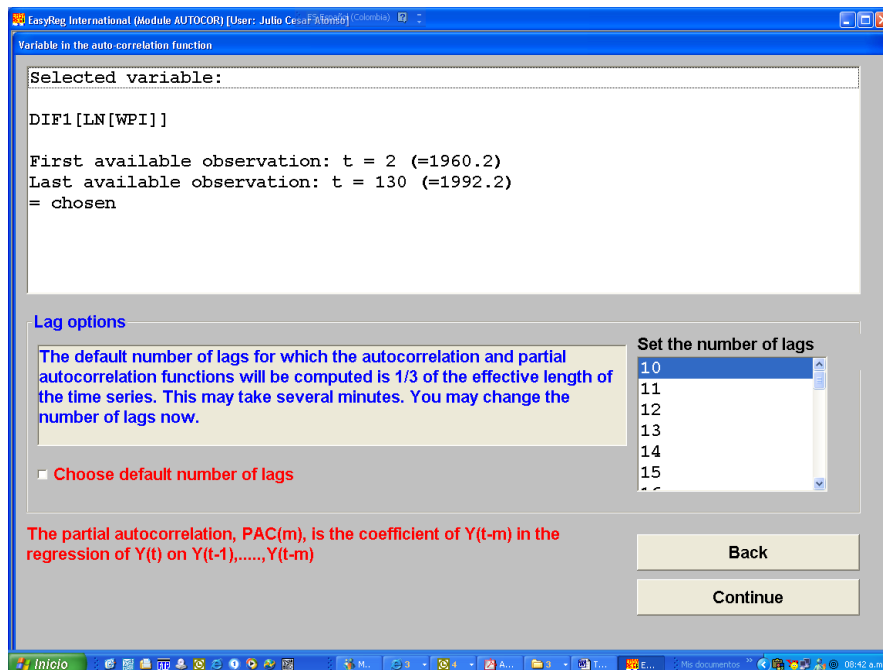
Note que de acuerdo al Gráfico 1-3 la serie parece tener una varianza constante y la media más o menos constante. Esta serie ya puede ser analizada para encontrar el correspondiente proceso generador de los datos.

2 Estimación de la Función de Autocorrelación y Autocorrelación Parcial.

Para determinar qué tipo de proceso ha generado la muestra que estamos analizando, estimemos la función de autocorrelación para esta muestra. Para esto, escoja “Menu / Data analysis / Auto/Cross correlations” y posteriormente escójala serie DIF1(LN(WPI)) haciendo doble clic sobre ella.

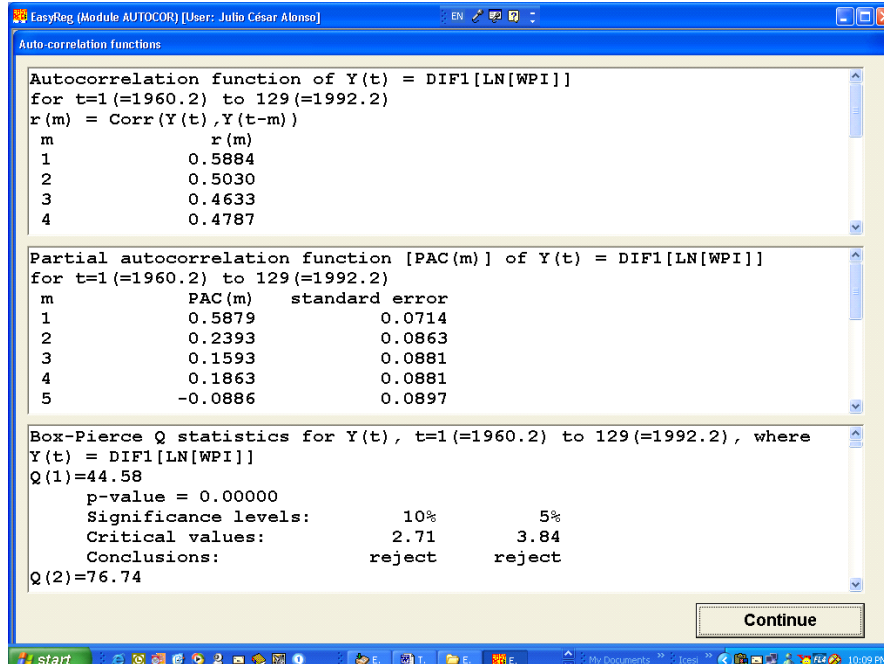


Ahora haga clic en el botón “Selection OK”, posteriormente en el botón “No” y en “Continue”. Observará la siguiente ventana.



En esta ventana, usted tendrá que escoger el número de rezagos para los cuales quiere estimar las autocorrelaciones y autocorrelaciones parciales. Pueden escoger el número

de rezagos que desee. En general, 15 rezagos son suficientes. Seleccione 15 en la ventana de la derecha y haga clic en el botón “Continue”. Observará la siguiente ventana.



En el primer panel encontrará las estimaciones para la función de autocorrelación. Recuerde que para probar la $H_0 : \rho_s = 0$ versus la hipótesis $H_A : \rho_s \neq 0$ a un nivel de confianza del 95%, se puede comparar el valor absoluto del valor estimado de la respectiva autocorrelación estimada con $\frac{2}{\sqrt{T}} \sqrt{1 + 2 \sum_{j=1}^{s-1} r_j^2}$. Así, si el valor absoluto de r_s

es mayor que $\frac{2}{\sqrt{T}} \sqrt{1 + 2 \sum_{j=1}^{s-1} r_j^2}$ podremos rechazar la $H_0 : \rho_s = 0$ ⁵. En este caso, para la

primera autocorrelación tenemos, $\frac{2}{\sqrt{T}} = \frac{2}{\sqrt{129}} = 0.176$ valor inferior a la correlación

muestral. Así, no se puede rechazar la hipótesis nula que la primera autocorrelación es cero. Los resultados para las correspondientes hipótesis nulas de los primeros 15 rezagos se reportan en Tabla 2-1. Note que empleando esta prueba individual,

⁵ Por ejemplo, si se desea determinar si $H_0 : \rho_1 = 0$ entonces la regla de decisión será $|r_s| > \frac{2}{\sqrt{T}}$

únicamente las correlaciones a partir del séptimo rezago no son individualmente significativas.

Tabla 2-1 Prueba de significancia individual para las autocorrelaciones y autocorrelación parcial del proceso $\Delta \ln(WPI_t)$


Rezago (s)	Autocorrelación			Autocorrelación Parcial		
	r_s	valor crítico (95%)	Decisión	r^*_s	valor crítico (95%)	Decisión
1	0.588	0.176	Rechazar Ho	0.588	0.143	Rechazar Ho
2	0.503	0.229	Rechazar Ho	0.239	0.173	Rechazar Ho
3	0.463	0.261	Rechazar Ho	0.159	0.176	No rechazar Ho
4	0.479	0.285	Rechazar Ho	0.186	0.176	Rechazar Ho
5	0.343	0.309	Rechazar Ho	-0.089	0.179	No rechazar Ho
6	0.363	0.321	Rechazar Ho	0.098	0.182	No rechazar Ho
7	0.217	0.333	No rechazar Ho	-0.201	0.189	Rechazar Ho
8	0.153	0.338	No rechazar Ho	-0.117	0.192	No rechazar Ho
9	0.107	0.340	No rechazar Ho	-0.016	0.195	No rechazar Ho
10	0.127	0.341	No rechazar Ho	0.045	0.197	No rechazar Ho
11	0.052	0.342	No rechazar Ho	0.010	0.200	No rechazar Ho
12	0.077	0.343	No rechazar Ho	0.109	0.200	No rechazar Ho
13	0.100	0.343	No rechazar Ho	0.145	0.201	No rechazar Ho
14	0.118	0.344	No rechazar Ho	0.052	0.203	No rechazar Ho
15	0.090	0.345	No rechazar Ho	-0.013	0.205	No rechazar Ho

En el segundo panel encontrará las estimaciones de la función de autocorrelación parcial. En este caso para comprobar si estas autocorrelaciones son significativamente diferentes de cero al 95% de confianza, se puede comparar el valor absoluto del valor estimado con 2 veces la correspondiente desviación estándar. Esta prueba se discutirá gráficamente más adelante y se reporta en la Tabla 2-1.

En el tercer panel encontrará inicialmente el estadístico de la prueba de Box-Pierce y después el estadístico de la prueba de Ljung-Box. Note que si consideramos las autocorrelaciones para los primeros 15 rezagos, se puede rechazar la hipótesis nula que todas las autocorrelaciones son simultáneamente iguales a cero (¿Por qué?). Haga clic en el botón “Continue”.


A continuación observará el gráfico de la función de autocorrelación estimada. Esta es reportada en el Gráfico 2-1. Note que a partir del rezago 7 estas autocorrelaciones están relativamente cercanas a cero, como lo constatamos anteriormente.

Gráfico 2-1 Función de Autocorrelación Estimada para $\Delta \ln(WPI_t)$



Haga nuevamente clic en el botón “Continue” y observará la función de autocorrelación parcial estimada. (Ver Gráfico 2-2). Note que este gráfico incluye intervalos de confianza de una (90% de confianza) y dos desviaciones estándar (95% de confianza) para las autocorrelaciones parciales estimadas. Recuerde que si la banda incluye cero (como en el caso de casi todos los rezagos a excepción de los rezagos 1, 2, 4 y 7) entonces no se puede rechazar la hipótesis nula que la correspondiente autocorrelación parcial es cero (Obviamente este resultado es igual al obtenido en la Tabla 2-1).

Gráfico 2-2 Función de Autocorrelación Parcial Estimada para $\Delta \ln(WPI_t)$



Como lo anota Enders (1995) se puede observar que:

- Tanto la ACF como la PACF estimadas convergen rápidamente a cero
- Estas funciones estimadas no corresponden a lo esperado teóricamente para procesos MA(q) y AR(1)
- La PACF estimada puede sugerir un proceso AR(2)
- La ACF estimada sugiere un salto en el rezago 4 y la PACF estimada presenta un pequeño pico en este mismo rezago. Esto puede ser porque estamos empleando datos trimestrales que probablemente presenten un comportamiento estacional en el rezago 4.

Estas observaciones sugieren un proceso generador de datos ARMA(1,1) o AR(2). Como se discutió en clase, una buena estrategia es estimar diferentes modelos relativamente parecidos y compararlos. Por tanto estimaremos los siguientes modelos ARMA(1,1), AR(1), AR(2), ARMA(1,2) y ARMA(2,2).

3 Selección del modelo ARMA(p,q) por medio de criterios de información

EasyReg puede comparar diferentes modelos ARMA(p,q) de acuerdo a los criterios de información de Akaike, Hannan-Quinn y Schwarz. Como lo discutimos en clase estos criterios de información se basan en el valor de la función de máxima verosimilitud ($L_T(k)$) y cada uno penaliza de forma diferente la cantidad de parámetros empleados en los modelos $k(= p + q)$. En este caso tenemos que:

$$Akaike = -2 \frac{\ln(L_T(k))}{T} + 2 \frac{k}{T} \quad (1)$$


$$Hanna - Quinn = -2 \frac{\ln(L_T(k))}{T} + 2 \frac{k \ln(\ln(T))}{T} \quad (2)$$

$$Schwarz = -2 \frac{\ln(L_T(k))}{T} + 2 \frac{k \ln(T)}{T} \quad (3)$$

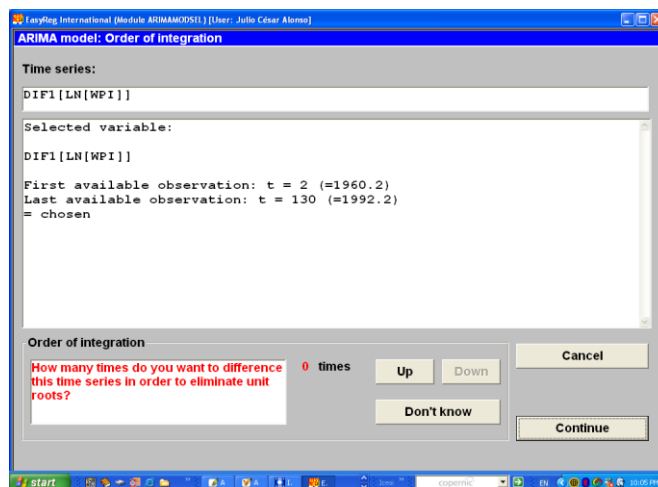
Así, el orden del modelo ARMA(p,q) puede ser determinado minimizando estos criterios. Antes de continuar, es importante anotar que es un hecho bien documentado que el criterio de Akaike tiende a sobre estimar el número de parámetros del modelo ARMA.

Retomando, nuestro objetivo será determinar el mejor modelo que describa los datos entre los modelos ARMA(1,1), AR(1), AR(2), ARMA(1,2) y ARMA(2,2). Así, deberíamos comparar los correspondientes valores de los criterios de información para estos modelos.

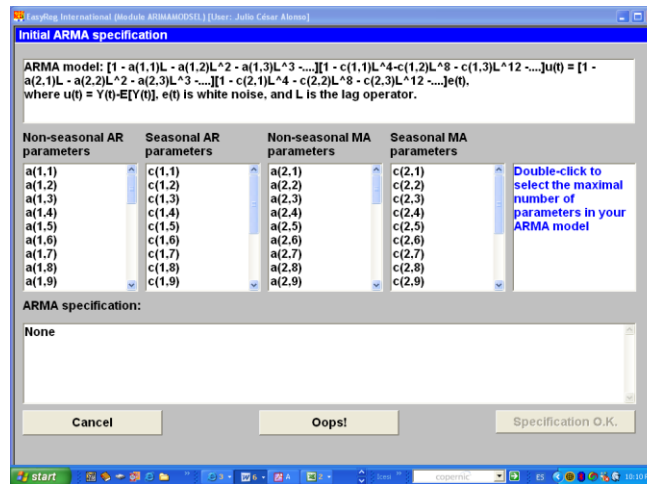
Haga clic en la opción “Menu/Single equation models/ARIMA model selection via information criteria”



En la siguiente ventana, haga doble clic en la serie DIF1(LN(WPI)) para seleccionar esta variable y posteriormente clic en el botón “Selection OK”. Ahora, oprima los botones “No” y “Continue”. Observará la siguiente ventana.



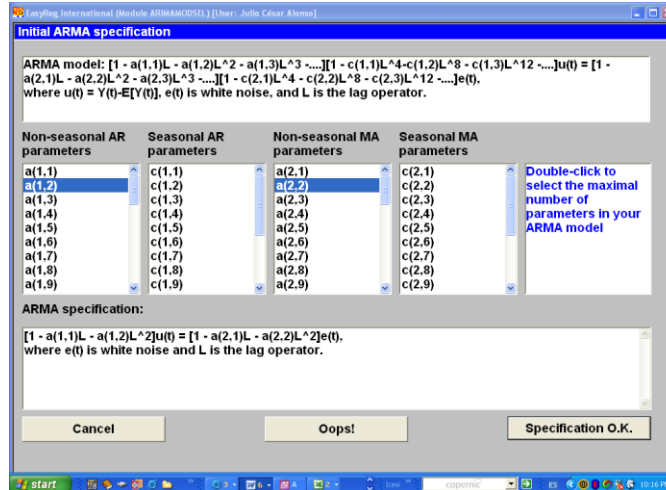
Esta ventana le permite determinar el orden de integración de la serie. Dado que hemos seleccionado la serie diferenciada, no necesitamos diferenciar más la serie. Así, haga clic en “Continue”, observará una ventana en la que puede determinar si desea un modelo con intercepto, tendencia (time trend) y/o dummies estacionales (Seasonal dummies). En este caso, incluiremos un intercepto, opción que está preestablecida. Por tanto, haga clic en “Continue”. Observará la siguiente ventana.



En esta ventana usted debe escoger el orden del proceso autoregresivo y de promedio móvil más grande que se va a comparar. Es decir, el máximo p y q. Note que las columnas 1 y 3 corresponden al orden p y q, respectivamente, mientras que las columnas 2 y 4 corresponden a polinomios de orden superior que permitiría recoger estacionalidades de la serie (si usted está considerando una serie anual, entonces las columnas 2 y 4 no aparecerán. Ignore estas dos columnas para este ejercicio.)

Como el modelo menos parsimonioso (más grande) a considerar en la comparación será el modelo ARMA(2,2), haga clic en a(1,2) en la primera columna y a(2,2) en la tercera columna. Estos dos elementos corresponden a ϕ_2 y θ_2 , respectivamente. Donde

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \varepsilon_t \text{ o de manera equivalente } Y_t [1 - \phi_1 L - \phi_2 L^2] = \delta + [1 + \theta_1 L + \theta_2 L^2] \varepsilon_t .$$

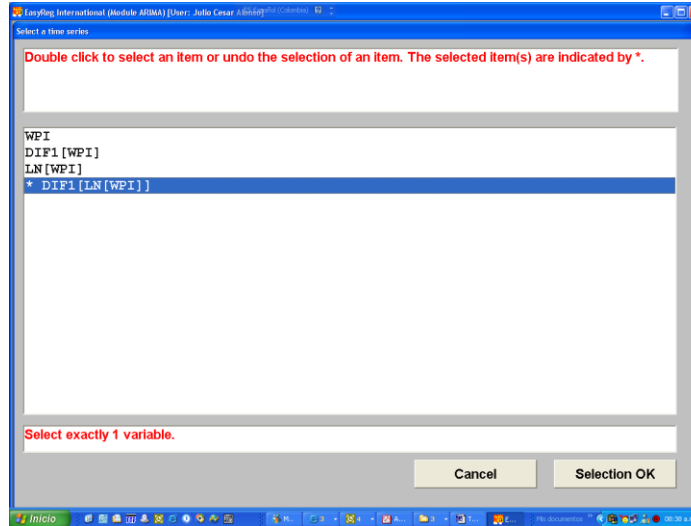


Note que en el panel inferior se presenta la especificación “máxima” que se empleará: $[1 - a(1,1)L - a(1,2)L^2]u(t) = [1 - a(2,1)L - a(2,2)L^2]e(t)$ donde $u(t)$ equivale en nuestro caso a Y_t y $e(t)$ corresponde a ε_t .

Haga clic en el botón “*Specification O.K.*”. En la siguiente ventana haga clic en “*Continue*” y posteriormente en “*Start*”. A continuación EasyReg calculará los tres criterios de información para 9 modelos: (Ruido blanco, AR(1), AR(2), MA(1), MA(2), ARMA(1,1), ARMA(1,2), ARMA(2,1) y ARMA(2,2)). Automáticamente, EasyReg encontrará el modelo que minimice los tres criterios. En este caso, el mejor modelo de acuerdo a los tres criterios de información es el modelo ARMA(1,1) (Modelo 4). Así, nuestro modelo a estimar será el modelo ARMA(1,1) para la serie de las primeras diferencias del logaritmo del WPI.

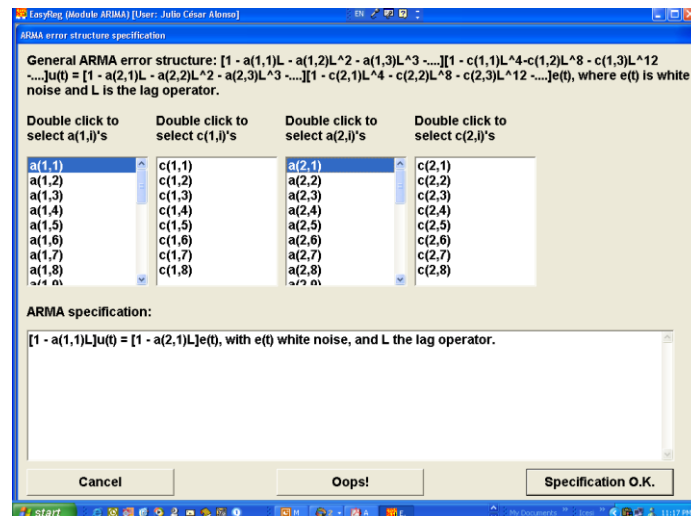
4 Estimación de un modelo ARMA(p,q)

Para estimar un modelo ARMA(1,1), haga clic en “*Menu/Single equation models/ARIMA estimation and forecasting*”. Observará la siguiente ventana.

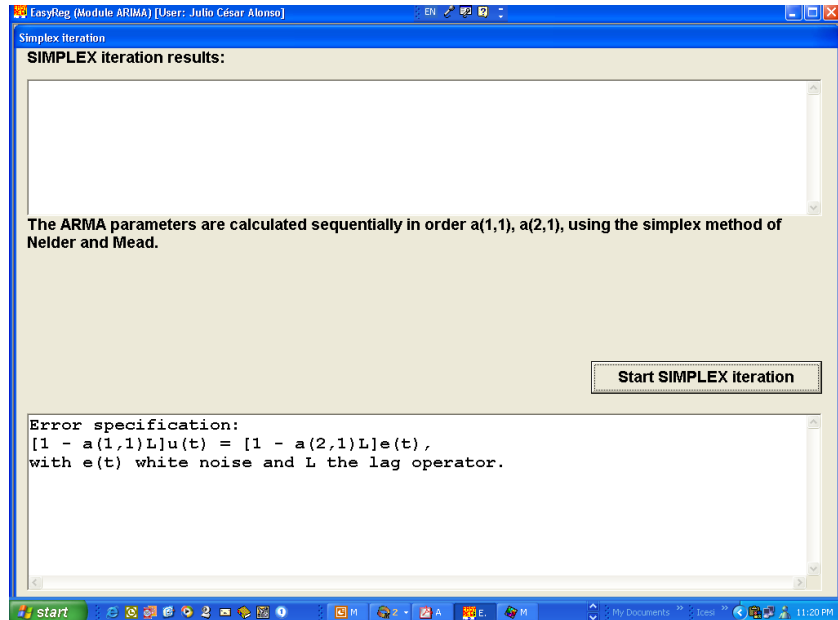


A continuación, haga doble clic en la serie DIF1(LN(WPI)) y haga clic en el botón “*Selection OK*”. Ahora, oprima los botones “*No*” y “*Continue*”. Observará una ventana que permite determinar el orden de integración (d) del modelo ARIMA(p,d,q). En este caso, d es cero, así que haga clic en “*Continue*”. La siguiente ventana ya es familiar, pues es idéntica a la observada en el proceso de selección del mejor modelo ARMA. Para este caso, como sólo incluiremos un intercepto, haga clic en “*Continue*”.

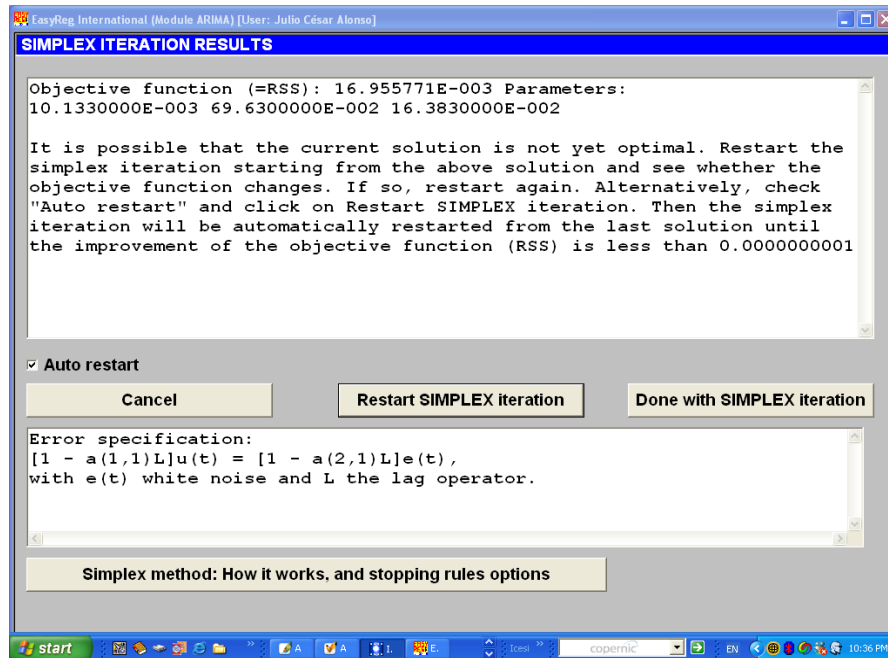
En la siguiente ventana, escoja el orden del proceso autoregresivo y de promedio móvil. Es decir, p=1 y q=1. Por lo tanto, en las columnas 1 y 3 haga clic en a(1,1) y en a(2,1), respectivamente. Una vez escogidos estos dos elementos observará lo siguiente.



Haga clic en “*Specification O.K.*” y luego en el botón “*Continue*”. Observará la siguiente ventana.



En esta ventana empezará el proceso de Maximización de la correspondiente función de Máxima Verosimilitud por medio del método Simplex, equivalente a minimizar el SSE. Haga clic en “*Start SIMPLEX iteration*”. Una vez EasyReg encuentre una solución al problema usted observará la siguiente ventana.



En la parte superior, usted encontrará los valores estimados. Como se discutió en clase, es recomendable emplear diferentes valores iniciales para el proceso de maximización simple. Entonces, haga clic en “*Restart SIMPLEX iteration*” un par de veces hasta que el valor de la Suma cuadrada de los residuos de la función objetivo de máxima verosimilitud (Objective function (=RSS)) converja (no cambie). En otras palabras, siga haciendo clic en “*Restart SIMPLEX iteration*” hasta que el RSS y los parámetros estimados no varíen mucho, es decir, hasta que encuentre un punto de convergencia. Note que en este caso después de tres veces de hacer clic en “*Restart SIMPLEX iteration*”, los parámetros no cambian mucho. En este punto podemos parar el proceso y asumir que hemos encontrado un máximo. Haga clic en “*Done with SIMPLEX iteration*” y posteriormente en “*Continue*”. A continuación, encontrará los valores estimados para el modelo. En la Tabla 4-1 se presentan los resultados.

Tabla 4-1 Estimaciones del Modelo ARMA(1,1) para $\Delta \ln(WPI_t)$

<p>Selected variable:</p> <p>DIF1[LN[WPI]]</p> <p>First available observation: t = 2 (=1960.2) Last available observation: t = 130 (=1992.2) = chosen</p> <p>Number of unobserved future values: 1 Number of observed future values: 0 These future values can be forecasted, where the forecasts of the observed future values will be compared with their realizations.</p> <p>Time series: $Y(t) = \text{DIF1}[\text{LN}[\text{WPI}]]$ Model: $Y(t) = b(1)x(1) + u(t)$, where $x(1) = 1$ Model for $u(t)$: $[1 - a(1,1)L]u(t) = [1 - a(2,1)L]e(t)$, where $e(t)$ is white noise and L is the lag operator.</p> <p>The objective function (RSS) has been minimized using the simplex method of Nelder and Mead. The algorithm involved is a Visual Basic translation of the Fortran algorithm involved in: W.H.Press, B.P.Flannery, S.A.Teukolsky and W.T.Vetterling, 'Numerical Recipes', Cambridge University Press, 1986, pp. 292-293</p> <p>Estimation results:</p>

Parameters	estimate	t-value	[p-value]	HC t-value)	[HC p-value]
b(1)	0.008503	2.098	[0.03586]	2.548	[0.01085]
a(1,1)	0.890100	14.968	[0.00000]	9.706	[0.00000]
a(2,1)	0.508040	4.553	[0.00001]	3.478	[0.00051]

(*) Based on White's heteroskedasticity consistent variance matrix.
 [The two-sided p-values are based on the normal approximation]

RSS = 16.100373297E-03
 s.e. = 11.304014351E-03
 R-square = 0.4038
 n = 129

Information criteria:
 Akaike: -8.94221E+00
 Hannan-Quinn: -8.91519E+00
 Schwarz: -8.87571E+00

If the model is correctly specified, in the sense that the conditional expectation of the error $e(t)$ relative to all past errors $e(t)$ equals zero, then the parameter estimators minus their true values, times the square root of the sample size n , are (asymptotically) jointly normally distributed with zero mean vector and variance matrix:

2.11802202E-03	-4.53761805E-03	-5.29941846E-03
-4.53761805E-03	4.56196342E-01	6.20255195E-01
-5.29941846E-03	6.20255195E-01	1.60636249E+00

provided that the conditional variances of the errors $e(t)$ is constant ($e(t)$ is homoskedastic), or

```

1.43699469E-03 9.14007146E-03 -3.39742608E-03
9.14007146E-03 1.08490443E+00 1.32555235E+00
-3.39742608E-03 1.32555235E+00 2.75274283E+00

```

if the conditional variances of the errors $e(t)$ are not constant ($e(t)$ is heteroskedastic).


El modelo estimado corresponde a $\hat{Y}_t = .008503 + .8901Y_{t-1} - .50804\varepsilon_{t-1}$. Note un aspecto muy importante: los valores estimados del componente de media móvil siempre tendrán que ser multiplicados por -1 para obtener el valor real. En este caso, el valor arrojado por EasyReg para $\hat{\theta}_1$ es 0.508040, para obtener el valor real, este número debe ser multiplicado por -1, por tanto el verdadero valor estimado para θ_1 es -0.50804.

Adicionalmente, tenemos que $R^2 = .43038$, $SSE = 0.016100$. Los demás elementos del resultado pueden ser interpretados como tradicionalmente lo ha hecho.

Note que en el menú “*Options*” tendrá la opción de guardar la serie de errores de la regresión (“*Write residuals to the input file*”), hacer pruebas de Wald sobre un conjunto de parámetros (“*Test parameter restrictions*”), graficar los errores de la estimación (“*Plot the fit*”), etc.

Recuerde que una vez estimamos un modelo, debemos constatar que los errores estimados corresponden a una serie de ruido blanco. Para esto, guarde la serie de residuos y haga el análisis necesario. Usted podrá comprobar que por ejemplo, el estadístico de Box-Pierce para 15 rezagos de los errores estimados es 12.24, el cual no permite rechazar la hipótesis nula de que esta serie es ruido blanco. Además, las ACF y PACF estimadas para los errores estimados refuerzan la idea que esta serie es ruido blanco. (ver Gráfico 4-1).

Gráfico 4-1 ACF y PACF estimadas para el error estimado del modelo ARMA(1,1)

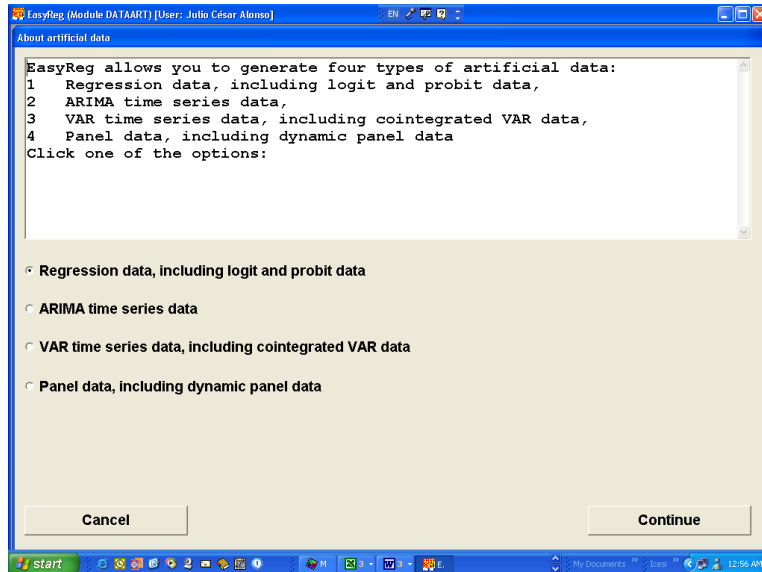


5 Generación de muestras aleatorias a partir de un proceso ARMA(p,q)

EasyReg le permite generar una muestra aleatoria para un proceso ARMA(p,q). Para esto, escoja “File/Choose an input file/Create artificial data”.

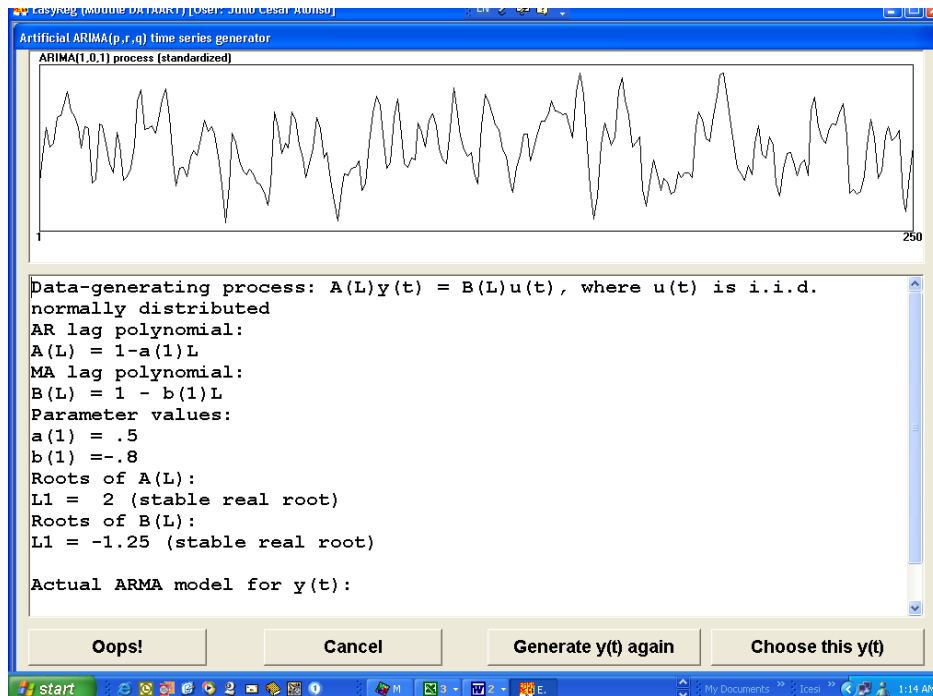


Observará la siguiente ventana:



Haga clic en el botón “ARIMA time series data” y en “Continue”. En la siguiente ventana puede escoger el número de observaciones ($n=T$), orden p y q del proceso ARIMA y el grado de integración del proceso (r según la notación de EasyReg y d según nuestra notación). Además, usted puede escoger la distribución del término de error. Escoja un error distribuido normalmente y el número de p y q que desee. Haga clic en “Options O.K.”. En la siguiente ventana podrá introducir el valor de los parámetros deseados. Es importante anotar que usted debe incluir un número negativo antes de los coeficientes del componente MA para que obtenga la serie deseada. Es decir, si usted quiere generar una muestra del modelo $Y_t = .8Y_{t-1} + .5\varepsilon_{t-1} + \varepsilon_t$, Usted debe introducir el parámetro $-.5$ y no $.5$ cuando le preguntan por el coeficiente asociado a ε_{t-1} .

Haga clic en “Continue”. En la siguiente ventana observará la serie generada



Si quiere trabajar con esta serie, puede hacer clic en “*Choose this $y(t)$* ”. Si desea generar otra serie, puede hacer clic en “*Generate $y(t)$ again*”.

6 Referencias

- Bierens, H. J. (2011), "EasyReg International", Department of Economics, Pennsylvania State University (<http://econ.la.psu.edu/~hbierens/EASYREG.HTM>)
- Enders, Walter. 1995. *Applied Econometric Time Series*: John Wiley & Sons.