

LABORATORIO 01**ECONOMETRÍA Y EL PROGRAMA VIEWS**

Eviews es un programa especializado que sirve para hacer análisis, regresiones y predicción así como simulaciones y evaluaciones de eficiencia y predicción de modelos.

Dado los siguientes datos hipotéticos (Período 1991-1995)

AÑO	Y	X1	X2
1991	3	3	5
1992	1	1	4
1993	8	5	6
1994	3	2	4
1995	5	4	6

Estime el modelo $Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \mu_t$

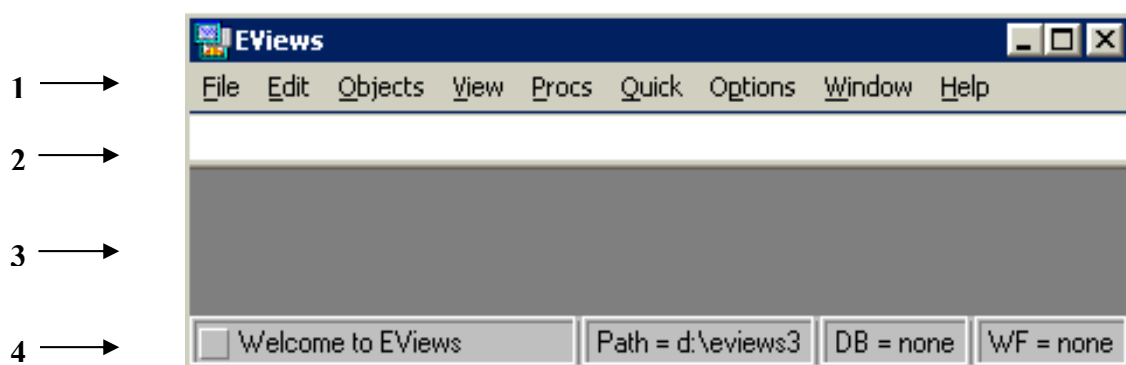
Y_t : variable dependiente o endógena

X_{1t} : variable independiente o exógena

X_{2t} : variable independiente o exógena

PROCEDIMIENTO:**A. Ingresar al programa EViews**

- Inicio
- Programas
- Eviews (hacer clic)
- Aparece el cuadro siguiente:

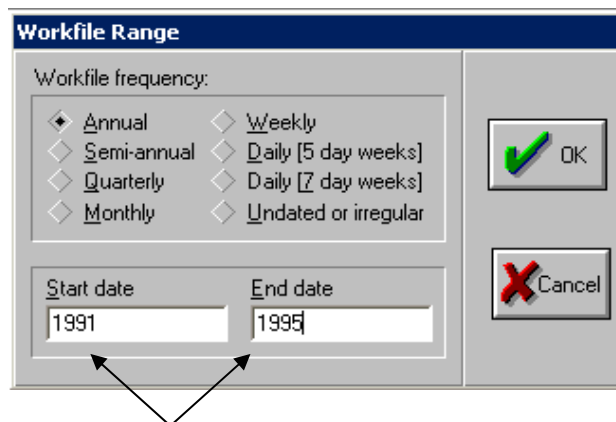


1. Barra de Menú
2. Barra de comandos
3. Área de Trabajo
4. Línea de Estado

B. Crear un Workfile (archivo de trabajo)

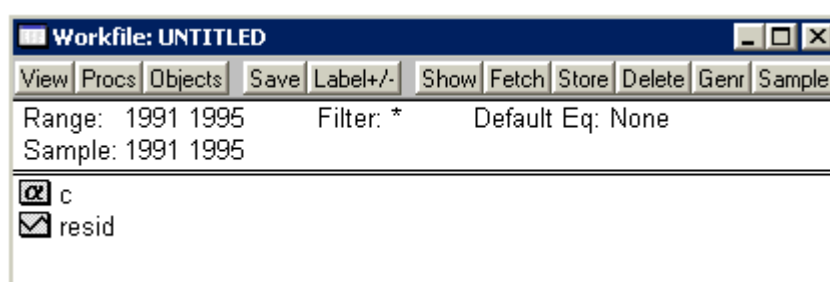
- File

- New
- Workfile
- Aparece la siguiente caja de dialogo

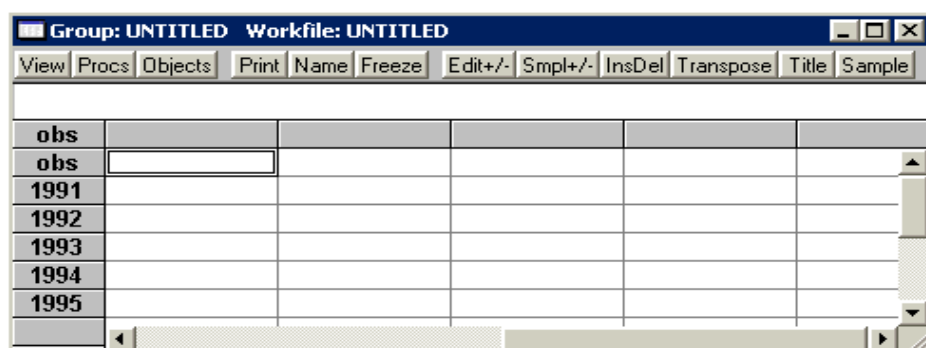


Escribir la fecha de inicio y la fecha final de los datos


- Seleccionar OK
- Aparece el workfile:

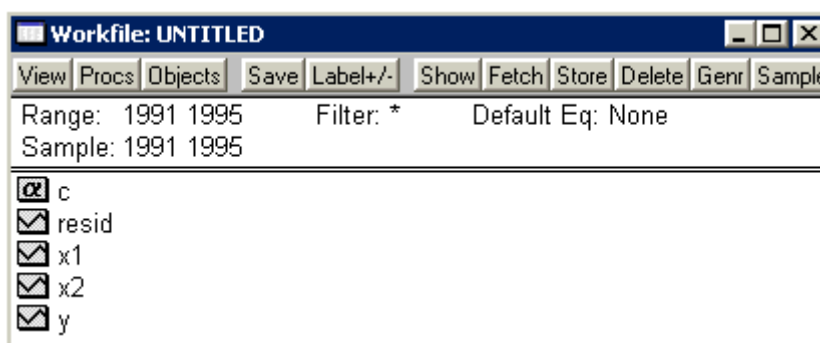


- En la barra del menú Principal, hacer clic en Quick y seleccionar Empty Group (Edit series)
- Aparece el siguiente cuadro:



- Se sombrea la primera columna vacía (de la izquierda)
- Se escribe el nombre de la primera variable en la primera celda vacía: Y, y ENTER.
- Se sombrea la segunda columna vacía y se escribe en la primera celda X1 y luego ENTER.

- Luego se selecciona la tercera columna y se escribe en la primera celdas X2 y Luego ENTER.
- Seguidamente digitar los datos (igualmente se puede importar la información de otro software, por ejemplo el excel), que puede ser por fila o por columna.
- Terminado el tipeado o pegado de los valores numéricos hacer clic en el botón  de la esquina superior del cuadro y hacer clic en YES.
- El workfile aparecerá con las nuevas series:



Adicionalmente, también se puede editar series mediante las siguientes formas:

CREAR Y EDITAR SERIES

- Para crear **una serie** haga clic en **Objects / New Objects/ Series**.
- En la ventana emergente escribir el nombre de la serie y **OK**.
- Para llenar o editar una serie generada o importada hacer doble clic en la serie (o clic derecho en **Open**).
- Una vez abierta la serie en el menú hacer clic en **Edit +/-** y editar la serie y para finalizar nuevamente **Edit +/-**.
- **Copy/paste:** Seleccionar las celdas a copiar desde Excel (Copy) y pegarlas en Eviews (Paste).

IMPORTAR DATOS DE HOJA DE CÁLCULO

- Para importar información desde archivos hojas de cálculo, hacer clic en **Procs / Import./ (Read Text-Lotus-Excel)**
- Aparecerá la ventana **Open** donde se debe buscar y seleccionar el archivo a utilizar.
- Si usted hace doble clic en el nombre del archivo, verá un segundo cuadro de diálogo pidiéndole detalles acerca del archivo (**Excel Spreadsheet Import**)
- Para un archivo de hoja de cálculo (Excel o Lotus), se debe especificar las coordenadas de la celda superior-izquierda que contiene la información. Por ejemplo, si los datos empiezan en la celda A2, entonces usted deberá especificar esta celda como celda de datos superior izquierda.
- Luego escribir el nombre o los nombres de las series.
- Si el archivo cuenta con varias hojas de trabajo, entonces se debe especificar el nombre de donde se desea importar.
- Hacer clic en OK y los datos serán incorporados en el archivo de trabajo.

C. Estimación de la ecuación: $Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \mu_t$

- En la barra de comandos se escribe: **LS Y C X1 X2** y luego ENTER
- Aparece las siguientes salidas (ESTIMATION OUTPUT):

Dependent Variable: Y				
Method: Least Squares				
Date: 07/26/02 Time: 16:28				
Sample: 1991 1995				
Included observations: 5				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.000000	4.474930	0.893869	0.4657
X1	2.500000	0.866025	2.886751	0.1020
X2	-1.500000	1.369306	-1.095445	0.3876
R-squared	0.946429	Mean dependent var	4.000000	
Adjusted R-squared	0.892857	S.D. dependent var	2.645751	
S.E. of regression	0.866025	Akaike info criterion	2.833904	
Sum squared resid	1.500000	Schwarz criterion	2.599567	
Log likelihood	-4.084760	F-statistic	17.66667	
Durbin-Watson stat	1.666667	Prob(F-statistic)	0.053571	

Análisis de las salidas de la regresión:

- a. Verificación de la significancia individual de cada uno de los coeficientes a partir de la hipótesis nula, que nos dice que “la variable “Xi” no es significativa en el modelo (prueba t, para lo cual su valor debe ser superior a un t de tabla, que para este caso debe ser con (n-2, es decir 5-2 grados de libertad y un nivel de significación = 0.05).

Alternativamente la prueba t se docima con la observación de la última columna (Prob = Que es la probabilidad de rechazar la hipótesis nula cuando es cierta).

Si la probabilidad asociada es mayor al 0.05, entonces se acepta la Ho de no significatividad de la variable “Xi”, en caso contrario se rechaza la Ho a un nivel de confianza del 95%.

En este modelo las probabilidades asociadas son superiores a 0.05, por lo tanto se acepta la Ho, es decir que todas las variables no son significativas en el modelo.

- b. Verificación de la significancia global del modelo (Prueba F). Al igual que la prueba estadística “t” se puede analizar de 2 formas: En base a la lectura del estadístico “F” statistic, o en base a la lectura del valor de Prob (F-statistic). Cualquiera conduce a la misma decisión.

La Hipótesis Nula es: la variable dependiente no es explicada por el modelo en su conjunto.

La Hipótesis Alternativa es: la variable dependiente es explicada por el modelo en su conjunto.

Si la probabilidad asociada (valor de Prob (F-statistic)), es superior a 0.05, entonces se acepta la Ho.

En nuestro modelo se observa que la probabilidad asociada es superior a 0.05, entonces se acepta la H_0 , es decir que la variable dependiente no es explicada por el modelo en su conjunto.

D. Para ver la representación clásica de la regresión hacer:


- VIEW
- REPRESENTATIONS
- Aparece la siguiente ecuación: $Y = 4 + 2.5 \cdot X_1 - 1.5 \cdot X_2$

E. Para ver los valores observados de la variable dependiente (Y), los valores estimados con la ecuación y los residuos, proceder de la siguiente manera:

- Estando en las salidas de la regresión (ESTIMACIÓN OUTPUT), hacer clic en VIEW que muestra una serie de alternativas.
- Escoger ACTUAL FITTED RESIDUAL
- Luego hacer clic en: ACTUAL FITTED RESIDUAL, TABLE

obs	Actual	Fitted	Residual	Residual Plot
1991	3.00000	4.00000	-1.00000	
1992	1.00000	0.50000	0.50000	
1993	8.00000	7.50000	0.50000	
1994	3.00000	3.00000	-2.7E-15	
1995	5.00000	5.00000	2.7E-15	

- También se puede escoger la alternativa ACTUAL FITTED RESIDUAL GRAPH (para observar la gráfica):



F. Hallar la matriz de varianzas y covarianzas:

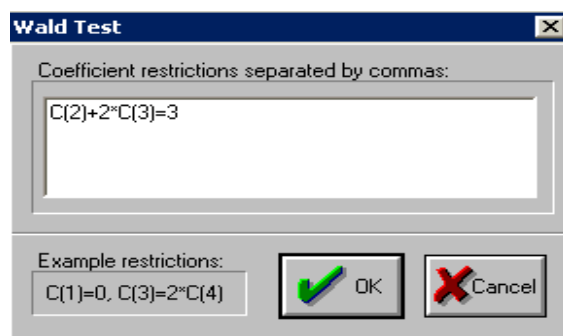
- Estando en las salidas de la regresión, hacer clic en VIEW
- Luego hacer clic en covariance matriz, aparecerá el siguiente cuadro:

	C	X1	X2
C	20.025	3.375	-6
X1	3.375	0.75	-1.125
X2	-6	-1.125	1.875

G. Inferencia con restricciones

Contrastar la hipótesis nula $H_0: \beta_2 + 2\beta_3 = 3$

- Estando en las salidas de la regresión, hacer clic en VIEW
- Luego, Coefficient Test y hacer clic en Wald Coefficient Restrictions.
- Aparecerá la siguiente caja de diálogo (en la cual se debe escribir la restricción)



- Hacer clic en OK
- Aparecerá los siguientes resultados:

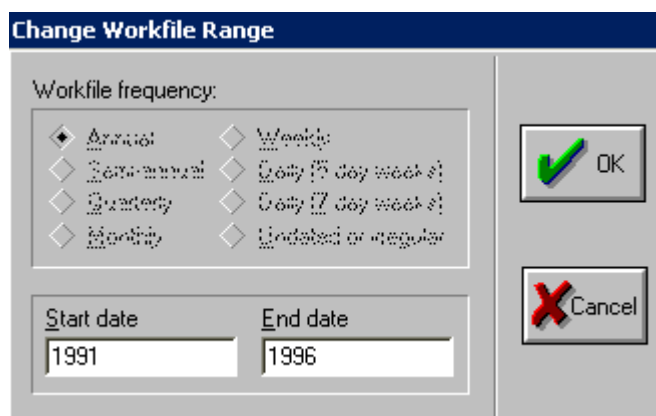
Wald Test:			
Equation: EQ01			
Null Hypothesis: C(2)+2*C(3)=3			
F-statistic	3.266667	Probability	0.212438
Chi-square	3.266667	Probability	0.070701

El valor de la Probabilidad de rechazar la hipótesis nula de 0.07 es superior a 0.05, en consecuencia no se cumple la restricción, $H_0: \beta_2 + 2\beta_3 = 3$

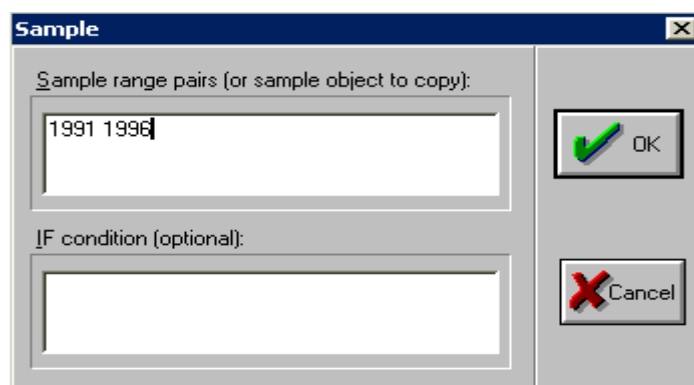
H. PREDICCIÓN:

Hallar la predicción de la variable Y en el período t+1 sabiendo que en el período t las variables X1 y X2 adoptan los valores de 6 y 8 respectivamente.

- El primer paso para predecir en el EViews es expandir el rango del período de análisis. Estando en el workfile hacer clic en Procs, y escoger, haciendo clic, la alternativa Change Workfile Range, aparecerá la siguiente caja de diálogo (en donde se debe poner el nuevo rango)



- Luego se debe cambiar el tamaño de la muestra. Estando en el workfile hacer clic en el botón Sample (muestra). Aparecerá la siguiente caja de diálogo, en la cual se debe poner el nuevo tamaño de la muestra.




- El paso siguiente es rellenar los datos de las variables exógenas. En el workfile seleccionar las variables exógenas (haciendo clic conjuntamente con la tecla CONTROL), luego hacer clic derecho y escoger la alternativa Open/ as Group, aparecerá lo siguiente:

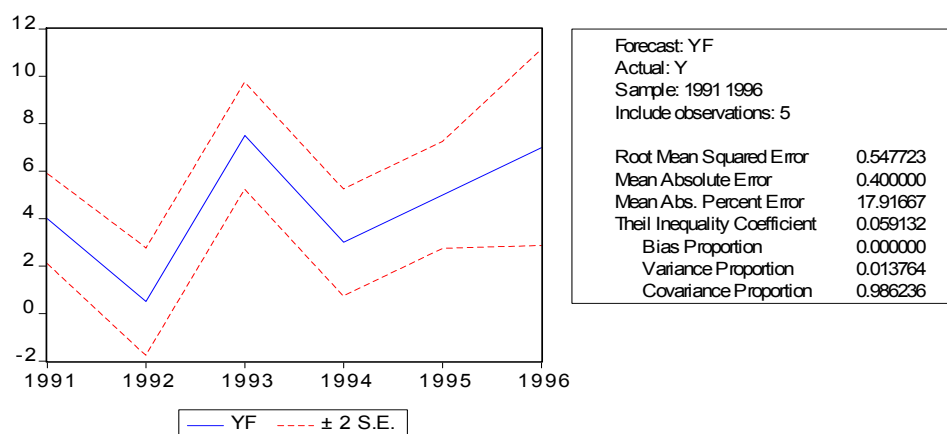
Group: UNTITLED Workfile: CONTRASTE DE HIPOTESIS FINAL					
View	Procs	Objects	Print	Name	Freeze
obs	X1	X2			
1991	3.000000	5.000000			
1992	1.000000	4.000000			
1993	5.000000	6.000000			
1994	2.000000	4.000000			
1995	4.000000	6.000000			
1996	NA	NA			

- Hacer clic en el botón Edit +/- y escribir los valores de las variables exógenas para los años que se va a predecir (1996 para nuestro ejemplo):

Group: UNTITLED Workfile: CONTRASTE DE HIPOTESIS FINAL					
View	Procs	Objects	Print	Name	Freeze
obs	X1	X2			
1991	3.000000	5.000000			
1992	1.000000	4.000000			
1993	5.000000	6.000000			
1994	2.000000	4.000000			
1995	4.000000	6.000000			
1996	6.000000	8.000000			

- Luego del llenado de los datos, hacer clic en el botón  de la esquina superior del cuadro y hacer clic en YES.

- El paso siguiente es regresar al output de la regresión inicial y hacer clic en el botón Forecast y luego en OK. Aparecerá la siguiente gráfica, donde se observa el valor proyectado de la variable dependiente:



- Automáticamente se grabará los valores de la variable dependiente con un nuevo nombre (en nuestro caso será YF). Para ver los valores de la predicción hacer doble clic en YF, aparecerá los valores estimados y proyectados:

Last updated: 07/31/02 - 09:46	
Modified: 1991 1996 // eq01.forecast yf	
1991	4.000000
1992	0.500000
1993	7.500000
1994	3.000000
1995	5.000000
1996	7.000000

RAIZ CUADRÁTICA MEDIA (rms):

Se determina mediante:

$$rms = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2}$$

Donde: \hat{Y}_t : Valor estimado de Y_t

Y_t : Valor real observado

n : Número de períodos

La raíz cuadrática media, mide que tan bueno es el modelo para predecir La rms, debe ser lo más pequeño posible para que el modelo sea bueno para la predicción.

En el ejercicio la rms alcanza los 0.5477.

COEFICIENTE DE THEIL (U)

Se define como:

$$U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t)^2} + \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t)^2}}$$

Donde: \hat{Y}_t : Valor estimado de Y_t

Y_t : Valor real observado

n : Número de períodos

El coeficiente de Theil, mide la calidad del modelo para predecir. Este coeficiente siempre caerá entre 0 y 1. Si $U = 0$, existe un ajuste perfecto y el modelo es bueno para predecir. Si $U = 1$, el modelo es muy malo para predecir.

En el ejercicio este coeficiente es 0.059, es pequeño, por lo tanto el modelo es bueno para predecir.

La proporción de sesgo del coeficiente de desigualdad de Theil es muy pequeño (0.0000). Esto significa que un sesgo sistemático muy pequeño o casi nulo está presente, así que es probable que el modelo sea confiable para predecir.

I. CONSTRUIR UN INTERVALO DE CONFIANZA PARA EL PREDICTOR

a. El valor promedio de Y se encuentra en el intervalo comprendido entre:

$$\hat{Y}_o - t_{\alpha/2} \sqrt{\sigma_{\mu}^2 X'_o (X'X)^{-1} X_o} \leq E(Y / X_o) \leq \hat{Y}_o + t_{\alpha/2} \sqrt{\sigma_{\mu}^2 X'_o (X'X)^{-1} X_o}$$

Donde $Y_o = 7$

$t_{\alpha/2} = 3.182$ Con 3 grados de libertad y un nivel de significancia del 5%

$$DS = \sqrt{\hat{\sigma}_{\mu}^2 X'_o (X'X)^{-1} X_o} = 1.8775, \text{ DS: Desviación Estándar}$$

Reemplazando los datos, tenemos que el valor promedio de Y se encuentra comprendido en el intervalo: (1.0258, 12.974)

b. El intervalo de confianza al 95% para la predicción puntual se calcula mediante la siguiente fórmula:

$$\hat{Y}_o - t_{\alpha/2} \sqrt{\hat{\sigma}_{\mu}^2 [1 + x'_o (X'X)^{-1} x_o]} \leq E(Y / X_o) \leq \hat{Y}_o + t_{\alpha/2} \sqrt{\hat{\sigma}_{\mu}^2 [1 + x'_o (X'X)^{-1} x_o]}$$

Donde $Y_o = 7$

$t_{\alpha/2} = 3.182$ Con 3 grados de libertad y un nivel de significancia del 5%

$$DS = \sqrt{\hat{\sigma}_{\mu}^2 [1 + x'_o (X'X)^{-1} x_o]} = 2.06761, \text{ DS: Desviación Estándar}$$

Reemplazando datos, tenemos que el intervalo de confianza para la predicción individual es:
(0.42087, 13.579)

ESTIMACIÓN, INFERENCIA Y PREDICCIÓN EN UN MODELO ECONOMETRICO CON MATRICES

1. a. Dado los siguientes datos, estime el modelo $y_t = \beta_1 + \beta_2x_{1t} + \beta_3x_{2t} + \mu_t$

$$Y = \begin{bmatrix} 3 \\ 1 \\ 8 \\ 3 \\ 5 \end{bmatrix}$$

$$X = \begin{bmatrix} 1 & 3 & 5 \\ 1 & 1 & 4 \\ 1 & 5 & 6 \\ 1 & 2 & 4 \\ 1 & 4 & 6 \end{bmatrix}$$

$$n = \boxed{5}$$

$$k = \boxed{3}$$

$$X' = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 3 & 1 & 5 & 2 & 4 \\ 5 & 4 & 6 & 4 & 6 \end{bmatrix}$$

$$Y' = \begin{bmatrix} 3 & 1 & 8 & 3 & 5 \end{bmatrix}$$

Se hallará los parámetros β : $\hat{\beta} = (X'X)^{-1}X'Y$

$$X'X = \begin{bmatrix} 5 & 15 & 25 \\ 15 & 55 & 81 \\ 25 & 81 & 129 \end{bmatrix}$$

$$X'Y = \begin{bmatrix} 20 \\ 76 \\ 109 \end{bmatrix}$$

$$Y'Y = \boxed{108}$$

$$(X'X)^{-1} = \begin{bmatrix} 26.7 & 4.5 & -8 \\ 4.5 & 1 & -1.5 \\ -8 & -1.5 & 2.5 \end{bmatrix}$$

$$\hat{\beta} = \begin{bmatrix} 4 \\ 2.5 \\ -1.5 \end{bmatrix}$$

$$\hat{\beta}' = \begin{bmatrix} 4 & 2.5 & -1.5 \end{bmatrix}$$

Estimando la varianza de los términos de perturbación: $\hat{\sigma}_\mu^2$

$$\hat{\sigma}_\mu^2 = (Y'Y - \hat{\beta}'X'Y)/(n-k) \quad n = \boxed{5}$$

$$k = \boxed{3}$$

$$Y'Y = \boxed{108}$$

$$\hat{\beta}'X'Y = \boxed{106.5}$$

$$\hat{\sigma}_\mu^2 = \boxed{0.75}$$

$$\hat{\sigma}_\mu = \boxed{0.86603}$$

Estimación de la matriz de varianzas y covarianzas de $\hat{\beta}$ de $\text{var}(\hat{\beta}) = \hat{\sigma}_\mu^2 (X'X)^{-1}$

$$(X'X)^{-1} = \begin{bmatrix} 26.7 & 4.5 & -8 \\ 4.5 & 1 & -1.5 \\ -8 & -1.5 & 2.5 \end{bmatrix}$$

$$\hat{\sigma}_\mu^2 = 0.75$$

$$\text{var}(\hat{\beta}) = \hat{\sigma}_\mu^2 (X'X)^{-1} = \begin{bmatrix} 20.025 & 3.375 & -6 \\ 3.375 & 0.75 & -1.125 \\ -6 & -1.125 & 1.875 \end{bmatrix}$$

Desviación estándar de $\hat{\beta}$

4.47493
0.86603
1.36931

Estimando el R^2

$$R^2 = (\hat{\beta}' X' Y - n \bar{Y}^2) / (Y' Y - n \bar{Y}^2) \quad \hat{\beta}' X' Y = 106.5 \quad \bar{Y} = 4 \quad \bar{Y}^2 = 16$$

$$n = 5 \quad Y' Y = 108 \quad \text{Desviación estándar de la variable dependiente}$$

Reemplazando los datos se obtiene: $R^2 = 0.9464$ 2.64575

Estimando el R^2 ajustado

$$R^2_{\text{ajustado}} = 1 - ((Y' Y - \hat{\beta}' X' Y) * (n-1)) / ((Y' Y - n \bar{Y}^2) * (n-K)) \quad k = 3$$

Reemplazando los datos en la ecuación del R^2 ajustado: $R^2_{\text{ajustado}} = 0.89286$

Décima de hipótesis con el estadístico F:

$$F_{\text{ESTADISTICO}} = \frac{\text{SUMA DE CUADRADOS EXPLICADA} / (k-1)}{\text{SUMA DE CUADRADOS RESIDUAL} / (n-k)} = \frac{\text{VARIANZA EXPLICADA}}{\text{VARIANZA NO EXPLICADA}}$$

$$\hat{\beta}' X' Y = 106.5 \quad \bar{Y}^2 = 16 \quad n = 5 \quad Y' Y = 108$$

$$k = 3$$

SUMA DE CUADRADOS EXPLICADA: $\hat{\beta}' X' Y - n \bar{Y}^2 = 26.5$

SUMA DE CUADRADOS RESIDUAL: $Y' Y - \hat{\beta}' X' Y = 1.5$

VARIANZA EXPLICADA = 13.25

VARIANZA NO EXPLICADA = 0.75

F ESTADISTICO = 17.6667

El F calculado es 17.6667 y el F de tablas es 19. Como el $F_{\text{tablas}} > F_{\text{calculado}}$, entonces no existe suficiente evidencia para rechazar la hipótesis nula, a un nivel de significancia del 5%, es decir que la variable dependiente (Y) no es explicado por el modelo en su conjunto.

FORMULA MATRICIAL PARA CALCULAR EL " F " ESTADISTICO

$$F_c = \frac{\hat{\beta}'_2 X'_2 Q X_2 \hat{\beta}_2}{\hat{\sigma}_\mu^2 (k-1)} \sim F(k-1, n-k)$$

$$Q = \begin{bmatrix} 0.8 & -0.2 & -0.2 & -0.2 & -0.2 \\ -0.2 & 0.8 & -0.2 & -0.2 & -0.2 \\ -0.2 & -0.2 & 0.8 & -0.2 & -0.2 \\ -0.2 & -0.2 & -0.2 & 0.8 & -0.2 \\ -0.2 & -0.2 & -0.2 & -0.2 & 0.8 \end{bmatrix}$$

$$Q = I_n - \frac{1}{n} 1_n 1_n'$$

$$X_2 = \begin{bmatrix} 3 & 5 \\ 1 & 4 \\ 5 & 6 \\ 2 & 4 \\ 4 & 6 \end{bmatrix}$$

$$X'_2 = \begin{bmatrix} 3 & 1 & 5 & 2 & 4 \\ 5 & 4 & 6 & 4 & 6 \end{bmatrix}$$

$$\hat{\beta}_2 = \begin{bmatrix} 2.5 \\ -1.5 \end{bmatrix}$$

$$\hat{\beta}'_2 = \begin{bmatrix} 2.5 & -1.5 \end{bmatrix}$$

$$X'_2 Q = \begin{bmatrix} 0.000 & -2 & 2 & -1 & 1 \\ 0.000 & -1 & 1 & -1 & 1 \end{bmatrix}$$

$$X'_2 Q X_2 = \begin{bmatrix} 10 & 6 \\ 6 & 4 \end{bmatrix}$$

$$(X'_2 Q X_2)^{-1} = \begin{bmatrix} 1 & -1.5 \\ -1.5 & 2.5 \end{bmatrix}$$

$$\hat{\beta}'_2 X'_2 Q X_2 = \begin{bmatrix} 16.00 & 9 \end{bmatrix}$$

$$\hat{\beta}'_2 X'_2 Q X_2 \hat{\beta}_2 = \begin{bmatrix} 26.5 \end{bmatrix} \hat{\sigma}_\mu^2 = \begin{bmatrix} 0.75 \end{bmatrix}$$

$$k = \begin{bmatrix} 3 \end{bmatrix}$$

$$F_c = \begin{bmatrix} 17.66667 \end{bmatrix}$$

METODO GENERAL

$$F_c = \frac{(\hat{\beta} - \beta)' (X'X) (\hat{\beta} - \beta)}{\frac{k}{\mu' \mu} (n-k)} \sim F(k, n-k)$$

$$F_c = \frac{(\hat{\beta} - \beta)' [\hat{\sigma}_\mu^2 (X'X)^{-1}]^{-1} (\hat{\beta} - \beta)}{k} \sim F(k, n-k)$$

Donde $[\beta] = [0]$, excepto el intercepto

$$\hat{\beta} - \beta = \begin{bmatrix} 4.0 \\ 2.5 \\ -1.5 \end{bmatrix} - \begin{bmatrix} 4.0 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 0.0 \\ 2.5 \\ -1.5 \end{bmatrix} \quad (\hat{\beta} - \beta)' = \begin{bmatrix} 0.0 & 2.5 & -1.5 \end{bmatrix}$$

$$\hat{\sigma}_\mu^2 (X'X)^{-1} = \begin{bmatrix} 20.025 & 3.375 & -6.000 \\ 3.375 & 0.750 & -1.125 \\ -6.000 & -1.125 & 1.875 \end{bmatrix} \quad \left(\hat{\sigma}_\mu^2 (X'X)^{-1} \right)^{-1} = \begin{bmatrix} 6.667 & 20 & 33.333 \\ 20 & 73.333 & 108 \\ 33.333 & 108 & 172 \end{bmatrix}$$

$$(\hat{\beta} - \beta)' [\hat{\sigma}_\mu^2 (X'X)^{-1}]^{-1} (\hat{\beta} - \beta) = \begin{bmatrix} 0.00000000000138 & 21.3333 & 12 \end{bmatrix}$$

$$(\hat{\beta} - \beta)' [\hat{\sigma}_\mu^2 (X'X)^{-1}]^{-1} (\hat{\beta} - \beta) = \begin{bmatrix} 35.333 \end{bmatrix} \quad k = \begin{bmatrix} 3 \end{bmatrix}$$

$$F_c = \begin{bmatrix} 17.66667 \end{bmatrix}$$

FORMULA PARA CALCULAR EL F ESTADISTICO, MEDIANTE EL R^2

$$F_c = \frac{R^2 / (k-1)}{(1-R^2) / (n-k)} = \boxed{17.6667}$$

DOCIMAS DE HIPOTESIS CON RESTRICCIONES

$H_0: R \hat{\beta} = r$

b. Contrastar la hipótesis nula $H_0: \beta_2 + 2\beta_3 = 3$

Sea el modelo: $y_t = \beta_1 + \beta_2 x_{1t} + \beta_3 x_{2t} + \mu_t$

$R = \begin{bmatrix} 0 & 1 & 2 \end{bmatrix}$

$\hat{\beta} = \begin{bmatrix} 4 \\ 2.5 \\ -1.5 \end{bmatrix}$

$r = \boxed{3}$

Dócima de hipótesis con el estadístico F:

$$F_c = \frac{(R\hat{\beta} - r)' [(R(X'X)^{-1}R')^{-1} (R\hat{\beta} - r)]}{\frac{(\hat{\mu}'\hat{\mu})}{n-k}} \sim F(q, n-k)$$

$\hat{\beta} = \begin{bmatrix} 4 \\ 2.5 \\ -1.5 \end{bmatrix}$

$R = \begin{bmatrix} 0 & 1 & 2 \end{bmatrix}$

$(X'X)^{-1} = \begin{bmatrix} 26.7 & 4.5 & -8 \\ 4.5 & 1 & -1.5 \\ -8 & -1.5 & 2.5 \end{bmatrix}$

$r = \boxed{3}$

$R' = \begin{bmatrix} 0 \\ 1 \\ 2 \end{bmatrix}$

$\hat{\sigma}_\mu^2 = \boxed{0.75}$

$R(X'X)^{-1} = \begin{bmatrix} -11.5 & -2 & 3.5 \end{bmatrix}$

$R(X'X)^{-1}R' = \boxed{5}$

$R\hat{\beta} = \boxed{-0.5}$

$R\hat{\beta} - r = \boxed{-3.5}$

$r - R\hat{\beta} = \boxed{3.5}$

$(X'X)^{-1}R' = \begin{bmatrix} -11.5 \\ -2 \\ 3.5 \end{bmatrix}$

$q = \boxed{1}$ Una restricción

$F_c = \boxed{3.266667}$

ESTIMACION DE LOS PARAMETROS β BAJO RESTRICCIONES: $\hat{\beta}_R$

$\hat{\beta}_R = \hat{\beta} + (X'X)^{-1}R' [(R(X'X)^{-1}R')^{-1} (r - R\hat{\beta})] = \begin{bmatrix} -4.05 \\ 1.1 \\ 0.95 \end{bmatrix}$

CONTRASTE DE HIPOTESIS MEDIANTE SUMAS RESIDUALES

El estadístico F se calcula mediante la siguiente fórmula: $F_c = \frac{(SRR - SRS) / q}{SRS / (n - k)}$

Donde:

SRR: Suma residual restringida

SRS: Suma residual sin restringir

$q = 1$
 $n = 5$
 $k = 3$
 $\hat{\beta} = \begin{bmatrix} 4 \\ 2.5 \\ -1.5 \end{bmatrix}$

Cálculo de la suma residual sin restringir (SRS): $Y'Y - \hat{\beta}'X'Y =$

$$\begin{aligned}
 Y'Y &= \boxed{108} & \hat{\beta}' X' Y &= \boxed{106.5} \\
 X'Y &= \begin{bmatrix} 20 \\ 76 \\ 109 \end{bmatrix} & \hat{\beta}'_R &= \begin{bmatrix} -4.05 & 1.1 & 0.95 \end{bmatrix} & \hat{\beta}'_R X' Y &= \boxed{106.15} \\
 SRS &= Y'Y - \hat{\beta}' X' Y & & & & = \boxed{1.50}
 \end{aligned}$$

Obtención de la suma residual restringida: $Y' Y^* - \hat{\beta}'_R X' Y^* =$
 A partir del modelo inicial, obtenemos:

$$\begin{aligned}
 Y &= \beta_1 + \beta_2 X_1 + \beta_3 X_2 & \text{Restricción: } & \beta_2 + 2\beta_3 = 3 \\
 Y &= \beta_1 + (3-2\beta_3)X_1 + \beta_3 X_2 \\
 Y - 3X_1 &= \beta_1 + \beta_3(-2X_1 + X_2) & Y^* &= \beta_1^* + \beta_2^* X^* + 1 & Y^*: & \text{Y restringido}
 \end{aligned}$$

Operando, obtenemos

$$\begin{aligned}
 Y^* &= \begin{bmatrix} -6 \\ -2 \\ -7 \\ -3 \\ -7 \end{bmatrix} & Y^{**} &= \begin{bmatrix} -6 & -2 & -7 & -3 & -7 \end{bmatrix} \\
 X^* &= \begin{bmatrix} 1 & -1.0 \\ 1 & 2.0 \\ 1 & -4.0 \\ 1 & 0.0 \\ 1 & -2.0 \end{bmatrix} & X^{**} &= \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ -1.0 & 2.0 & -4.0 & 0.000 & -2.0 \end{bmatrix} \\
 X^{**} X^{**} &= \begin{bmatrix} 5 & -5 \\ -5 & 25 \end{bmatrix} & (X^{**} X^{**})^{-1} &= \begin{bmatrix} 0.25 & 0.05 \\ 0.05 & 0.05 \end{bmatrix} \\
 X^{**} Y^{**} &= \begin{bmatrix} -25 \\ 44 \end{bmatrix} & \hat{\beta}'_R^* &= \begin{bmatrix} -4.05 & 0.95 \end{bmatrix} & \hat{\beta}'_R^* X^{**} Y^{**} &= \boxed{143.05} \\
 SRR &= Y^{**} Y^{**} - \hat{\beta}'_R^* X^{**} Y^{**} = \boxed{3.95} & \text{LUEGO para hallar } \beta_2 \text{ se utiliza:} & & & \\
 & & \beta_2 + 2\beta_3 = 3 & \text{despejando} & & \\
 & & \beta_2 = -2(0.95) + 3 = 1.1 & & & 1.1
 \end{aligned}$$

Reemplazando datos en la fórmula del F estadístico, tenemos :

$$F_c = \frac{(SRR - SRS) / q}{SRS / (n - k)} = \boxed{3.26667}$$

PREDICCIÓN

PREDICCIÓN EN MEDIA : $\hat{Y}_i = x_i' \hat{\beta}$ PREDICCIÓN DE UN VALOR INDIVIDUAL $(\hat{Y}_i / x_o) = x_o' \hat{\beta}$

$$\begin{aligned}
 \text{SEA } X_o &= \begin{bmatrix} 1 \\ 6 \\ 8 \end{bmatrix} & X_o' &= \begin{bmatrix} 1 & 6 & 8 \end{bmatrix} & \hat{\beta} &= \begin{bmatrix} 4 \\ 2.5 \\ -1.5 \end{bmatrix} \\
 Y_o &= X_o' \hat{\beta} = \boxed{7}
 \end{aligned}$$

VARIANZA DE LA PREDICCIÓN :

$$\begin{aligned}
 (X' X)^{-1} &= \begin{bmatrix} 26.7 & 4.5 & -8 \\ 4.5 & 1 & -1.5 \\ -8 & -1.5 & 2.5 \end{bmatrix} & \hat{\sigma}_\mu^2 &= \boxed{0.75} \\
 X_o' (X' X)^{-1} &= \begin{bmatrix} -10.3 & -1.5 & 3 \end{bmatrix} & X_o' (X' X)^{-1} X_o &= \boxed{4.7}
 \end{aligned}$$

Remplazando en las fórmulas para obtener las varianzas, tenemos:

Varianza de la predicción promedio

$$\text{var}(Y/x_0) = \hat{\sigma}_\mu^2 x_0' (X'X)^{-1} x_0 = \boxed{3.525} \quad \text{DS: Desviación Estándar}$$

$$\text{DS} = \sqrt{\hat{\sigma}_\mu^2 x_0' (X'X)^{-1} x_0} = \boxed{1.8775}$$

El valor promedio de Y se encuentra en el intervalo comprendido entre:

$$Y_0 - t_{\alpha/2} \sqrt{\hat{\sigma}_\mu^2 X_0' (X'X)^{-1} X_0} \leq E(Y / X_0) \leq Y_0 + t_{\alpha/2} \sqrt{\hat{\sigma}_\mu^2 X_0' (X'X)^{-1} X_0} \quad Y_0 = \boxed{7}$$

Donde: $t_{\alpha/2} = \boxed{3.182}$ Con 3 grados de libertad y un nivel de significancia del 5%

Reemplazando los datos, tenemos que el valor promedio de Y se encuentra comprendido en el intervalo: $\boxed{1.0258}$, $\boxed{12.9742}$

VARIANZA DE LA PREDICCIÓN INDIVIDUAL :

$$\text{var}(Y/x_0) = \hat{\sigma}_\mu^2 [1 + x_0' (X'X)^{-1} x_0] = \boxed{4.275}$$

$$\text{DS} = \sqrt{\hat{\sigma}_\mu^2 [1 + x_0' (X'X)^{-1} x_0]} = \boxed{2.06761}$$

El intervalo de confianza al 95% para la predicción puntual se calcula mediante la siguiente fórmula:

$$Y_0 - t_{\alpha/2} \sqrt{\hat{\sigma}_\mu^2 [1 + x_0' (X'X)^{-1} x_0]} \leq E(Y / X_0) \leq Y_0 + t_{\alpha/2} \sqrt{\hat{\sigma}_\mu^2 [1 + x_0' (X'X)^{-1} x_0]} =$$

$$Y_0 = \boxed{7} \quad \text{Donde: } t_{\alpha/2} = \boxed{3.182}$$

Entonces el intervalo de confianza para la predicción individual es: $\boxed{0.42087}$, $\boxed{13.5791}$

EVALUACION DEL MODELO ESTIMADO (PARA PREDECIR)

$$X = \begin{bmatrix} 1 & 3 & 5 \\ 1 & 1 & 4 \\ 1 & 5 & 6 \\ 1 & 2 & 4 \\ 1 & 4 & 6 \end{bmatrix} \quad \hat{\beta} = \begin{bmatrix} 4 \\ 2.5 \\ -1.5 \end{bmatrix}$$

$$\hat{Y}_t = \begin{bmatrix} 4 \\ 0.5 \\ 7.5 \\ 3 \\ 5 \end{bmatrix} \quad Y_t = \begin{bmatrix} 3 \\ 1 \\ 8 \\ 3 \\ 5 \end{bmatrix} \quad \hat{Y}_t - Y_t = \begin{bmatrix} 1 \\ -0.5 \\ -0.5 \\ -5.7E-14 \\ 0 \end{bmatrix} \quad (\hat{Y}_t - Y_t)^2 = \begin{bmatrix} 1 \\ 0.25 \\ 0.25 \\ 3.2E-27 \\ 0 \end{bmatrix}$$

$$n = \boxed{5} \quad \sum (\hat{Y}_t - Y_t)^2 = \boxed{1.5}$$

Raíz Cuadrática Media (rms):

$$\text{rms} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2}$$

Donde: \hat{Y}_t : Valor estimado de Yt
 Y_t : Valor observado de Yt

Reemplazando datos, la rms es igual a : $\boxed{0.5477}$

La rms, debe ser lo más pequeño posible para que el modelo sea bueno para predecir.

Coefficiente de Theil (U):

$$U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t)^2} + \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t)^2}}$$

Donde: \hat{Y}_t : Valor estimado de Y_t
 Y_t : Valor observado de Y_t

$$(\hat{Y}_t)^2 = \begin{bmatrix} 16 \\ 0.25 \\ 56.25 \\ 9 \\ 25 \end{bmatrix}$$

$$(Y_t)^2 = \begin{bmatrix} 9 \\ 1 \\ 64 \\ 9 \\ 25 \end{bmatrix}$$

$$\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2} = \boxed{0.54772}$$

$$n = \boxed{5}$$

$$\sum (\hat{Y}_t)^2 = \boxed{106.5}$$

$$\sum (Y_t)^2 = \boxed{108}$$

$$\sqrt{\frac{1}{n} \sum (\hat{Y}_t)^2} = \boxed{4.615192}$$

$$\sqrt{\frac{1}{n} \sum (Y_t)^2} = \boxed{4.6476}$$

Reemplazando datos se tiene, que U es igual a: **0.0591**

El **índice de Theil** nos dice que cuanto más cercano a cero, el modelo será bueno para predecir. Este coeficiente mide la **rms** en términos relativos.

Dependent Variable: Y
 Method: Least Squares
 Date: 08/17/02 Time: 00:40
 Sample: 1991 1995
 Included observations: 5

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4	4.47493	0.8939	0.4657
X1	2.5	0.86603	2.8868	0.102
X2	-1.5	1.36931	-1.0954	0.3876
R-squared	0.946429	Mean dependent	4	
Adjusted R	0.892857	S.D. dependent	2.6458	
S.E. of regr	0.866025	Akaike info crit	2.8339	
Sum square	1.5	Schwarz criteric	2.5996	
Log likelih	-4.08476	F-statistic	17.667	
Durbin-Wa	1.666667	Prob(F-statistic)	0.0536	

GUIA PRÁCTICA ECONOMETRICS EIEWS 3.0

Eviews es un programa especializado que sirve para hacer análisis, regresiones y predicción así como simulaciones y evaluaciones de eficiencia y predicción de modelos.

CREAR UN WORKFILE

- Para crear un archivo de trabajo haga clic en **File / New / Workfile**.
- Aparecerá el diálogo Workfile Range. Haga clic en la frecuencia apropiada, que dependiendo del proyecto, puede ser anual, semi-anual, etc. La Start date es la fecha más cercana que usted piensa usar en el proyecto y la End date es la fecha última.
Forma de introducir las fechas de inicio y fin de los datos:

Anual	Año inicio	Año final	Ej: 1990	2001
Semestral	Año: Semestre inicio	Año: Semestre final	Ej: 1970:1	1988:2
Trimestral	Año: Trimestre inicio	Año: Trimestre final	Ej: 1970:1	1998:4
Mensual	Año: Mes inicio	Año: Mes final	Ej: 1970:1	1998:12
*Semanal	Mes: Día: Año inicio	Mes: Día: Año final	Ej: 1:15: 1994	12:31:1997
Diario	Mes: Día: Año inicio	Mes: Día: Año final	Ej: 8:15: 1994	12:31:1996
Undated	Observación inicial	Observación final	Ej: 1	220

* Para realizar la opción semanal se recomienda que la fecha de inicio sea un lunes para poner los datos en la hoja de manera más ordenada.

- Después de haber suministrado la información y haber hecho clic en OK, usted verá la ventana del archivo de trabajo.
- Los archivos de trabajo contienen dos objetos al principio, un vector de coeficientes, C, y una serie de residuales, RESID, El icono de la izquierda identifica el tipo de objeto, una α para un coeficiente vector y un pequeño gráfico para una serie de tiempo.

CREAR Y EDITAR SERIES

- Para crear una serie haga clic en **Objects / New Objects/ Series**.
- En la ventana emergente escribir el nombre de la serie y **OK**.
- Para llenar o editar una serie generada o importada hacer doble clic en la serie (o clic derecho en **Open**).
- Una vez abierta la serie en el menú hacer clic en **Edit +/-** y editar la serie y para finalizar nuevamente **Edit +/-** .
- **Copy/paste**, es el método más recomendado y más sencillo. Seleccionar las celdas a copiar desde Excel y pegarlas en Eviews.

IMPORTAR DATOS DE HOJA DE CÁLCULO

- Para importar información desde archivos hojas de cálculo, hacer clic en **Procs / Import./ (Real Text-Lotus-Excel)**
- Aparecerá la ventana **Open** donde se debe buscar y seleccionar el archivo a utilizar.
- Si usted hace doble clic en el nombre del archivo, verá un segundo cuadro de diálogo pidiéndole detalles acerca del archivo (**Excel Spreadsheet Import**)
- Para un archivo de hoja de cálculo (Excel o Lotus), se debe especificar las coordenadas de la celda superior-izquierda que contiene la información. Por ejemplo, si los datos empiezan en la celda A2, entonces usted deberá especificar esta celda como celda de datos superior izquierda.
- Luego escribir el nombre o los nombres de las series.

- Si el archivo cuenta con varias hojas de trabajo, entonces se debe especificar el nombre de donde se desea importar.
- Hacer clic en OK y los datos serán incorporados en el archivo de trabajo.

OTRA FORMA DE INGRESAR DATOS

- Otra manera de ingresar los valores que correspondan a una o varias series es mediante **Quick/Empty Group (Edit Series)**, del menú principal.
- Aparecerá una hoja de cálculos donde se digitaran o se pegaran los datos.
- La primera serie recibirá el nombre de SER1, el que podrá ser cambiado posteriormente.
- Presionar luego **Edit+/-** para que no se modifiquen los datos.

GRABAR AL WORKFILE

- Para dar nombre y grabar su archivo para uso futuro, presione el botón **SAVE** de la barra de herramientas para grabar una copia del archivo de trabajo en el disco.
- También puede grabar el archivo por la alternativa **File / Save As** del menú principal y aparecerá una ventana.
- Una vez que se halla localizado el directorio correcto, tipee el nombre que desee darle al archivo y presione **OK**.
- Su nombre será grabado con la extensión WF1.
- Cuando el archivo es nombrado y grabado, se puede grabar cualquier actualización con la opción **File / Save** del menú principal.

ABRIR UN WORKFILE

- Se usará **File / Open** para recuperar cualquier archivo de trabajo grabado anteriormente.
- Aparecerá una ventana similar a aquella de Save As. En la parte inferior izquierda se mostrará todos los archivos de trabajo del directorio especificado por la información hacia la derecha.
- Una vez especificado el directorio, hacer doble clic en el nombre del archivo de trabajo y la ventana del archivo de trabajo se abrirá.

SALIR DEL EVIEWS

- Para apagar el Eviews, haga doble clic en la caja X en la parte superior derecha.
- Otra forma de apagar el Eviews es escoger **File / Exit** del menú principal.

CREAR NUEVAS VARIABLES

- Presionar el botón **Genr** de la barra de herramientas de la ventana del archivo de trabajo.
- Usted verá una caja de diálogo donde puede tipear la fórmula.
- Tipear el nombre que se le va a dar a la nueva serie, un signo =, y la fórmula que describe cómo calcular la nueva serie.
- Hacer clic en **OK** y verá el nombre que le ha dado a la nueva serie, en el lado izquierdo de del signo = de su fórmula, en el directorio del archivo de trabajo.

Ej: $L X = \text{Log}(X)$

LABORATORIO 02**APLICATIVO DE REGRESIÓN LINEAL**

Se tiene información de la demanda de autos, del ingreso disponible y del índice de precios de los autos del País “A”.

AÑO	DAUTOS	YDISP	IPAUTOS
1988	12.30	263.0	93.1
1989	16.00	275.4	93.3
1990	15.70	278.3	92.5
1991	21.20	296.7	89.2
1992	17.90	309.3	91.7
1993	18.80	315.8	96.1
1994	15.40	318.8	100.0
1995	19.00	333.0	103.9
1996	20.00	340.2	102.5
1997	18.40	350.7	102.5
1998	21.80	367.3	102.1
1999	24.10	381.3	101.5
2000	25.60	406.5	101.2
2001	30.00	430.8	99.0

DAUTOS: Demanda de autos (en billones de dólares a precios de 1994)

YDISP: Ingreso disponible (en billones de dólares a precios de 1994)

IPAUTOS: Índice de precios de los autos (base 1994=100)

A. En base a estos datos analizar el siguiente modelo:

$$\text{DAUTOS} = \beta_1 + \beta_2 \text{YDISP} + \beta_3 \text{IPAUTOS} + \mu \quad \dots \text{ (Modelo I)}$$

PROCEDIMIENTO:

- Crear una hoja de Workfile (File/New/Workfile). Período de inicio 1988 y período final 2001
- Ingresar los datos (Quick/ Empty Group (Edit series)).
- En la barra de comandos escribir: *ls dautos c ipautos ydisp*, y luego ENTER:

Dependent Variable: DAUTOS				
Method: Least Squares				
Date: 07/24/02 Time: 11:12				
Sample: 1988 2001				
Included observations: 14				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	21.42181	8.424537	2.542788	0.0273
IPAUTOS	-0.391554	0.105780	-3.701596	0.0035
YDISP	0.109742	0.010440	10.51143	0.0000
R-squared	0.922375	Mean dependent var		19.72857
Adjusted R-squared	0.908261	S.D. dependent var		4.609093
S.E. of regression	1.396024	Akaike info criterion		3.692543
Sum squared resid	21.43772	Schwarz criterion		3.829484
Log likelihood	-22.84780	F-statistic		65.35301
Durbin-Watson stat	2.757532	Prob(F-statistic)		0.000001

$$DAUTOS = 21.42181264 - 0.391554485*IPAUTOS + 0.1097418292*YDISP$$

B. Docimar la hipótesis de que ante aumentos del ingreso disponible, los residentes del país “P” aumentarán su demanda por los autos en un 15% de los ingresos: ($\beta_3 = 0.15$)

PROCEDIMIENTO

- Estando en Output de la regresión, hacer clic en VIEW/ Coefficient Test / Wald Coefficient Restrictions.
- En la caja de dialogo que aparece, escribir la siguiente restricción: $C(3) = \beta_3 = 0.15$ y luego hacer clic en OK
- Seguidamente aparecerá los siguientes resultados:

Wald Test:			
Equation: EQ01			
Null Hypothesis: $C(3) = 0.15$			
F-statistic	14.86918	Probability	0.002671
Chi-square	14.86918	Probability	0.000115

En las salidas de la regresión se observa que la probabilidad asociada al estadístico F, es inferior al 5% (nivel de significancia), entonces se rechaza la hipótesis nula a un 95% de confianza, es decir que los residentes del país no modifican su demanda en un 15% ante cambios en su ingreso disponible.

C. Bajo la hipótesis anterior ($\beta_3 = 0.15$), estimar los parámetros restringidos

PROCEDIMIENTO:

- En el modelo inicial: $DAUTOS = \beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \mu$; introducir la restricción ($\beta_3 = 0.15$). Obtenemos el siguiente modelo:

$$\begin{aligned} DAUTOS &= \beta_1 + \beta_2 YDISP + (0.15) * IPAUTOS + \mu \\ DAUTOS - (0.15) * IPAUTOS &= \beta_1 + \beta_2 YDISP + \mu \\ DAUTOS1 &= \beta_1 + \beta_2 YDISP + \mu \quad \dots(a) \end{aligned}$$

- Se observa en el nuevo modelo (a) que la variable DAUTOS se ha transformado por lo tanto para regresionar el modelo se debe generar una nueva variable (dautos1).

- En el workfile hacer clic en Genr, digitar $dautos1 = dautos - 0.5*ipaautos$ y luego OK
- En la barra de comandos escribir: *ls dautos1 c ydisp*, y luego ENTER:
- Se obtendrán los siguientes resultados:

Dependent Variable: DAUTOS1				
Method: Least Squares				
Date: 07/02/99 Time: 00:37				
Sample(adjusted): 1988 2001				
Included observations: 14 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-19.58465	4.598165	-4.259230	0.0011
YDISP	0.073942	0.013652	5.416332	0.0002
R-squared	0.709701	Mean dependent var	5.065000	
Adjusted R-squared	0.685509	S.D. dependent var	4.383611	
S.E. of regression	2.458307	Akaike info criterion	4.768386	
Sum squared resid	72.51925	Schwarz criterion	4.859680	
Log likelihood	-31.37870	F-statistic	29.33665	
Durbin-Watson stat	1.291834	Prob(F-statistic)	0.000156	

Los parámetros restringidos serán: $\beta_1 = -19.58465$; $\beta_2 = 0.073942$; $\beta_3 = 0.15$

SE INCORPORA AL MODELO LA SIGUIENTE VARIABLE:

PUBL: Publicidad de autos (en billones de dólares de 1994).

AÑO	PUBL
1988	1.2
1989	1.6
1990	1.5
1991	2.1
1992	1.7
1993	1.8
1994	1.5
1995	1.9
1996	2.0
1997	1.8
1998	2.1
1999	2.4
2000	2.5
2001	3.0

$$DAUTOS = \beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \beta_4 PUBL + \mu \quad \dots \text{(Modelo II)}$$

C. DETERMINAR LA SIGNIFICANCIA INDIVIDUAL DE LA INCORPORACIÓN DE LA VARIABLE PUBL:

Para determinar la significancia de la inclusión de la nueva variable se realizará un análisis de varianza parcial. La dócima a realizar es:

H₀: La variable publ no mejora el modelo

H₁: La inclusión de la variable publ mejora el modelo

PROCEDIMIENTO:

- Ingresar los datos de la nueva variable (Quick/ Empty Group (Edit series)).
- En la barra de comandos escribir: **ls dautos c ipautos publ ydisp**, y luego ENTER:

Dependent Variable: DAUTOS				
Method: Least Squares				
Date: 07/24/02 Time: 11:39				
Sample: 1988 2001				
Included observations: 14				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
IPAUTOS	-0.073743	0.028366	-2.599733	0.0265
PUBL	8.510236	0.514967	16.52578	0.0000
YDISP	0.016691	0.005995	2.784276	0.0193
C	4.899746	1.938356	2.527785	0.0300
R-squared	0.997258	Mean dependent var		19.72857
Adjusted R-squared	0.996435	S.D. dependent var		4.609093
S.E. of regression	0.275181	Akaike info criterion		0.492180
Sum squared resid	0.757245	Schwarz criterion		0.674768
Log likelihood	0.554740	F-statistic		1212.339
Durbin-Watson stat	2.042640	Prob(F-statistic)		0.000000

$$DAUTOS = 4.899745974 - 0.07374303995 * IPAUTOS + 8.510235732 * PUBL + 0.01669149847 * YDISP$$

- El análisis de varianza parcial consiste en obtener un estadístico el cual se halla mediante la siguiente fórmula:

$$F_c = \frac{(SCE_{II} - SCE_I) / s}{(SCR_{II}) / (n - (k + s))}$$

k: N° de parámetros a estimar en el modelo inicial

s: N° de variables incluidas en el modelo

n: Total de la muestra

- Obtener las sumas explicada de los modelos (modelo I y modelo II). De las salidas de la regresión tenemos, para ello se usará la igualdad: $SCE = SCT - SCR$ (la SCT y la SCR se obtiene del output de la regresión)

MODELO I: $DAUTOS = \beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \mu$

DAUTOS: Demanda de autos

YDISP: Ingreso disponible

IPAUTOS: Índice de precios de los autos

A partir de la S.D. dependent var (4.609093) obtenemos la SCT (Suma cuadrado total)

$$SCT_1 = 4.609093^2 * (n-1) = 4.609093^2 * (14-1) = 276.168598$$

$$SCR_1 = \text{Sum squared resid} = 21.43772$$

$$SCE_1 = SCT_1 - SCR_1 = 276.16860 - 21.43772 = 254.73088$$

MODELO II: DAUTOS = $\beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \beta_4 PUBL + \mu$

DAUTOS: Demanda de autos

YDISP: Ingreso disponible

IPAUTOS: Índice de precios de los autos

PUBL: Publicidad de autos

A partir de la S.D. dependent var (4.609093) obtenemos la SCT (Suma cuadrado total)

$$SCT_{II} = 4.609093^2 * (n-1) = 4.609093^2 * (14-1) = 276.168598$$

$$SCR_{II} = \text{Sum squared resid} = 0.75725$$

$$SCE_{II} = SCT_{II} - SCR_{II} = 276.16860 - 0.75725 = 275.41135$$

Con las sumas obtenidas, hallamos:

$$SCE_{II} - SCE_I = 275.41135 - 254.73088 = 20.68047$$

$$SCR_{II} = 0.75725$$

Además: $k = 3$; $s = 1$ (inclusión de la variable PUBL); $n = 14$

$$F_c = \frac{(SCE_{II} - SCE_I)/s}{(SCR_{II})/(n-(k+s))} = \frac{20.68047/1}{0.75725/10} = 273.0996$$

El F de tablas ($F_{1, 10, 05}$) es 4.96. Entonces como el F calculado es mayor al F de tablas, se rechaza la Hipótesis nula, luego la inclusión de la nueva variable mejora el modelo.

D. ¿LOS RESIDUOS SE DISTRIBUYEN NORMALMENTE (en el modelo II)?

DAUTOS = $\beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \beta_4 PUBL + \mu$

Ho: Los residuos se distribuyen normalmente

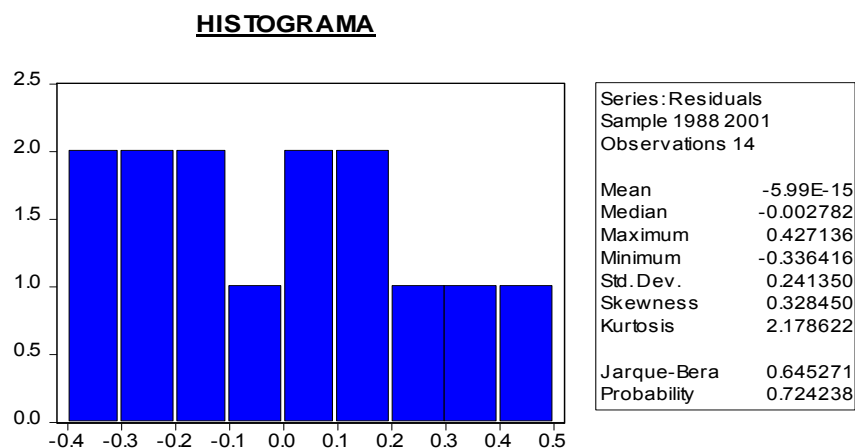
H₁: Los residuos no se distribuyen normalmente.

Se analiza la hipótesis utilizando el estadístico Jarque Bera. Bajo la hipótesis nula de normalidad, JB está distribuida como un estadístico Ji-cuadrado con 2 g de libertad.

La regla de decisión a partir de la observación de la probabilidad es: si es mayor que 0.05 se acepta Ho, en caso contrario se rechaza.

PROCEDIMIENTO:

- Estando en el Output de la regresión hacer clic en View/ Residual Tests/ Histogram-Normality Test
- Aparecerá la siguiente gráfica :



El estadístico Jarque-Bera revela que ante un nivel de significancia del 5% no existe suficiente evidencia para rechazar la hipótesis nula, en consecuencia se acepta que los residuos se distribuyen normalmente.

E. ¿LOS PARÁMETROS SON ESTABLES EN EL PERÍODO DE ANÁLISIS (en el modelo II)?

H₀: Los parámetros son estables en el periodo de análisis

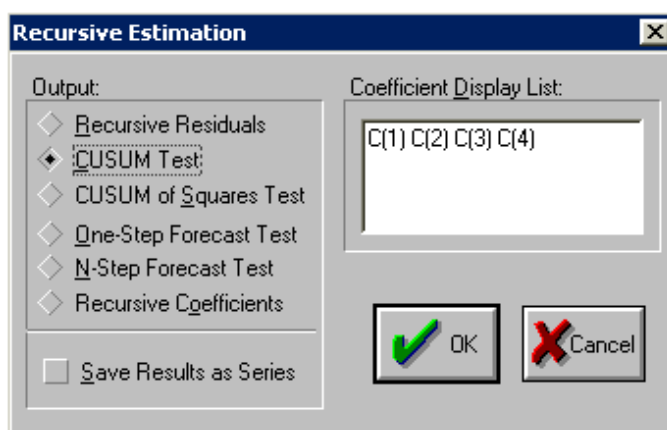
H₁: Los parámetros no son estables en el periodo de análisis

$$DAUTOS = \beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \beta_4 PUBL + \mu$$

Se puede verificar la estabilidad de parámetros mediante los test de CUSUM y CUSUM Q ambos contrastan la H₀: los parámetros son estables en el período de análisis.

PROCEDIMIENTO:

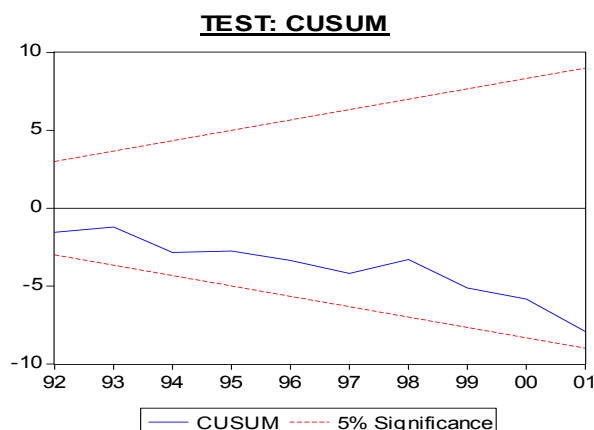
- Estando en el Output de la regresión hacer clic en View/ Stability Tests/ Recursive Estimates (OLS only)
- Aparecerá la siguiente caja de dialogo:




- Seleccionar el Test que se desea evaluar y hacer clic en OK
- Para hallar el test de Cusum, seleccionar CUSUM Test y para realizar el Test de Cusum Q, seleccionar la alternativa CUSUM of Squares Test.

Evaluando mediante los siguientes test, obtenemos:

TEST DE CUSUM: Observamos en la gráfica que el estadístico no sale fuera de las bandas de confianza, por lo tanto se puede afirmar que los parámetros son estables en el período de análisis, a un nivel de confianza del 95%.



TEST DE CUSUM Q: El estadístico no sale fuera de las bandas de confianza, por lo tanto se puede afirmar que los parámetros son estables en el período de análisis, a un nivel de 5% de significancia.



F. ¿EL MODELO II ESTÁ CORRECTAMENTE ESPECIFICADO?

$$DAUTOS = \beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \beta_4 PUBL + \mu$$

Ho: El modelo está correctamente especificado

H1: El modelo no está correctamente especificado

PROCEDIMIENTO:

- Estando en el Output de la regresión hacer clic en View/ Stability Tests/ Ramsey RESET Test.
- Aparecerá la siguiente caja de dialogo, en la cual se debe especificar el número de términos que se va agregar al Test (en el ejemplo se escogió 2 términos). Seguidamente hacer clic en OK:



F-statistic	3.836146	Probability	0.067894	
Log likelihood ratio	9.414339	Probability	0.009030	
Test Equation:				
Dependent Variable: DAUTOS				
Method: Least Squares				
Date: 08/01/02 Time: 09:25				
Sample: 1988 2001				
Included observations: 14				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5.027819	1.865505	2.695151	0.0273
IPAUTOS	-0.134954	0.055682	-2.423641	0.0416
PUBL	11.76966	5.379121	2.188026	0.0601
YDISP	0.028890	0.012466	2.317498	0.0491
FITTED^2	-0.013080	0.030646	-0.426809	0.6808
FITTED^3	9.30E-05	0.000475	0.195538	0.8498
R-squared	0.998600	Mean dependent var	19.72857	
Adjusted R-squared	0.997726	S.D. dependent var	4.609093	
S.E. of regression	0.219812	Akaike info criterion	0.105441	
Sum squared resid	0.386540	Schwarz criterion	0.379323	
Log likelihood	5.261910	F-statistic	1141.542	
Durbin-Watson stat	3.301186	Prob(F-statistic)	0.000000	

Aplicando la Prueba de Reset Ramsey, obtenemos que a un nivel de 5% de significancia, se acepta la hipótesis nula, es decir que el modelo está correctamente especificado (se llega a esta conclusión observando la probabilidad asociada (6.7%), que es mayor al 5%)

G. PREDECIR LA DEMANDA DE AUTOS PARA LOS AÑOS 2002-2005, DADO LAS PROYECCIONES PARA LOS AÑOS 2002-2005

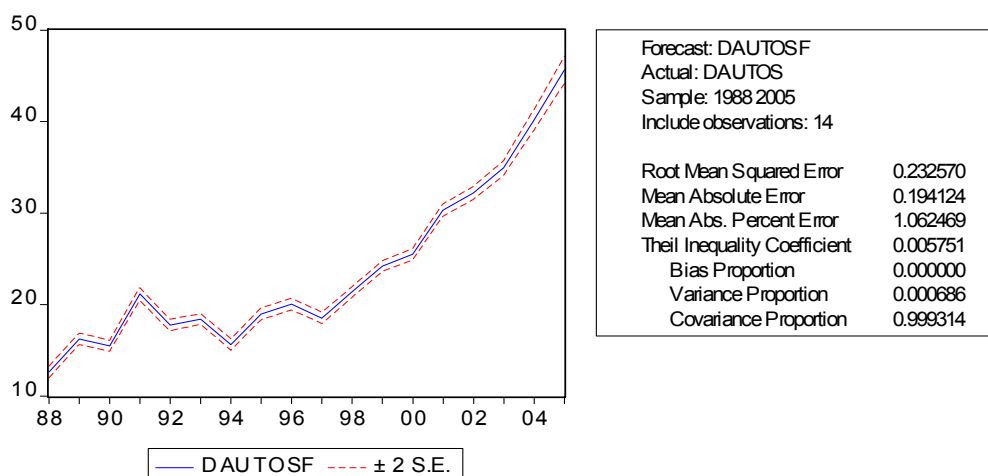
AÑO	IPAUTOS	PUBL	YDISP
2002	99.00000	3.200000	440.3000
2003	99.50000	3.500000	454.6000
2004	99.90000	4.100000	462.8000
2005	98.70000	4.700000	479.8000

Se tienen el modelo:

$$DAUTOS = \beta_1 + \beta_2 YDISP + \beta_3 IPAUTOS + \beta_4 PUBL + \mu$$

PROCEDIMIENTO:

- Expandir el rango del período de análisis. Estando en el workfile hacer clic en Procs/ Change Workfile Range, en la caja de diálogo que aparece cambiar la fecha de término: digitar 2005 en al fecha final.
- Luego cambiar el tamaño de la muestra. Estando en el workfile hacer clic en el botón Sample. Digitar el nuevo tamaño de la muestra.
- En el workfile seleccionar las variables exógenas (haciendo clic conjuntamente con la tecla CONTROL), luego hacer clic derecho y escoger la alternativa Open/ as Group.
- Hacer clic en el botón Edit +/- y escribir los valores de las variables exógenas para los años que se va a predecir (2002-2005).
- Luego del llenado de los datos, hacer clic en el botón de la esquina superior del cuadro y hacer clic en YES.
- Estando en el output de la regresión inicial, hacer clic en el botón/OK. Aparecerá la siguiente gráfica, donde se observa el valor proyectado de la variable dependiente:

DEMANDA DE AUTOS (1988-2005)

- En los resultados de la predicción podemos analizar la calidad del modelo para la predicción mediante dos estadísticos: la raíz cuadrática media y el índice de Theil. Estos deben ser muy cercanos a cero para que el modelo sea bueno para la predicción. En este ejercicio la raíz cuadrática media es bajo (23 %), por lo tanto se dirá que el modelo es bueno para predecir. El índice de Theil es un indicador más eficaz, en el ejercicio toma el valor de 0.0058, se concluye entonces que el modelo es bueno para la predicción.
- Los valores estimados y proyectados se grabaran automáticamente en el workfile con un nuevo nombre (en el ejemplo: DAUTOSF). Para ver los valores de esta variable hacer doble clic en la nueva variable.

La demanda de autos para los siguientes cuatro años será:

AÑO	DAUTOS
2002	32.18121
2003	34.93609
2004	40.14961
2005	45.62800

LABORATORIO 03

REGRESIÓN POR MINIMOS CUADRADOS

Modelo Econométrico:

$$Y = K^\alpha + L^\beta$$

Donde:

Y: nivel de producción

K: factor de producción (horas - máquina)

L: factor de producción (horas de trabajo)

$$\text{Log } Y = \alpha \text{Log } K + \beta \text{Log } L + \mu$$

Estimación:

Existen varias formas de realizar una regresión por MCO:

- Ingresar a QUICK / ESTIMATE EQUATION. En este caso para definir la ecuación se debe listar las variables colocando primero la endógena y luego las exógenas.
- Escribir en el editor: LS (Least Squares) y luego la variable endógena seguida de las exógenas.

Al estimar la ecuación *LY C LK LL*, encontramos los siguientes resultados:

Dependent Variable: LY				
Method: Least Squares				
Date: 05/24/02 Time: 07:53				
Sample: 1985 1999				
Included observations: 15				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LL	1.788728	0.458296	3.902993	0.0021
LK	0.899058	0.233206	3.855215	0.0023
C	-13.18104	2.188629	-6.022511	0.0001
R-squared	0.956417	Mean dependent var	5.743963	
Adjusted R-squared	0.949153	S.D. dependent var	0.614351	
S.E. of regression	0.138532	Akaike info criterion	-0.938581	
Sum squared resid	0.230292	Schwarz criterion	-0.796971	
Log likelihood	10.03936	F-statistic	131.6682	
Durbin-Watson stat	1.588439	Prob(F-statistic)	0.000000	

R-squared (0.956417): Mide el éxito de la ecuación de regresión dentro de la muestra.

$$R^2 = 1 - \frac{\sum_{t=1}^T e_t^2}{\sum_{t=1}^T (y_t - \bar{y})^2}$$

Adjusted R-squared (0.949153): Castiga al R^2 por la inclusión de mayores variables explicativas.

$$R^2 = 1 - \frac{\frac{1}{T-k} \sum_{t=1}^T e_t^2}{\frac{1}{T-1} \sum_{t=1}^T (y_t - \bar{y})^2}$$

S.E. of regresión (0.13853): (error estándar de la regresión) Es la variable muestral, es decir un estimado de la varianza de los errores poblacionales.

$$S^2 = \frac{\sum_{t=1}^T e_t^2}{T - k}$$

Sum squared resid (0.230292): Es el valor que obtiene la suma de los residuos al cuadrado cuando han sido minimizado, por sí mismo no tiene mucho valor, pero sirve como dato en otras pruebas.

$$SCR = \sum_{t=1}^T e_t^2$$

Log likelihood (10.03936): (Verosimilitud logarítmica) Es el valor maximizado del logaritmo de la función de verosimilitud, no tiene aplicación directa, pero es útil para comparar modelos y comprobar hipótesis.

Durbin-Watson stat (1.588439): (estadístico Durbin Watson) Mide la autocorrelación de los errores de primer orden.

$$DW = \frac{\sum_{t=1}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}$$

Mean dependent var (5.743963): Es el promedio de la variable dependiente.

$$\bar{y} = \frac{1}{T} \sum_{t=1}^T y_t$$

S.D. dependent var (0.614351): (desviación estándar de la variable dependiente) Mide la desviación estándar muestral de la variable dependiente.

$$DS = \sqrt{\frac{\sum_{t=1}^T (y_t - \bar{y})^2}{T - 1}}$$

Akaike info criterion (-0.938581): También es un estimador de la varianza del error, pero penaliza aún más los grados de libertad. Se usa para elegir entre modelos alternativos.

$$AIC = \exp(-2k/T) \frac{\sum_{t=1}^T e_t^2}{T}$$

Schwarz criterion (-0.796971): Penaliza aún más los grados de libertad

$$SIC = T \frac{k}{T} \frac{\sum_{t=1}^T e_t^2}{T}$$

F-statistic (131.6682): Se emplea para comprobar la hipótesis de los coeficientes de todas las variables en la regresión.

$$F = \frac{\frac{SCR_{res} - SCR}{k - 1}}{\frac{SCR}{T - k}}$$

Prob(F-statistic) (0.000000): Indica que se rechaza abrumadoramente la hipótesis nula de no significancia.

ESTABILIDAD DE LOS PARÁMETROS

Modelo Econométrico:

$$Llban_t = Llpbi_t + Llban_{t-1}$$

Donde:

$Llban_t$: Logaritmo de la liquidez en el sistema bancario en el periodo t.

$Llpbi_t$: Logaritmo del PBI en el periodo t.

$Llban_{t-1}$: Logaritmo de la liquidez en el sistema bancario en el periodo t-1.


ESTIMACIÓN DEL MODELO POR MCO

$$ls Llban_t \ c \ Llpbi_t \ Llban_{t-1}$$

El Output de la regresión es el siguiente:

Dependent Variable: LLBAN				
Method: Least Squares				
Date: 06/07/02 Time: 17:55				
Sample(adjusted): 1971 1987 1991 2001				
Included observations: 28 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LPBI	0.175059	0.032430	5.398090	0.0000
LLBAN(-1)	0.809000	0.036476	22.17872	0.0000
R-squared	0.940227	Mean dependent var	10.20872	
Adjusted R-squared	0.937928	S.D. dependent var	0.376366	
S.E. of regression	0.093768	Akaike info criterion	-1.827230	
Sum squared resid	0.228605	Schwarz criterion	-1.732072	
Log likelihood	27.58122	F-statistic	408.9818	
Durbin-Watson stat	1.674632	Prob(F-statistic)	0.000000	

Dentro de View optar por la opción Actual, FITTED; RESIDUAL/ GRAPH: Se observa la gráfica de los valores actuales y estimados de la variable dependiente, así como los residuos:



La estabilidad de parámetros es uno de los supuestos de la estimación MCO. Mediante los test de estabilidad, podemos determinar si los estimadores MCO de una ecuación son estables en el período de análisis.

- Test de Punto de Quiebre de Chow
- Test de Residuos recursivos
- Test CUSUM y CUSUM CUADRADO
- Test de Coeficientes recursivos

TEST DE PUNTO DE QUIEBRE DE CHOW

- ◆ Regresionar el modelo MCO
- ◆ Ingresar a VIEW/ STABILITY TEST / BREAKPOINT TEST
- ◆ Ingresar la Fecha de quiebre estructural.
- ◆ La Hipótesis nula es que no hay cambio estructural.


Escogemos el año 1986:

Chow Breakpoint Test: 1986		
F-statistic	1.710077	0.199863
		Probability
Log likelihood ratio	3.697322	0.157448
		Probability

Concluimos que no existe quiebre estructural al 5% de significancia. Los parámetros son estables en el tiempo.

TEST DE RESIDUOS RECURSIVOS



- ◆ Regresionar el modelo MCO
- ◆ Ingresar a VIEW/ STABILITY TEST / RECURSIVE ESTIMATES
- ◆ Seleccionar la opción RECURSIVE RESIDUALS
- ◆ Si la gráfica de residuos recursivos sale fuera de las bandas, entonces los parámetros son inestables en el período de análisis (al 5% de significancia).



Como el gráfico está dentro de las bandas, podemos aseverar que no existe suficiente evidencia para rechazar la H_0 a un 95% de confianza, es decir que los parámetros son estables en el período de análisis. (1971-1987, 1991-2001)

TEST CUSUM Y CUSUM CUADRADO

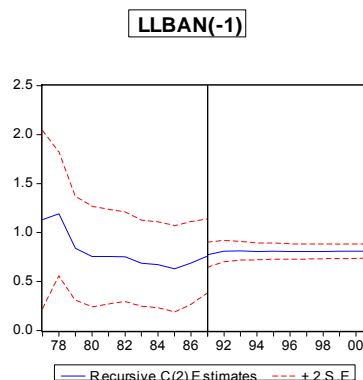
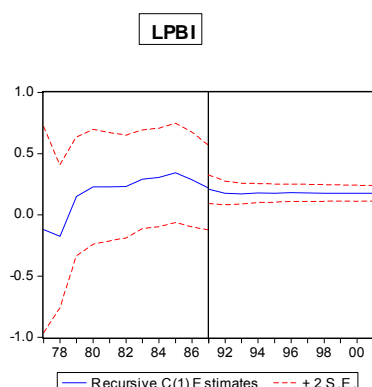
- ◆ Regresionar el modelo MCO
- ◆ Ingresar a VIEW/ STABILITY TEST / RECURSIVE ESTIMATES
- ◆ Seleccionar la opción CUSUM O CUSUM OF SQUARES TEST.
- ◆ El programa reporta un gráfico, conteniendo la evolución de un estadístico. Si el estadístico se encuentra dentro de las bandas, entonces los parámetros son estables en el período de análisis (al 5% de significancia). No existe suficiente evidencia para rechazar la H_0 de estabilidad de los parámetros.



Ambos estadísticos nos señala que los parámetros en el tiempo, a un 95% de confianza (se acepta la H_0)

TEST DE RECURSIVOS COEFICIENTES

- ◆ Regresionar el modelo MCO
- ◆ Ingresar a VIEW/ STABILITY TEST / RECURSIVE ESTIMATES
- ◆ Seleccionar la opción RECURSIVE COEFFICIENTS.
- ◆ Si la gráfica presenta cambios significativos quiere decir que el parámetro es inestable, a un 95 % de confianza.




Se observa que las gráficas no presentan cambios significativos, por lo tanto no podemos rechazar la H_0 de estabilidad de los parámetros, a un 5% de significancia

NORMALIDAD DE LOS RESIDUOS

El supuesto de normalidad de las perturbaciones es importante por cuanto dependiendo de la validez de dicho supuesto, podremos hacer inferencia estadística sobre los parámetros y cualquier prueba de hipótesis.

PROCEDIMIENTO

- ◆ Regresionar el modelo MCO
- ◆ Ingresar a VIEW/ RESIDUAL TEST
- ◆ Seleccionar la opción HISTOGRAM-NORMALITY TEST.
- ◆ El estadístico Jarque Bera nos permite verificar la normalidad de los residuos. La H_0 es que los residuos se distribuyen normalmente. Si la probabilidad asociada al estadístico es mayor al 5%, entonces no se puede rechazar la H_0 de normalidad de los residuos.

HISTOGRAMA TEST DE NORMALIDAD DE RESIDUOS

La probabilidad asociada del estadístico Jarque Bera nos señala que no debemos rechazar la hipótesis nula de normalidad de los residuos, bajo un nivel de significancia del 5%.

MODELO CON VARIABLES DUMMY:

Generar la variable dummy para eliminar la perturbación que genera el periodo atípico:

PROCEDIMIENTO

- ◆ En el Workfile, hacer click en Genr; aparecerá una caja de diálogo en donde se debe escribir lo siguiente:
- ◆ $d1 = 1$, en la parte inferior de la caja de diálogo (simple) digitar el periodo: 1970:1987, 1991:2001, y ENTER
- ◆ Luego, Hacer nuevamente clic en Genr y escribir: $d = 0$, en la parte inferior de la caja de diálogo (sample) digitar el periodo: 1988: 1990.
- ◆ Regresionar el modelo inicial incluyendo la variable d .

$$d1 = \begin{cases} 1 & \text{periodo } 1970 - 1987, 1991 - 2001 \\ 0 & \text{periodo } 1988 - 1990 \end{cases}$$

1° Forma (intercepto)

$$Llban_t = \alpha_0 + \alpha_1 d_t + \beta_1 Llpbi_t + \beta_2 Llban_{t-1} + \mu_t$$

Regresionar : ls Llban_t c d1 Lpbi_t Llban_{t-1}

Dependent Variable: LLBAN				
Method: Least Squares				
Date: 08/13/02 Time: 22:14				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.813114	1.307002	1.387231	0.1767
D1	0.719657	0.065899	10.92055	0.0000
LPBI	-0.000197	0.110178	-0.001788	0.9986
LLBAN(-1)	0.756721	0.040163	18.84136	0.0000
R-squared	0.960740	Mean dependent var		10.10262
Adjusted R-squared	0.956378	S.D. dependent var		0.494309
S.E. of regression	0.103241	Akaike info criterion		-1.583581
Sum squared resid	0.287787	Schwarz criterion		-1.398550
Log likelihood	28.54551	F-statistic		220.2396
Durbin-Watson stat	1.961862	Prob(F-statistic)		0.000000

Se observa en las salidas de la regresión que la variable incorporada (dummy para el intercepto) es significativa en el modelo, pero la variable LPBI se hace no significativa a un nivel de 5% de significancia.

2° Forma (pendiente)

$$Llban_t = \alpha_0 + \beta_1 Llpbi_t + \beta_2 Llban_{t-1} + \beta_3 d1_t Llpbi_t + \mu_t$$

ls Llban c Lpbi Llban(-1) d1*Lpbi

Dependent Variable: LLBAN				
Method: Least Squares				
Date: 08/13/02 Time: 22:23				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.511355	1.307247	1.921102	0.0653
LPBI	-0.062342	0.109981	-0.566840	0.5755
LLBAN(-1)	0.757647	0.039912	18.98311	0.0000
D1*LPBI	0.063204	0.005749	10.99471	0.0000
R-squared	0.961171	Mean dependent var		10.10262
Adjusted R-squared	0.956857	S.D. dependent var		0.494309
S.E. of regression	0.102672	Akaike info criterion		-1.594631
Sum squared resid	0.284624	Schwarz criterion		-1.409600
Log likelihood	28.71678	F-statistic		222.7868
Durbin-Watson stat	1.960242	Prob(F-statistic)		0.000000

La variable dummy (para la pendiente) es significativa en el modelo, pero la variable LPBI es no significativa en el modelo, ello a un nivel de 5% de significancia.

3° Forma (intercepto y pendiente)

$$Llban_t = \alpha_0 + \alpha_1 d1_t + \beta_1 Llpbi_t + \beta_2 Llban_{t-1} + \beta_3 d1_t Llpbi_t + \mu_t$$

ls Llban c d1 Lpbi Llban(-1) d1*Lpbi

Dependent Variable: LLBAN				
Method: Least Squares				
Date: 08/13/02 Time: 22:27				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	21.46369	8.983732	2.389173	0.0244
D1	-19.60577	9.206065	-2.129658	0.0428
LPBI	-1.751282	0.799772	-2.189728	0.0377
LLBAN(-1)	0.787394	0.040045	19.66269	0.0000
D1*LPBI	1.782919	0.807525	2.207880	0.0363
R-squared	0.966938	Mean dependent var		10.10262
Adjusted R-squared	0.961852	S.D. dependent var		0.494309
S.E. of regression	0.096546	Akaike info criterion		-1.690907
Sum squared resid	0.242349	Schwarz criterion		-1.459618
Log likelihood	31.20905	F-statistic		190.1031
Durbin-Watson stat	1.990491	Prob(F-statistic)		0.000000

Las salidas de la regresión nos indica que toda las variables son significativas en el modelo, ya que las probabilidades asociadas de éstas, son inferiores a 0.05, por lo tanto se puede rechazar la Ho de no significatividad de los parámetros.. Además el R² es alto y el modelo no posee problemas de autocorrelación de primer grado. La probabilidad asociada al F estadístico, nos indica que las variables regresoras explican muy bien a la variable dependiente.

MODELOS LINEALES Y PREDICCIÓN

CASO: HARINA DE PESCADO

Se tiene los siguientes modelos y los siguientes outputs:

$$\text{MODELO 1: } \text{VOLUMENX}_t = \alpha_1 + \alpha_2 \text{PRECIOX}_t + \alpha_3 \text{IPCX}_t + \mu_t$$

$$\text{MODELO 2: } \text{VOLUMENX}_t = \alpha_1 + \alpha_2 \text{PRECIOX}_t + \alpha_3 \text{IPCX}_t + \alpha_4 \text{IPCPBI}_t + \mu_t$$

Donde:

VOLUMENX = Volumen de exportación de harina de pescado,

PRECIOX = Precio de exportación de la harina de pescado,

IPCX = Índice de precios de las exportaciones,

IPCPBI = Índice de precios del PBI

PERU: EXPORTACIONES Y PRECIOS DE HARINA DE PESCADO Y PRECIOS

AÑO	Harina de	Precio	IPC	IPC	Volumen
	pescado				
	MM US\$	US\$/tm			
1970	303	162	0.000000643	0.000000359	1873
1971	267	153	0.000000588	0.000000384	1750
1972	219	144	0.000000592	0.000000414	1524
1973	138	395	0.000000842	0.000000047	348
1974	202	321	0.000001068	0.000000542	629
1975	168	216	0.000000996	0.000000668	781
1976	168	284	0.000001408	0.000000862	592
1977	184	422	0.00000224	0.00000117	436
1978	196	405	0.000004123	0.000001859	483
1979	256	390	0.000008366	0.000003225	657
1980	195	469	0.00001267	0.000005279	417
1981	141	448	0.000017008	0.000009029	315
1982	202	329	0.000025912	0.000015138	616
1983	80	387	0.000060568	0.000031389	205
1984	137	342	0.000127313	0.000066829	401
1985	118	233	0.00035821	0.000178604	508
1986	206	288	0.000457197	0.000308954	716
1987	229	308	0.000743838	0.0005632	741
1988	356	439	0.006599323	0.004107135	812
1989	411	372	0.14	0.11	1103
1990	339	310	9.44	6.75	1093
1991	441	393	33.3	31.9	1123
1992	427	430	55	53.9	993
1993	545	348	81.8	79.3	1568
1994	713	321	100	100	2221
1995	712	392	113.8	112.9	1816
1996	835	519	124.2	124.8	1610
1997	1031	535	136.1	134.3	1926
1998	392	588	127.8	142.9	666
1999	533	360	139.1	148.6	1482
2000	873	371	148.7	154	2352

a.- Analice los R^2 y los R^2 ajustado de ambos modelos ¿Qué se puede afirmar?

Resumiendo la bondad del ajuste para ambos modelos:

	Modelo 1	Modelo 2
R²	0.732639	0.808625
R² ajustado	0.713542	0.787361

Podemos observar que el coeficiente de determinación ha crecido al considerar la variable Índice de precios del PBI, lo cual implica que se da una mejor explicación al modelo.

Resultados Modelo 1

Dependent Variable: VOLUMENX				
Method: Least Squares				
Date: 09/10/02 Time: 10:18				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1920.016	220.8601	8.693359	0.0000
PRECIOX	-3.543931	0.642381	-5.516871	0.0000
IPCX	10.73698	1.249634	8.592100	0.0000
R-squared	0.732639	Mean dependent var	1024.419	
Adjusted R-squared	0.713542	S.D. dependent var	615.0496	
S.E. of regression	329.1857	Akaike info criterion	14.52289	
Sum squared resid	3034170.	Schwarz criterion	14.66166	
Log likelihood	-222.1047	F-statistic	38.36362	
Durbin-Watson stat	1.013287	Prob(F-statistic)	0.000000	

Wald Test:			
Equation: Untitled			
Null Hypothesis:	C(2)+3*C(3)=10		
F-statistic	28.51752	Probability	0.000011
Chi-square	28.51752	Probability	0.000000

Resultados Modelo 2

Dependent Variable: VOLUMENX				
Method: Least Squares				
Date: 09/10/02 Time: 10:24				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1835.397	192.0336	9.557687	0.0000
PRECIOX	-3.356909	0.556396	-6.033306	0.0000
IPCX	69.13566	17.86850	3.869137	0.0006
IPCPBI	-56.81575	17.35257	-3.274197	0.0029
R-squared	0.808625	Mean dependent var		1024.419
Adjusted R-squared	0.787361	S.D. dependent var		615.0496
S.E. of regression	283.6168	Akaike info criterion		14.25304
Sum squared resid	2171840.	Schwarz criterion		14.43807
Log likelihood	-216.9221	F-statistic		38.02798
Durbin-Watson stat	0.987144	Prob(F-statistic)		0.000000

Wald Test:			
Equation: Untitled			
Null Hypothesis:	C(2)+3*C(3)=10		
F-statistic	13.08252	Probability	0.001208
Chi-square	13.08252	Probability	0.000298

b.- Pruebe la significancia de incorporar la variable IPCPBI al modelo (mediante un análisis de varianza parcial).

Para determinar la significancia de la inclusión de la nueva variable se realizará un análisis de varianza parcial. La dócima a realizar es:

Ho: La variable IPCPBI no mejora el modelo,

H1: La inclusión de la variable IPCPBI mejora el modelo.

Modelo1: (n= 31)

$$SCT = 615.0496^2 * (n-1) = 11'348,580.31$$

$$SCR = 3'034,170$$

$$SCE = SCT - SCR = 8'314,410.31$$

Modelo 2: (n=31)

$$SCT = 615.0496^2 * (n-1) = 11'348,580.31$$

$$SCR = 2'171,840$$

$$SCE = SCT - SCR = 9'176,740.31$$

De los 02 modelos hallamos:

$$SCE(2) - SCE(1) = 9'176,740.31 - 8'314,410.31 = 862,330$$

$$SCR(2) = 2'171,840$$

Además:

$$K = 3; s = 1; n = 31$$

$$F_c = \frac{862,330 / 1}{2'171,840 / 27} = \frac{862,330}{80,438.51} = 10.72$$

La F de tablas (F1,27,05) es 4.215. El F calculado es mayor al F de tablas, se rechaza la hipótesis nula, la inclusión de la nueva variable mejora el modelo.

c.- Docimar la restricción $\alpha_2 + 3*\alpha_3 = 10$

De acuerdo con los resultados obtenidos para ambos modelos, se observa que la probabilidad asociada al estadístico F es inferior al 5%, entonces se rechaza la hipótesis nula a un 95% de confianza.

d.- Estimar los parámetros bajo la restricción anterior

Del modelo 1, se tiene:

$$VOLUMENX_t = \alpha_1 + \alpha_2 PRECIOX_t + \alpha_3 IPCX_t + \mu_t$$

$$\alpha_2 + 3*\alpha_3 = 10$$

$$\alpha_2 = 10 - 3*\alpha_3$$

reemplazando:

$$VOLUMENX = \alpha_1 + (10-3*\alpha_3)*PRECIOX + \alpha_3*IPCX$$

$$VOLUMENX = \alpha_1 + 10*PRECIOX - 3*\alpha_3*PRECIOX + \alpha_3*IPCX$$

$$VOLUMENX - 10*PRECIOX = \alpha_1 + \alpha_3*(IPCX - 3*PRECIOX)$$

$$VOLPRECIO = \alpha_1 + \alpha_3 *IPCPRECIO$$

Donde:

$$VOLPRECIO = VOLUMENX - 10*PRECIOX$$

$$IPCPRECIO = (IPCX - 3*PRECIOX)$$

$$\alpha_2 = 10 - 3*\alpha_3$$

Dependent Variable: VOLPRECIO				
Method: Least Squares				
Date: 09/10/02 Time: 11:20				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1758.992	305.4387	5.758904	0.0000
IPCPRECIO	4.152439	0.283533	14.64533	0.0000
R-squared	0.880897	Mean dependent var		-2547.839
Adjusted R-squared	0.876789	S.D. dependent var		1309.211
S.E. of regression	459.5508	Akaike info criterion		15.16072
Sum squared resid	6124421.	Schwarz criterion		15.25323
Log likelihood	-232.9911	F-statistic		214.4857
Durbin-Watson stat	0.564516	Prob(F-statistic)		0.000000


Los parámetros restringidos serán:

$$\alpha_1 = 1758.992$$

$$\alpha_3 = 4.152439$$

$$\alpha_2 = 10 - 3 * 4.152439 = -2.457317$$

e.- Si las variables PRECIOX, IPCX y IPCPBI, aumentan en el año 2002 en 10%, 8% y 5% respectivamente. Hallar la predicción de la variable VOLUMENX para ese año.



f.- Es el modelo bueno para predecir?

Al realizar la simulacion sobre los datos historicos, encontramos un Coeficiente de Desigualdad de Theil = 0.112648.

Este indicador trata de acotar el valor del indicador de bondad de prediccion entre [0,1]. Muestra si la correlacion entre los valores observados en una prediccion expost es alta o baja. En nuestro caso el U no tiende a 0, con lo cual el modelo no puede ser utilizado para predecir.

El Coeficiente de Theil se puede descomponer en:

Bias Proportion=0.000; El Bias proportion indica algun error sistemático. En nuestro caso, no existe error sistematico.

Variance Proportion=0.053055; La Variance Proportion indica la habilidad del pronostico para replicar la variabilidad de la variable real observada. Si es muy alto tiene una menor capacidad de replicar el comportamiento de la serie. En nuestro caso este indicador es bastante bajo.

Covariance Proportion=0.946945; El Covariance Proportion indica la correlacion entre los valores predichos y los valores observados. En nuestro caso, el modelo tiene adecuada capacidad de replicar los quiebres de la variable estudiada.

Pero, en general no se recomienda utilizar el modelo para predecir por que el indicador de Theil es muy alto y no tiende a cero.

LABORATORIO 04**MULTICOLINEALIDAD**

MODELO: $IMPORT = f(FBK, IPC, IPIMP, PBI, PRPBIIMP, TC)$

IMPORT: Importaciones (en millones de n. s. de 1994)

FBK: Formación Bruta de Capital (Inversión)

IPC: Índice de Precios al consumidor (base 1994 = 100)

IPIMP: Índice de Precios de las importaciones

PBI: Producto Bruto Interno (millones de n.s. de 1994)

PRPBIIMP: Precios relativos del PBI con respecto a las importaciones

TC: Tipo de Cambio

ls import c fbk ipc ipimp pbi prpbiimp tc

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/22/02 Time: 22:20				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2415.177	1724.547	1.400470	0.1742
FBK	0.694739	0.050926	13.64202	0.0000
IPC	39.40721	46.41346	0.849047	0.4042
IPIMP	45.08153	78.19173	0.576551	0.5696
PBI	-0.049104	0.016365	-3.000441	0.0062
PRPBIIMP	2397.155	1346.987	1.779643	0.0878
TC	-2686.357	2703.368	-0.993708	0.3303
R-squared	0.978953	Mean dependent var	13535.42	
Adjusted R-squared	0.973691	S.D. dependent var	4362.854	
S.E. of regression	707.6618	Akaike info criterion	16.15749	
Sum squared resid	12018844	Schwarz criterion	16.48129	
Log likelihood	-243.4411	F-statistic	186.0465	
Durbin-Watson stat	1.602012	Prob(F-statistic)	0.000000	

Observamos que algunos de los parámetros no son significativos (la constante, IPC, IPIMP y el TC) a un nivel de significancia del 5%. El estadístico F nos dice que la variable dependiente es explicado por el modelo en su conjunto, además el éxito de la regresión es de 98% (R^2). No obstante de acuerdo a la teoría económica los signos que acompañan a algunas variables están cambiados.

De acuerdo a la teoría económica debe haber una relación positiva entre las importaciones y el IPC, FBK, PBI, PRPBIIMPOR. Debe Darse una relación negativa entre las importaciones y el IPIMP, y el TC. Los resultados no muestran necesariamente ello.

ESPECIFICACIÓN DEL MODELO**TEST DE RESET RAMSEY**

- ◆ En el Output de la regresión hacer clic en View/ Stability Tests/ Ramsey RESET Test/ 2
- ◆ La Ho es que el modelo está correctamente especificado
- ◆ Obtenemos las siguientes salidas

Ramsey RESET Test:				
F-statistic	1.548750	Probability	0.234809	
Log likelihood ratio	4.083500	Probability	0.129801	
Test Equation:				
Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/22/02 Time: 22:51				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6158.230	3446.215	1.786954	0.0877
FBK	-0.347838	1.009241	-0.344654	0.7336
IPC	-127.9753	105.4132	-1.214034	0.2376
IPIMP	26.52713	117.4411	0.225876	0.8234
PBI	0.025511	0.074692	0.341547	0.7359
PRPBIIMP	-741.2388	3513.452	-0.210972	0.8349
TC	3496.867	5254.115	0.665548	0.5126
FITTED^2	8.57E-05	9.88E-05	0.867419	0.3951
FITTED^3	-1.31E-09	2.16E-09	-0.606135	0.5506
R-squared	0.981550	Mean dependent var	13535.42	
Adjusted R-squared	0.974841	S.D. dependent var	4362.854	
S.E. of regression	692.0160	Akaike info criterion	16.15480	
Sum squared resid	10535494	Schwarz criterion	16.57111	
Log likelihood	-241.3993	F-statistic	146.3029	
Durbin-Watson stat	2.066392	Prob(F-statistic)	0.000000	

La probabilidad asociada a este estadístico nos señala que a un nivel de significancia del 5% no se debe rechazar la Ho, es decir que el modelo está correctamente especificado. Esta conclusión errónea que contradice el planteamiento inicial, nos conduce a plantear que primero debe solucionarse el problema de la multicolinealidad

1. DETECCIÓN DE MULTICOLINEALIDAD

A. La multicolinealidad se detecta tradicionalmente cuando se cumple lo siguiente:

- ◆ Estadísticos “t” no significativos
- ◆ R^2 altos
- ◆ Parámetros estimados diferente a los esperados

En las salidas de la regresión observamos que algunos de los coeficientes no son significativos y el R^2 es alto, además los coeficientes de algunas variables tienen signos contrarios a los que la teoría económica señala. Entonces cabe la posibilidad de que el modelo tenga problemas de multicolinealidad.

B. Un segundo método consiste en hallar la matriz de correlaciones de las variables. Si la correlación entre dos variables es cercana a 1, entonces podría existir multicolinealidad en el modelo.

PASOS:

- ◆ Seleccionar las variables independientes del modelo, en el workfile sombrear estas variables, hacer clic derecho, luego OPEN/ AS GROUP
- ◆ Se abrirá una ventana con los datos de las variables. En esta ventana hacer clic en VIEW/ CORRELATION
- ◆ Aparecerá la matriz de correlación.

	FBK	IPC	IPIMP	PBI	PRPBIIMP	TC
FBK	1.000000	0.677333	0.655700	0.806744	0.431248	0.647928
IPC	0.677333	1.000000	0.998190	0.756649	0.830123	0.996716
IPIMP	0.655700	0.998190	1.000000	0.748190	0.828185	0.999139
PBI	0.806744	0.756649	0.748190	1.000000	0.487402	0.744262
PRPBIIMP	0.431248	0.830123	0.828185	0.487402	1.000000	0.826176
TC	0.647928	0.996716	0.999139	0.744262	0.826176	1.000000

Se observa que la variable IPC está altamente correlacionada con las variables IPIMP y el TC, alrededor del 99%; la variable IPIMP está altamente correlacionada con el TC.

Para verificar la relación existente entre dichas variables regresionaremos los siguientes modelos:

ls ipc c ipimp

Dependent Variable: IPC				
Method: Least Squares				
Date: 08/22/02 Time: 04:47				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.294665	0.734909	-0.400954	0.6914
IPIMP	1.001567	0.011205	89.38557	0.0000
R-squared	0.996383	Mean dependent var	35.19497	
Adjusted R-squared	0.996259	S.D. dependent var	56.29402	
S.E. of regression	3.443251	Akaike info criterion	5.373050	
Sum squared resid	343.8234	Schwarz criterion	5.465566	
Log likelihood	-81.28228	F-statistic	7989.779	
Durbin-Watson stat	1.120692	Prob(F-statistic)	0.000000	

ls ipc c tc

Dependent Variable: IPC				
Method: Least Squares				
Date: 08/22/02 Time: 04:49				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.254179	0.989734	-0.256816	0.7991
TC	46.64217	0.703713	66.28011	0.0000
R-squared	0.993442	Mean dependent var	35.19497	
Adjusted R-squared	0.993216	S.D. dependent var	56.29402	
S.E. of regression	4.636720	Akaike info criterion	5.968232	
Sum squared resid	623.4760	Schwarz criterion	6.060748	
Log likelihood	-90.50760	F-statistic	4393.053	
Durbin-Watson stat	0.831213	Prob(F-statistic)	0.000000	

ls ipimp c tc

Dependent Variable: IPIMP				
Method: Least Squares				
Date: 08/22/02 Time: 22:24				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.018567	0.505233	0.036749	0.9709
TC	46.59795	0.359227	129.7174	0.0000
R-squared	0.998280	Mean dependent var	35.43411	
Adjusted R-squared	0.998220	S.D. dependent var	56.10422	
S.E. of regression	2.366922	Akaike info criterion	4.623399	
Sum squared resid	162.4673	Schwarz criterion	4.715914	
Log likelihood	-69.66268	F-statistic	16826.60	
Durbin-Watson stat	1.137780	Prob(F-statistic)	0.000000	

Observamos que los R^2 de las regresiones son altísimos (99%) esto evidencia que el modelo tiene problemas de multicolinealidad.

2. CORRECCIÓN DE MULTICOLINEALIDAD

Para corregir la multicolinealidad se ha optado por eliminar las variables del modelo que producen multicolinealidad. Se irá eliminando según el grado de correlación que tenga con las demás variables.

El TC, el IPC y el IPIMP son las variables que están altamente correlacionadas, por lo tanto se irán eliminando del modelo:

ls import c fbk ipc ipimp pbi prpbiimp

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 19:23				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2236.015	1714.666	1.304053	0.2041
FBK	0.701056	0.050515	13.87804	0.0000
IPC	45.25769	46.02698	0.983286	0.3349
IPIMP	-19.01619	44.18429	-0.430384	0.6706
PBI	-0.049075	0.016361	-2.999467	0.0060
PRPBIIMP	2508.090	1342.016	1.868897	0.0734
R-squared	0.978087	Mean dependent var	13535.42	
Adjusted R-squared	0.973704	S.D. dependent var	4362.854	
S.E. of regression	707.4842	Akaike info criterion	16.13329	
Sum squared resid	12513347	Schwarz criterion	16.41084	
Log likelihood	-244.0660	F-statistic	223.1703	
Durbin-Watson stat	1.678695	Prob(F-statistic)	0.000000	

Por la presencia de multicolinealidad los estimadores de los parámetros del ipc, el índice de precios de las importaciones y los precios relativos pbi-importaciones no son significativos.

ls import c fbk ipimp pbi prpbiimp tc

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 19:54				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1650.080	1606.765	1.026958	0.3139
FBK	0.725142	0.044151	16.42415	0.0000
IPIMP	24.04988	5.825251	4.128556	0.0003
PBI	-0.049685	0.016339	-3.040836	0.0053
PRPBIIMP	2857.422	1293.312	2.209384	0.0362
R-squared	0.977239	Mean dependent var	13535.42	
Adjusted R-squared	0.973737	S.D. dependent var	4362.854	
S.E. of regression	707.0330	Akaike info criterion	16.10672	
Sum squared resid	12997289	Schwarz criterion	16.33801	
Log likelihood	-244.6542	F-statistic	279.0769	
Durbin-Watson stat	1.668096	Prob(F-statistic)	0.000000	

En este caso los signos diferentes a los esperados para IPIMP, nos indica aún la presencia de multicolinealidad

ls import c fbk ipc pbi prpbiiimp tc

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 19:59				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2461.911	1699.485	1.448622	0.1599
FBK	0.690082	0.049606	13.91128	0.0000
IPC	57.07922	34.38421	1.660042	0.1094
PBI	-0.048547	0.016117	-3.012099	0.0059
PRPBIIMP	2379.955	1328.555	1.791386	0.0853
TC	-1400.579	1507.453	-0.929103	0.3617
R-squared	0.978661	Mean dependent var	13535.42	
Adjusted R-squared	0.974393	S.D. dependent var	4362.854	
S.E. of regression	698.1493	Akaike info criterion	16.10673	
Sum squared resid	12185311	Schwarz criterion	16.38427	
Log likelihood	-243.6543	F-statistic	229.3127	
Durbin-Watson stat	1.632186	Prob(F-statistic)	0.000000	

Observamos en los modelos, que la variable TC es el menos significativo, por lo tanto se eliminará del modelo. Pero se observa que algunos parámetros se hacen no significativos por lo que se seguirá eliminando variables.

Seguidamente se eliminarán las variables IPC e IPIMP.

ls import c fbk ipimp pbi prpbiiimp

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 19:27				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1650.080	1606.765	1.026958	0.3139
FBK	0.725142	0.044151	16.42415	0.0000
IPIMP	24.04988	5.825251	4.128556	0.0003
PBI	-0.049685	0.016339	-3.040836	0.0053
PRPBIIMP	2857.422	1293.312	2.209384	0.0362
R-squared	0.977239	Mean dependent var	13535.42	
Adjusted R-squared	0.973737	S.D. dependent var	4362.854	
S.E. of regression	707.0330	Akaike info criterion	16.10672	
Sum squared resid	12997289	Schwarz criterion	16.33801	
Log likelihood	-244.6542	F-statistic	279.0769	
Durbin-Watson stat	1.668096	Prob(F-statistic)	0.000000	

Continúan teniendo signo cambiado IPIMP y PBI

ls import c fbk ipc pbi prpbiimp

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 20:10				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2061.085	1639.487	1.257152	0.2199
FBK	0.711196	0.043979	16.17143	0.0000
IPC	25.62157	5.976165	4.287292	0.0002
PBI	-0.049792	0.016019	-3.108267	0.0045
PRPBIIMP	2600.908	1303.654	1.995090	0.0566
R-squared	0.977924	Mean dependent var	13535.42	
Adjusted R-squared	0.974528	S.D. dependent var	4362.854	
S.E. of regression	696.3106	Akaike info criterion	16.07616	
Sum squared resid	12606061	Schwarz criterion	16.30745	
Log likelihood	-244.1805	F-statistic	287.9398	
Durbin-Watson stat	1.680064	Prob(F-statistic)	0.000000	

El modelo ls import c fbk ipc pbi prpbiimp es el que tiene un mayor R^2 por lo tanto se optó por eliminar la variable IPIMP del modelo. Se observa que los estimadores de los parámetros son significativos, pero el coeficiente del PBI sigue siendo negativo. Entonces se seguirá eliminando variables.

Recordemos que según la matriz de correlaciones el IPC está altamente correlacionado con PRPBIIMP y la FBK con el PBI. Inicialmente se descarta el IPC, porque PRPBIIMP incorpora simultáneamente los índices de precios de las importaciones y el PBI

ls import c fbk pbi prpbiimp

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 19:31				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-4111.862	1005.291	-4.090221	0.0003
FBK	0.747660	0.055320	13.51527	0.0000
PBI	-0.016805	0.018014	-0.932896	0.3591
PRPBIIMP	7126.502	980.8217	7.265849	0.0000
R-squared	0.962318	Mean dependent var	13535.42	
Adjusted R-squared	0.958131	S.D. dependent var	4362.854	
S.E. of regression	892.7278	Akaike info criterion	16.54635	
Sum squared resid	21517999	Schwarz criterion	16.73139	
Log likelihood	-252.4685	F-statistic	229.8378	
Durbin-Watson stat	1.249504	Prob(F-statistic)	0.000000	

Observamos que el coeficiente del PBI sigue saliendo negativo.

Entonces se probará eliminar la FBK o el PBI (cabe recalcar que estas variables están altamente correlacionadas entre sí). Una opción alternativa es trabajar con una variable capital /producto, aunque sólo se dispone del flujo de inversión

ls import c pbi prpbiimp

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 20:18				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-7746.159	2650.651	-2.922361	0.0068
PBI	0.167552	0.032196	5.204139	0.0000
PRPBIIMP	8103.802	2676.628	3.027616	0.0052
R-squared	0.707385	Mean dependent var		13535.42
Adjusted R-squared	0.686484	S.D. dependent var		4362.854
S.E. of regression	2442.871	Akaike info criterion		18.53150
Sum squared resid	1.67E+08	Schwarz criterion		18.67027
Log likelihood	-284.2383	F-statistic		33.84446
Durbin-Watson stat	0.356910	Prob(F-statistic)		0.000000

En este modelo aunque el modelo es significativo en forma individual y en conjunto, el R² es bajo. Alternativamente se plantea el modelo importaciones respecto a la inversión (fbk), y los precios relativos PBI/importaciones; así como la función con respecto a la relación capital producto FBK/PBI.

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/23/02 Time: 12:16				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-11903.51	2688.814	-4.427050	0.0001
FBKPBI	76428.28	11635.74	6.568408	0.0000
PRPBIIMP	13207.69	2072.454	6.372971	0.0000
R-squared	0.773444	Mean dependent var		13535.42
Adjusted R-squared	0.757261	S.D. dependent var		4362.854
S.E. of regression	2149.514	Akaike info criterion		18.27564
Sum squared resid	1.29E+08	Schwarz criterion		18.41441
Log likelihood	-280.2724	F-statistic		47.79478
Durbin-Watson stat	0.365923	Prob(F-statistic)		0.000000

Es un modelo que mejora el anterior pero tiene un R² relativamente bajo.

ls import c fbk prpbiiimp

Dependent Variable: IMPORT				
Method: Least Squares				
Date: 08/22/02 Time: 06:19				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-4731.248	753.0978	-6.282381	0.0000
FBK	0.708582	0.036048	19.65651	0.0000
PRPBIIIMP	6887.088	944.4566	7.292117	0.0000
R-squared	0.961103	Mean dependent var	13535.42	
Adjusted R-squared	0.958325	S.D. dependent var	4362.854	
S.E. of regresión	890.6577	Akaike info criterion	16.51356	
Sum squared resid	22211592	Schwarz criterion	16.65234	
Log likelihood	-252.9602	F-statistic	345.9240	
Durbin-Watson stat	1.165777	Prob(F-statistic)	0.000000	

De las salidas de la regresión podemos concluir que el modelo:

ls import c fbk prpbiiimp

Tiene un mejor ajuste por lo tanto se elegirá este modelo como el más correcto. Este segundo modelo tiene las siguientes características: todas las variables son significativas, ya que sus probabilidades asociadas son inferiores a 0.5, el R^2 es alto (96%) y los coeficientes tienen los signos esperados, según la teoría económica. Además la Probabilidad asociada al F estadístico nos señala que las variables independientes explican el modelo en su conjunto.

Dependent Variable: IMPORT
Method: Least Squares
Date: 08/23/02 Time: 12:56
Sample: 1970 2000
Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2037.950	606.0236	-3.362823	0.0022
FBK	0.694075	0.035814	19.37982	0.0000
PRPBIIIMP2	4583.035	602.5098	7.606572	0.0000
R-squared	0.963225	Mean dependent var	13535.42	
Adjusted R-squared	0.960599	S.D. dependent var	4362.854	
S.E. of regression	866.0174	Akaike info criterion	16.45745	
Sum squared resid	20999610	Schwarz criterion	16.59623	
Log likelihood	-252.0905	F-statistic	366.6969	
Durbin-Watson stat	1.159083	Prob(F-statistic)	0.000000	

obs	INVERSION	IPC	IPINV	IPPBI	PBI	TI
1970	10306.00	1.90E-07	3.51E-07	3.59E-07	62022.00	3.500000
1971	11630.00	2.10E-07	3.89E-07	3.84E-07	64627.00	1.600000
1972	12069.00	2.20E-07	4.15E-07	4.14E-07	66501.00	4.900000
1973	16176.00	2.40E-07	4.25E-07	4.70E-07	70092.00	-3.900000
1974	20066.00	2.80E-07	4.94E-07	5.42E-07	76611.00	-8.300000
1975	20572.00	3.50E-07	6.35E-07	6.68E-07	79215.00	-11.900000
1976	18451.00	4.70E-07	8.52E-07	8.62E-07	80800.00	-2.300000
1977	16413.00	6.40E-07	1.19E-06	1.17E-06	81123.00	-13.800000
1978	14954.00	1.02E-06	2.04E-06	1.86E-06	81366.00	-30.000000
1979	17103.00	1.70E-06	3.57E-06	3.23E-06	86086.00	-17.000000
1980	20846.00	2.71E-06	5.67E-06	5.28E-06	90562.00	-14.600000
1981	24205.00	4.80E-06	9.61E-06	9.03E-06	95181.00	-6.100000
1982	23680.00	7.80E-06	1.73E-05	1.51E-05	94610.00	-6.500000
1983	16545.00	1.65E-05	3.86E-05	3.14E-05	83446.00	-27.600000
1984	15530.00	3.47E-05	9.04E-05	6.68E-05	87785.00	-21.200000
1985	13777.00	9.15E-05	0.000270	0.000179	90243.00	-34.700000
1986	16303.00	0.000163	0.000399	0.000309	99267.00	-39.900000
1987	19338.00	0.000302	0.000627	0.000563	107208.0	-41.500000
1988	16646.00	0.002319	0.005299	0.004107	97881.00	-88.400000
1989	13349.00	0.081000	0.140000	0.110000	86429.00	-20.370000
1990	13625.00	6.150000	7.610000	6.750000	81983.00	-18.000000
1991	13929.00	31.350000	31.700000	31.900000	83760.00	-2.000000
1992	14060.00	54.390000	52.700000	53.900000	83401.00	-0.280000
1993	15627.00	80.820000	81.100000	79.300000	87375.00	-0.262000
1994	20901.00	100.0000	100.0000	100.0000	98577.00	-0.195000
1995	25468.00	111.1300	113.8000	112.9000	107039.0	-0.505000
1996	24738.00	123.9700	124.7000	124.8000	109709.0	-0.530000
1997	28518.00	134.5600	131.2000	134.3000	117110.0	-0.403000
1998	28110.00	144.3200	138.9000	142.9000	116485.0	0.442000
1999	24984.00	149.3300	153.5000	148.6000	117590.0	1.439000
2000	23731.00	154.9400	159.4000	154.0000	121267.0	1.312000

EJERCICIOS DE MULTICOLINEALIDAD

SOLUCIÓN PREGUNTA N° 1

Se propone el siguiente modelo de las cantidades demandadas de productos lácteos por el país "P" del país "Z" en función de los precios e ingresos :

$$Imp = \beta_1 + \beta_2 PP + \beta_3 IP + \beta_4 ICV + \beta_5 YNN$$

Imp = Cantidades inportadas por "P"

PP = Precios promedios al detalle en "P" de productos lacteos importados de "Z"

IP = Números índices de los precios promedios al detalle en "P" de productos lácteos no importados de "Z"

ICV = Indice del costo de vida

YNN = Ingreso nacional neto a costo de factores

Convirtiendo la ecuación a logarítmica:

$$Lg Imp = \beta_1 + \beta_2 Lg PP + \beta_3 Lg NIP + \beta_4 Lg ICV + \beta_5 Lg YNN$$

Tenemos la siguiente tabla de datos :

<i>AÑO</i>	<i>LIMP</i>	<i>LPP</i>	<i>LNIP</i>	<i>LICV</i>	<i>LYNN</i>
1984	3.1565	1.1062	3.0000	2.3034	3.5682
1985	3.1724	1.1697	3.0055	2.2814	3.5848
1986	3.1738	1.1345	3.0082	2.2840	3.5932
1987	3.2039	1.1361	3.0241	2.2840	3.5999
1988	3.1928	1.1245	2.9894	2.2765	3.5926
1989	3.22269	1.1059	2.9805	2.2637	3.6175
1990	3.2143	1.1294	2.9987	2.2610	3.6184
1991	3.2567	1.1249	2.9899	2.2558	3.6209
1992	3.3192	1.0522	2.9284	2.2367	3.5974
1993	3.3596	0.9404	2.8768	2.2081	3.5642
1994	3.4002	0.9249	2.8470	2.1962	3.5524
1995	3.4630	0.8468	2.7882	2.1872	3.5714
1996	3.4847	0.8185	2.7497	2.1903	3.5889
1997	3.4605	0.8600	2.7709	2.1962	3.6137
1998	3.4742	0.9117	2.8109	2.2081	3.6423
1999	3.4956	0.9411	2.8482	2.2284	3.6643
2000	3.4469	0.9686	2.8561	2.2342	3.6694

A) Regresione el modelo y evalúe los parámetros.

Dependent Variable: LIMP Method: Least Squares Date: 09/15/02 Time: 14:39 Sample: 1984 2000 Included observations: 17				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.187357	1.556175	1.405598	0.1852
LPP	-0.701950	0.368778	-1.903449	0.0812
LNIP	0.029628	0.481688	0.061509	0.9520
LICV	-1.098483	0.442209	-2.484080	0.0287
LYNN	1.172611	0.206303	5.683918	0.0001
R-squared	0.977628	Mean dependent var	3.323352	
Adjusted R-squared	0.970171	S.D. dependent var	0.129914	
S.E. of regression	0.022437	Akaike info criterion	-4.516242	
Sum squared resid	0.006041	Schwarz criterion	-4.271180	
Log likelihood	43.38806	F-statistic	131.0986	
Durbin-Watson stat	1.657679	Prob(F-statistic)	0.000000	

El intercepto C y las variables LPP y $LNIP$ a un nivel de significancia del 5% no son significativas.

R^2 es aproximadamente un 97% lo cual nos indica un buen grado de linealidad de los datos con respecto a la línea estimada. Cuando R^2 es muy cercano a 1 se dice que el modelo de regresión es capaz de explicar un alto porcentaje de las variaciones que registra la variable explicada.

B) A priori cuáles son los signos de los parámetros que espera hallar?

De acuerdo a los datos presentados y a la relación entre los mismos se debe tener que aquellos como LPP , $LNIP$ y $LICV$ por ser descendentes deberán tener signo negativo, y $LYNN$ por ser ascendente tendrá signo positivo. Cabe indicar que a pesar de lo que se puede esperar a priori se obtiene que $LNIP$ aparece con signo positivo

C) Interpretación de los parámetros**D) Cree Ud. que existe multicolinealidad. Dar tres razones fundamentales.**

Si existe multicolinealidad porque:

- Cuando R^2 es muy cercano a 1 se dice que el modelo de regresión es capaz de explicar un alto porcentaje de las variaciones que registra la variable explicada. El R^2 es casi a 1 lo cual nos indica un alineamiento casi perfecto de los datos.

- *LNIP a pesar de lo que se puede esperar a priori, signo negativo, aparece con signo positivo*
- *El intercepto C y las variables LPP y LNIP a un nivel de significancia del 5% no son significativas.*

Por el método de la matriz de correlaciones de las variables también se determinar si existe multicolinealidad :

	LICV	LNIP	LPP	LYNN
LICV	1	0.937526	0.938392	0.002873
LNIP	0.937526	1	0.988619	-0.10719
LPP	0.938392	0.988619	1	-0.0258
LYNN	0.002873	-0.10719	-0.0258	1

De la matriz de correlaciones vemos que existe una alta correlación entre la variables ICV-LNIP , ICV-PP además de NIP-PP. la que presenta casi de 99% es NIP-PP.

Si regresionamos el modelo LS INIP LPP obtenemos un R2 de 97.7% , valor bastante alto que nos indicaría el alto grado de correlación que existe entre estas variables.

E) Cuáles son los principales efectos de la multicolinealidad?

Una alta correlación de las variables es consecuencia de la multicolinealidad existente en el modelo, esto distorsiona los valores produciendo confusión entre uno u otro.

F) Es posible predecir en presencia de multicolinealidad? porqué?

Es muy riesgoso predecir cuando existe multicolinealidad ya que esto genera una distorsión de los parámetros, es recomendable asociar las variables más explicativas o significativas y prescindir o eliminar las variables menos significativas.

G) Si existe multicolinealidad con que modelo recomienda trabajar?

Las variables LNIP y LPP están altamente correlacionadas por lo tanto iremos eliminando del modelo hasta obtener valores de R² más bajos y que los coeficientes sean más significativos.

Eliminamos del modelo la variable LPP y regresionamos :

LS LIMP C LNIP LICV LYNN y obtenemos:

Dependent Variable: LIMP				
Method: Least Squares				
Date: 09/16/02 Time: 11:17				
Sample: 1984 2000				
Included observations: 17				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.810229	0.792733	6.067903	0.0000
LNIP	-0.822996	0.194184	-4.238226	0.0010
LICV	-1.161413	0.483418	-2.402505	0.0319
LYNN	0.974265	0.195191	4.991337	0.0002
R-squared	0.970874	Mean dependent var	3.323352	
Adjusted R-squared	0.964152	S.D. dependent var	0.129914	
S.E. of regression	0.024597	Akaike info criterion	-4.370044	
Sum squared resid	0.007865	Schwarz criterion	-4.173994	
Log likelihood	41.14538	F-statistic	144.4446	
Durbin-Watson stat	1.503959	Prob(F-statistic)	0.000000	

Se observa que los T-estadísticos son todos significativos, esto nos indica que existe un mejor ajuste, además la variable LNIP ahora aparece con signo negativo de acuerdo a lo que se esperaba, así mismo el R^2 indica un 97% de éxito del modelo estimado y la probabilidad asociada al F-estadístico nos señala que las variables independientes explican al modelo en su conjunto.

El modelo con que se recomienda trabajar es :

$$LIMP = 4.810 - 0.823 LNIP - 1.1614 LICV + 0.9742 LYNN$$

SOLUCION PREGUNTA N° 2

Caso de embotelladora de bebidas:

Se desea ajustar el modelo de regresión lineal múltiple : $Y = b_0 + b_1X_1 + b_2X_2$ donde :

Y = tiempo requerido para cubrir la ruta de abastecimiento.

X_1 = número de bebidas

X_2 = distancia recorrida.

<i>Obs</i>	<i>Tiempo Entrega</i>	<i>Número de Bebidas</i>	<i>Distancia (pies)</i>
1	16.68	7	560
2	11.50	3	220
3	12.03	3	340
4	14.88	4	80
5	13.75	6	150
6	18.11	7	330
7	8.00	2	110
8	17.83	7	210
9	79.24	30	1460
10	21.50	5	605
11	40.33	16	688
12	21.00	10	215
13	13.50	4	255
14	19.75	6	462
15	24.00	9	448
16	29.00	10	776
17	15.35	6	200
18	19.00	7	132
19	9.50	3	36
20	35.10	17	770
21	17.90	10	140
22	52.32	26	810
23	18.75	9	450
24	19.83	8	635
25	10.75	4	150

A) Analice la correlación simple entre X_1 y X_2

Aplicamos correlación para numero de bebidas y distancia de recorrido.

	<i>DIST</i>	<i>NBEBIDAS</i>
<i>DIST</i>	1.000000	0.824215
<i>NBEBIDAS</i>	0.824215	1.000000

La correlación existente entre variables es del orden del 82.42%, valor que nos es muy cercano a 1.

B) Calcular los parámetros del modelo

Dependent Variable: TENTREGA				
Method: Least Squares				
Date: 09/16/02 Time: 12:14				
Sample: 1 25				
Included observations: 25				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.341231	1.096730	2.134738	0.0442
NBEBIDAS	1.615907	0.170735	9.464421	0.0000
DIST	0.014385	0.003613	3.981313	0.0006
R-squared	0.959594	Mean dependent var	22.38400	
Adjusted R-squared	0.955920	S.D. dependent var	15.52490	
S.E. of regression	3.259473	Akaike info criterion	5.313175	
Sum squared resid	233.7317	Schwarz criterion	5.459440	
Log likelihood	-63.41469	F-statistic	261.2351	
Durbin-Watson stat	1.169567	Prob(F-statistic)	0.000000	

C) Sospecha que existe multicolinealidad en los datos?

El intercepto C y las variables $NBEBIDAS$ y $DIST$ son significativos, los signos de los coeficientes son los que se esperaban y el R^2 esta al nivel de 95% de linealidad de los datos con el modelo; el F estadístico indica que las variables independientes explican al modelo en su conjunto .

D) Suponiendo que si existe pero $B1$ y $B2$ son individualmente significativas al 5% y que el F -estadístico también es significativo Entonces ¿Deberíamos preocuparnos sobre el problema de la multicolinealidad?

No ya que la correlación entre parámetros no es subjetiva si no objetivas o natural.

SOLUCION PREGUNTA N° 3

La siguiente tabla proporciona datos sobre importaciones, PNB e índice de precios al consumidor (IPC) para los Estados Unidos durante el período 1970 – 1983.

<i>Año</i>	<i>Import. (Mill \$)</i>	<i>PNB (Bill \$)</i>	<i>IPC 1967= 100</i>	<i>Ln import</i>	<i>Ln PNB</i>	<i>Ln IPC</i>
1970	39866	992.7	116.3	10.5933	6.9004	4.7562
1971	45579	1077.6	121.3	10.7272	6.9825	4.7983
1972	55797	1185.9	125.3	10.9295	7.0783	4.8307
1973	70499	1326.4	133.1	11.1634	7.1902	4.8911
1974	103811	1434.2	147.7	11.5503	7.2684	4.9952
1975	98185	1549.2	161.2	11.4946	7.3455	5.0826
1976	124228	1718	170.5	11.7299	7.4489	5.1387
1977	151907	1918.3	181.5	11.9310	7.5592	5.2013
1978	176020	2163.9	195.4	12.0784	7.6797	5.2750
1979	212028	2417.8	217.4	12.2645	7.7906	5.3817
1980	249781	2631.7	246.8	12.4283	7.8754	5.5086
1981	265086	2957.8	272.4	12.4878	7.9922	5.6073
1982	247667	3069.3	289.1	12.4198	8.0292	5.6668
1983	261312	3304.8	298.4	12.4735	8.1031	5.6984

Considerar el modelo:

$$\ln import_t = b_1 + b_2 \ln PNB_t + b_3 \ln IPC_t$$

A) Calcular los parámetros de este modelo utilizando la información dada:

Dependent Variable: LNIMP				
Method: Least Squares				
Date: 09/16/02 Time: 13:34				
Sample: 1970 1983				
Included observations: 14				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2.310140	1.028723	-2.245638	0.0462
LNPNB	3.229506	0.750718	4.301892	0.0013
LNIPC	-1.967151	0.919614	-2.139105	0.0557
R-squared	0.973658	Mean dependent var		11.73368
Adjusted R-squared	0.968868	S.D. dependent var		0.672825
S.E. of regression	0.118715	Akaike info criterion		-1.236772
Sum squared resid	0.155026	Schwarz criterion		-1.099831
Log likelihood	11.65741	F-statistic		203.2885
Durbin-Watson stat	1.313851	Prob(F-statistic)		0.000000

La variable LNIPC tiene un valor esperado positivo pero los resultados arrojan un valor negativo y no significativo. R^2 tiene un valor muy cercano a 1 (97.3%). Cuando R^2 es muy cercano a 1 se dice que el modelo de regresión es capaz de explicar un alto porcentaje de las variaciones que registra la variable explicada.

B) Analice la matriz de correlaciones simples

	LNPNB	LNIPC
LNPNB	1.000000	0.994096
LNIPC	0.994096	1.000000

De la matriz de correlaciones simples se observa una alta correlación entre las variables Ln PNB y Ln IPC de 0.994 .

C) Sospecha que existe multicolinealidad en los datos?

Si existe multicolinealidad debido a la alta correlación que existe entre las variables IPC y PNB es por eso que el coeficiente LnIPC resulta de signo negativo cuando se esperaba que fuera de signo positivo.

D) Regresionar

$$\ln imp_t = a_1 + a_2 \ln PNB_t$$

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.543158	0.698537	-0.777565	0.4519
LNPNB	1.633123	0.092798	17.59866	0.0000
R-squared	0.962700	Mean dependent var		11.73368
Adjusted R-squared	0.959591	S.D. dependent var		0.672825

$$\ln imp_t = b_1 + b_2 \ln IPC_t$$

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.508208	0.815463	1.849511	0.0892
LNIPC	1.965575	0.156459	12.56287	0.0000
R-squared	0.929339	Mean dependent var		11.73368
Adjusted R-squared	0.923451	S.D. dependent var		0.672825

$$\ln PNB_t = C_1 + C_2 \ln IPC_t$$

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.182332	0.199973	5.912469	0.0001
LNIPC	1.217749	0.038368	31.73881	0.0000
R-squared	0.988228	Mean dependent var		7.517400
Adjusted R-squared	0.987247	S.D. dependent var		0.404230

D) Cual es la naturaleza de la multicolinealidad?

La multicolinealidad se genera debido a la alta correlación entre PNB y el IPC.

SOLUCIÓN PREGUNTA N° 4

Dado el siguiente modelo:

$$INV_t = a_1 + a_2 PBI_t + a_3 r_t + a_4 IPINV_t + a_5 PR_t + \mu_t$$

A) Calcule el estimador M.C.O. de los parámetros e intérpretelos

Dependent Variable: INV				
Method: Least Squares				
Date: 09/16/02 Time: 14:51				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-10954.63	4774.259	-2.294519	0.0301
PBI	0.353642	0.062086	5.695976	0.0000
TIR	116.7644	36.94933	3.160122	0.0040
IPINV	-270.8711	263.4286	-1.028253	0.3133
IPPBI	239.2287	263.2265	0.908832	0.3718
R-squared	0.760594	Mean dependent var		18440.32
Adjusted R-squared	0.723762	S.D. dependent var		4999.747
S.E. of regression	2627.784	Akaike info criterion		18.73236
Sum squared resid	1.80E+08	Schwarz criterion		18.96365
Log likelihood	-285.3516	F-statistic		20.65050
Durbin-Watson stat	0.950988	Prob(F-statistic)		0.000000

APLICACIONES DE MULTICOLINEALIDAD**CASO: PRODUCTOS LACTEOS****CASO: EMBOTELLADORA DE BEBIDAS****CASO: IMPORTACIONES DE EE.UU 1970-1983****1.-Verifique si las siguientes afirmaciones son ciertas o falsas. De una breve razón:****(a)La prueba h de Durbin es válida en muestras grandes y pequeñas**

VERDADERO

El estadístico h de Durbin Watson es utilizado para detectar autocorrelación de orden 1 y se refiere cuando en el modelo se tiene una variable explicativa que esté rezagada un periodo. Pero esta prueba se recomienda mejor en muestras grandes.

(b)El modelo de Koyck no tendría sentido si algunos coeficientes de los rezagos distribuidos son positivos y algunos negativos.

VERDADERO

El modelo de Koyck supone que los parámetros β tienen todos los mismos signos y decaen geoméricamente. Por lo tanto, los β no cambian de signo.

(c)Si los modelos de Koyck y de expectativas adaptativas son estimados mediante MCO, los estimadores serán sesgados pero consistentes.

FALSO

El modelo de Koyck ha sido obtenido por un proceso algebraico y no tiene fundamento en términos estadísticos. En el modelo de expectativas adaptativas si es factible aplicar MCO.

(d)En la presencia de una variable rezagada como regresor, el estadístico d de Durbin Watson para la detección de autocorrelación es inútil.

VERDADERO

El modelo de regresión de Durbin Watson no incluye valores rezagados de la variable dependiente como una de las variables explicativas.

2.-Deduzca el modelo de rezago distribuido de Koyck? ¿Qué problemas se hallan en la estimación de este modelo?

Para el modelo de rezago infinito:

$$Y_t = \alpha + \beta_0 \cdot X_t + \beta_1 X_{t-1} + \dots$$

Koyck utiliza un artificio matemático que permite convertir al modelo de rezago distribuido en uno autoregresivo.

$$Y_t = \beta_0 + \beta_1 \cdot X_t + \beta_2 Y_{t-1}$$

Kyock supone que los β tienen todos los mismos signos y decaen geoméricamente de tal manera que:

$$\beta_k = \beta_0 \cdot \lambda^k$$

donde $K = 0, 1, 2, \dots$

λ : tasa de decaimiento

$$0 < \lambda < 1$$

$1 - \lambda$: velocidad de ajuste.

El modelo final es: $Y_t = \beta_1 + \beta_2 \cdot X_t + \beta_3 Y_{t-1} + v_t$

donde:

$$v_t = (\mu_t - \lambda \cdot \mu_{t-1})$$

3.-Cual es la estructura de rezago en el modelo de Almon? ¿Cuáles son las ventajas y desventajas del modelo de rezago de Almon con respecto al modelo de Koyck?

El modelo de Almon tiene la siguiente estructura:

$$Y_t = \alpha + a_0 Z_{0t} + a_1 Z_{1t} + a_2 Z_{2t} + a_3 Z_{3t}$$

El modelo de rezago distribuido de Kyock es:

$$Y_t = \beta_1 + \beta_2 \cdot X_t + \beta_3 Y_{t-1} + v_t$$

Los 02 modelos son aparentemente parecidos, pero teóricamente son diferentes.

4.-Un inversionista desea elaborar un modelo econométrico con el que explicar e l nivel de producción del sector construcción (PBICONST) a través de las ventas de cemento (VCEMENTO) y de las ventas de las barras de construcción (VBARRA). Para ello se tiene una serie mensualizada de 1992 a enero del 2001, con el cual se debe estimar el siguiente modelo inicial:

$$PBICONST = C_0 + C_1 * VCEMENTO + C_2 * VBARRA + \mu$$

4° LABORATORIO			
mes	vtacem	vtabarra	pbi construcción (soles)
mes	VCEMENTO	VBARRA	PBICONST
199201	183,213	16,925	18.3
199202	194,484	12,929	17.0
199203	176,178	12,175	17.3
199204	178,918	10,119	16.7
199205	158,561	11,013	15.4
199206	160,630	10,018	15.0
199207	172,372	11,052	16.1
199208	178,754	13,178	17.3
199209	197,417	11,799	17.9
199210	201,507	12,311	18.2
199211	183,455	11,871	16.2
199212	196,976	13,841	18.6
199301	165,602	12,341	17.1
199302	180,878	12,730	16.8
199303	201,011	15,306	18.5
199304	198,593	12,756	17.9
199305	183,761	12,059	17.0
199306	186,465	14,113	18.5
199307	189,744	15,644	19.2
199308	232,517	17,988	22.2
199309	231,768	15,301	21.4
199310	227,776	15,075	20.3
199311	219,757	16,718	21.0
199312	230,442	16,226	23.5
199401	213,194	18,287	21.9
199402	208,455	18,404	19.9
199403	231,596	19,733	23.5
199404	220,376	18,092	22.4
199405	235,017	18,136	22.7
199406	233,380	19,054	23.5
199407	246,724	17,217	24.0
199408	299,957	23,004	27.6
199409	317,009	23,204	29.8
199410	320,803	23,613	30.1
199411	333,757	18,895	29.5
199412	318,943	21,024	31.2
199501	292,259	26,109	28.8
199502	285,689	23,562	27.2
199503	315,214	24,692	29.8
199504	293,054	25,080	28.2
199505	326,852	23,499	32.3
199506	296,535	26,479	29.4
199507	302,599	25,651	28.7
199508	335,925	26,872	31.8
199509	328,595	26,406	30.6
199510	338,925	26,564	32.1
199511	327,876	27,194	30.2
199512	306,074	24,807	29.5
199601	307,481	27,176	28.8

4° LABORATORIO			
mes	vtacem	vtabarra	pbi construcción (soles)
mes	VCEMENTO	VBARRA	PBICONST
199602	296,386	24,772	26.3
199603	298,544	26,345	28.5
199604	295,281	26,058	25.3
199605	321,715	32,333	28.1
199606	289,842	28,467	24.9
199607	325,212	30,775	27.3
199608	336,051	31,945	29.3
199609	334,620	30,488	28.4
199610	351,596	31,664	31.3
199611	335,806	34,078	29.9
199612	345,818	29,146	32.6
199701	351,193	37,124	34.0
199702	328,424	34,671	30.5
199703	314,409	30,290	30.2
199704	336,822	25,696	31.8
199705	346,085	16,278	32.1
199706	326,683	27,268	30.7
199707	346,447	40,558	32.8
199708	373,488	34,893	34.1
199709	391,529	35,262	37.5
199710	403,797	34,510	42.3
199711	374,946	33,476	37.5
199712	395,240	34,404	36.5
199801	361,198	32,896	35.1
199802	332,984	33,305	32.8
199803	359,779	31,045	35.4
199804	331,183	28,486	32.4
199805	321,998	23,684	31.1
199806	344,054	33,549	33.5
199807	372,117	36,077	36.1
199808	425,734	36,791	38.2
199809	397,771	38,757	37.5
199810	353,001	32,837	36.6
199811	348,144	25,179	34.4
199812	343,260	23,133	32.3
199901	311,203	29,896	30.5
199902	273,058	25,760	27.6
199903	331,499	27,957	30.8
199904	284,956	24,050	27.5
199905	278,223	24,667	25.1
199906	285,707	25,501	26.4
199907	300,335	27,220	28.2
199908	324,273	32,619	31.4
199909	339,146	34,993	32.8
199910	343,501	34,588	36.1
199911	353,612	30,587	35.3
199912	350,593	27,946	32.8
200001	312,532	31,391	32.0

(a) Estimar el modelo inicial y analizar los resultados,

Dependent Variable: PBICONST				
Method: Least Squares				
Date: 09/09/02 Time: 11:57				
Sample: 1992:01 2000:01				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.359737	0.667219	0.539158	0.5911
VCEMENTO	9.02E-05	4.84E-06	18.61325	0.0000
VBARRA	4.21E-05	4.10E-05	1.026586	0.3072
R-squared	0.957725	Mean dependent var		27.47113
Adjusted R-squared	0.956826	S.D. dependent var		6.567644
S.E. of regression	1.364651	Akaike info criterion		3.490113
Sum squared resid	175.0535	Schwarz criterion		3.569744
Log likelihood	-166.2705	F-statistic		1064.777
Durbin-Watson stat	0.988372	Prob(F-statistic)		0.000000

$$\text{PBICONST} = C_0 + C_1 \cdot \text{VCEMENTO} + C_2 \cdot \text{VBARRA} + \mu$$

$C_0 = 0.359737$, indica el nivel promedio (o autónomo) del PBICONST, cuando el resto de parámetros son cero.

$C_1 = 0.0000902$, este resultado nos muestra que si las ventas de cemento varía en una unidad, la cantidad del PBICONST varía en 0.0000902.

$C_2 = 0.0000421$, este resultado nos muestra que si las ventas de las barras de construcción VBARRA varía en una unidad, la cantidad del PBICONST varía en 0.0000421.

Que refleja R^2 y el R^2 ajustado

$$R^2 = 0.956826$$

$$R^2 \text{ ajustado} = 0.956826$$

Reflejan la bondad del ajuste. Cuando R^2 es muy cercano a 1 se dice que el modelo de regresión es capaz de explicar un alto porcentaje de las variaciones que registra la variable explicada.

El R^2 ajustado, tiene el mismo objetivo como medida de bondad de ajuste, pero le añade una corrección por los grados de libertad que se pierden por la inclusión de una variable adicional en el modelo. En consecuencia, se dice que esta nueva medida de bondad de ajuste es relativamente neutral a la introducción de variables adicionales.

Los residuos se distribuyen normalmente?

H_0 : los residuos se distribuyen normalmente


H_1 : Los residuos no se distribuyen normalmente

La regla de decisión es: si es mayor que 0.05 se acepta H_0 . El estadístico Jarque-Bera sigue una distribución χ^2 con dos grados de libertad. Considerando un nivel de confianza del 5%, tenemos:

$$\text{Chi calc.} = 3.430680 < \text{Chi tabla,} = 5.99$$

Entonces , aceptamos la hipótesis nula.

Existe evidencia estadística de que los residuos se distribuyen normalmente, con un 95% de confianza.




Los parámetros son estables en el período de análisis?


Ho: los parámetros son estables en el período de análisis,

H1: los parámetros no son estables en el período de análisis.

Se observa que la gráfica del test de CUSUM muestra al estadístico dentro de la banda de confianza, por lo tanto se puede afirmar que los parámetros son estables en el período de análisis, a un nivel de confianza del 95%.



En el test de CUSUM Q, muestra una porción de los datos fuera de la banda de confianza, por lo tanto se puede afirmar que los parámetros no son estables en el período de análisis, a un nivel de confianza del 95%. Esto se nota claramente en el periodo 1994 – 1998.



El modelo está correctamente especificado?

Ho: El modelo esta correctamente especificado,

H1: El modelo no esta correctamente especificado,

Aplicando la prueba de Reset Ramsey, observamos que aun nivel de 5% de significancia, se acepta la hipótesis nula, es decir el modelo está correctamente especificado. Se llega a esta conclusión, observando la probabilidad asociada (78.3%) que es mayor que 5%.

Ramsey RESET Test:				
F-statistic	0.245591	Probability	0.782753	
Log likelihood ratio	0.516500	Probability	0.772402	
Test Equation:				
Dependent Variable: PBICNST				
Method: Least Squares				
Date: 09/09/02 Time: 12:06				
Sample: 1992:01 2000:01				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.740340	9.829252	0.075320	0.9401
VCEMENTO	9.16E-05	0.000108	0.846452	0.3995
VBARRA	4.32E-05	6.65E-05	0.649589	0.5176
FITTED^2	-0.003105	0.044937	-0.069095	0.9451
FITTED^3	6.85E-05	0.000543	0.126078	0.8999
R-squared	0.957950	Mean dependent var	27.47113	
Adjusted R-squared	0.956122	S.D. dependent var	6.567644	
S.E. of regression	1.375736	Akaike info criterion	3.526026	
Sum squared resid	174.1239	Schwarz criterion	3.658743	
Log likelihood	-166.0122	F-statistic	523.9656	
Durbin-Watson stat	1.016619	Prob(F-statistic)	0.000000	

(b) Utilizando el modelo de Alt Tinbergen hallar que ecuación de regresión es la “mejor”,

El modelo original es:

$$PBICNST = C_0 + C_1 * VCEMENTO + C_2 * VBARRA$$

Dependent Variable: PBICNST				
Method: Least Squares				
Date: 09/09/02 Time: 11:57				
Sample: 1992:01 2000:01				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.359737	0.667219	0.539158	0.5911
VCEMENTO	9.02E-05	4.84E-06	18.61325	0.0000
VBARRA	4.21E-05	4.10E-05	1.026586	0.3072
R-squared	0.957725	Mean dependent var	27.47113	
Adjusted R-squared	0.956826	S.D. dependent var	6.567644	
S.E. of regression	1.364651	Akaike info criterion	3.490113	
Sum squared resid	175.0535	Schwarz criterion	3.569744	
Log likelihood	-166.2705	F-statistic	1064.777	
Durbin-Watson stat	0.988372	Prob(F-statistic)	0.000000	

Los resultados nos indican que la variable explicativa VCEMENTO es significativa en el modelo a un 95% de confianza y C y VBARRA no son significativas (probabilidad > 5%).

Regresionando el modelo, luego de haber añadido el primer rezago (ls PBICNST C VCEMENTO VBARRA VBARRA(-1))

Dependent Variable: PBICNST				
Method: Least Squares				
Date: 09/09/02 Time: 12:16				
Sample(adjusted): 1992:02 2000:01				
Included observations: 96 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.389956	0.708163	0.550659	0.5832
VCEMENTO	8.90E-05	5.61E-06	15.86440	0.0000
VBARRA	2.63E-05	4.66E-05	0.564790	0.5736
VBARRA(-1)	2.87E-05	4.54E-05	0.633038	0.5283
R-squared	0.957157	Mean dependent var	27.56667	
Adjusted R-squared	0.955760	S.D. dependent var	6.534019	
S.E. of regression	1.374325	Akaike info criterion	3.514577	
Sum squared resid	173.7668	Schwarz criterion	3.621424	
Log likelihood	-164.6997	F-statistic	685.1207	
Durbin-Watson stat	0.973043	Prob(F-statistic)	0.000000	

De la salida de la regresión podemos afirmar a un nivel de 5% de significancia que no se puede rechazar la H_0 de no significancia de la variable rezagada, es decir que ésta no es significativa en el modelo.

Continuamos rezagando la variable en 02 periodos: (ls PBICNST C VCEMENTO VBARRA VBARRA(-1) VBARRA(-2))

Dependent Variable: PBICONST				
Method: Least Squares				
Date: 09/09/02 Time: 12:21				
Sample(adjusted): 1992:03 2000:01				
Included observations: 95 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.747233	0.739908	1.009899	0.3153
VCEMENTO	8.49E-05	6.34E-06	13.39535	0.0000
VBARRA	3.35E-05	4.76E-05	0.704661	0.4828
VBARRA(-1)	2.23E-06	5.31E-05	0.041975	0.9666
VBARRA(-2)	5.38E-05	4.54E-05	1.186631	0.2385
R-squared	0.957212	Mean dependent var		27.67789
Adjusted R-squared	0.955310	S.D. dependent var		6.476671
S.E. of regression	1.369161	Akaike info criterion		3.517470
Sum squared resid	168.7143	Schwarz criterion		3.651884
Log likelihood	-162.0798	F-statistic		503.3504
Durbin-Watson stat	0.974787	Prob(F-statistic)		0.000000

De la salida de la regresión podemos afirmar a un nivel de 5% de significancia que no se puede rechazar la H_0 de no significancia de la variable rezagada, es decir que ésta no es significativa en el modelo. Continuamos rezagando la variable en 02 períodos: (ls PBICONST C VCEMENTO VBARRA VBARRA(-1) VBARRA(-2))

Dependent Variable: PBICONST				
Method: Least Squares				
Date: 09/09/02 Time: 13:34				
Sample(adjusted): 1992:04 2000:01				
Included observations: 94 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.677324	0.753369	0.899061	0.3711
VCEMENTO	8.42E-05	6.39E-06	13.17655	0.0000
VBARRA	2.57E-05	4.75E-05	0.540409	0.5903
VBARRA(-1)	9.76E-06	5.30E-05	0.184156	0.8543
VBARRA(-2)	-5.44E-06	5.62E-05	-0.096818	0.9231
VBARRA(-3)	7.17E-05	4.06E-05	1.764698	0.0811
R-squared	0.957517	Mean dependent var		27.78830
Adjusted R-squared	0.955104	S.D. dependent var		6.420898
S.E. of regression	1.360508	Akaike info criterion		3.515295
Sum squared resid	162.8864	Schwarz criterion		3.677633
Log likelihood	-159.2189	F-statistic		396.6878
Durbin-Watson stat	0.926122	Prob(F-statistic)		0.000000

Los modelos obtenidos son:

C0	C1	C2	C2(-1)	C2(-2)	C2(-3)
0.3597	0.0000902	0.0000421			
0.3899	0.0000890	0.0000263	0.0000287		
0.7472	0.0000849	0.0000335	0.0000223	0.0000538	
0.6773	0.0000842	0.0000257	0.0000097	-0.0000544	0.0000717
t	t	t	t	T	T
0.539158	18.61325	1.026586			
0.550659	15.86440	0.564790	0.633038		
1.009899	13.39535	0.704661	0.041975	1.186631	
0.899061	13.17655	0.540409	0.184156	-0.096818	1.764698

El modelo que se acepta es el último, debido a que la variable rezagada VBARRA se ha convertido en cercana a ser estadísticamente negativa y ha ocurrido un cambio de signo de la variable rezagada VBARRA.

(c) Utilizando el modelo de retardo geométrico de Koyck o método de modelo rezagados distribuidos hallar los estimadores de los parámetros, considerando un $k=1$, ¿Qué ocurre con el modelo si $k=2$?

Para $k=1$, utilizamos el modelo:

$$PBICONST = C_0 + C_1 * VCEMENTO + C_2 * VBARRA + C_3 * PBICONST(-1)$$

Dependent Variable: PBICONST				
Method: Least Squares				
Date: 09/09/02 Time: 13:45				
Sample(adjusted): 1992:02 2000:01				
Included observations: 96 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.114613	0.601865	-0.190430	0.8494
VCEMENTO	6.69E-05	6.09E-06	10.98875	0.0000
VBARRA	2.28E-05	3.63E-05	0.627599	0.5318
PBICONST(-1)	0.280428	0.050910	5.508265	0.0000
R-squared	0.967642	Mean dependent var	27.56667	
Adjusted R-squared	0.966587	S.D. dependent var	6.534019	
S.E. of regression	1.194377	Akaike info criterion	3.233899	
Sum squared resid	131.2413	Schwarz criterion	3.340747	
Log likelihood	-151.2272	F-statistic	917.0545	
Durbin-Watson stat	1.553885	Prob(F-statistic)	0.000000	

$$-0.114613 = \alpha(1-\lambda) = \alpha(1 - 0.2804) \Rightarrow \alpha = -0.15927$$

$$\beta_0 = 0.0000669$$

$$\beta_1 = 0.0000228$$

$$\beta_2 = \beta_1 * \lambda = 0.0000228 * 0.280428 = 0.00000639$$

$$\lambda = 0.280428$$

El modelo resultante será:

$$PBICONST = -0.15927 + 0.0000669 * VCEMENTO + 0.0000228 * VBARRA + 0.00000639 * PBICONST(-1)$$

$$\text{La velocidad de ajuste de los } \beta = 1 - 0.2804 = 0.7196$$

$$\text{En el largo plazo el impacto total será : } 0.0000228 / (1-0.2804) = 0.00003168$$

$$\text{El valor promedio de rezagos es: } 0.2804 / 0.7196 = 0.38966$$

Para $K = 2$, tendremos:

$$PBICONST = C_0 + C_1 * VCEMENTO + C_2 * VBARRA + C_3 * PBICONST(-1) + C_4 * PBICONST(-2)$$

Dependent Variable: PBICNST				
Method: Least Squares				
Date: 09/09/02 Time: 13:57				
Sample(adjusted): 1992:03 2000:01				
Included observations: 95 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.027524	0.611443	-0.045014	0.9642
VCEMENTO	6.67E-05	6.16E-06	10.82983	0.0000
VBARRA	2.15E-05	3.65E-05	0.588435	0.5577
PBICNST(-1)	0.271065	0.071456	3.793435	0.0003
PBICNST(-2)	0.010193	0.059557	0.171154	0.8645
R-squared	0.967187	Mean dependent var		27.67789
Adjusted R-squared	0.965729	S.D. dependent var		6.476671
S.E. of regression	1.198996	Akaike info criterion		3.252042
Sum squared resid	129.3833	Schwarz criterion		3.386457
Log likelihood	-149.4720	F-statistic		663.2030
Durbin-Watson stat	1.534895	Prob(F-statistic)		0.000000

$$-0.027524 = \alpha(1-\lambda) = \alpha(1 - 0.010) \Rightarrow \alpha = -0.0278$$

$$\beta_0 = 0.0000667$$

$$\beta_1 = 0.0000215$$

$$\beta_2 = 0.271065$$

$$\beta_3 = \beta_2 * \lambda = 0.271065 * 0.010 = 0.00271065$$

$$\lambda = 0.010193$$

El modelo resultante será:

$$PBICNST = -0.0278 + 0.0000667*VCEMENTO + 0.0000215*VBARRA + 0.271065*PBICNST(-1) + 0.00271065*PBICNST(-2)$$

(d) Con los resultados obtenidos en c (k=1), hallar los estimadores de los parámetros para los modelos de las expectativas adaptables y del ajuste parcial.

De acuerdo con el modelo de Expectativas adaptables:

$$PBICNST = -0.15927 + 0.0000669*VCEMENTO + 0.0000228*VBARRA + 0.00003168*PBICNST(-1)$$

El modelo de ajuste parcial será

$$PBICNST = -0.15927 + 0.0000669*VCEMENTO + 0.0000228*VBARRA + 0.00003168*PBICNST(-1)$$

Se obtienen valores similares al modelo de expectativas adaptables, no obstante la interpretación es diferente.

(e) Que sucede con los estimadores cuando se aplica el modelo mixto?

Para el modelo mixto:

$$-0.027524 = B_0 \delta \gamma$$

$$B_1 = 0.0000667$$

$$B_2 = B_1 \delta \gamma = 0.0000215$$

$$\gamma_0 = (1-\gamma) + (1-\delta) = 0.271065$$

$$\phi = -1(1-\gamma)(1-\delta) = 0.010193$$

$$\delta \gamma = 0.32234$$

$$B_0 = -0.08539$$

$$PBICCONST = -0.0278 + 0.0000667*VCEMENTO + 0.0000215*VBARRA + 0.271065*PBICCONST(-1) + 0.00271065*PBICCONST(-2)$$

La lectura de los estadísticos muestran que el VBARRA y el PBICCONST en su forma (-2) no tiene significancia en términos estadísticos, en consecuencia el análisis del modelo mixto a partir de los consumos observados pasados no tiene sentido.

(f) Evalúe si el modelo en (e) presenta problemas de autocorrelación?

El output de la regresión nos muestra el estadístico Durbin Watson, el cual mide la autocorrelación de primer grado. Si, toma un valor cercano a 2, entonces no existe autocorrelación, si este es cercano a 4 entonces existe autocorrelación negativa y si es cercano a 0, entonces existe autocorrelación positiva. Para el caso se observa que toma el valor de 1.5348, el cual es cercano a 2 por lo que no existe autocorrelación.

LABORATORIO 5

HETEROSCEDASTICIDAD

(PARTE I)

MODELO: GASTOS DE VIVIENDA = f(INGRESOS)

Dependent Variable: GASTOSV				
Method: Least Squares				
Date: 07/07/02 Time: 06:31				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.890000	0.204312	4.356086	0.0004
INGRESOS	0.237200	0.014921	15.89724	0.0000
R-squared	0.933511	Mean dependent var		3.855000
Adjusted R-squared	0.929817	S.D. dependent var		1.408050
S.E. of regression	0.373021	Akaike info criterion		0.960274
Sum squared resid	2.504600	Schwarz criterion		1.059847
Log likelihood	-7.602738	F-statistic		252.7223
Durbin-Watson stat	1.363966	Prob(F-statistic)		0.000000

I. DOCIMAS DE HIPOTESIS CON RESTRICCIONES $H_0: \mathbf{R} \hat{\beta} = \mathbf{r}$

Contrastar la hipótesis nula $H_0: \hat{\beta}_2 + = 2$

$$2. \text{ ESTADISTICO DE WALD: } \mathbf{W} = (\mathbf{R} \hat{\beta} - \mathbf{r})' \left[\mathbf{R} \hat{\sigma}_\mu^2 (\mathbf{X}' \mathbf{X})^{-1} \mathbf{R}' \right]^{-1} (\mathbf{R} \hat{\beta} - \mathbf{r}) \sim \chi^2_{(q)}$$

PROCEDIMIENTO:

- ◆ Regresionar el modelo
- ◆ Ingresar a VIEW/ COEFFICIENT /TESTS / WALD COEFFICIENT RESTRICTIONS
- ◆ Aparecerá una caja de diálogo, se debe digitar la restricción: $\mathbf{C} (2) = 2$
- ◆ Si la probabilidad asociada al estadístico de Wald es mayor a 0.05, aceptar la H_0 .

Wald Test:			
Equation: Untitled			
Null Hypothesis: C(2)=2			
F-statistic	13957.90	Probability	0.000000
Chi-square	13957.90	Probability	0.000000

- ◆ En este caso la probabilidad asociada al test de Wald es menor a 0.05, por lo tanto se rechaza la H_0 .

II. PREDICCIÓN


Estimar los gastos en ingresos, si se sabe que los ingresos se modificaran de la siguiente manera:

OBS	INGRESOS
21	20.5
22	20.5
23	21
24	21

25	22
----	----

PROCEDIMIENTO:

- ◆ Expandir el rango y el tamaño de la muestra
- ◆ Ingresar a las variables independientes e introducir los nuevos valores
- ◆ Ingresar al Output de la regresión inicial y hacer clic en FORECAST
- ◆ Se generará automáticamente una nueva variable (INGRESOSOVF) en el workfile, el cual será los valores estimados y proyectados de la variable dependiente.



Raíz Cuadrática Media (rms): Es un estimador que mide la calidad del modelo para la predicción, este debe ser lo más pequeño posible. Se define mediante la siguiente ecuación:

$$rms = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2}$$

\hat{Y}_t : Valor estimado de Y_t

Y_t : Valor observado de Y_t

Coefficiente de Theil (U): Este estadístico también mide la calidad del modelo para predecir, el cual debe ser un valor pequeño para que el modelo sea bueno para la predicción; se define:

$$U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t)^2} + \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t)^2}}$$


En nuestro modelo el U de Theil es 0.043321, entonces se podría afirmar que el modelo es bueno para la predicción

III. HETEROSCEDASTICIDAD

GRÁFICA DE LOS RESIDUOS

PROCEDIMIENTO:

- ◆ Regresionar el modelo
- ◆ Ingresar a VIEW/ ACTUAL,FITTED,RESIDUAL/ RESIDUAL GRAPH



Observamos en la gráfica que el modelo presenta problemas de Heteroscedasticidad.

TEST DE WHITE

El test de White es un contraste general que no requiere la elección de una variable que explique la volatilidad de los residuos. En particular, esta prueba supone que dicha varianza es una función lineal de los regresores originales del modelo, sus cuadrados y productos cruzados.

$$e_i^2 = f(\alpha, x_1 \dots x_p, x_1^2 \dots x_p^2, x_1x_2 \dots x_{p-1}x_p)$$

PROCEDIMIENTO:

- ◆ Regresionar el modelo
- ◆ Ingresar a VIEW/ RESIDUAL TESTS / WHITE HETEROSKEDASTICITY (no cross terms)
Como solo tiene una variable explicativa no hay necesidad de hacer términos cruzados
- ◆ La Ho nos dice que el modelo no presenta heteroscedasticidad. Si la probabilidad asociada al test es mayor a 0.05, aceptar la Ho.

White Heteroskedasticity Test:				
F-statistic	5.979575	Probability	0.010805	
Obs*R-squared	8.259324	Probability	0.016088	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 06/28/02 Time: 10:58				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.092180	0.178932	0.515169	0.6131
INGRESOS	-0.021234	0.032647	-0.650395	0.5241
INGRESOS^2	0.001592	0.001285	1.238321	0.2324
R-squared	0.412966	Mean dependent var	0.125230	
Adjusted R-squared	0.343903	S.D. dependent var	0.177434	
S.E. of regression	0.143721	Akaike info criterion	-0.904400	
Sum squared resid	0.351149	Schwarz criterion	-0.755040	
Log likelihood	12.04400	F-statistic	5.979575	
Durbin-Watson stat	1.235556	Prob(F-statistic)	0.010805	

La prueba de hipótesis se realiza sobre la base del estadístico $nR^2 \sim X^2_{(p-1)}$ (donde n es el número de observaciones de la muestra, R² el coeficiente de bondad de ajuste de la regresión auxiliar y p el número de parámetros a estimar en dicha regresión).

Observamos que la probabilidad asociada al test de White (0.01), es inferior a 0.05, entonces se concluye que el modelo presenta problemas de heteroscedasticidad a un nivel de confianza del 95%.

TEST ARCH LM

El proceso ARCH(p) puede escribirse como:

$$\text{Var}(\mu_t) = \sigma^2_t = \alpha_0 + \alpha_1\mu_{t-1}^2 + \alpha_2\mu_{t-2}^2 + \dots + \alpha_p\mu_{t-p}^2 \quad \dots\dots(3)$$

PROCEDIMIENTO:

- ◆ Regresionar el modelo
- ◆ Ingresar a VIEW/ RESIDUAL TESTS / ARCH LM TEST / Número de rezagos de la variable
- ◆ La Ho del test ARCH LM es que la VARIANZA NO PRESENTA UN PROCESO DE COMPORTAMIENTO ARCH(n), es decir que no depende de ella misma rezagada (n) veces. Esto no significa necesariamente que la varianza sea constante, es decir que no exista heteroscedasticidad; simplemente se descarta la posibilidad de que el proceso heteroscedástico que pueda presentar la varianza sea del tipo ARCH(n)
- ◆ Si la probabilidad asociada al test LM es mayor a 0.05, aceptar la Ho.

ARCH Test:				
F-statistic	5.217462	Probability	0.019053	
Obs*R-squared	7.384675	Probability	0.024914	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 07/07/02 Time: 09:24				
Sample(adjusted): 3 20				
Included observations: 18 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.088274	0.044340	1.990844	0.0650
RESID^2(-1)	0.789597	0.244862	3.224655	0.0057
RESID^2(-2)	-0.405218	0.244597	-1.656673	0.1183
R-squared	0.410260	Mean dependent var	0.134592	
Adjusted R-squared	0.331628	S.D. dependent var	0.184697	
S.E. of regression	0.150997	Akaike info criterion	-0.792096	
Sum squared resid	0.342003	Schwarz criterion	-0.643701	
Log likelihood	10.12886	F-statistic	5.217462	
Durbin-Watson stat	1.696999	Prob(F-statistic)	0.019053	

Calculando el nR^2 , donde R² es el coeficiente de determinación obtenido en la regresión auxiliar (4) puede demostrarse que:

$$nR^2 \sim X^2_p \quad \dots\dots(5)$$

donde p es el número de grados de libertad y equivale al grado de autocorrelación.

Si el estadístico contenido nR^2 es mayor que el X^2_p se aceptaría que existe correlación entre las varianzas del término de perturbación.

El Eviews lo calcula directamente, observándose que la probabilidad asociada al estadístico es inferior a 0.05 por lo tanto se rechaza la H_0 . Se concluye que la varianza presenta un proceso de comportamiento ARCH de orden 2.

PRUEBA DE BREUSCH-PAGAN

Aquí se supone que el término de error para cada observación depende de un vector de variables x_i de dimensión p , es decir,

$$\sigma_i^2 = h(X_i' \alpha) = h(\alpha_1 + \alpha_2 Z_{i2} + \alpha_3 Z_{i3} + \dots + \alpha_p Z_{ip})$$

Donde los Z_i podrían ser las mismas variables X_i

$$\sigma_i^2 = h(X_i' \alpha) = h(\alpha_1 + \alpha_2 X_{i2} + \alpha_3 X_{i3} + \dots + \alpha_p X_{ip})$$

PASOS:

- ◆ Obtener los residuos de la regresión por MCO del modelo original de:
GASTOS DE VIVIENDA = f(INGRESOS)
- ◆ Grabarlos residuos obtenidos con un nuevo nombre (resid1), para ello se debe generar esta nueva variable. En el workfile hacer clic en Genr y digitar:
resid1 = resid.

Se construye las variables p_i (residuos normalizados), que se asumen como equivalentes a σ_i^2 y están definidas como:

$$P_i = \frac{\hat{\mu}_i}{\hat{\sigma}}$$

donde:

$$\hat{\sigma} = \frac{\sum \hat{\mu}_i^2}{n} \quad i = 1, 2, \dots, n$$

haciéndolo en el Eviews:

- ◆ Generar la variable de los residuos normalizados: $\text{resid2} = \frac{\text{resid1}^2}{\hat{\sigma}_{MV}^2}$.
- ◆ Donde $\hat{\sigma}_{MV}^2$ es la varianza de máxima verosimilitud, la cual se obtiene dividiendo la SCR entre el total de la muestra ($2.504600/20 = 0.12523$).
- ◆ En el workfile hacer clic en Genr y digitar:
resid2 = (resid1^2)/0.12523

Se regresiona los p_i así contruidos sobre las x_i (fórmula general):

$$P_i = \alpha_1 + \alpha_2 X_{2i} + \dots + \alpha_p X_{pi} + v_i$$

- ◆ Aplicado al ejemplo, regresionar resid2 en función de la variable independiente. En este caso es respecto a la variable ingresos

Ls resid2 c ingresos

Dependent Variable: RESID2				
Method: Least Squares				
Date: 07/07/02 Time: 21:35				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.852831	0.637845	-1.337050	0.1979
INGRESOS	0.148226	0.046582	3.182080	0.0052
R-squared	0.360014	Mean dependent var		1.000000
Adjusted R-squared	0.324460	S.D. dependent var		1.416867
S.E. of regression	1.164541	Akaike info criterion		3.237170
Sum squared resid	24.41079	Schwarz criterion		3.336743
Log likelihood	-30.37170	F-statistic		10.12563
Durbin-Watson stat	1.234451	Prob(F-statistic)		0.005162

- ◆ Con los datos del output de la regresión se obtiene los siguientes resultados:
Sum squared resid (SRC): 24.41079
S.D. dependent var (Desviación estándar de la variable dependiente): 1.416867
Operando la SD, obtenemos la suma total de cuadrados (SCT): 38.14273
Se cumple: $SCT = SCE + SRC$ \square $SEC = SCT - SRC = 38.14273 - 24.41079 = 13.73194$
Entonces: $\Theta = \frac{1}{2} (SEC) = \frac{1}{2} (13.73194) = 6.86597$.
- ◆ Bajo la hipótesis nula de homoscedasticidad y términos de error normalmente distribuidos, el cociente $SCE/2$ calculado para la anterior regresión se distribuye de acuerdo a una distribución Chi – Cuadrado con $p = 1$ grados de libertad. Comparar con el estadístico de tablas. Si $SCE/2$ es menor al estadístico de tablas, entonces aceptar la H_0 de homoscedasticidad.

Se tiene que el $X^2_{(1,0.05)}$ es 3.84146, comparándola con el estadístico calculado, podemos concluir que a un nivel de 0.05 de significancia se debe rechazar la H_0 de homoscedasticidad, es decir que los residuos presentan problemas de Heteroscedasticidad.

PRUEBA DE GOLDFELD – QUANDT

El test consiste en verificar que la varianza de μ no es función monótona creciente o decreciente de las x_s , en cuyo caso no habría heteroscedasticidad.

Pasos:

Ordenar las observaciones de la serie en orden creciente, tomando como referencia los datos de la variable exógena (x_i) que supuestamente produce el problema de heteroscedasticidad.

Se toma dos grupos en los extremos estimándose para cada uno su respectiva varianza.

Grupo I	Grupo II
$\hat{\sigma}_{\mu_I}^2 = \frac{e'_I e_I}{n_1 - k}$	$\hat{\sigma}_{\mu_{II}}^2 = \frac{e'_{II} e_{II}}{n_2 - k}$

$$\frac{\sigma_{\mu_{II}}^2}{\sigma_{\mu_I}^2} = F_c \sim F_{(n_1-k, n_2-k; k)}$$

Si el F_c es mayor que el de tabla se rechaza la H_0 de homoscedasticidad

PASOS en el Eviews:

- ◆ En el Excel ordenar las observaciones de la serie en orden creciente, tomando como referencia los datos de la variable exógena (ingresos).
- ◆ Omitir $c = 6$ observaciones centrales, y dividir las observaciones restantes $(n-c)$ en dos grupos, cada uno de $(n-2)/2 = 7$ observaciones.
- ◆ En el eviews hacer clic en Quick Empty Group (Edit series) y copiar las observaciones ordenadas en forma ascendente y ponerles nuevos nombres a las series (GASTOSORD e INGRESOSORD).
- ◆ Regresionar el modelo ls gastosord c ingresosord. En el workfile seleccionar la variable gastord e ingresosord. Hacer clic derecho en dicha selección y escoger OPEN/AS EQUATION, aparecerá la ecuación digitada en una caja de dialogo. En esta caja aparece la opción sample cambiar la muestra: 1 7 y OK.
- ◆ Se obtiene los siguientes resultados:

Dependent Variable: GASTOSORD				
Method: Least Squares				
Date: 08/30/02 Time: 13:33				
Sample: 1 7				
Included observations: 7				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.860000	0.132966	6.467811	0.0013
INGRESOSORD	0.224000	0.019514	11.47888	0.0001
R-squared	0.963441	Mean dependent var		2.300000
Adjusted R-squared	0.956129	S.D. dependent var		0.556776
S.E. of regression	0.116619	Akaike info criterion		-1.224852
Sum squared resid	0.068000	Schwarz criterion		-1.240306
Log likelihood	6.286983	F-statistic		131.7647
Durbin-Watson stat	2.035294	Prob(F-statistic)		0.000088

- ◆ Regresionar el modelo ls gastosord c ingresosord. En el workfile seleccionar la variable gastord e ingresosord. Hacer clic derecho en dicha selección y escoger OPEN/AS EQUATION cambiar la muestra: 14 20 y OK. Se obtiene lo siguiente:

Dependent Variable: GASTOSORD				
Method: Least Squares				
Date: 08/30/02 Time: 13:43				
Sample: 14 20				
Included observations: 7				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.980000	1.732836	1.719724	0.1461
IGRESOSORD	0.128000	0.092624	1.381932	0.2255
R-squared	0.276383	Mean dependent var	5.357143	
Adjusted R-squared	0.131660	S.D. dependent var	0.594018	
S.E. of regression	0.553534	Akaike info criterion	1.889969	
Sum squared resid	1.532000	Schwarz criterion	1.874515	
Log likelihood	-4.614893	F-statistic	1.909735	
Durbin-Watson stat	0.917493	Prob(F-statistic)	0.225545	

- ◆ Se obtiene las sumas residuales (SCR) para ambas regresiones y se obtiene el estadístico F.

$$F_{\text{cal}} = \frac{e'_{II}e_{II} / g.l.}{e'_I e_I / g.l.} = \frac{e'_{II}e_{II}}{e'_I e_I} = \frac{1.5320}{0.0680} = 22.529$$

A continuación se realiza la hipótesis

Ho: No Existe heteroscedasticidad

H₁: Existe heteroscedasticidad

- ◆ El F_(5,5) de tablas a un nivel del 5% de significancia es 5.05 , como el F de la tabla es menor al F calculado, entonces se rechaza la Ho. Se concluye que el modelo presenta problemas de Heteroscedasticidad.

PRUEBA DE PARK

Park sugiere que si σ_i^2 es una función de la variable explicativa, la fórmula propuesta es:

$$\sigma_i^2 = \sigma_\mu^2 x_i^\alpha e^{vi}$$

e : log. Neperiano

vi : Término de perturbación estocástico.

Modelo linealizado:

$$\ln \sigma_i^2 = \ln \sigma_\mu^2 + \alpha \ln x_i + \mu_i$$

Se utiliza como variable alternativa los residuales al cuadrado que han dado forma de la siguiente manera:

$$\ln e_i^2 = \ln \sigma_\mu^2 + \alpha \ln x_i$$

Si α es estadísticamente significativa nos sugiere que existe heteroscedasticidad.

PASOS (En el Eviews):

- ◆ Obtener los residuos de la regresión por MCO del modelo original de:
GASTOS DE VIVIENDA = f(INGRESOS)
- ◆ Grabarlos residuos obtenidos con un nuevo nombre (resid1), para ello se debe generar esta nueva variable. En el workfile hacer clic en Genr y digitar:
resid1 = resid
- ◆ Generar nuevas variables. En el workfile hacer clic en Genr y digitar:
Lresid2 = Log(resid1²) OK
Lingresos = log (ingresos) OK
- ◆ Regresionar el siguiente modelo:

ls lresid2 c ingresos

Dependent Variable: LRESID2				
Method: Least Squares				
Date: 08/30/02 Time: 14:14				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-8.444036	1.744775	-4.839614	0.0001
LINGRESOS	2.134129	0.709350	3.008570	0.0075
R-squared	0.334602	Mean dependent var	-3.313694	
Adjusted R-squared	0.297636	S.D. dependent var	1.970700	
S.E. of regression	1.651588	Akaike info criterion	3.935991	
Sum squared resid	49.09936	Schwarz criterion	4.035564	
Log likelihood	-37.35991	F-statistic	9.051496	
Durbin-Watson stat	2.029052	Prob(F-statistic)	0.007543	

- ◆ Ho: No existe Heterocedasticidad (homoscedasticidad).
H₁: Existe heteroscedasticidad
- ◆ Se debe docimar la significancia respecto al coeficiente de la variable independiente (ingresos).

$$\ln e^2_i = \ln \sigma^2_\mu + \alpha * \ln \text{Ingresos}_i$$

- ◆ Si α es significativa (p inferior a 0.05), entonces hay Heteroscedasticidad importante causada por la variación de los ingresos. Entonces como $p = 0.0075$ inferior al nivel de significancia del 0.05 se rechaza la hipótesis de homoscedasticidad

PRUEBA DE GLEJSER

Forma funcional: $|e_i| = \beta_1 + \beta_i \sqrt{x_i} + v_i$

Estimando la regresión con respecto a los residuales, se docima la significancia de los β_i del mismo modo que en el caso de PARK, si los β son significativos estaría indicando la existencia de heteroscedasticidad.

PASOS:

- ◆ Obtener los residuos de la regresión por MCO del modelo original de:
GASTOS DE VIVIENDA = f(INGRESOS)
- ◆ Grabarlos residuos obtenidos con un nuevo nombre (resid1), para ello se debe generar esta nueva variable. En el workfile hacer clic en Genr y digitar:
resid1 = resid
- ◆ Obtener el valor absoluto de la variable resid (en Excel) y nombrarla como varesid1.
- ◆ Generar la raíz de la variable ingresos. En Genr digitar: ringresos = ingresos^(1/2)
- ◆ Regresionar el siguiente modelo:

$$|e_i| = \beta_1 + \beta_i \sqrt{x_i} + v_i$$

donde $X_i = \text{ringresos}$

Dependent Variable: VARESID1				
Method: Least Squares				
Date: 08/30/02 Time: 15:40				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.275944	0.170653	-1.616990	0.1233
RINGRESOS	0.161573	0.048268	3.347423	0.0036
R-squared	0.383672	Mean dependent var		0.279200
Adjusted R-squared	0.349432	S.D. dependent var		0.223082
S.E. of regression	0.179933	Akaike info criterion		-0.497823
Sum squared resid	0.582767	Schwarz criterion		-0.398250
Log likelihood	6.978232	F-statistic		11.20524
Durbin-Watson stat	1.490781	Prob(F-statistic)		0.003585

- ◆ H_0 : No existe Heterocedasticidad (homoscedasticidad).
 H_1 : Existe heteroscedasticidad
- ◆ Se debe docimar la significancia respecto al coeficiente de la variable independiente (ingresos).

$$|e_i| = \beta_1 + \beta_i \sqrt{x_i} + v_i$$

- ◆ Si β_i es significativa (p inferior a 0.05), entonces hay Heteroscedasticidad causada por la variación de los ingresos. Entonces como $p = 0.0036$ inferior al nivel de significancia del 0.05 se rechaza la hipótesis de homoscedasticidad.

CORRECCIÓN DE HETEROSCEDASTICIDAD**PASOS:**

- ◆ Generar nuevas variables:
- ◆ $\text{NVGASTOSV} = \text{GASTOSV}/\text{INGRESOS}$
- ◆ $\text{INVINGRESOS} = 1/\text{INGRESOS}$
- ◆ Regresionar el nuevo modelo: $\text{NVGASTOSV} = \text{INVINGRESOS}$

$$Y_i = \beta_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_k x_k + u_i$$

$$E(u_i^2) = \sigma_u^2 a_i^2$$

Entonces:

$$\frac{y_i}{a_i} = \frac{\beta_1}{a_i} + \beta_2 \frac{x_{2i}}{a_i} + \dots + \frac{\beta_k x_{ki}}{a_i} + \frac{\mu_i}{a_i}$$

Dependent Variable: NVGASTOSV				
Method: Least Squares				
Date: 06/28/02 Time: 10:03				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
INVINGRESOS	0.752923	0.098255	7.662934	0.0000
C	0.249487	0.011723	21.28124	0.0000
R-squared	0.765382	Mean dependent var		0.327917
Adjusted R-squared	0.752348	S.D. dependent var		0.051375
S.E. of regression	0.025567	Akaike info criterion		-4.400404
Sum squared resid	0.011766	Schwarz criterion		-4.300831
Log likelihood	46.00404	F-statistic		58.72056
Durbin-Watson stat	1.493042	Prob(F-statistic)		0.000000

Realizar el test de White para probar la presencia de heteroscedasticidad en este nuevo modelo.

White Heteroskedasticity Test:				
F-statistic	0.379713	Probability	0.689715	
Obs*R-squared	0.855237	Probability	0.652060	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 06/28/02 Time: 11:24				
Sample: 1 20				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.001028	0.000956	1.074960	0.2974
INVINGRESOS	-0.006636	0.018745	-0.354016	0.7277
INVINGRESOS^2	0.017685	0.072099	0.245290	0.8092
R-squared	0.042762	Mean dependent var		0.000588
Adjusted R-squared	-0.069854	S.D. dependent var		0.000625
S.E. of regression	0.000647	Akaike info criterion		-11.71152
Sum squared resid	7.11E-06	Schwarz criterion		-11.56216
Log likelihood	120.1152	F-statistic		0.379713
Durbin-Watson stat	1.322094	Prob(F-statistic)		0.689715

- ◆ La Ho nos dice que el modelo no presenta heteroscedasticidad. Si la probabilidad asociada al test es mayor a 0.05, aceptar la Ho.
Observamos que la probabilidad asociada al test de White (0.652060), es superior a 0.05, entonces se concluye que el modelo no presenta problemas de heteroscedasticidad a un nivel de confianza del 95%.

LABORATORIO 5**HETEROSCEDASTICIDAD
(PARTE II)**

1. Los resultados de la Encuesta Económica Anual dirigido al Sector Comercio en el año 1990, ha permitido elaborar el cuadro siguiente:

Remuneración Promedio del Personal Ocupado en las principales
Empresas de Comercio

ESTRATO DE VENTAS		REMUNERACION PROMEDIO	
		PERMANENTE	EVENTUAL
TOTAL		990,30	740,50
I	300000 a 400000	608,10	380,94
II	400001 a 500000	881,50	518,50
III	500001 a 600000	1022,50	620,50
IV	600001 a 700000	970,40	760,50
V	700001 a 800000	1033,50	880,50
VI	800001 a 900000	1037,50	910,50
VII	900001 a 1000000	1181,60	1010,00

- a. Desarrolle los modelos apropiado de regresión que explique las remuneraciones promedio del personal permanente y eventual en función de los estratos de ventas (utilice la marca de clase de los estratos de venta como X_i)

PRIMER MODELO: $RE = \hat{\alpha}_0 + \hat{\alpha}_1 EV + \mu$

Dependent Variable: RE
Method: Least Squares
Date: 08/30/02 Time: 11:03
Sample: 1 7
Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	45.46738	45.10731	1.007983	0.3597
EV	0.001047	6.63E-05	15.78314	0.0000
R-squared	0.980323	Mean dependent var	725.9200	
Adjusted R-squared	0.976388	S.D. dependent var	228.4037	
S.E. of regression	35.09700	Akaike info criterion	10.18906	
Sum squared resid	6158.998	Schwarz criterion	10.17361	
Log likelihood	-33.66173	F-statistic	249.1076	
Durbin-Watson stat	1.327224	Prob(F-statistic)	0.000019	

El modelo nos indica que la variable estrato de ventas es significativa para el modelo, es decir, que explica a la variable dependiente “**remuneración eventual**”, también podemos observar que el modelo es bueno **R-squared = 0.980323**.

SEGUNDO MODELO: $R_p = \hat{\alpha}_2 + \hat{\alpha}_3 EV + \mu$


Dependent Variable: RP
 Method: Least Squares
 Date: 09/06/02 Time: 16:16
 Sample: 1 7
 Included observations: 7


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	487.7730	122.4047	3.984921	0.0105
EV	0.000730	0.000180	4.054849	0.0098
R-squared	0.766811	Mean dependent var	962.1571	
Adjusted R-squared	0.720173	S.D. dependent var	180.0429	
S.E. of regression	95.24038	Akaike info criterion	12.18564	
Sum squared resid	45353.65	Schwarz criterion	12.17019	
Log likelihood	-40.64974	F-statistic	16.44180	
Durbin-Watson stat	1.551211	Prob(F-statistic)	0.009779	

Este modelo nos indica que la variable estrato de ventas es significativa para el modelo, es decir, que explica a la variable dependiente “remuneración permanente”, también podemos observar que el modelo es bueno R-squared 0.980323.

b. Para el caso del Personal permanente:

- Realizar análisis gráfico de residuos y los contrastes de picos.





- Hacer una regresión de e_i entre Y_i ¿Existe una relación significativa entre ambas?

Dependent Variable: RESID1
 Method: Least Squares
 Date: 09/06/02 Time: 16:44
 Sample: 1 7
 Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RP	0.233189	0.189110	1.233092	0.2723
C	-224.3648	184.6634	-1.214993	0.2786
R-squared	0.233189	Mean dependent var		-5.68E-14
Adjusted R-squared	0.079827	S.D. dependent var		86.94217
S.E. of regression	83.39983	Akaike info criterion		11.92013
Sum squared resid	34777.66	Schwarz criterion		11.90467
Log likelihood	-39.72044	F-statistic		1.520515
Durbin-Watson stat	1.137682	Prob(F-statistic)		0.272349

El modelo nos indica que no existe dependencia entre las variables e_i con y_i , además podemos observar que el modelo no es muy bueno (R-squared=0.23)

aplicando la prueba de Park regresar $\ln(e_i^2)$ contra $\ln(x)$

$$\ln e_i^2 = B_0 + B_1 \ln X_i + U_i$$

$$H_0 : \text{No existe heteroscedasticidad} \sim B_1 = 0$$

$$H_a : \text{Existe heteroscedasticidad} \sim B_1 \neq 0$$

$$\alpha = 0.05$$

Después de correr nuestro modelo tenemos la siguiente presentación:

Dependent Variable: LE2
 Method: Least Squares
 Date: 08/30/02 Time: 11:50
 Sample: 1 7
 Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-12.93042	1.367181	-9.457727	0.0002
LEV	1.950640	0.102511	19.02867	0.0000
R-squared	0.986379	Mean dependent var		13.07722
Adjusted R-squared	0.983655	S.D. dependent var		0.700840
S.E. of regression	0.089600	Akaike info criterion		-1.751967
Sum squared resid	0.040141	Schwarz criterion		-1.767421
Log likelihood	8.131883	F-statistic		362.0902
Durbin-Watson stat	1.376162	Prob(F-statistic)		0.000007

De donde se obtienen:

	parámetros	t-student
$B_1 =$	1.950640	(19.02867)
$B_0 =$	-12.93042	(-9.457727)

Luego hallamos el t_c

$$T_c = B_1 / \sigma(B_1) = 19.03$$

Como el $t_c > t_{(5, 0.025)} = 2.571$, entonces se rechaza H_0 y se concluye que hay evidencia estadística suficiente para afirmar que existe heteroscedasticidad en el modelo, entre la remuneración permanente contra el estrato de ventas con los datos originales.

La prueba de Park sugiere que existe heteroscedasticidad en el modelo con los datos originales.

- Aplique la prueba de Glejser con las siguientes funciones:

$$|e| = a + bx_i$$

$$|e| = a + b\sqrt{x}$$

$$|e| = bx_i$$

$$|e| = b\sqrt{x}$$

Realizando el primer modelo: $|e| = a + bx_i$

Dependent Variable: ABSRESID

Method: Least Squares

Date: 09/06/02 Time: 19:03

Sample: 1 7

Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
EV	-0.000187	8.84E-05	-2.120607	0.0874
C	181.1005	60.11922	3.012356	0.0297
R-squared	0.473517	Mean dependent var	59.24892	
Adjusted R-squared	0.368220	S.D. dependent var	58.85095	
S.E. of regression	46.77744	Akaike info criterion	10.76364	
Sum squared resid	10940.64	Schwarz criterion	10.74818	
Log likelihood	-35.67272	F-statistic	4.496976	
Durbin-Watson stat	2.918077	Prob(F-statistic)	0.087438	

Con los resultados de este primer modelo podemos decir que existe heteroscedasticidad.

Corriendo el segundo modelo:

$$|e| = a + b\sqrt{x}$$

Dependent Variable: ABSRESID

Method: Least Squares

Date: 09/06/02 Time: 19:09

Sample: 1 7

Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RAIZ_EV	-0.299582	0.136983	-2.186999	0.0804
C	297.7559	110.4392	2.696106	0.0430
R-squared	0.488907	Mean dependent var	59.24892	
Adjusted R-squared	0.386689	S.D. dependent var	58.85095	
S.E. of regression	46.08864	Akaike info criterion	10.73397	
Sum squared resid	10620.81	Schwarz criterion	10.71851	
Log likelihood	-35.56888	F-statistic	4.782964	
Durbin-Watson stat	2.984064	Prob(F-statistic)	0.080400	

Esta prueba nos indica que existe la presencia de heteroscedasticidad.

Estimando tercer modelo: $y_i = \beta x_i$

Dependent Variable: ABSRESID

Method: Least Squares

Date: 09/06/02 Time: 19:14

Sample: 1 7

Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
EV	6.71E-05	3.98E-05	1.684094	0.1431
R-squared	-0.481976	Mean dependent var		59.24892
Adjusted R-squared	-0.481976	S.D. dependent var		58.85095
S.E. of regression	71.64305	Akaike info criterion		11.51283
Sum squared resid	30796.36	Schwarz criterion		11.50511
Log likelihood	-39.29491	Durban-Watson stat		1.199469

Aqui el modelo nos indica la ausencia de heteroscedasticidad.

Cuarto modelo: $|e_i| = b \sqrt{x_i}$

Dependent Variable: ABSRESID

Method: Least Squares

Date: 09/06/02 Time: 19:17

Sample: 1 7

Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RAIZ EV	0.065116	0.030897	2.107510	0.0796
R-squared	-0.254118	Mean dependent var		59.24892
Adjusted R-squared	-0.254118	S.D. dependent var		58.85095
S.E. of regression	65.90565	Akaike info criterion		11.34589
Sum squared resid	26061.33	Schwarz criterion		11.33816
Log likelihood	-38.71061	Durban-Watson stat		1.386950

Este modelo también muestra indicios de la no existencia de heteroscedasticidad. En conclusión podemos obtener de la prueba de glejser que existe heteroscedasticidad debido a la existencia de heteroscedasticidad en dos de los cuatros modelos.

Encuentre la correlación del rango de SPEARMAN entre $|e_i|$ y x_i

Ei	ei	ran ei	ev	rang ev	di	di2
-135.1104	135.1104	7	350000	1	6	36
65.30706	65.30706	4	450000.5	2	2	4
133.3249	133.3249	6	550000.5	3	3	9
8.242805	8.242805	3	650000.5	4	-1	1
-1.639323	1.639323	2	750000.5	5	-3	9
-70.62145	70.62145	5	850000.5	6	-1	1
0.496421	0.496421	1	950000.5	7	-6	36
					Suma:	96

H_0 : No existe heteroscedasticidad

H_a : Existe heteroscedasticidad

$$\alpha = 0.05$$

$$r_s = 1-6 \left[\frac{\sum d_i^2}{N(N^2 - 1)} \right] = 1-6 \left[\frac{96}{7(7^2 - 1)} \right] = 0.29$$

$$t_c = \frac{r_s \sqrt{N-2}}{\sqrt{1-r_s^2}} = \frac{0.29 \sqrt{7-2}}{\sqrt{1-0.29^2}} = 0.678$$

Como $t_c < t(5, 0.025) = 2.571$ se acepta H_0 . Por tanto no existe evidencia de una relación sistemática entre la variable explicativa y los valores absolutos de los residuos, lo que puede sugerir que no existe heteroscedasticidad.

- c. Suponiendo que la varianza del término de perturbación del 1er modelo (remuneración personal permanente = f (estrato de ventas), es proporcional al modelo de la variable explicativa transforma los datos de modo que el término de perturbación sea homocedástico.**

$$\mathbf{Rp} = \mathbf{a}_2 + \mathbf{a}_3 \mathbf{EV} + \boldsymbol{\mu}$$

Suponiendo:

$$\sigma^2_{\boldsymbol{\mu}} = \sigma^2 \text{RP} \quad \text{entonces:} \quad p = \sqrt{\text{RP}}$$

Transformando el modelo:

$$\mathbf{Rp}^* = \mathbf{a}_2 + \mathbf{a}_3 \mathbf{EV}^* + \boldsymbol{\mu}^*$$

Donde:

$$\text{Rp}^* = \text{Rp} / \sqrt{\text{RP}}$$

$$\text{EV}^* = \text{EV} / \sqrt{\text{RP}}$$

$$\boldsymbol{\mu}^* = \boldsymbol{\mu} / \sqrt{\text{RP}}$$

- d. Repite (e_i), suponiendo que la varianza es proporcional al Estrato de Ventas.**

$$\mathbf{Rp} = \mathbf{a}_2 + \mathbf{a}_3 \mathbf{EV} + \boldsymbol{\mu}$$

Suponiendo: $\sigma^2_{\boldsymbol{\mu}} = \sigma^2 \text{EV} \quad p = \sqrt{\text{EV}}$

Transformando el modelo:

$$\mathbf{Rp}^* = \mathbf{a}_2 + \mathbf{a}_3 \mathbf{EV}^* + \boldsymbol{\mu}^*$$

Donde:

$$\text{Rp}^* = \text{Rp} / \sqrt{\text{EV}}$$

$$\text{EV}^* = \text{EV} / \sqrt{\text{EV}}$$

$$\boldsymbol{\mu}^* = \boldsymbol{\mu} / \sqrt{\text{EV}}$$

- e. Son iguales las varianzas de las remuneraciones promedio de los Trabajadores permanentes y eventuales.

Descriptive Stats	REMUNERACION PROMEDIO	
	PERMANENTE	EVENTUAL
Mean	962,1571	725,9200
Median	1.022,5000	760,5000
Maximum	1.181,6000	1.010,0000
Minimum	608,1000	380,9400
Std. Dev.	180,0429	228,4037
Skewness	-1,0281	-0,2750
Kurtosis	3,3581	1,7422
Jarque-Bera	1,2705	0,5497
Probability	0,5298	0,7597
Observations	7	7
Var	32415,4595	52168,2502

Se puede observar que las varianzas de las remuneraciones promedio de los trabajadores permanentes y eventuales es diferente, siendo la varianza de las remuneraciones promedio de los trabajadores permanentes menor que la de los trabajadores eventuales.

2. Desarrolle el test de white

Aplicaremos el test para el primer modelo:

$$R_p = \alpha_2 + \alpha_3 EV + \mu$$

White Heteroskedasticity Test:

F-statistic	1.963800	Probability	0.254587
Obs*R-squared	3.468035	Probability	0.176574

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 09/06/02 Time: 20:38

Sample: 1 7

Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	40135.37	30957.76	1.296456	0.2646
EV	-0.083687	0.101444	-0.824956	0.4558
EV^2	4.48E-08	7.74E-08	0.579749	0.5932
R-squared	0.495434	Mean dependent var	6479.093	
Adjusted R-squared	0.243150	S.D. dependent var	8148.897	
S.E. of regression	7089.304	Akaike info criterion	20.86809	
Sum squared resid	2.01E+08	Schwarz criterion	20.84491	
Log likelihood	-70.03831	F-statistic	1.963800	
Durban-Watson stat	3.324507	Prob(F-statistic)	0.254587	

Esta prueba nos señala la ausencia de heteroscedasticidad

Ahora aplicamos la prueba para el segundo modelo:

$$RE = \hat{\alpha}_0 + \hat{\alpha}_1 EV + \mu$$

White Heteroskedasticity Test:

F-statistic	0.294190	Probability	0.759978
Obs*R-squared	0.897628	Probability	0.638385

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 09/06/02 Time: 20:46

Sample: 1 7

Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1297.742	4231.321	-0.306699	0.7744
EV	0.005874	0.013865	0.423614	0.6936
EV^2	-3.55E-09	1.06E-08	-0.335449	0.7541
R-squared	0.128233	Mean dependent var	879.8569	
Adjusted R-squared	-0.307651	S.D. dependent var	847.3526	
S.E. of regression	968.9695	Akaike info criterion	16.88787	
Sum squared resid	3755608.	Schwarz criterion	16.86469	
Log likelihood	-56.10755	F-statistic	0.294190	
Durbin-Watson stat	2.090585	Prob(F-statistic)	0.759978	

Esta prueba nos indica la ausencia de heteroscedasticidad

3. Aplique la prueba de Breusch-Pagan:

para el primer modelo:

$$R_p = \hat{\alpha}_2 + \hat{\alpha}_3 EV + \mu$$

Hallamos: $\sigma_{\mu}^2 = \frac{SR}{T}$

$$SR = 45353.65$$

$$T = 7$$

$$\sigma_{\mu}^2 = 6479.0928$$

Para luego hallar:

$$e^2_t = \frac{\mu^2_t}{\sigma_{\mu}^2}$$

Y así poder estimar la regresión siguiente:

$$e^2_t = \hat{\alpha}_4 + \hat{\alpha}_5 EV + v_t$$

Dependent Variable: EE
 Method: Least Squares
 Date: 09/06/02 Time: 22:09
 Sample: 1 7
 Included observations: 7

Variable	Coefficient	Std. Error	t-Statistic	Prob.
EV	-3.92E-06	1.93E-06	-2.035037	0.0975
C	3.547189	1.309578	2.708650	0.0423
R-squared	0.453036	Mean dependent var	1.000000	
Adjusted R-squared	0.343644	S.D. dependent var	1.257722	
S.E. of regression	1.018954	Akaike info criterion	3.110386	
Sum squared resid	5.191335	Schwarz criterion	3.094932	
Log likelihood	-8.886352	F-statistic	4.141374	
Durbin-Watson stat	3.154814	Prob(F-statistic)	0.097483	

A continuación calcularemos SCE, teniendo en cuenta:

$$\begin{aligned} \text{STC} &= \text{SCR} + \text{SCE} \\ 75463 &= 5.191335 + \text{SCE} \\ \text{SCE} / 2 &= 2.354997 / 2 = 1.1774985 \end{aligned}$$

Teniendo en cuenta que SCE tiene una distribución chi-cuadrado con 1 g.l.
 Chi – cuadrado = 3.841416, entonces aceptamos la H_0 , es decir, hay homocedasticidad

4. Aplique la prueba de Goldfedt y Quandt

Anteriormente hemos aplicado las pruebas de Park y Spearman para detectar la heteroscedasticidad entre la remuneración del Personal permanente en función de estrato de ventas, resultando que si existe heteroscedasticidad, por tanto nos quedará por analizar si existe heteroscedasticidad entre remuneración del personal eventual en función del estrato de ventas.

Utilizaremos el Test de Goldfed-Quant para el siguiente modelo:

$$\text{RE} = B_0 + B_1 \text{EV}$$

Copiamos los datos ordenados de Remuneración Eventual (en forma ascendente) en función del estrato de ventas (EV).

RE	EV	
380.94	350000	
518.5	450000.5	Obs. Para 1era. Regresión= 3
620.5	550000.5	
760.5	650000.5	Obs. Omitida= 1
880.5	750000.5	
910.5	850000.5	Obs. Para la 2da. Regresión= 3
1010	950000.5	

De la primera regresión obtenemos:

Dependent Variable: RE₁
 Method: Least Squares
 Date: 08/30/02 Time: 16:00
 Sample: 1 3
 Included observations: 3

Variable	Coefficient	Std. Error	t-Statistic	Prob.
EV	0.001198	0.000103	11.66865	0.0544
C	-32.36245	46.94716	-0.689338	0.6158
R-squared	0.992709	Mean dependent var	506.6467	
Adjusted R-squared	0.985418	S.D. dependent var	120.2191	
S.E. of regression	14.51706	Akaike info criterion	8.423248	
Sum squared resid	210.7452	Schwarz criterion	7.822323	
Log likelihood	-10.63487	F-statistic	136.1574	
Durbin-Watson stat	3.000000	Prob(F-statistic)	0.054425	

$$e_1' e_1 = \sum e_1^2 = 210.7452$$

De la segunda regresión, obtenemos:

Method: Least Squares
 Date: 08/30/02 Time: 16:00
 Sample: 1 3
 Included observations: 3

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	383.2913	171.3199	2.237284	0.2676
EV	0.000648	0.000201	3.227346	0.1913
R-squared	0.912402	Mean dependent var	933.6667	
Adjusted R-squared	0.824804	S.D. dependent var	67.78704	
S.E. of regression	28.37326	Akaike info criterion	9.763492	
Sum squared resid	805.0417	Schwarz criterion	9.162567	
Log likelihood	-12.64524	F-statistic	10.41577	
Durbin-Watson stat	3.000000	Prob(F-statistic)	0.191286	

De las dos estimaciones podemos obtener las sumas residuales (SCR):

$$SCR_1 = 210.7452$$

$$SCR_2 = 805.0417.$$

Hallando el FC tenemos: $F_c = 805.0417 / 210.7452$

$$F_c = 3.819976445$$

Siendo el $F_{\tau} = 6.61$

Pudiendo indicar de este resultado que no existe heteroscedasticidad.

5. Como Se Corregiria La Heteroscedasticidad

Para corregir la heteroscedasticidad tenemos que:



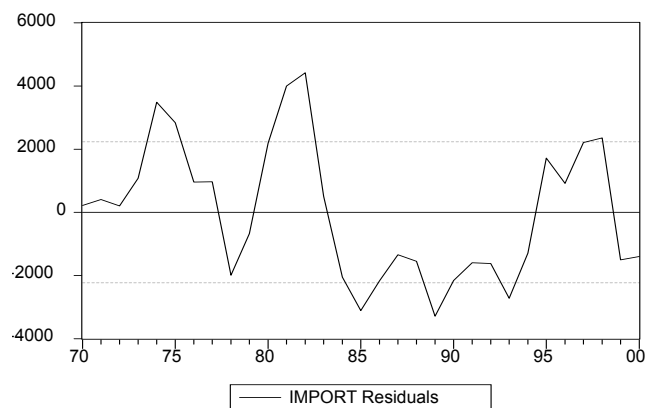
- Detectar cual es la variable que mas explica a los residuos al cuadrado .
- Correr una regresión de los residuos al cuadrado sobre dicha variable y una constante.
- Obtener el estimado de la variable dependiente(de los residuos al cuadrado) al que llamaremos “trans”
- Regresiones el modelo original indicando en la estimación la inversa de la matriz cuadrada de “trans”.

LABORATORIO 6

AUTOCORRELACIÓN

1. Detección de Autocorrelación

Grafico de los residuos



Gráficamente:

- Del primer grafico se puede observar que los residuos presentan problemas de autocorrelación.
- Del segundo grafico los residuos no se comportan de forma totalmente aleatoria

- Del tercer grafico podemos observar que la mayoría de los puntos se encuentran en el primero y tercer cuadrante, lo que llevaría a pensar en la posible existencia de autocorrelación según un esquema AR(1) con coeficiente positivo.


Estadístico DURBIN WATSON

El output de la regresión nos muestra al estadístico Durbin Watson, el cual mide la autocorrelación de primer grado. Si, toma un valor cercano a 2, entonces no existe autocorrelación, si éste es cercano a 4 entonces existe autocorrelación negativa y si es cercano a 0, entonces existe autocorrelación positiva.

En el ejercicio podemos observar que toma un valor inferior a 2 (0.655933), por lo tanto podemos afirmar que el modelo tiene problemas de autocorrelación posita de primer orden a un nivel de significancia del 5%.

Del modelo:

$$\begin{array}{l}
 k = 3 \\
 n = 31 \\
 \alpha = 0.05
 \end{array}
 \Rightarrow
 \begin{array}{l}
 D_L = 1.229 \\
 4 - D_L = 2.771 \\
 D_U = 1.650 \\
 4 - D_U = 2.350
 \end{array}$$



Del Output tenemos que el indicador Durbin Watson es 0.655933, por lo tanto podemos afirmar que existen problemas de autocorrelación positiva de primer orden con un nivel de significancia del 5%.

Test de LAGRANGE

Detección de autocorrelación de orden p.

Luego de estimar los residuos de la ecuación, se debe aplicar la siguiente fórmula:

$$e_t = \alpha + \beta_1 X_{1t} + \dots + \beta_k X_{kt} + \delta_1 e_{t-1} + \dots + \delta_p e_{t-p} + w_t$$

Obtener el coeficiente de determinación (R^2).

El estadístico de prueba es: $n R^2$ donde $LM \approx X^2_p$

Regla de decisión es:

Si $LM > X^2$ crítico – Existe autocorrelación significativa de orden p.

Harvey demostró que en muestras pequeñas, el contraste de LM pierde confiabilidad, maximizando la probabilidad de ocurrencia de errores tipo y propone la siguiente modificación:

$$LM^* = \frac{(n-k)R^2}{p(1-R^2)} \sim F(p, n-k)$$

PROCEDIMIENTO

- ◆ Estando en el Output de la regresión, hacer clic en VIEW/ RESIDUAL TESTS/ SERIAL CORRELATION LM TEST
- ◆ Aparecerá una caja de diálogo, en el cual se debe digitar el número de rezagos a considerar, el cual determina que orden de autocorrelación se desea docimar. (En el ejercicio consideraremos 2 rezagos)
- ◆ Hacer clic en OK
- ◆ La Ho es que el modelo no tiene autocorrelación de orden p ($p = 2$). Obtenemos las siguientes salidas:

H0 : El Modelo no tiene autocorrelación de orden p ($p = 2$).

H1 : El Modelo si tiene autocorrelación de orden p ($p = 2$).

Breusch-Godfrey Serial Correlation LM Test:				
F-statistic	15.24058	Probability	0.000042	
Obs*R-squared	16.72975	Probability	0.000233	
Test Equation:				
Dependent Variable: RESID				
Method: Least Squares				
Date: 09/06/02 Time: 03:49				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-482.4213	2323.977	-0.207584	0.8372
IPC	-1.393453	7.800520	-0.178636	0.8596
PBI	0.005824	0.027703	0.210227	0.8351
RESID(-1)	0.944639	0.179381	5.266111	0.0000
RESID(-2)	-0.407837	0.181036	-2.252797	0.0329
R-squared	0.539669	Mean dependent var	2.57E-13	
Adjusted R-squared	0.468849	S.D. dependent var	2155.707	
S.E. of regression	1571.081	Akaike info criterion	17.70361	
Sum squared resid	64175681	Schwarz criterion	17.93489	
Log likelihood	-269.4059	F-statistic	7.620288	
Durbin-Watson stat	1.948734	Prob(F-statistic)	0.000334	

Como Prob.= 0.000233 < 0.05. Entonces se rechaza la hipótesis nula. Es decir el Modelo tiene problemas de autocorrelación con una probabilidad del 95%.

Test ESTADÍSTICO-Q. (BOX – PIERCE)

Sea ρ_s el coeficiente de autocorrelación de e_t y e_{t-1} ($s = 1, 2, 3, \dots, \rho$).

Para contrastar autocorrelación de primer orden

$$Q_1 = n\hat{\rho}_1^2, \text{ siendo } \hat{\rho}_1 = \frac{\sum e_t e_{t-1}}{\sum e_t^2} \quad Q_1 \sim X^2_1$$

Para contrastar autocorrelación de orden p

$$Q_p = n[\rho_1^2 + \rho_2^2 + \dots + \rho_p^2] \text{ siendo } \hat{\rho}_p = \frac{\sum e_t e_{t-p}}{\sum e_t^2}$$

Este test permite determinar la existencia de autocorrelación hasta un orden establecido.

PROCEDIMIENTO

- ◆ Estando en el Output de la regresión, hacer clic en VIEW/ RESIDUAL TESTS/ CORRELOGRAM Q-STATISTICS
- ◆ Aparecerá una caja de diálogo, en el cual se debe digitar el número de rezagos a considerar, este dependerá desorden de autocorrelación que queremos probar. Por ejemplo, 16 rezagos permite evaluar la posible existencia de autocorrelación de orden 1, 2, ..., hasta 16.
- ◆ Luego, hacer clic en OK.
- ◆ La H_0 es que el modelo no tiene autocorrelación hasta el orden p.

H_0 : El Modelo no tiene autocorrelación hasta el orden p(p=2).

H_1 : El Modelo si tiene autocorrelación de orden p (p=2).

Date: 09/06/02 Time: 04:06						
Sample: 1970 2000						
Included observations: 31						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. *****	. *****	1	0.665	0.665	15.073	0.000
. **	. ***	2	0.217	-0.404	16.730	0.000
. .	. .	3	-0.040	0.055	16.790	0.001
. *	. *	4	-0.134	-0.073	17.472	0.002
. .	. **	5	0.008	0.299	17.475	0.004
. *	. *	6	0.145	-0.104	18.333	0.005
. *	. .	7	0.125	-0.027	19.004	0.008
. .	. *	8	-0.018	-0.173	19.019	0.015
. *	. .	9	-0.171	0.013	20.380	0.016
. **	. *	10	-0.240	-0.106	23.195	0.010
. **	. **	11	-0.296	-0.233	27.688	0.004
. **	. *	12	-0.303	-0.090	32.628	0.001
. *	. *	13	-0.169	0.160	34.248	0.001
. .	. .	14	-0.034	-0.012	34.319	0.002
. .	. .	15	0.057	0.051	34.525	0.003
. .	. **	16	0.026	-0.198	34.571	0.005

Rechazamos la hipótesis nula de no autocorrelación hasta el orden 16 hasta el orden 16 debido a que las probabilidades asociadas al estadístico Q es menor a 0.05 aun nivel de confianza del 95%; es decir que puede existir autocorrelación de orden 1, 2, ..., 15, ó 16.

Para determinar cual es el orden de la autocorrelación, analizamos el comportamiento de los coeficientes de la autocorrelación parcial, los cuales están reflejados en el correlograma (PARTIAL CORRELATION). El orden de la autocorrelación esta determinado por el orden del último coeficiente que está fuera de las bandas de confianza.

En el ejercicio, el primer y segundo coeficiente de autocorrelación parcial está fuera de las bandas, es decir que existe autocorrelación de segundo orden.

Corrección de la Autocorrelación

1.- Estadístico Durbin Watson

El procedimiento completo es el siguiente:

- 1° Estimación MCO del modelo, y cálculo del estadístico d de Durbin y Watson.
- 2° Obtención de $\hat{\rho}$ mediante la relación aproximada entre $\hat{\rho}$ y d .
- 3° Aplicación de la ecuación de diferencias generalizadas, considerando el valor de $\hat{\rho}$ estimado, en el paso 2.

- ◆ En el workfile, hacer clic en GENR y digitar las nuevas variables:

importacionesd = importaciones-0.6720335*importaciones(-1) OK
pbid=pbi-0.6720335*pbi(-1) OK
ipcd = ipc - 0.6720335*ipc(-1) OK

Para el año 1970, generar:

$$\begin{aligned} \text{importacionesd}_{1970} &= \sqrt{1 - \hat{\rho}^2} * \text{importaciones}_{1970} & \text{sample 1970}^1 \\ \text{pbid}_{1970} &= \sqrt{1 - \hat{\rho}^2} * \text{pbi}_{1970} & \text{pbid} = ((1 - 0.6720335^2)^{(1/2)} * \text{pbi} & \text{sample 1970} \\ \text{ipcd}_{1970} &= \sqrt{1 - \hat{\rho}^2} * \text{ipc}_{1970} & \text{ipcd} = ((1 - 0.6720335^2)^{(1/2)} * \text{ipc} & \text{sample 1970} \end{aligned}$$

- ◆ En la barra de comandos digitar: **ls importacionesd c pbid ipcd ENTER**

Analizaremos la autocorrelación de primer orden

Dependent Variable: IMPORTACIONESD
 Method: Least Squares
 Date: 09/19/02 Time: 10:17
 Sample: 1970 2000

¹ SAMPLE 1970: EN GENR DIGITAR LA MUESTRA 1970 1970 ; LUEGO HACER CLIC EN OK.

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2119.581	1413.029	-1.500026	0.1448
PBID	0.207043	0.047158	4.390456	0.0001
IPCD	22.84478	15.22981	1.500004	0.1448
R-squared	0.598372	Mean dependent var	4802.570	
Adjusted R-squared	0.569684	S.D. dependent var	2337.408	
S.E. of regression	1533.303	Akaike info criterion	17.60000	
Sum squared resid	65828514	Schwarz criterion	17.73877	
Log likelihood	-269.8000	F-statistic	20.85814	
Durbin-Watson stat	1.327187	Prob(F-statistic)	0.000003	

De las salidas de la regresión se observa que el estadístico Durbin Watson ha aumentado su valor a 1.327187, lo cual es un indicio de que se está corrigiendo el problema de autocorrelación, pero todavía persiste levemente así que se corregirá otra vez, para ello se usará el Durbin-Watson stat =1.327187.

$$\hat{\rho} = 1 - 1.327187 / 2 = 0.3364065$$

a. Generar las nuevas variables, utilizando $\hat{\rho}$, y luego regresionar el modelo por MCO:

◆ En el workfile, hacer clic en GENR y digitar las nuevas variables:

SEGUNDO CAMBIO DE VARIABLE

El coeficiente estimado de la variable rezagada nos servirá para corregir a las variables

Así corregimos nuevamente con $d = 1.327187$

Además:

$$d = 2(1 - \rho) \Rightarrow \rho = 1 - d/2$$

$$\rho = 0.3364065$$

Así generando nuevas variables:

1. $importaciones1p = importaciones1 - 0.3364065 * importaciones1(-1)$, de 1971 –2000
 2. $pbid1 = pbid - 0.3364065 * pbid(-1)$, de 1971 –2000
 3. $ipcd1 = ipcd - 0.3364065 * ipcd(-1)$, de 1971 –2000
-
1. $importacionesd1 = ((1 - 0.3364065^2)^{(1/2)}) * importaciones1$, de 1970.
 2. $pbid1 = ((1 - 0.3364065^2)^{(1/2)}) * pbid$, de 1970.
 3. $ipcd1 = ((1 - 0.3364065^2)^{(1/2)}) * ipcd$, de 1970.

Dependent Variable: IMPORTACIONESD1

Method: Least Squares

Date: 09/19/02 Time: 10:28

Sample: 1970 2000

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1355.666	854.7584	-1.586022	0.1240
PBID1	0.203359	0.040381	5.036036	0.0000
IPCD1	23.06234	18.77573	1.228305	0.2296
R-squared	0.566868	Mean dependent var		3251.578
Adjusted R-squared	0.535930	S.D. dependent var		2134.947
S.E. of regression	1454.383	Akaike info criterion		17.49432
Sum squared resid	59226466	Schwarz criterion		17.63309
Log likelihood	-268.1619	F-statistic		18.32270
Durbin-Watson stat	1.947398	Prob(F-statistic)		0.000008

Midiendo la autocorrelación de primer orden:


Donde:

k = numero de variables explicativas

(numero de parámetros menos 1)

n = numero de observaciones

$$D_{k; n; \alpha} = D_{2; 31; 0.05} \Rightarrow \begin{matrix} D_L = 1.297 \\ 4 - D_L = 2.703 \\ D_U = 1.570 \\ 4 - D_U = 2.430 \end{matrix}$$



Se observa, que el estadístico Durbin Watson es cercano a 2 (1.947398), por lo tanto se afirmará que el modelo ya no tiene problemas de autocorrelación. Pero los parámetros se han vuelto no significativos en el modelo, aunque el modelo en su conjunto si explica a la variable dependiente.

2. Procedimiento Bietapico De Durbin

Lo que se busca es despejar el valor presente de la variable endógena, para estimar la ecuación autoregresiva y obtener el valor de ρ , el mismo que posteriormente es reemplazado en la misma ecuación de diferencias generalizadas, considerando finalmente la autocorrelación.

En síntesis el procedimiento es como sigue:

Primera Etapa

Se estima

$$Y_t = \beta_0(1-\rho) + \beta_1 X_{1t} - \beta_1 \rho X_{1t} + \dots + \beta_k X_{kt} - \beta_k \rho X_{kt} + \rho Y_{t-1} + v_t$$

Segunda Etapa

Reemplazar la estimación $\hat{\rho}$ de la primera etapa en la ecuación:

$$Y_t - \hat{\rho} Y_{t-1} = \beta_0(1 - \hat{\rho}) + \beta_1(X_{1t} - \hat{\rho} X_{1,t-1}) + \dots + v_t$$

Siendo $\hat{\rho}$ obtenido por la regresión MCO de Y_t en $X_{1t}, X_{2t}, \dots, X_{kt}$ y de Y_{t-1} .

PASOS:

- b. Regresionar el modelo original y determinar el valor del estadístico Durbin Watson.
- c. A partir del estadístico Durbin Watson que se obtuvo en el output de la regresión, hallamos el valor de $\hat{\rho}$, mediante la igualdad:

$$d = 2(1 - \hat{\rho}) \Rightarrow \hat{\rho} = 1 - d/2$$

En las salidas de la regresión, vemos que el estadístico d es 0.655933. Entonces $\hat{\rho}$ es:

$$\hat{\rho} = 1 - 0.655933 / 2 = 0.6720335$$

- d. Generar las nuevas variables, utilizando $\hat{\rho}$, y luego regresionar el modelo por MCO:

$$Y_t^* = Y_t - \hat{\rho} Y_{t-1}$$

$$X_t^* = X_t - \hat{\rho} X_{t-1}$$

PASOS:

- a. Regresionar el modelo original incluyendo los valores rezagados de todas las variables, incluyendo la variable dependiente, con el objeto de estimar $\hat{\rho}$:

$$\text{IMPORTACIONES} = f(\text{PBI}, \text{IPC}, \text{PBI}_{-1}, \text{IPC}_{-1}, \text{IMPORTACIONES}_{-1})$$

Debo correr el siguiente modelo en el Eviews:

ls importaciones c pbi pbi(-1) ipc ipc(-1) importaciones(-1)

Dependent Variable: IMPORTACIONES				
Method: Least Squares				
Date: 08/14/02 Time: 21:13				
Sample(adjusted): 1971 2000				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-381.8357	3035.663	-0.125783	0.9010
PBI	0.266580	0.065483	4.070960	0.0004
PBI(-1)	-0.234833	0.061333	-3.828808	0.0008
IPC	42.81238	44.28178	0.966817	0.3433
IPC(-1)	-39.08934	54.40694	-0.718462	0.4794
IMPORTACIONES(-1)	0.777712	0.152200	5.109785	0.0000
R-squared	0.897137	Mean dependent var	13670.23	
Adjusted R-squared	0.875708	S.D. dependent var	4371.270	
S.E. of regression	1541.097	Akaike info criterion	17.69523	
Sum squared resid	56999488	Schwarz criterion	17.97547	
Log likelihood	-259.4285	F-statistic	41.86418	
Durbin-Watson stat	1.613895	Prob(F-statistic)	0.000000	

El coeficiente estimado de la variable dependiente rezagada ($\hat{\rho} = 0.777712$), nos servirá para corregir a las variables. Para ello se debe generar nuevas variables.

- ◆ En el workfile, hacer clic en GENR y generar las nuevas variables:

Importaciones1 = importaciones-0.777712*importaciones(-1) OK

Pbi1 = pbi - 0.777712*pbi(-1) OK

Ipc1 = ipc - 0.777712*ipc(-1) OK

Para el año 1970, generar:

$$\text{importaciones1}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{importaciones}_{1970}$$

$$\text{importaciones1} = ((1 - 0.777712^2)^{1/2}) * \text{importaciones} \quad \text{sample 1970}$$

$$\text{pbi1}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{pbi}_{1970} \quad \text{pbi1} = ((1 - 0.777712^2)^{1/2}) * \text{pbi} \quad \text{sample 1970}$$

$$\text{ipc1}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{ipc}_{1970} \quad \text{ipc1} = ((1 - 0.777712^2)^{1/2}) * \text{ipc} \quad \text{sample 1970}$$

- ◆ En la barra de comandos digitar:

ls importaciones1 c pbi1 ipc1 ENTER

Dependent Variable: IMPORTACIONES1

Method: Least Squares

Date: 09/19/02 Time: 11:31

Sample: 1970 2000

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1836.272	999.6587	-1.836899	0.0769
PBI1	0.221979	0.046046	4.820800	0.0000
IPC1	22.89478	17.80257	1.286038	0.2090
R-squared	0.567518	Mean dependent var		3407.546
Adjusted R-squared	0.536626	S.D. dependent var		2208.156
S.E. of regression	1503.126	Akaike info criterion		17.56025
Sum squared resid	63262869	Schwarz criterion		17.69902
Log likelihood	-269.1838	F-statistic		18.37129
Durbin-Watson stat	1.490982	Prob(F-statistic)		0.000008

Midiendo la autocorrelación de primer orden:

Donde:

k' = número de variables explicativas

(número de parámetros menos 1)

n = número de observaciones


$$D_{k'; n; \alpha} = D_{2; 31; 0.05}$$

$$D_L = 1.297$$

$$4 - D_L = 2.703$$

$$D_U = 1.570$$

$$4 - D_U = 2.430$$



Se observa que estadístico Durbin Watson es 1.490982, encontrándose en la zona de indecisión por lo tanto no se puede descartar la presencia de autocorrelación en un valor cercano a 2 por lo tanto se puede afirmar que modelo ya no tiene problemas de autocorrelación. Sin embargo la variables IPCD1 pierde significancia individual, así como pierde bondad de ajuste, aun cuando el modelo en conjunto sigue explicando a la variable dependiente (Prueba F).

3.- Procedimiento Iterativo De Cochran Orcutt

Primera Etapa

Estimación MCO del modelo

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_k X_{kt} + \mu_t \quad (1)$$

y obtención del estimador de la autocorrelación de Cochran-Orcutt, con el fin de aplicar la ecuación de diferencias generalizadas:

$$\rho = \frac{\sum e_t e_{t-1}}{\sum e_t^2}$$

Asimismo, se puede estimar con el modelo $e_t = \rho e_{t-1} + \varepsilon_t$

Se transforma la variable :

$$Y_t - \rho Y_{t-1} = \beta_1(1-\rho) + \beta_2(x_{2t} - \rho x_{2t-1}) + \dots + \beta_k(x_{kt} - \rho x_{kt-1}) + (\mu_t - \rho \mu_{t-1})$$

Segunda Etapa

A partir de los residuos MCO de la ecuación de diferencias generalizadas de la primera etapa, obtener un nuevo estimador de Cochran-Orcutt, tal como:

$$\hat{\rho}^* = \frac{\sum e_t^* e_{t-1}^*}{\sum e_t^{*2}}$$

el mismo que se reemplaza en una nueva ecuación de diferencias generalizadas como:

$$Y_t - \hat{\rho}^* Y_{t-1} = \beta_1(1 - \hat{\rho}^*) + \beta_2(X_{1t} - \hat{\rho}^* X_{1t-1}) + \dots + v_t$$

Alternativamente se estima “ ρ^* ” en el modelo:

$$e_t^* = \rho^* e_{t-1}^* + \varepsilon_t^*$$

Tercera Etapas y sucesivas.

De los residuos MCO de la ecuación de diferencias generalizadas anterior (segunda etapa), puede lograrse una nueva estimación del coeficiente de autocorrelación, tal como:

$$\hat{\rho}^{**} = \frac{\sum e_t^{**} e_{t-1}^{**}}{\sum e_t^{**2}}$$

Forma alternativa para estimar ρ^{**} :

$$e_t^{**} = \rho e_{t-1}^{**} + \varepsilon_t^{**}$$

Para de esta manera reemplazarlo en una nueva ecuación de diferencias generalizadas, y así sucesivamente, el proceso puede repetirse hasta que las estimaciones de sucesivas de ρ no difieran significativamente entre sí, pudiendo lograrse 2, 5, 10 ó más iteraciones.

PASOS:

- a. Regresionar el modelo original:

IMPORTACIONES = f(PBI, IPC)

ls importaciones c pbi ipc

- b. Con los residuos obtenidos regresionar el siguiente modelo: $e_t = \rho e_{t-1} + \varepsilon_t$ y obtener el estimador de COCHRAN – ORCUTT

ls resid1 c resid1(-1)

Dependent Variable: RESID1				
Method: Least Squares				
Date: 08/14/02 Time: 22:35				
Sample(adjusted): 1971 2000				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-38.80981	302.4778	-0.128306	0.8988
RESID1(-1)	0.674691	0.141307	4.774637	0.0001
R-squared	0.448788	Mean dependent var	-7.394418	
Adjusted R-squared	0.429102	S.D. dependent var	2192.159	
S.E. of regression	1656.347	Akaike info criterion	17.72696	
Sum squared resid	76817625	Schwarz criterion	17.82037	
Log likelihood	-263.9044	F-statistic	22.79716	
Durbin-Watson stat	1.458345	Prob(F-statistic)	0.000051	

El coeficiente estimado de la variable explicativa (resid1(-1)), nos servirá para transformar las variables.

- ◆ En el workfile, hacer clic en GENR y generar las nuevas variables:

Importaciones2 = importaciones-0.674691*importaciones(-1) OK

Pbi2 = pbi - 0.674691*pbi(-1) OK

Ipc2 = ipc - 0.674691*ipc(-1) OK

Para el año 1970, generar:

$$\begin{aligned} \text{importaciones2}_{1970} &= \sqrt{1 - \hat{\rho}^2} * \text{importaciones}_{1970} && \text{sample 1970} \\ \text{importaciones2} &= ((1 - 0.674691^2)^{1/2}) * \text{importaciones} && \text{sample 1970} \\ \text{pbi2}_{1970} &= \sqrt{1 - \hat{\rho}^2} * \text{pbi}_{1970} && \text{pbi2} = ((1 - 0.674691^2)^{1/2}) * \text{pbi} && \text{sample 1970} \\ \text{ipc2}_{1970} &= \sqrt{1 - \hat{\rho}^2} * \text{ipc}_{1970} && \text{ipc2} = ((1 - 0.674691^2)^{1/2}) * \text{ipc} && \text{sample 1970} \end{aligned}$$

- ◆ En la barra de comandos digitar:

ls importaciones2 c pbi2 ipc2

Dependent Variable: IMPORTACIONES2

Method: Least Squares

Date: 09/19/02 Time: 12:40

Sample: 1970 2000

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2117.422	1401.949	-1.510342	0.1422
PBI2	0.207486	0.047117	4.403617	0.0001
IPC2	22.80412	15.27169	1.493228	0.1466
R-squared	0.597614	Mean dependent var		4767.610
Adjusted R-squared	0.568873	S.D. dependent var		2333.324
S.E. of regression	1532.067	Akaike info criterion		17.59839
Sum squared resid	65722441	Schwarz criterion		17.73716
Log likelihood	-269.7750	F-statistic		20.79250
Durbin-Watson stat	1.331629	Prob(F-statistic)		0.000003

Segunda Etapa: Regresionamos el modelo por MCO:

Con los residuos obtenidos en el ultimo modelo:

$$e^* t = \rho^* e^* t-1 + \varepsilon^* t$$

Dependent Variable: RESID2

Method: Least Squares

Date: 09/19/02 Time: 12:44

Sample(adjusted): 1971 2000

Included observations: 30 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.803428	263.6973	0.018216	0.9856
RESID2(-1)	0.331815	0.178823	1.855545	0.0741
R-squared	0.109501	Mean dependent var		12.52136
Adjusted R-squared	0.077698	S.D. dependent var		1503.750
S.E. of regression	1444.150	Akaike info criterion		17.45277
Sum squared resid	58395919	Schwarz criterion		17.54618
Log likelihood	-259.7915	F-statistic		3.443048
Durbin-Watson stat	1.904826	Prob(F-statistic)		0.074074

El coeficiente estimado de la variable RESID2 rezagada es 0.331815 el cual aproximamos como un $\hat{\rho} = 0.331815$, cuyo valor servirá para corregir a las variables. Para ello debo generar nuevas variables:

Así generando nuevas variables:

- 1.- importaciones2a = importaciones2-0.331815* importaciones (-1), de 1971 –2000
- 2.- pbi2a = pbi2-0.331815*pbi2(-1) , de 1971 –2000
- 3.- ipc2a = ipc2-0.331815*ipc2(-1), de 1971 –2000

- 1.- importaciones2a = $((1-0.331815^2)^{(1/2)})^*$ importaciones2, de 1970.
- 2.- pbi2a = $((1-0.331815^2)^{(1/2)})^*$ pbi2 , de 1970.
- 3.- ipc2a = $((1-0.331815^2)^{(1/2)})^*$ ipc2 , de 1970.

Haciendo la regresión:

Dependent Variable: IMPORTACIONES2A

Method: Least Squares

Date: 09/19/02 Time: 13:12

Sample: 1970 2000

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1359.692	855.4361	-1.589473	0.1232
PBI2A	0.203597	0.040451	5.033229	0.0000
IPC2A	23.06025	18.77613	1.228168	0.2296
R-squared	0.566682	Mean dependent var		3249.057
Adjusted R-squared	0.535730	S.D. dependent var		2134.615
S.E. of regression	1454.470	Akaike info criterion		17.49444
Sum squared resid	59233498	Schwarz criterion		17.63321
Log likelihood	-268.1638	F-statistic		18.30881
Durbin-Watson stat	1.943394	Prob(F-statistic)		0.000008

Observamos que mediante el estadístico Durbin Watson, que no existe Autocorrelación, pero el modelo presenta pierde significancia individual en la variable IPC 2A, así como disminuye ligeramente su bondad de ajuste.

Realizaremos un nuevo proceso para analizar los cambios en la percepción de autocorrelación, significancia y bondad de ajuste:

Tercera Etapa: Regresionamos el modelo por MCO:

Con los residuos obtenidos en el ultimo modelo:

$$e^{**} t = \rho^{**} e^{**} t-1 + \varepsilon^{**} t$$

Dependent Variable: RESID3

Method: Least Squares

Date: 09/19/02 Time: 13:15

Sample(adjusted): 1971 2000

Included observations: 30 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	27.75120	263.9197	0.105150	0.9170
RESID3(-1)	0.021544	0.188060	0.114559	0.9096
R-squared	0.000468	Mean dependent var		27.47374
Adjusted R-squared	-0.035229	S.D. dependent var		1420.679
S.E. of regression	1445.487	Akaike info criterion		17.45462
Sum squared resid	58504108	Schwarz criterion		17.54803
Log likelihood	-259.8193	F-statistic		0.013124
Durbin-Watson stat	1.947803	Prob(F-statistic)		0.909612

El coeficiente estimado de la variable RESID3 rezagada es 0.021544 el cual aproximamos como un $\hat{\rho} = 0.021544$, cuyo valor servirá para corregir a las variables. Para ello debo generar nuevas variables:

Así generando nuevas variables:

- 1.- importaciones2b = importaciones a - 0.021544 * importaciones a(-1), de 1971 –2000
- 2.- pbi2b = pbi2a - 0.021544 * pbi2a(-1), de 1971 –2000
- 3.- ipc2b = ipc2a - 0.021544 * ipc2a(-1), de 1971 –2000
- 1.- importaciones2b = $((1 - 0.021544^2)^{1/2})$ * importaciones2a, de 1970.
- 2.- pbi2b = $((1 - 0.021544^2)^{1/2})$ * pbi2a, de 1970.
- 3.- ipc2b = $((1 - 0.021544^2)^{1/2})$ * ipc2a, de 1970.

Haciendo la regresión:

Dependent Variable: IMPORTACIONES2B				
Method: Least Squares				
Date: 09/19/02 Time: 13:23				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1312.642	833.4782	-1.574897	0.1265
PBI2B	0.202633	0.040064	5.057783	0.0000
IPC2B	23.23856	19.07484	1.218283	0.2333
R-squared	0.565187	Mean dependent var		3183.027
Adjusted R-squared	0.534129	S.D. dependent var		2131.303
S.E. of regression	1454.716	Akaike info criterion		17.49477
Sum squared resid	59253578	Schwarz criterion		17.63355
Log likelihood	-268.1690	F-statistic		18.19773
Durbin-Watson stat	1.982754	Prob(F-statistic)		0.000009

Una conclusión preliminar respecto a la autocorrelación empleando esta metodología es que solo será necesario regresionar en dos etapas, puesto hasta esta etapa se supero el problema de autocorrelación, seguir otra etapa significaría reducir (ligeramente) la significancia de los parámetros.

4.- Procedimiento De Theil –Nagar

El coeficiente de autocorrelación según el procedimiento de Theil-Nágar es como sigue:

$$\hat{\rho}_{TN} = \frac{n^2(1 - d/2) + k^2}{n^2 - k^2}$$

Donde
 n = Número de observaciones
 d = Valor del estadístico Durbin – Watson
 k = Número de parámetros a estimarse

PASOS:

- Regresionar el modelo original y determinar el valor del estadístico Durbin Watson.

Dependent Variable: IMPORTACIONES				
Method: Least Squares				
Date: 09/19/02 Time: 09:20				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3427.817	3293.850	1.040672	0.3069
PBI	0.094182	0.039275	2.398012	0.0234
IPC	45.02326	11.06852	4.067687	0.0004
R-squared	0.755860	Mean dependent var		13535.42
Adjusted R-squared	0.738422	S.D. dependent var		4362.854
S.E. of regression	2231.369	Akaike info criterion		18.35038
Sum squared resid	1.39E+08	Schwarz criterion		18.48916
Log likelihood	-281.4309	F-statistic		43.34425
Durbin-Watson stat	0.655933	Prob(F-statistic)		0.000000

- b. A partir del estadístico Durbin Watson que se obtuvo en el output de la regresión, hallamos el valor de $\hat{\rho}$, mediante la igualdad:

$$\hat{\rho}_{TN} = \frac{n^2(1-d/2)+k^2}{n^2-k^2} = \frac{31^2(1-0.655933/2)+3^2}{31^2-3^2} = 0.68784054$$

El coeficiente estimado es $\hat{\rho}_{TN} = 0.68784054$ cuyo valor servirá para corregir a las variables. Para ello debo generar nuevas variables:

- c. Generar las nuevas variables, utilizando $\hat{\rho}$, y luego regresionar el modelo por MCO:

En el workfile, hacer clic en GENR y digitar las nuevas variables:

Importaciones3 = importaciones- 0.68784054*importaciones(-1) OK

Pbi3 = pbi- 0.68784054*pbi(-1) OK

Ipc3 = ipc - 0.68784054*ipc(-1) OK

Para el año 1970, generar lo siguiente:

importaciones3₁₉₇₀ = $\sqrt{1 - \hat{\rho}^2}$ importaciones₁₉₇₀
importaciones3 = ((1- 0.68784054²)^{1/2})*importaciones **sample 1970**

pbi3₁₉₇₀ = $\sqrt{1 - \hat{\rho}^2}$ pbi₁₉₇₀

pbi3 = ((1- 0.68784054²)^{1/2})*pbi **sample 1970**

ipc3₁₉₇₀ = $\sqrt{1 - \hat{\rho}^2}$ ipc₁₉₇₀

ipc3 = ((1- 0.68784054²)^{1/2})*ipc **sample 1970**

Regresionar el modelo que contiene a las nuevas variables con el MCO

ls importaciones3 c pbi3 ipc3

Dependent Variable: IMPORTACIONES3

Method: Least Squares

Date: 09/19/02 Time: 13:54

Sample: 1970 2000

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2102.329	1347.590	-1.560066	0.1300
PBI3	0.209615	0.046923	4.467242	0.0001
IPC3	22.63101	15.49276	1.460748	0.1552
R-squared	0.593849	Mean dependent var		4594.543
Adjusted R-squared	0.564838	S.D. dependent var		2313.741
S.E. of regression	1526.301	Akaike info criterion		17.59085
Sum squared resid	65228642	Schwarz criterion		17.72962
Log likelihood	-269.6581	F-statistic		20.46994
Durbin-Watson stat	1.353506	Prob(F-statistic)		0.000003

Debo calcular $\hat{\rho}$

Mediante la siguiente expresión:

$$\hat{\rho}_{TN} = \frac{n^2(1-d/2) + k^2}{n^2 - k^2}$$

$$\hat{\rho}_{TN} = \frac{31^2(1-1.353506/2) + 3^2}{31^2 - 3^2} = 0.33575669$$

El coeficiente estimado es $\hat{\rho}_{TN}=0.33575669$, cuyo valor servirá para corregir a las variables. Para ello debo generar nuevas variables:

Así generando nuevas variables:

- 1.- importaciones3a = import3-0.33575669*importaciones3(-1), de 1971 –2000
 - 2.- pbi3a = pbi3-0.33575669*pbi3(-1) , de 1971 –2000
 - 3.- ipc3a = ipc3-0.33575669*ipc3(-1) , de 1971 –2000
-
- 1.- importaciones3a = ((1-0.33575669^2)^(1/2))* importaciones3, de 1970.
 - 2.- pbi3a = ((1-0.33575669^2)^(1/2))*pbi3 , de 1970.
 - 3.- ipc3a = ((1-0.33575669^2)^(1/2))*ipc3 , de 1970.

Dependent Variable: IMPORTACIONES3A

Method: Least Squares

Date: 09/19/02 Time: 14:04

Sample: 1970 2000

Included observations: 31

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1324.869	825.1249	-1.605658	0.1196
PBI3A	0.204711	0.040497	5.054971	0.0000
IPC3A	22.99831	19.34972	1.188560	0.2446
R-squared	0.562548	Mean dependent var		3113.305
Adjusted R-squared	0.531302	S.D. dependent var		2126.587
S.E. of regression	1455.895	Akaike info criterion		17.49639
Sum squared resid	59349607	Schwarz criterion		17.63517
Log likelihood	-268.1941	F-statistic		18.00353
Durbin-Watson stat	1.970226	Prob(F-statistic)		0.000009

Aplicando el Método de Theil Nagar, observamos que el estadístico Durbin Watson, indica que la autocorrelación ha sido corregida, sin embargo pierde significancia individual en la variable IPC 3A, así como disminuye ligeramente su bondad de ajuste.

5.- PREDICCIÓN

Estimar los gastos en ingresos, si se sabe que los ingresos se modificaran de la siguiente manera:

OBS	PBI	IPC
2001	121,568	160.0
2002	122,036	165.02
2003	122,657	170.25
2004	122,975	174.36
2005	123,278	176.89

PROCEDIMIENTO:

- ◆ Expandir el rango y el tamaño de la muestra
- ◆ Ingresar a las variables independientes e introducir los nuevos valores
- ◆ Luego generar para el período 2001-2005 nuevas variables:


1° PARA EL MODELO: ls importacionesd c pbi ipc

Generar lo siguiente:

$$\text{pbid} = \text{pbi} - 0.6720335 * \text{pbi}(-1) \quad \text{OK}$$

$$\text{ipcd} = \text{ipc} - 0.6720335 * \text{ipc}(-1) \quad \text{OK}$$

- ◆ Ingresar al Output de la regresión de las diferencias generalizadas y hacer clic en FORECAST
- ◆ Se generará automáticamente una nueva variable (IMPORTACIODF) en el workfile, el cual será los valores estimados y proyectados de la variable dependiente.



- ◆ La variable que se ha proyectado es la diferencias generalizadas, entonces para hallar las proyecciones de la variable dependiente original simplemente se debe despejar de la ecuación siguiente:

$$\text{Importacionesd}^* = \text{importaciones}^* - 0.6720335 * \text{importaciones}^*(-1)$$

$$\text{importaciones}^* = \text{importacionesd}^* + 0.6720335 * \text{importaciones}^*(-1)$$

Importacionesd*: IMPORTACIDF (en el workfile)

Por ejemplo, para el año 2001, se tiene:

$$\text{IMPORTACIODF}_{2001} = 7418.589$$

$$\text{importaciones}^*(-1) = \text{importaciones}(2000) = 20428.00$$

$$\text{importaciones}^*_{2001} = 7418.589 + 0.6720335 * 20428.00 = 21146.88932$$

Las estimaciones del modelo corregido son:

Corregida la autocorrelación precedemos a la predicción:

En base a los siguientes pronósticos:

Año	IMPORT	PBI	IPC
2001		121568	160
2002		122036	165.02
2003		122657	170.25
2004		122975	174.36
2005		123278	176.89

1 Para el Modelo: ls importacionesd c pbid ipcd


Año	importacionesd
2001	7418.589
2002	7515.985
2003	7627.905
2004	7634.972
2005	7639.592

2° PARA EL MODELO: ls importacionesd1 c pbid1 ipcd1

Generar lo siguiente (sample 1970-2005):

pbid1 = pbid-0.3364065*pbid(-1) OK
ipcd1 = ipcd - 0.3364065*ipcd(-1) OK

- ◆ Ingresar al Output de la regresión de este último modelo y hacer clic en FORECAST
- ◆ Se generará automáticamente una nueva variable (IMPORTAD1F) en el workfile, el cual será los valores estimados y proyectados de la variable dependiente.



Se observa en las salidas de la predicción que el coeficiente de Theil del segundo modelo predicho (19.92%), es mayor al obtenido por el primero (14.60%), entonces se podría deducir que el primer modelo es mejor para la predicción.

Año	Importacionesd1p
2001	4806.349
2002	4980.457
2003	5059.087
2004	5031.870
2005	5030.988

CORRECCIÓN DE AUTOCORRELACIÓN DE SEGUNDO ORDEN

Se ha observado que el modelo tiene problemas de autocorrelación de segundo orden por ello se ha propuesto la corrección de este mediante el modelo de Cochran Orcutt.

1. Regresionamos el modelo original:

Dependent Variable: RESID1				
Method: Least Squares				
Date: 09/19/02 Time: 15:52				
Sample(adjusted): 1972 2000				
Included observations: 29 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-19.05861	292.1253	-0.065241	0.9485
RESID1(-1)	0.943024	0.179419	5.255986	0.0000
RESID1(-2)	-0.407993	0.181040	-2.253605	0.0329
R-squared	0.538820	Mean dependent var	-21.63177	
Adjusted R-squared	0.503345	S.D. dependent var	2229.550	
S.E. of regression	1571.248	Akaike info criterion	17.65483	
Sum squared resid	64189322	Schwarz criterion	17.79627	
Log likelihood	-252.9950	F-statistic	15.18856	
Durbin-Watson stat	1.968664	Prob(F-statistic)	0.000043	

2. Utilizo los coeficientes estimados de las variables explicadas resid1(-1) y resid1(-2), para transformar las variables:

Así generando nuevas variables:

- 1.- $import2o = import - 0.943024 * import(-1) + 0.407993 * import(-2)$, de 1971 –2000
 - 2.- $pbi2o = pbi - 0.943024 * pbi(-1) + 0.407993 * pbi(-2)$, de 1971 –2000
 - 3.- $ipc2o = ipc - 0.943024 * ipc(-1) + 0.407993 * ipc(-2)$, de 1971 –2000
-
- 1.- $import2o = ((1 - 0.407993^2)^{1/2}) * import$, de 1971.
 - 2.- $pbi2o = ((1 - 0.407993^2)^{1/2}) * pbi$, de 1971.
 - 3.- $ipc2o = ((1 - 0.407993^2)^{1/2}) * ipc$, de 1971.

Dependent Variable: IMPORT2O				
Method: Least Squares				
Date: 09/19/02 Time: 16:11				
Sample(adjusted): 1971 2000				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-968.6563	1734.464	-0.558476	0.5811
PBI2O	0.158657	0.041787	3.796818	0.0008
IPC2O	31.29594	12.85795	2.433976	0.0218
R-squared	0.636849	Mean dependent var	6552.616	
Adjusted R-squared	0.609949	S.D. dependent var	2399.435	
S.E. of regression	1498.544	Akaike info criterion	17.55702	
Sum squared resid	60632136	Schwarz criterion	17.69713	
Log likelihood	-260.3552	F-statistic	23.67464	
Durbin-Watson stat	1.831468	Prob(F-statistic)	0.000001	

En conclusión superamos el problema de autocorrelación manteniendo la significancia individual de los coeficientes de las variables, igualmente la significancia colectiva y mejorando la bondad de ajuste.

En conclusión consideramos este modelo para la predicción

PREDICCIÓN


Expandiendo el rango generamos las siguientes variables:

- 1.- $import2oP = import - 0.943024 * import(-1) + 0.407993 * import(-2)$, de 1971 –2005
- 2.- $pbi2oP = pbi - 0.943024 * pbi(-1) + 0.407993 * pbi(-2)$, de 1971 –2005
- 3.- $ipc2oP = ipc - 0.943024 * ipc(-1) + 0.407993 * ipc(-2)$, de 1971 –2005

- 1.- $import2oP = ((1 - 0.407993^2)^{(1/2)}) * import$, de 1971.
- 2.- $pbi2oP = ((1 - 0.407993^2)^{(1/2)}) * pbi$, de 1971.
- 3.- $ipc2oP = ((1 - 0.407993^2)^{(1/2)}) * ipc$, de 1971.

Efectuando la regresión y la predicción respectiva obtenemos los siguientes resultados:

Año	Import2o
2001	10129.56
2002	10494.93
2003	10618.20
2004	10638.31
2005	10704.95



Entonces hallando la predicción del 2001:

$$import2oP_{2001} = import_{2001} - 0.943024 * import_{2000} + 0.407993 * import_{1999}$$

$$import_{2001} = import2oP_{2001} + 0.943024 * import_{2000} - 0.407993 * import_{1999}$$

$$import_{2001} = (10129.56) + 0.943024 * (20428) - 0.407993 * (19724)$$

$$import_{2001} = 21346.40$$

EJERCICIOS DE HETEROSCEDASTICIDAD Y AUTOCORRELACIÓN

1. Estimar el siguiente modelo, con los datos del cuadro:

$$PRODT = \beta_1 + \beta_2 PARMAQ + \beta_3 FINPRIV + \beta_4 VOLFIT$$

PERIODO	PRODT	PARMAQ	FINPRIV	VOLFIT
1990:1	172200.0	38079.00	1636.000	1179.000
1990:2	211710.0	44511.00	2142.000	1018.000
1991:1	220160.0	52756.00	2135.000	909.0000
1991:2	222370.0	64143.00	3507.000	930.0000
1992:1	249610.0	80191.00	4214.000	1668.000
1992:2	281670.0	105390.0	5640.000	1647.000
1993:1	319760.0	133490.0	69048.00	2096.000
1993:2	320110.0	157980.0	62048.00	2264.000
1994:1	341030.0	185180.0	73876.00	2170.000
1994:2	386330.0	218230.0	84599.00	2769.000
1995:1	403540.0	254800.0	99050.00	2976.000
1995:2	433630.0	292210.0	124050.0	3029.000
1996:1	462300.0	332450.0	144850.0	3480.000
1996:2	471830.0	363680.0	158490.0	3642.000
1997:1	535650.0	398770.0	176786.0	415.0000
1997:2	578840.0	438290.0	196320.0	4708.000
1998:1	675400.0	480110.0	235340.0	5614.000
1998:2	813020.0	523490.0	281960.0	6095.000
1999:1	917140.0	566950.0	319250.0	6660.000
1999:2	1016000.0	606070.0	372840.0	6850.000

Donde:

PRODT = Producción total agroindustrial

PARMAQ = Parque de maquinaria

FINPRIV = Financiación privada del sector

VOLFIT = Volumen de fitosanitarios empleados

Dependent Variable: PARMAQ				
Method: Least Squares				
Date: 07/25/02 Time: 12:47				
Sample: 1990:1 1999:2				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	136372.6	45185.90	3.018035	0.0082
PRODT	-0.328260	0.231150	-1.420115	0.1748
FINPRIV	2.319536	0.468433	4.951689	0.0001
VOLFIT	-0.563388	8.952247	-0.062933	0.9506
R-squared	0.974638	Mean dependent var		266838.5
Adjusted R-squared	0.969882	S.D. dependent var		187225.7
S.E. of regression	32491.95	Akaike info criterion		23.79223
Sum squared resid	1.69E+10	Schwarz criterion		23.99138
Log likelihood	-233.9223	F-statistic		204.9534
Durbin-Watson stat	1.162566	Prob(F-statistic)		0.000000

A. ESTIMAR POR MCO LOS PARÁMETROS DEL MODELO:

$$PARMAQ = 136372.6161 - 0.3282598547*PRODT + 2.319535752*FINPRIV - 0.5633877208*VOLFIT$$

B. ¿MEDIANTE EL TEST DE WHITE DETERMINAR SI EL MODELO TIENE PROBLEMAS DE HETEROSCEDASTICIDAD?**PROCEDIMIENTO:**

- Estando en el Output de la regresión hacer clic en View/ Residual Tests/ White Heteroskedasticity
- Se obtienen los siguientes resultados:

White Heteroskedasticity Test:				
F-statistic	1.135728	Probability	0.395271	
Obs*R-squared	6.878208	Probability	0.332258	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 08/01/02 Time: 15:25				
Sample: 1990:1 1999:2				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	44799626	3.61E+09	0.012427	0.9903
PRODT	2647.628	19842.44	0.133433	0.8959
PRODT^2	-0.013746	0.023271	-0.590678	0.5649
FINPRIV	-16895.85	26888.60	-0.628365	0.5406
FINPRIV^2	0.178827	0.128265	1.394198	0.1866
VOLFIT	1310369.	958397.5	1.367250	0.1947
VOLFIT^2	-275.4099	186.0902	-1.479980	0.1627
R-squared	0.343910	Mean dependent var	8.45E+08	
Adjusted R-squared	0.041100	S.D. dependent var	1.07E+09	
S.E. of regression	1.05E+09	Akaike info criterion	44.64791	
Sum squared resid	1.43E+19	Schwarz criterion	44.99642	
Log likelihood	-439.4791	F-statistic	1.135728	
Durbin-Watson stat	1.404491	Prob(F-statistic)	0.395271	

La Ho de este test es que el modelo no tiene problemas de Heterocedasticidad. Observamos la probabilidad asociado al estadístico (0.39252), este es menor a 0.05 por lo tanto se acepta la hipótesis nula y se concluye que no existe Heterocedasticidad en el modelo.

¿QUE REFLEJA EL ESTADISTICO DURBIN-WATSON?

En las salidas de la regresión, se observa que el Durbin Watson es 1.162566, este valor es muy inferior a 2 (valor que toma cuando no existe Autocorrelación). Entonces el modelo tiene un problema de autocorrelación positiva de primer orden.

B. DETERMINAR SI EL MODELO TIENE AUTOCORRELACIÓN DE ORDEN SUPERIOR MEDIANTE EL TEST DE BREUSH-GODFREY (Hacer la prueba con 3 rezagos):

PROCEDIMIENTO:

- Estando en el Output de la regresión hacer clic en View/ Residual Tests/ Serial Correlation LM Test
- Aparecerá una caja de dialogo en la que se debe especificar el número de rezagos que incluirá el test. En el ejercicio se pide con 3 rezagos.

Mediante el test de Breush-Godfrey, (con 3 rezagos) obtenemos las siguientes salidas:

Breusch-Godfrey Serial Correlation LM Test:					
F-statistic	0.587697	Probability	0.633757		
Obs*R-squared	2.388513	Probability	0.495776		
Test Equation:					
Dependent Variable: RESID					
Method: Least Squares					
Date: 07/26/02 Time: 09:04					
Variable	Coefficient	Std. Error	t-Statistic	Prob.	
C	-12143.50	50430.93	-0.240795	0.8135	
PRODT	0.081451	0.277471	0.293546	0.7737	
FINPRIV	-0.175187	0.596913	-0.293488	0.7738	
VOLFIT	-1.481586	9.498193	-0.155986	0.8784	
RESID(-1)	0.388800	0.347723	1.118131	0.2837	
RESID(-2)	0.069479	0.356950	0.194646	0.8487	
RESID(-3)	-0.117749	0.386159	-0.304925	0.7653	
R-squared	0.119426	Mean dependent var	3.27E-11		
Adjusted R-squared	-0.286993	S.D. dependent var	29816.66		
S.E. of regression	33825.72	Akaike info criterion	23.96505		
Sum squared resid	1.49E+10	Schwarz criterion	24.31355		
Log likelihood	-232.6505	F-statistic	0.293849		
Durbin-Watson stat	1.641492	Prob(F-statistic)	0.929215		

La Hipótesis nula nos dice que no hay Autocorrelación. La probabilidad asociada a este estadístico es superior a 0.05, por lo tanto se acepta la hipótesis nula, es decir no existe Autocorrelación de orden 3.

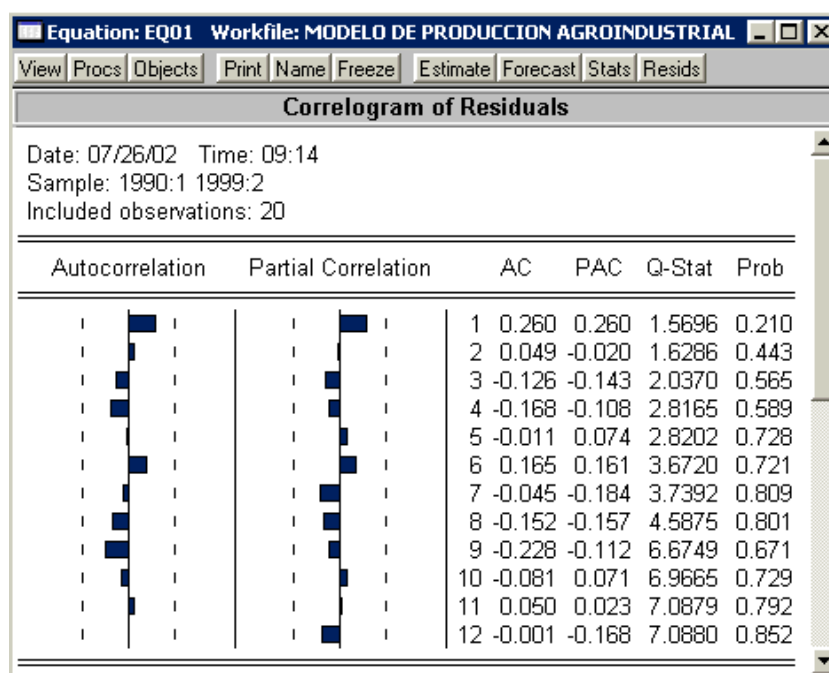
C. REALIZAR LA PRUEBA DEL CORRELOGRAMA (con los cuadrados de los residuos) PARA DETERMINAR SI EL MODELO TIENE AUTOCORRELACIÓN DE ORDEN 12.

PROCEDIMIENTO:

- Estando en el Output de la regresión hacer clic en View/ Residual Tests/ Correlogram Squared Residuals.
- Aparecerá una caja de dialogo en la que se debe especificar el número de rezagos que incluirá el test. En el ejercicio se ha considerado 12 rezagos.

La hipótesis nula es que el modelo no tiene Autocorrelación. Observamos en el correlograma que las bandas no salen fuera de las bandas permisibles (tanto para la Autocorrelación, como para la correlación parcial). Por lo tanto no existe Autocorrelación.

Además las probabilidades asociadas al estadístico Q son superiores al 5%, en todos los casos. Entonces hasta el orden 12 no existe Autocorrelación.

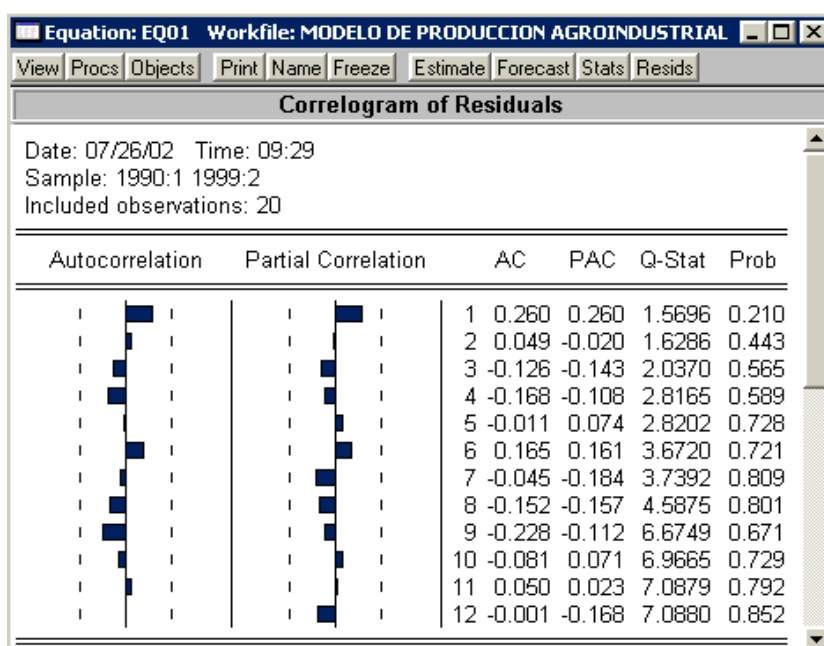


D. DETERMINAR SI EXISTE AUTOCORRELACIÓN MEDIANTE EL TEST BOX-PIERCE Q (CON 12 REZAGOS)

PROCEDIMIENTO:

- Estando en el Output de la regresión hacer clic en View/ Residual Tests/ Correlogram-Q-statistics.
- Aparecerá una caja de dialogo en la que se debe especificar el número de rezagos que incluirá el test. En el ejercicio se consideró 12 rezagos.

Este test nos arroja el siguiente correlograma:



La Hipótesis nula es que no existe Autocorrelación de orden 1, 2, 3, 4..., n. Este test nos confirma que el modelo no tiene autocorrelación (hasta el orden 12), ya que las gráficas no pasan las bandas permisibles y sus probabilidades asociadas son superiores al 0.05.

2. Se tiene información de los gastos en investigación y desarrollo de diferentes agrupaciones industriales (en un determinado país), además se tienen los datos de ventas y utilidades:

obs	AGRUPACIONES INDUSTRIALES	IYD	VENTAS	UTILIDADES
1	Contenedores y empaques	62.50000	6375.300	185.1000
2	Industrias financieras no bancaria	92.90000	11626.40	1569.500
3	Industrias de Servicios	178.3000	14655.10	276.8000
4	Metales y minería	258.4000	21869.20	2828.100
5	Vivienda y Construcción	494.7000	26408.30	225.9000
6	Manufacturas en general	1083.000	32405.60	3751.900
7	Ind. Rel. Con descanso y esparcimiento	1620.600	35107.70	2884.100
8	Papel y productos forestales	421.7000	40295.40	4645.700
9	Alimentos	509.2000	70761.60	5036.400
10	Salud	66201.10	80552.80	13869.90
11	Industria aeroespacial	3918.600	95294.00	4487.800
12	Productos del consumidor	1595.300	101314.1	10278.90
13	Productos eléctricos y electrónicos	6107.500	116141.3	8787.300
14	Químicos	4454.100	122315.7	16438.80
15	Conglomerados	3163.800	141649.9	9761.400
16	Equipos de oficina y computadores	13210.70	175025.8	19774.50
17	Combustibles	1703.800	230614.5	22626.60
18	Automotores	9528.200	293543.0	18415.50

LABORATORIO 7**MODELO NO LINEAL**

MODELO: $M = f(\text{PBI}, \text{TREL})$

M: Cantidad de Dinero (liquidez en el sistema bancario)

PBI: Producto Bruto Interno

TREL: Tasa de Interés

MODELO DOBLEMENTE LOGARÍTMICO: $M = A * \text{PBI}^\alpha * \text{TREL}^\beta$

Tomando logaritmos se obtiene: **$\text{LM} = \text{LA} + \alpha\text{LPBI} + \beta\text{LR} + \mu$**

En el E-views, se tiene que generar estas nuevas variables. En el workfile hacemos clic en Genr y digitamos lo siguiente:

LM = Log M OK

LPBI = Log PBI OK

LTREL = Log TREL OK

Regresionamos el modelo doblemente logarítmico:

Is lm c lpbi ltrel

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	13.31479	3.831986	3.474645	0.0017
LPBI	-0.263470	0.335055	-0.786349	0.4383
LTREL	0.579210	0.083328	6.950970	0.0000
R-squared	0.634115	Mean dependent var		10.10262
Adjusted R-squared	0.607980	S.D. dependent var		0.494309
S.E. of regression	0.309494	Akaike info criterion		0.584012
Sum squared resid	2.682030	Schwarz criterion		0.722785
Log likelihood	-6.052187	F-statistic		24.26335
Durbin-Watson stat	0.318203	Prob(F-statistic)		0.000001

De las salidas de la regresión observamos que el modelo en su conjunto es explicado por las variables, pero en la significancia individual, obtenemos que el LPBI no es significativo en el modelo. Por otro lado el R^2 no es muy alto (63.4%).

MODELO SEMILOGARÍTMICO: $\text{LM} = \beta_1 + \beta_2\text{PBI} + \beta_3\text{TREL} + \mu$

En el E-views, se tiene que generar la nueva variable logarítmica, en el workfile hacemos clic en Genr y digitamos lo siguiente:

LM = Log M

Regresionamos el siguiente modelo

Ls lm c pbi trel

Dependent Variable: LM				
Method: Least Squares				
Date: 08/29/02 Time: 15:27				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	9.359034	0.339107	27.59907	0.0000
PBI	-5.05E-06	3.69E-06	-1.369711	0.1817
TREL	1.498593	0.213985	7.003263	0.0000
R-squared	0.638797	Mean dependent var		10.10262
Adjusted R-squared	0.612997	S.D. dependent var		0.494309
S.E. of regression	0.307508	Akaike info criterion		0.571133
Sum squared resid	2.647709	Schwarz criterion		0.709906
Log likelihood	-5.852559	F-statistic		24.75934
Durbin-Watson stat	0.334122	Prob(F-statistic)		0.000001

En este modelo el R^2 es 63.8%, es ligeramente mayor al obtenido en el modelo anterior. Las probabilidades asociadas al estadístico t nos dicen que el PBI no es significativo en el modelo, y si lo son la variable TREL y el intercepto. La probabilidad asociada al F estadístico nos revela que la variable dependiente es explicada por el modelo es su conjunto.

$$\text{MODELO RECÍPROCO: } M = \beta_1 + \beta_2 \left(\frac{1}{\text{PBI}} \right) + \beta_3 \left(\frac{1}{\text{TREL}} \right) + \mu$$

Se tiene que generar las siguientes variables:

$$\begin{aligned} \text{PBIR} &= 1/\text{PBI} && \text{OK} \\ \text{TRELR} &= 1/\text{TREL} && \text{OK} \end{aligned}$$

Regresionamos el siguiente modelo:

Ls m c pbir trelr

Dependent Variable: M				
Method: Least Squares				
Date: 08/29/02 Time: 15:30				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	24595.03	8544.571	2.878439	0.0076
PBIR	5.50E+08	7.62E+08	0.721329	0.4767
TRELR	-1824.785	440.5693	-4.141879	0.0003
R-squared	0.380730	Mean dependent var		26837.90
Adjusted R-squared	0.336497	S.D. dependent var		9702.586
S.E. of regression	7903.309	Akaike info criterion		20.87972
Sum squared resid	1.75E+09	Schwarz criterion		21.01849
Log likelihood	-320.6356	F-statistic		8.607281
Durbin-Watson stat	0.606037	Prob(F-statistic)		0.001220

En el modelo recíproco el R^2 y el R^2 ajustados son bajísimos (38% y 33% respectivamente). Además el PBIR es no significativo en el modelo, entonces no es un buen modelo.

$$\text{POLINOMIAL: } M = \beta_1 + \beta_2 \text{PBI} + \beta_3 \text{PBI}^2 + \beta_4 R + \beta_5 R^2 + \mu$$

Se tiene que generar las siguientes variables:

$$\text{PBIP} = \text{PBI}^2 \quad \text{OK}$$

$$\text{RP} = R^2 \quad \text{OK}$$

Regresionamos el siguiente modelo:

Ls m c pbi pbip trel trelp

Dependent Variable: M				
Method: Least Squares				
Date: 08/29/02 Time: 15:33				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-17914.91	55429.71	-0.323200	0.7491
PBI	0.587247	1.227190	0.478530	0.6363
PBIP	-3.78E-06	6.64E-06	-0.569651	0.5738
TREL	31873.35	25558.22	1.247088	0.2235
TRELp	-2795.589	23409.23	-0.119423	0.9059
R-squared	0.545300	Mean dependent var	26837.90	
Adjusted R-squared	0.475347	S.D. dependent var	9702.586	
S.E. of regression	7027.870	Akaike info criterion	20.69984	
Sum squared resid	1.28E+09	Schwarz criterion	20.93113	
Log likelihood	-315.8476	F-statistic	7.795153	
Durbin-Watson stat	0.319406	Prob(F-statistic)	0.000287	

En el modelo recíproco las variables se hacen no significativas y el R^2 que mide el éxito de la regresión es 54%. Sin embargo la probabilidad asociada al estadístico F nos señala que la variable dependiente es explicada por el modelo en su conjunto a un nivel de 0.05 de significancia.

DETECCIÓN DE HETEROCEDASTICIDAD:

TEST DE WHITE

- ◆ Regresionar el modelo
- ◆ Ingresar a VIEW/ RESIDUAL TESTS / WHITE HETEROSKEDASTICITY
- ◆ La H_0 nos dice que el modelo no presenta heterocedasticidad. Si la probabilidad asociada al test es mayor a 0.05, aceptar la H_0 .

White Heteroskedasticity Test:				
F-statistic	1.588199	Probability	0.207184	
Obs*R-squared	6.087160	Probability	0.192733	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 08/29/02 Time: 15:40				
Sample: 1971 2001				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-185.3214	124.6833	-1.486336	0.1492
LPBI	32.53909	21.86197	1.488388	0.1487
LPBI^2	-1.427419	0.958056	-1.489912	0.1483
LTREL	-0.146572	0.171337	-0.855461	0.4001
LTREL^2	-0.069454	0.064197	-1.081894	0.2892
R-squared	0.196360	Mean dependent var	0.086517	
Adjusted R-squared	0.072723	S.D. dependent var	0.153362	
S.E. of regression	0.147681	Akaike info criterion	-0.840840	
Sum squared resid	0.567049	Schwarz criterion	-0.609551	
Log likelihood	18.03302	F-statistic	1.588199	
Durbin-Watson stat	0.463371	Prob(F-statistic)	0.207184	

La probabilidad asociada al estadístico del test de white, es mayor a 0.05 entonces aceptamos la H_0 al 5% de significancia, es decir que el modelo no tiene problemas de Heterocedasticidad.

DETECCIÓN DE AUTOCORRELACIÓN:


3. ESTADISTICO DURBIN WATSON

El output de la regresión nos muestra al estadístico Durbin Watson, el cual mide la autocorrelación de primer grado. Observamos que este es inferior a 2 (0.318203), por lo tanto podemos afirmar que el modelo tiene problemas de autocorrelación positiva de primer orden a un nivel de significancia del 5%.

4. TEST ESTADISTICO-Q

PROCEDIMIENTO

- ◆ Estando en el Output de la regresión, hacer clic en VIEW/ RESIDUAL TESTS/ CORRELOGRAM Q-STATISTICS/ 12 OK
- ◆ La H_0 es que el modelo no tiene autocorrelación hasta el orden p ($p = 12$).



Rechazamos la hipótesis nula de no autocorrelación hasta el orden 12 hasta el orden 16 debido a que las probabilidades asociadas al estadístico Q es menor a 0.05 aun nivel de confianza del 95%; es decir que puede existir autocorrelación de orden 1, 2, ..., 15, ó 16.

Para determinar cual es el orden de la autocorrelación, analizamos el comportamiento de los coeficientes de la autocorrelación parcial. Observamos que el primer y segundo coeficiente de autocorrelación parcial está fuera de las bandas, es decir que existe autocorrelación de segundo orden.

PREDICCIÓN

Estimar la cantidad de dinero, si se sabe que el PBI y la TREL se modificaran de la siguiente manera:

OBS	PBI	TREL
2002	122,036	1.060
2003	122,657	1.062
2004	122,975	1.062
2005	123,278	1.063

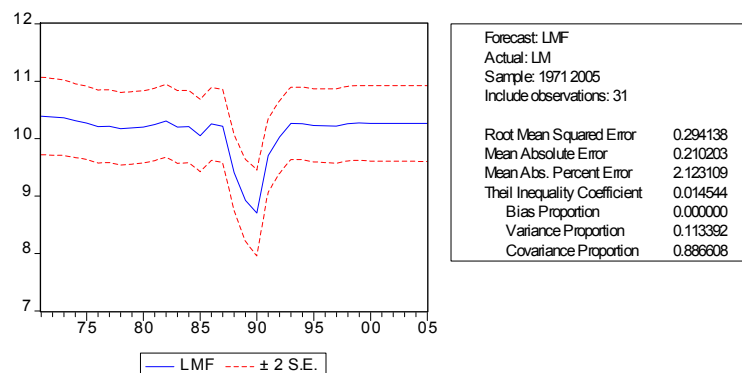
PROCEDIMIENTO:

- ◆ Expandir el rango y el tamaño de la muestra
- ◆ Ingresar a las variables independientes e introducir los nuevos valores
- ◆ Luego generar para el período 2002-2005 nuevas variables:

LPBI = Log PBI OK

LTREL = Log TREL OK

- ◆ Ingresar al Output de la regresión del modelo doblemente logarítmico y hacer clic en FORECAST.
- ◆ Se generará automáticamente en el workfile una nueva variable: LMF, el cual ser los valores estimados y proyectados de la variable LM.



♦ Como se obtiene los valores proyectados de la variable LMF, lo que se tiene que hacer es simplemente hallarle el antilogaritmo. En el workfile hacer clic en Genr y digitar lo siguiente: $mpred = \exp lmf$; se le pone otro nombre a la variable proyectada de la cantidad de dinero para no perder los datos anteriores. Entonces tenemos

AÑO	LMF	MPRED
2002	10.26276	28,645.80
2003	10.26252	28,638.77
2004	10.26183	28,619.24
2005	10.26173	28,616.28

LABORATORIO 08**ESTIMACIÓN DE MODELOS DE REZAGOS DISTRIBUIDOS Y AUTORREGRESIVOS**

Los modelos autoregresivos incluyen también a las variables dependientes rezagadas como explicativas.

$$Y_t = \beta_1 + \beta_2 X_t + \beta_3 Y_{t-1} + u_t$$

Los modelos de rezagos distribuidos sólo trabajan con los rezagos de las variables independientes

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \beta_3 X_{t-3} + \dots + \mu_t$$

II. SIGNIFICADO DE LOS PARAMETROS

Sea el modelo de rezagos distribuidos siguiente:

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \dots + \beta_k X_{t-k} + \mu$$

β_0 : Es el multiplicador de corto plazo.

$\beta_1, \beta_2 \dots \beta_k$: miden el impacto en el valor medio de Y debido a un cambio unitario en X, en varios periodos anteriores de tiempo

$\beta = \sum_{i=0}^k \beta_i = \beta_0 + \beta_1 + \dots + \beta_k$: Es el multiplicador de largo plazo, o total o con rezagos

distribuidos con tal que la suma β exista.

Proporción del efecto total que se deja sentir j periodos después de producido la variación de la variable explicativa.

La mediana de rezagos es el tiempo transcurrido para que se sienta la primera mitad del cambio total, en la variable dependiente.

Retardo promedio Es el promedio ponderado de todos los rezagos involucrados, actuando los coeficientes B como ponderaciones.

- ♦ **ALT Y TINBERGEN**, este método sugiere que para estimar el modelo se regresiona Y_t con X_t , luego Y_t con X_t y X_{t-1} , seguidamente Y_t con X_t , X_{t-1} y X_{t-2} y así sucesivamente hasta que las variables rezagadas se vuelvan estadísticamente no significativas y/o cuando ocurra un cambio de signo de las variables rezagadas.

El modelo original a regresionar es: $CP_t = \alpha + \beta_0 PBI_t + \mu_t$

Donde: CP_t : Consumo Privado

PBI_t : Producto Bruto Interno (Ingreso)

Dependent Variable: CP				
Method: Least Squares				
Date: 07/05/02 Time: 17:17				
Sample: 1970 2001				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PBI	0.660941	0.017464	37.84677	0.0000
C	7116.295	1622.393	4.386294	0.0001
R-squared	0.979485	Mean dependent var		67568.47
Adjusted R-squared	0.978802	S.D. dependent var		11046.32
S.E. of regression	1608.307	Akaike info criterion		17.66421
Sum squared resid	77599506	Schwarz criterion		17.75582
Log likelihood	-280.6274	F-statistic		1432.378
Durbin-Watson stat	0.906101	Prob(F-statistic)		0.000000

$$\hat{CP}_t = 7116.295 + 0.660941PBI_t$$

Los resultados nos indican que la variable explicativa es significativa en el modelo a un 95% de confianza.

Regresionando el modelo, luego de haber añadido el primer rezago, tenemos:

$$CP_t = \alpha + \beta_0 PBI_t + \beta_1 PBI_{t-1} + \mu_t$$

Dependent Variable: CP				
Method: Least Squares				
Date: 07/08/02 Time: 08:40				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6681.167	1783.650	3.745784	0.0008
PBI	0.632927	0.057233	11.05870	0.0000
PBI(-1)	0.033133	0.057369	0.577537	0.5682
R-squared	0.977808	Mean dependent var		68170.55
Adjusted R-squared	0.976223	S.D. dependent var		10681.85
S.E. of regression	1647.136	Akaike info criterion		17.74323
Sum squared resid	75965551	Schwarz criterion		17.88200
Log likelihood	-272.0200	F-statistic		616.8496
Durbin-Watson stat	0.909362	Prob(F-statistic)		0.000000

$$\hat{CP}_t = 6681.167 + 0.632927PBI_t + 0.033133PBI_{t-1}$$

De las salidas de la regresión podemos afirmar a un nivel de 5% de significancia que no se puede rechazar la H_0 de no significancia de la variable rezagada, es decir que ésta no es significativa en el modelo.

$$CP_t = \alpha + \beta_0 PBI_t + \beta_1 PBI_{t-1} + \beta_2 PBI_{t-2} + \mu_t$$

Dependent Variable: CP				
Method: Least Squares				
Date: 07/05/02 Time: 18:29				
Sample(adjusted): 1972 2001				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7227.737	1909.824	3.784505	0.0008
PBI	0.588144	0.060757	9.680230	0.0000
PBI(-1)	0.184408	0.097567	1.890063	0.0699
PBI(-2)	-0.114275	0.061373	-1.861966	0.0739
R-squared	0.978526	Mean dependent var		68763.83
Adjusted R-squared	0.976048	S.D. dependent var		10331.93
S.E. of regression	1599.017	Akaike info criterion		17.71573
Sum squared resid	66478265	Schwarz criterion		17.90256
Log likelihood	-261.7360	F-statistic		394.9164
Durbin-Watson stat	0.900879	Prob(F-statistic)		0.000000

$$\hat{CP}_t = 7227.737 + 0.588144PBI_t + 0.184408PBI_{t-1} + -0.114275PBI_{t-2}$$

El estadístico "t", de la variable rezagada en 2 períodos son bajos, es por ello que no se puede rechazar la H_0 de no significancia de las variables, es decir que estas no son significativas en el modelo. Pero cambio el signo del estimador del Parámetro.

Resumen del Método de Alt & Tinbergen:

$$\hat{CP}_t = 7116.295 + 0.660941PBI_t$$

$$t = (37.84677) \quad (4.386294)$$

$$\hat{CP}_t = 6681.167 + 0.632927PBI_t + 0.033133PBI_{t-1}$$

$$t = (3.745784) \quad (11.05870) \quad (0.577537)$$

$$\hat{CP}_t = 7227.737 + 0.588144PBI_t + 0.184408PBI_{t-1} + -0.114275PBI_{t-2}$$

$$t = (3.784505) \quad (9.680230) \quad (1.890063) \quad (-1.861966)$$

El modelo que se acepta es el primero, debido a que en los siguientes las variables rezagadas no son significativamente explicativas.

♦ **MODELO DE KOYCK,**

Para el modelo de rezago infinito

$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \dots$ Koyck supone que los β 's. tienen todos los mismos signos y decaen geométricamente donde:

$$\beta_k = \beta_0 \lambda^k \quad k = 0, 1, \dots \quad 0 < \lambda < 1 \quad : \text{Tasa de descenso}$$

$$1 - \lambda \quad : \text{Velocidad de ajuste}$$

El nuevo modelo será:

$$Y_t = \alpha(1 - \lambda) + \beta_0 X_t + \lambda Y_{t-1} + u_t$$

Se puede presentar el modelo finalmente:

$$Y_t = \beta_1 + \beta_2 X_t + \beta_3 Y_{t-1} + u_t$$

donde:

β_0 es el multiplicador de corto plazo.

El multiplicador de Largo Plazo, es una cantidad finita

$$\sum_{k=0}^{\infty} \beta_k = \beta_0 \left(\frac{1}{1 - \lambda} \right) = \beta_0 + \beta_1 + \beta_2 + \beta_3 + \dots \beta_k = \beta_0 + \beta_0 \lambda + \beta_0 \lambda^2 + \beta_0 \lambda^3 \dots \beta_0 \lambda^k$$

Aplicando al ejemplo del Consumo Privado en función del PBI:

$$CP_t = \alpha(1 - \lambda) + \beta_0 PBI_t + \lambda CP_{t-1} + u_t$$

$$CP_t = \alpha_0 + \beta PBI_t + \gamma CP_{t-1} + \mu_t$$

♦ este método estima los modelos de rezagos distribuidos de la siguiente manera:

$$CP_t = \alpha_0 + \beta PBI_t + \gamma CP_{t-1} + \mu_t$$

Dependent Variable: CP				
Method: Least Squares				
Date: 07/08/02 Time: 11:32				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5653.548	1848.808	3.057942	0.0049
PBI	0.598965	0.044490	13.46305	0.0000
CP(-1)	0.107048	0.066691	1.605137	0.1197
R-squared	0.979436	Mean dependent var		68170.55
Adjusted R-squared	0.977967	S.D. dependent var		10681.85
S.E. of regression	1585.573	Akaike info criterion		17.66704
Sum squared resid	70393148	Schwarz criterion		17.80582
Log likelihood	-270.8392	F-statistic		666.7884
Durbin-Watson stat	1.035641	Prob(F-statistic)		0.000000

$$\hat{CP}_t = \alpha(1 - \lambda) + \beta_0 PBI_t + \lambda CP_{t-1} + (\mu_t - \lambda \mu_{t-1})$$

$$\hat{CP}_t = 5653.548 + 0.598965 PBI_t + 0.107048 CP_{t-1}$$

Aunque la lectura de los estimadores de los parámetros nos dice que el Consumo privado del periodo anterior es significativo con un nivel de confianza del 88%, se realizará con fines académicos la explicación de los parámetros.

Despejando, obtenemos los siguientes resultados:

$$\alpha_0 = \alpha(1 - \lambda) = 5653.548 \quad \Rightarrow \quad \alpha = 6331.3011$$

$$\beta = \beta_0 = 0.598965$$

$$\gamma = \lambda = 0.107048$$

El impacto de corto plazo de la propensión marginal a consumir ($\beta = \beta_0 = 0.598965$) nos indica que si el PBI se incrementa en UN nuevo Sol, el consumo se incrementa en el mismo año en 60 centavos. El impacto en el consumo tiene una tasa de decrecimiento ($\gamma = \lambda =$) de 0.11 en la propensión marginal a consumir en cada periodo, es decir tiene un descenso lento por cada periodo. Luego la velocidad de ajuste es de $(1 - \lambda) = 0.89$, es muy rápido, es decir no se requiere muchos rezagos.

En el largo plazo el impacto total será $\sum_{k=0}^{\infty} \beta_k = \beta_0 \left(\frac{1}{1 - \lambda} \right) = \beta_0 (1 + \lambda + \lambda^2 + \lambda^3 \dots)$

$$(0.60 / 0.89) = 0.674$$

La mediana de rezagos, es decir el tiempo requerido en el cual se da la mitad del impacto es de $-(\log 2 / \log \lambda) =$

$$\text{El valor promedio de rezagos es } ((\lambda / 1 - \lambda) = 0.11 / 0.89) = 0.124$$

◆ **MODELO DE EXPECTATIVAS ADAPTABLES,**

Este método se basa en la siguiente ecuación:

$$CP_t = \beta_0 + \beta_1 PBI_t^* \quad (1)$$

El Consumo privado depende del PBI esperado

Hipótesis de expectativas adaptativas:

$$PBI_t^* - PBI_{t-1}^* = \gamma (PBI_t - PBI_{t-1}^*) \quad \text{donde} \quad 0 \leq \gamma \leq 1 \quad (2)$$

$0 < \gamma \leq 1$: Coeficiente de expectativas

Reemplazando (2) en (1), rezagando un periodo la ecuación (1) y multiplicando por $(1 - \gamma)$

Y operando

$$\hat{CP}_t = \beta_0 \gamma + \beta_1 \gamma PBI_t + (1 - \gamma) CP_{t-1} + (\mu_t - \mu_{t-1} (1 - \gamma))$$

que podría presentarse también de la siguiente manera:

$$\bullet \quad CP_t = \gamma\beta_0 + \gamma\beta_1 PBI_t + (1-\gamma)CP_{t-1} + v_t$$

Aplicando al ejemplo del Consumo Privado en función del PBI:

Partiendo de la hipótesis que el consumo privado depende del PBI esperado

$$CP_t = \beta_0 + \beta_1 PBI_t^*$$

Despejando, obtenemos lo siguiente:

$$\alpha_0 = \beta_0 \gamma = 5653.548 \quad \Rightarrow \quad \beta_0 = 6331.3011$$

$$\beta = \beta_1 \gamma = 0.598965 \quad \Rightarrow \quad \beta_1 = 0.670769$$

$$\gamma = (1 - \gamma) = 0.107048 \quad \Rightarrow \quad \gamma_1 = 0.892952$$

De acuerdo al resultado el $\gamma = 0.9$ (coeficiente de expectativas) nos indica que casi lo que se espera que sea el PBI en el periodo "t" se cumple.

$$PBI_t^* - PBI_{t-1}^* = \gamma(PBI_t - PBI_{t-1}^*) \quad \text{donde} \quad 0 \leq \gamma \leq 1$$

otra forma de expresar

$$PBI_t^* = \gamma PBI_t + (1 - \gamma) PBI_{t-1}^*$$

En la fórmula se aprecia que el PBI esperado se acerca mucho al PBI observado por ser el coeficiente de expectativas muy elevado (0.9). El modelo con expectativas:

$$CP_t = 6331.30 + 0.6708 PBI_t^*$$

- ◆ **MODELO DE AJUSTE PARCIAL**, este método se expresa mediante la siguiente ecuación:

$$CP_t^* = \beta_0 + \beta_1 PBI_t$$

Partiendo de la hipótesis que el nivel deseado del consumo privado es una función lineal del PBI.

$$\hat{CP}_t = \beta_0 \gamma + \beta_1 \gamma PBI_t + (1 - \gamma) CP_{t-1} + (\mu_t - \mu_{t-1} (1 - \gamma))$$

Despejando, obtenemos lo siguiente:

$$\alpha_0 = \beta_0 \gamma = 5653.548 \quad \Rightarrow \quad \beta_0 = 6331.3011$$

$$\beta = \beta_1 \gamma = 0.598965 \quad \Rightarrow \quad \beta_1 = 0.670769$$

$$\gamma = (1 - \gamma) = 0.107048 \quad \Rightarrow \quad \gamma_1 = 0.892952$$

Se obtiene valores similares al modelo de expectativas adaptables, no obstante la interpretación es diferente.

$$\bullet \quad CP_t = \delta\beta_0 + \delta\beta_1 PBI_t + (1-\delta)CP_{t-1} + v_t$$

Hipótesis de ajuste parcial:

$$CP_t - CP_{t-1} = \delta(CP_t^* - CP_{t-1}) \quad \text{donde} \quad 0 < \delta \leq 1$$

$CP_t - CP_{t-1}$: Cambio observado

$CP_t^* - CP_{t-1}$: Cambio deseado

donde:

$$\Rightarrow \quad \gamma_1 = \delta : \text{coeficiente de ajuste.}$$

Los resultados nos dicen que esta ecuación postula que el cambio observado en el consumo privado en cualquier momento del tiempo t es 0.90 del cambio deseado durante ese período.

$$CP_t - CP_{t-1} = \text{cambio observado} \quad CP_t^* - CP_{t-1} = \text{cambio deseado}$$

Igualmente se puede interpretar

$$CP_t = 0.9Y_t^* + (1-0.9)CP_{t-1} \dots\dots\dots(2)$$

El consumo privado observado es muy similar al consumo privado deseado por ser el coeficiente de ajuste de 0.9. El modelo de ajuste parcial:

$$CP_t^* = 6331.30 + 0.6708PBI_t$$

◆ MODELO MIXTO

$$Y_t^* = \beta_0 + \beta_1 X_t^* + \mu_t$$

donde:

Y_t^* = CP nivel de consumo deseado.

X_t^* = PBI nivel esperado de producción.

$$CP_t = \alpha + \beta PBI_t + \gamma CP_{t-1} + \phi CP_{t-2} + \mu_t$$

Dependent Variable: CP				
Method: Least Squares				
Date: 07/05/02 Time: 18:38				
Sample(adjusted): 1972 2001				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PBI	0.567847	0.042189	13.45972	0.0000
CP(-1)	0.319981	0.096785	3.306101	0.0028
CP(-2)	-0.184287	0.065949	-2.794376	0.0096
C	6368.226	1820.600	3.497872	0.0017
R-squared	0.982685	Mean dependent var		68763.83
Adjusted R-squared	0.980687	S.D. dependent var		10331.93
S.E. of regression	1435.825	Akaike info criterion		17.50043
Sum squared resid	53601439	Schwarz criterion		17.68726
Log likelihood	-258.5065	F-statistic		491.8703
Durbin-Watson stat	1.267716	Prob(F-statistic)		0.000000

La lectura de los estadísticos muestran que el consumo privado en su forma rezagada tiene significancia en términos estadísticos, en consecuencia el análisis del modelo mixto a partir de los consumos observados pasados tiene sentido. No obstante el signo negativo del CP(-2) no es económicamente válido.

Analizando los resultados. Sea la fórmula del modelo mixto:

$$CP_t = \beta_0 \delta \gamma_1 + \beta_1 \delta \gamma_1 PBI_t + [(1-\gamma) + (1-\delta)]CP_{t-1} - (1-\delta)(1-\gamma)CP_{t-2} + [\delta \mu_t - \delta(1-\gamma)\mu_{t-1}]$$

$$CP_t = \alpha + \beta PBI_t + \gamma CP_{t-1} + \phi CP_{t-2} + \mu_t$$

donde:

$$\alpha_0 = \beta_0 \delta \gamma_1 = 6368.226 \quad \dots (1)$$

$$\beta = \beta_1 \delta \gamma_1 = 0.567847 \quad \dots (2)$$

$$\gamma = (1-\gamma_1) + (1-\delta) = 0.319981 \quad \dots (3)$$

$$\phi = -(1-\gamma_1)(1-\delta) = -0.184287 \quad \dots (4)$$

Despejando, obtenemos los siguientes resultados:

$$\delta = 0.135927118 \quad \text{o} \quad \delta = 1.544091882$$

$$\gamma_1 = 1.544091882 \quad \gamma_1 = 0.135927118$$

$$\beta_0 = 30341.6516$$

$$\beta_1 = 30341.6516$$

$$Y_t^* = \beta_0 + \beta_1 X_t^* + \mu_t$$

El modelo plantea que el consumo privado esperado, depende del PBI esperado.

$$PBI_t^* - PBI_{t-1}^* = \gamma(PBI_t - PBI_{t-1}^*) \quad \text{donde} \quad \gamma = 0.1359$$

$$CP_t - CP_{t-1} = \delta(CP_t^* - CP_{t-1}) \quad \text{donde} \quad \delta = 0.1359$$

$\Rightarrow \gamma_1 = \delta$: coeficiente de ajuste .

MEDICIÓN DE LA AUTOCORRELACIÓN EN MODELOS AUTORREGRESIVOS

$$\hat{CP}_t = \hat{\alpha} + \beta PBI_t + \gamma \hat{CP}_{t-1}$$

$$h = \left(1 - \frac{1}{2}d\right) \sqrt{\frac{n}{1 - n(\text{Var}(\gamma))}}$$

De la regresión, se obtiene los siguientes datos:

$$d = 1.035641$$

$$n = 31$$

$$\text{Var}(\gamma) = (0.066691)^2 =$$

Reemplazando datos se obtiene:

$$h = \left(1 - \frac{1}{2}1.035641\right) \sqrt{\frac{31}{1 - 31(0.004448)}} = C$$

donde h se distribuye en forma asintóticamente normal con varianza cero y varianza unitaria.

El valor se compara con 1.96 que corresponde a un nivel de significación del 5%.

♦ **METODO DE LAS PONDERACIONES SUBJETIVAS**

obs	CP	PBI	Z _{0t}	Z _{1t}
1970	48904.00	62022.00	NA	NA
1971	50372.00	64627.00	NA	NA
1972	51178.00	66501.00	NA	NA
1973	53278.00	70092.00	NA	NA
1974	58435.00	76611.00	168518.8	890471.0
1975	59244.00	79215.00	177608.5	931684.0
1976	60633.00	80800.00	188089.8	964429.0
1977	60768.00	81123.00	195724.2	998897.0
1978	59131.00	81366.00	200463.2	1033384.
1979	61760.00	86086.00	203531.2	1066659.
1980	64822.00	90562.00	207811.0	1101232.
1981	68283.00	95181.00	216126.0	1135158.
1982	68880.00	94610.00	225189.5	1157000.
1983	62814.00	83446.00	230150.0	1143653.
1984	64029.00	87785.00	228510.2	1165252.
1985	65382.00	90243.00	220999.5	1189932.
1986	75148.00	99267.00	223098.8	1210671.
1987	82526.00	107208.0	231432.5	1226963.
1988	76418.00	97881.00	244409.0	1236833.
1989	63358.00	86429.00	249950.0	1208192.
1990	61814.00	81983.00	240012.0	1210155.
1991	62990.00	83760.00	224103.0	1210029.
1992	62788.00	83401.00	212398.0	1147489.
1993	64935.00	87375.00	209903.0	1109744.
1994	71306.00	98577.00	214108.5	1147911.
1995	78198.00	107039.0	226063.8	1214527.
1996	80584.00	109709.0	244061.5	1259845.
1997	84081.00	117110.0	262303.2	1341551.
1998	83376.00	116485.0	275549.0	1418255.
1999	83056.00	117590.0	286364.2	1468014.
2000	86289.00	121267.0	291579.0	1509789.
2001	87411.00	121490.0	296116.0	1547494.

$$Z_t = \frac{1}{4} PBI_t + \frac{1}{2} PBI_{t-1} + PBI_{t-2} + \frac{1}{2} PBI_{t-3} + \frac{1}{4} PBI_{t-4}$$

Por ejemplo reemplazando en los años de la serie

$$Z_{1974} = \frac{1}{4} PBI_{1974} + \frac{1}{2} PBI_{1973} + PBI_{1972} + \frac{1}{2} PBI_{1971} + \frac{1}{4} PBI_{1970} = 168,518.8$$

$$CP_t = \alpha + \beta Z_t$$

Si la relación con Z fuera de otra manera, por ejemplo:

$$Z_{1t} = 4PBI_t + 2PBI_{t-1} + PBI_{t-2} + 2PBI_{t-3} + 4PBI_{t-4}$$

$$Z_{12001} = 4PBI_{2001} + 2PBI_{2000} + PBI_{1999} + 2PBI_{1998} + 4PBI_{1997} = 1547,494.0$$

$$CP_t = \alpha + \beta Z_{1t}$$

Dependent Variable: CP				
Method: Least Squares				
Date: 09/06/02 Time: 12:05				
Sample(adjusted): 1974 2001				
Included observations: 28 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	14063.54	7716.472	1.822535	0.0799
Z _{0t}	0.244704	0.033469	7.311366	0.0000
R-squared	0.672775	Mean dependent var		69944.96
Adjusted R-squared	0.660190	S.D. dependent var		9637.076
S.E. of regression	5617.766	Akaike info criterion		20.17400
Sum squared resid	8.21E+08	Schwarz criterion		20.26916
Log likelihood	-280.4361	F-statistic		53.45607
Durbin-Watson stat	0.754393	Prob(F-statistic)		0.000000

La lectura del estadístico, denota significatividad de la nueva variable “Z”, con las características de una “V” invertida, aunque el R² es relativamente bajo (67%).

$$Y_t = \alpha + \beta \left(\frac{1}{4} X_t + \frac{1}{2} X_{t-1} + X_{t-2} + \frac{1}{2} X_{t-3} + \frac{1}{4} X_{t-4} \right) + \mu_t$$

$$CP_t = \alpha + \beta \left(\frac{1}{4} PBI_t + \frac{1}{2} PBI_{t-1} + PBI_{t-2} + \frac{1}{2} PBI_{t-3} + \frac{1}{4} PBI_{t-4} \right) + \mu_t$$

$$\hat{CP}_t = 14063.54 + 0.244704 \left(\frac{1}{4} PBI_t + \frac{1}{2} PBI_{t-1} + PBI_{t-2} + \frac{1}{2} PBI_{t-3} + \frac{1}{4} PBI_{t-4} \right)$$

$$\hat{CP}_t = 14063.54 + 0.061176PBI_t + 0.122352PBI_{t-1} + 0.244704PBI_{t-2} + 0.122352PBI_{t-3} + 0.061176PBI_{t-4}$$

A continuación se construirá otra variable “Z”

$$CP_t = \alpha + \beta Z_{1t}$$

donde Z tiene la forma de una V

$$Y_t = \alpha + \beta (4X_t + 2X_{t-1} + X_{t-2} + 2X_{t-3} + 4X_{t-4}) + \mu_t$$

Remplazando en la fórmula del Consumo respecto al PBI

$$CP_t = \alpha + \beta (4PBI_t + 2PBI_{t-1} + PBI_{t-2} + 2PBI_{t-3} + 4PBI_{t-4}) + \mu_t$$

Corrido el modelo los resultados son los siguientes:

Dependent Variable: CP				
Method: Least Squares				
Date: 09/06/02 Time: 12:30				
Sample(adjusted): 1974 2001				
Included observations: 28 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	8648.765	7090.598	1.219751	0.2335
Z _{1t}	0.051625	0.005920	8.721157	0.0000
R-squared	0.745244	Mean dependent var		69944.96
Adjusted R-squared	0.735446	S.D. dependent var		9637.076
S.E. of regression	4956.812	Akaike info criterion		19.92366
Sum squared resid	6.39E+08	Schwarz criterion		20.01882
Log likelihood	-276.9313	F-statistic		76.05858
Durbin-Watson stat	0.690119	Prob(F-statistic)		0.000000

Z_{1t} es significativo y la bondad de ajuste del modelo es de aproximadamente 74.5%.

Remplazando en el modelo se tiene las siguientes ecuaciones:

$$CP_t = 8648.765 + 0.051625(4PBI_t + 2PBI_{t-1} + PBI_{t-2} + 2PBI_{t-3} + 4PBI_{t-4}) + \mu_t$$

$$\hat{CP}_t = 8648.765 + 0.2065PBI_t + 0.10325PBI_{t-1} + 0.051625PBI_{t-2} + 0.10325PBI_{t-3} + 0.2065PBI_{t-4}$$

♦ **METODO DE SHIRLEY ALMON**

Trabajando con la misma serie histórica, se plantea la construcción de un modelo donde "Z" es una ecuación polinómica de tercer grado con 3 rezagos.

1. **Modelo :**

$$CP_t = \alpha + \beta_0 PBI_t + \beta_1 PBI_{t-1} + \beta_2 PBI_{t-2} + \beta_3 PBI_{t-3} + \mu_t$$

$$CP_t = \alpha + \sum_{i=0}^3 \beta_i PBI_{t-i} + \mu_t$$

2. **Supuesto :** Los β_i pueden ser aproximados mediante un polinomio de tercer grado.

$$\beta_i = a_0 + a_1 i + a_2 i^2 + a_3 i^3$$

$$CP_t = \alpha + \sum_{i=0}^3 (a_0 + a_1 i + a_2 i^2 + a_3 i^3) PBI_{t-i} + \mu_t$$

$$CP_t = \alpha + \sum_0^3 \beta_i PBI_{t-i} = \alpha + a_0 \sum_0^3 PBI_{t-i} + a_1 \sum_0^3 i PBI_{t-i} + a_2 \sum_0^3 i^2 PBI_{t-i} + a_3 \sum_0^3 i^3 PBI_{t-i}$$

$$CP_t = \alpha + a_0 Z_{0t} + a_1 Z_{1t} + a_2 Z_{2t} + a_3 Z_{3t} + \mu_t$$

Datos Transformados:

$$\begin{aligned} Z_{0t} &= PBI_t + PBI_{t-1} + PBI_{t-2} + PBI_{t-3} & Z_{0t} &= \sum_{i=0}^3 PBI_{t-i} \\ Z_{1t} &= PBI_{t-1} + 2PBI_{t-2} + 3PBI_{t-3} & Z_{1t} &= \sum_{i=0}^3 iPBI_{t-i} \\ Z_{2t} &= PBI_{t-1} + 4PBI_{t-2} + 9PBI_{t-3} & Z_{2t} &= \sum_{i=0}^3 i^2 PBI_{t-i} \\ Z_{3t} &= PBI_{t-1} + 8PBI_{t-2} + 27PBI_{t-3} & Z_{3t} &= \sum_{i=0}^3 i^3 PBI_{t-i} \end{aligned}$$

A continuación, se tiene la serie transformada del PBI:

obs	CP	PBI	Z _{0t}	Z _{1t}	Z _{2t}	Z _{3t}
1970	48904.00	62022.00	NA	NA	NA	NA
1971	50372.00	64627.00	NA	NA	NA	NA
1972	51178.00	66501.00	NA	NA	NA	NA
1973	53278.00	70092.00	263242.0	381821.0	883207.0	2258111.
1974	58435.00	76611.00	277831.0	396975.0	917739.0	2347029.
1975	59244.00	79215.00	292419.0	416298.0	955488.0	2432874.
1976	60633.00	80800.00	306718.0	442713.0	1016487.	2584587.
1977	60768.00	81123.00	317749.0	469063.0	1087159.	2783017.
1978	59131.00	81366.00	322504.0	480368.0	1117258.	2866328.
1979	61760.00	86086.00	329375.0	486012.0	1133058.	2911950.
1980	64822.00	90562.00	339137.0	492187.0	1141657.	2927335.
1981	68283.00	95181.00	353195.0	506832.0	1167200.	2976132.
1982	68880.00	94610.00	366439.0	534563.0	1232203.	3143999.
1983	62814.00	83446.00	363799.0	556658.0	1290392.	3301232.
1984	64029.00	87785.00	361022.0	558209.0	1318515.	3410213.
1985	65382.00	90243.00	356084.0	538507.0	1273059.	3309823.
1986	75148.00	99267.00	360741.0	516151.0	1192397.	3045565.
1987	82526.00	107208.0	384503.0	543108.0	1250304.	3191406.
1988	76418.00	97881.00	394599.0	576471.0	1316463.	3337905.
1989	63358.00	86429.00	390785.0	610098.0	1420116.	3635754.
1990	61814.00	81983.00	373501.0	603815.0	1442825.	3764093.
1991	62990.00	83760.00	350053.0	548484.0	1308628.	3416202.
1992	62788.00	83401.00	335573.0	507013.0	1189553.	3073207.
1993	64935.00	87375.00	336519.0	496870.0	1156288.	2967022.
1994	71306.00	98577.00	353113.0	505457.0	1174819.	3016103.
1995	78198.00	107039.0	376392.0	523530.0	1198686.	3049404.
1996	80584.00	109709.0	402700.0	566318.0	1287722.	3254780.
1997	84081.00	117110.0	432435.0	619518.0	1425058.	3627600.
1998	83376.00	116485.0	450343.0	657645.0	1519297.	3884835.
1999	83056.00	117590.0	460894.0	679832.0	1572306.	4015508.
2000	86289.00	121267.0	472452.0	701890.0	1637520.	4211440.
2001	87411.00	121490.0	476832.0	705902.0	1639992.	4207082.

Parámetros estimados: $\hat{\beta}_0 = \bar{a}_0$

$$\hat{\beta}_1 = \bar{a}_0 + \bar{a}_1 + \bar{a}_2 + \bar{a}_3$$

$$\hat{\beta}_2 = \bar{a}_0 + 2\bar{a}_1 + 4\bar{a}_2 + 8\bar{a}_3$$

Los resultados son:

Dependent Variable: CP				
Method: Least Squares				
Date: 07/05/02 Time: 18:19				
Sample(adjusted): 1973 2001				
Included observations: 29 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
Z _{0t}	0.589702	0.064874	9.089887	0.0000
Z _{1t}	-0.390550	0.572711	-0.681933	0.5018
Z _{2t}	-0.061712	0.532320	-0.115931	0.9087
Z _{3t}	0.041838	0.117976	0.354633	0.7260
C	7268.342	2180.323	3.333607	0.0028
R-squared	0.976065	Mean dependent var		69370.24
Adjusted R-squared	0.972076	S.D. dependent var		9956.667
S.E. of regression	1663.821	Akaike info criterion		17.82721
Sum squared resid	66439231	Schwarz criterion		18.06295
Log likelihood	-253.4945	F-statistic		244.6760
Durbin-Watson stat	0.885465	Prob(F-statistic)		0.000000

Aunque R^2 es bueno Z_{1t} , Z_{2t} y Z_{3t} no son relevantes por que sus parámetros no son significativos.

$$\hat{CP}_t = 7268.342 + 0.589702Z_{0t} - 0.390550Z_{1t} - 0.061712Z_{2t} + 0.041838Z_{3t}$$

$$\beta_0 = a_0 \qquad \beta_0 = 0.589702$$

$$\beta_1 = a_0 + a_1 + a_2 + a_3 \qquad \beta_1 = 0.179278$$

$$\beta_2 = a_0 + 2a_1 + 2^2 a_2 + 2^3 a_3 \qquad \beta_2 = -0.103542$$

$$\beta_3 = a_0 + 3a_1 + 3^2 a_2 + 3^3 a_3 \qquad \beta_3 = -0.00773$$

$$Y_t = 7268.342 + 0.589702X_t + 0.179278X_{t-1} - 0.103542X_{t-2} - 0.00773X_{t-3}$$

MODELO CUADRÁTICO Y CON 2 REZAGOS

$$CP_t = \alpha + \sum_{i=1}^2 \beta_i PBI_{t-i} = \alpha + a_0 \sum_{i=1}^2 PBI_{t-i} + a_1 \sum_{i=1}^2 iPBI_{t-i} + a_2 \sum_{i=1}^2 i^2 PBI_{t-i}$$

$$Z_{0t} = PBI_t + PBI_{t-1} + PBI_{t-2}$$

$$Z_{0t} = \sum_{i=0}^2 PBI_{t-i}$$

$$Z_{1t} = PBI_{t-1} + 2PBI_{t-2}$$

$$Z_{1t} = \sum_{i=0}^2 iPBI_{t-i}$$

$$Z_{2t} = PBI_{t-1} + 4PBI_{t-2}$$

$$Z_{2t} = \sum_{i=0}^2 i^2 PBI_{t-i}$$

$$\beta_i = a_0 + a_1 i + a_2 i^2$$

Dependent Variable: CP				
Method: Least Squares				
Date: 09/06/02 Time: 18:12				
Sample(adjusted): 1972 2001				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7227.737	1909.824	3.784505	0.0008
ACZ _{0t}	0.588144	0.060757	9.680230	0.0000
ACZ _{1t}	-0.456263	0.297715	-1.532551	0.1375
ACZ _{2t}	0.052527	0.148043	0.354808	0.7256
R-squared	0.978526	Mean dependent var		68763.83
Adjusted R-squared	0.976048	S.D. dependent var		10331.93
S.E. of regression	1599.017	Akaike info criterion		17.71573
Sum squared resid	6647826	Schwarz criterion		17.90256
Log likelihood	-261.7360	F-statistic		394.9164
Durbin-Watson stat	0.900879	Prob(F-statistic)		0.000000

El R^2 es alto, pero el ACZ_{2t} , no es relevante por que su parámetro no es significativo.

$$\hat{CP}_t = 7227.737 + 0.588144ACZ_{0t} - 0.456263ACZ_{1t} + 0.052527ACZ_{2t}$$

MODELO LINEAL Y CON 2 REZAGOS

$$CP_t = \alpha + \sum_{i=1}^2 \beta_i PBI_{t-i} = \alpha + a_0 \sum_{i=1}^2 PBI_{t-i} + a_1 \sum_{i=1}^2 iPBI_{t-i}$$

$$Z_{0t} = PBI_t + PBI_{t-1} + PBI_{t-2} \qquad Z_{0t} = \sum_{i=0}^2 PBI_{t-i}$$

$$Z_{1t} = PBI_{t-1} + 2PBI_{t-2} \qquad Z_{1t} = \sum_{i=0}^2 iPBI_{t-i}$$

$$\beta_i = a_0 + a_1 i$$

Dependent Variable: CP				
Method: Least Squares				
Date: 09/06/02 Time: 18:14				
Sample(adjusted): 1972 2001				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7358.531	1843.326	3.991985	0.0005
ALZ _{0t}	0.570238	0.033282	17.13362	0.0000
ALZ _{1t}	-0.351296	0.032803	-10.70932	0.0000
R-squared	0.978422	Mean dependent var		68763.83
Adjusted R-squared	0.976823	S.D. dependent var		10331.93
S.E. of regression	1572.921	Akaike info criterion		17.65390
Sum squared resid	6680014.4	Schwarz criterion		17.79402
Log likelihood	261.8084	F-statistic		612.1291
Durbin-Watson stat	0.949942	Prob(F-statistic)		0.000000

La bondad de ajuste es alta ($R^2 = 97.8\%$) y los ACZ_{0t} , y ACZ_{1t} son relevantes ya que sus parámetros no son significativos.

$$\hat{CP}_t = 7358.531 + 0.570238ALZ_{0t} - 0.351296ALZ_{1t}$$

◆ **ESTIMACION MEDIANTE EL METODO DE VARIABLES INSTRUMENTALES**

1º $CP_t = \alpha + \beta_0 PBI_t + \mu_t$ ⇒ \hat{CP}_t , esta variable se incorporará al modelo, rezagándolo un período.

2º $CP_t = \alpha + \beta_0 PBI_t + \beta_1 \hat{CP}_{t-1} + \mu_t$

Dependent Variable: CP				
Method: Least Squares				
Date: 07/05/02 Time: 18:57				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6324.429	1951.786	3.240329	0.0031
PBI	0.632927	0.057233	11.05870	0.0000
CPestimado(-1)	0.050130	0.086799	0.577537	0.5682
R-squared	0.977808	Mean dependent var	68170.55	
Adjusted R-squared	0.976223	S.D. dependent var	10681.85	
S.E. of regression	1647.136	Akaike info criterion	17.74323	
Sum squared resid	75965551	Schwarz criterion	17.88200	
Log likelihood	-272.0200	F-statistic	616.8496	
Durbin-Watson stat	0.909362	Prob(F-statistic)	0.000000	

En las salidas de la regresión, se observa que el ajuste es bueno, ya que el R^2 y el $R^2_{ajustado}$ son altos.

LABORATORIO 09**REGRESIÓN DE UNA VARIABLE DICOTÓMICA****EJERCICIO: VARIABLES DICOTÓMICAS**

El modelo original a regresionar es: $CP_t = \alpha_0 + \beta_1 PBI_t + \mu_t$

Periodo de análisis: 1970-2001

Donde:

CP_t : Consumo Privado

PBI_t : Producto Bruto Interno (Ingreso)

Dependent Variable: CP				
Method: Least Squares				
Date: 07/09/02 Time: 10:43				
Sample: 1970 2001				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7116.295	1622.393	4.386294	0.0001
PBI	0.660941	0.017464	37.84677	0.0000
R-squared	0.979485	Mean dependent var	67568.47	
Adjusted R-squared	0.978802	S.D. dependent var	11046.32	
S.E. of regression	1608.307	Akaike info criterion	17.66421	
Sum squared resid	77599506	Schwarz criterion	17.75582	
Log likelihood	-280.6274	F-statistic	1432.378	
Durbin-Watson stat	0.906101	Prob(F-statistic)	0.000000	

INCORPORACIÓN DE LAS VARIABLES DICOTÓMICAS EN LA REGRESIÓN

En el ejercicio, se incorpora una variable dicotómica $D1_t$, el cual representa el período de hiperinflación que se registró en el Perú (1988-1991). Se determinará si este suceso afectó significativamente el consumo privado, ya sea afectando al consumo autónomo o por cambios en el nivel del ingreso.

La asignación de los valores 0 y 1 a las categorías es arbitraria, es decir puede ser:

- $$D1_t = \begin{cases} 1 & \text{periodo de hiperinflación : } 1988 - 1991 \\ 0 & \text{periodo de estabilidad econ. : } 1970 - 1987, 1992 - 2001 \end{cases} \quad \text{ó}$$
- $$D1_t = \begin{cases} 1 & \text{periodo de estabilidad econ. : } 1970 - 1987, 1992 - 2001 \\ 0 & \text{periodo de hiperinflación : } 1988 - 1991 \end{cases}$$

Para la interpretación: (en cualquier caso) se espera que el consumo promedio en época de hiperinflación sea menor que en época de estabilidad económica.

Es decir, que para una correcta interpretación es indispensable saber como se asignaron "0" y "1". El grupo al que se le asigna valor cero "0", recibe el nombre de categoría base, de

comparación omitida. Es la base en el sentido que todas las comparaciones se hacen con respecto a esa categoría

En el ejercicio se tomará la siguiente asignación de los valores 0 y 1:

$$D1_t = \begin{cases} 1 & \text{periodo de hiperinflación : } 1988 - 1991 \\ 0 & \text{periodo de estabilidad econ. : } 1970 - 1987, 1992 - 2001 \end{cases}$$

Entonces, generamos la nueva variable $D1_t$, : en GENR digitar lo siguiente:

D1 = 1 Sample: 1988 1991 y,
D1 = 0 Sample: 1970 1987, 1992 2001

A continuación se regresionará el modelo de 3 formas (modelo aditivo, modelo multiplicativo y modelo aditivo y multiplicativo):

1º Forma (intercepto) Modelo Aditivo:

$$CP_t = \alpha_0 + \alpha_1 D1_t + \beta_1 PBI_t + \mu_t$$

Donde:

$\alpha_1 : (D1_t)$ Es el coeficiente diferencial del intercepto y se espera que deba tener signo negativo.

Se estima que:

1. En época de hiperinflación (1988-1991):

$$E(CP_t / D1_t = 1) = (\alpha_0 + \alpha_1) + \beta_1 PBI_t$$

2. En época de estabilidad económica (1970-1987, 1992-2001):

$$E(CP_t / D1_t = 0) = \alpha_0 + \beta_1 PBI_t$$

Regresionando el nuevo modelo obtenemos:

Dependent Variable: CP				
Method: Least Squares				
Date: 09/13/02 Time: 11:30				
Sample: 1970 2001				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6711.947	1598.878	4.197910	0.0002
D1	1368.771	840.4809	1.628557	0.1142
PBI	0.663491	0.017074	38.86049	0.0000
R-squared	0.981204	Mean dependent var	67568.47	
Adjusted R-squared	0.979908	S.D. dependent var	11046.32	
S.E. of regression	1565.768	Akaike info criterion	17.63920	
Sum squared resid	71097299	Schwarz criterion	17.77661	
Log likelihood	-279.2272	F-statistic	756.9578	
Durbin-Watson stat	1.034595	Prob(F-statistic)	0.000000	

La probabilidad asociada al estadístico t nos indica que a un nivel de 5% de significancia no se puede rechazar la hipótesis nula de no significancia, es decir que la variable incorporada no es significativa en el modelo. Además el coeficiente diferencial del intercepto que se obtuvo, no tiene el signo esperado, ya que es un valor positivo.

En el período de inflación no se alteró en una proporción mayor el consumo autónomo.

2º Forma (pendiente) Modelo Multiplicativo:

$$CP_t = \alpha_0 + \beta_1 PBI_t + \beta_2 D1_t * PBI_t + \mu_t$$

1. En época de hiperinflación (1988-1991):

$$E(CP_t/D1_t = 1) = \alpha_0 + (\beta_1 + \beta_2) PBI_t$$

2. En época de estabilidad económica (1970-1987, 1992-2001):

$$E(CP_t/D1_t = 0) = \alpha_0 + \beta_1 PBI_t$$

En este caso se supone que los consumos no varían para cualquier realidad, sino más bien se dan variaciones en la Tasa de Cambio del Consumo al variar el Producto Bruto Interno.

Aceptando que se consume menos en época de inflación, se espera que:

$$(\beta_1 + \beta_2) < \beta_1$$

Entonces, las variaciones en el consumo en época de hiperinflación, deberían ser inferiores a los del periodo de estabilidad económica, cuando se presenten variaciones en el ingreso (PBI).

Regresionando el modelo, obtuvimos:

Dependent Variable: CP				
Method: Least Squares				
Date: 07/09/02 Time: 11:13				
Sample: 1970 2001				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6700.907	1580.694	4.239220	0.0002
PBI	0.663430	0.016891	39.27765	0.0000
D1*PBI	0.017166	0.009474	1.811858	0.0804
R-squared	0.981572	Mean dependent var	67568.47	
Adjusted R-squared	0.980301	S.D. dependent var	11046.32	
S.E. of regression	1550.400	Akaike info criterion	17.61947	
Sum squared resid	69708439	Schwarz criterion	17.75689	
Log likelihood	-278.9116	F-statistic	772.3282	
Durbin-Watson stat	1.044042	Prob(F-statistic)	0.000000	

En las salidas de la regresión podemos observar que la probabilidad asociada al estadístico "t" de la variable D1*PBI, nos indica que a un nivel de confianza del 95% no se puede rechazar la Ho de no significancia de la variable, es decir que D1*PBI no es significativa en el modelo.

Las tasas de cambio en el consumo privado ante variaciones en el ingreso no fueron diferentes en los dos períodos.

Además se observa que la relación esperada entre los coeficientes, no se cumple, ya que se tienen que: $(\beta_1 + \beta_2) > \beta_1$

3º Forma (intercepto y pendiente) Modelo Aditivo y Multiplicativo:

$$CP_t = \alpha_0 + \alpha_1 D1_t + \beta_1 PBI_t + \beta_2 D1_t * PBI_t + \mu_t$$

1. En época de hiperinflación (1988-1991):

$$E(CP_t/D1_t = 1) = (\alpha_0 + \alpha_1) + (\beta_1 + \beta_2) PBI_t$$

2. En época de estabilidad económica (1970-1987, 1992-2001):

$$E(CP_t/D1_t = 0) = \alpha_0 + \beta_1 PBI_t$$

Regresionando este modelo, tenemos:

Dependent Variable: CP				
Method: Least Squares				
Date: 09/13/02 Time: 11:20				
Sample: 1970 2001				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7197.740	1488.902	4.834262	0.0000
D1	-23992.37	10346.59	-2.318867	0.0279
PBI	0.658213	0.015904	41.38595	0.0000
D1*PBI	0.289525	0.117785	2.458077	0.0204
R-squared	0.984540	Mean dependent var	67568.47	
Adjusted R-squared	0.982884	S.D. dependent var	11046.32	
S.E. of regression	1445.167	Akaike info criterion	17.50631	
Sum squared resid	58478233	Schwarz criterion	17.68952	
Log likelihood	-276.1009	F-statistic	594.3926	
Durbin-Watson stat	1.184912	Prob(F-statistic)	0.000000	

En este tercer caso, podemos observar que las variables D1 y D1*PBI se vuelven significativas, bajo un nivel de confianza del 5%, es decir que el período de hiperinflación sí influyó en el consumo privado.

Si observamos los R^2 y el $R^2_{ajustado}$ de todos los modelos (incluyendo el modelo inicial), podemos concluir que en la última regresión: $CP_t = \alpha_0 + \alpha_1 D1_t + \beta_1 PBI_t + \beta_2 D1_t PBI_t + \mu_t$, se obtuvo la mayor bondad de ajuste: 98.5% y 98.2% respectivamente.

Sin embargo se observa, que el modelo tiene autocorrelación, es por ello que se procederá a su corrección mediante el procedimiento **ITERATIVO DE COCHRAN – ORCUTT**.

- c. Con los residuos obtenidos del último modelo (en Genr digitar: Resid1 = resid), se regresará el siguiente modelo: $e_t = \rho e_{t-1} + \varepsilon_t$ y, se obtendrá el estimador de COCHRAN – ORCUTT, que será el coeficiente estimado de la variable explicativa (resid1(-1)), nos servirá para transformar las variables.

Is resid1 c resid1(-1)

Dependent Variable: RESID1				
Method: Least Squares				
Date: 07/18/03 Time: 14:54				
Sample(adjusted): 1971 2001				
Included observations: 31 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-25.27831	231.7843	-0.109060	0.9139
RESID1(-1)	0.400673	0.168847	2.372989	0.0245
R-squared	0.162602	Mean dependent var		
Adjusted R-squared	0.133726	S.D. dependent var		
S.E. of regression	1290.498	Akaike info criterion		
Sum squared resid	48296205	Schwarz criterion		
Log likelihood	-264.9997	F-statistic		
Durbin-Watson stat	1.668387	Prob(F-statistic)		

d. Se transforma todas las variables del modelo. En GENR digitar lo siguiente:

CP1= CP - 0.400673*CP(-1) OK
D2 = D1 - 0.400673*D1(-1) OK
PBI1= PBI - 0.400673*PBI(-1) OK
D1PBI1= D1*PBI - 0.400673*D1*PBI(-1) OK

Para el año 1970, generar:

$$\text{CP1}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{CP}_{1970} \quad \text{CP1} = ((1 - 0.400673^2)^{(1/2)}) * \text{CP} \quad \text{sample}$$

1970

$$\text{D2}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{D1}_{1970} \quad \text{D2} = ((1 - 0.400673^2)^{(1/2)}) * \text{D1} \quad \text{sample}$$

1970

$$\text{PBI1}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{PBI}_{1970} \quad \text{PBI1} = ((1 - 0.400673^2)^{(1/2)}) * \text{PBI} \quad \text{sample}$$

1970

$$\text{D1PBI1}_{1970} = \sqrt{1 - \hat{\rho}^2} * \text{D1PBI}_{1970} \quad \text{D1PBI1} = ((1 - 0.400673^2)^{(1/2)}) * \text{D1} * \text{PBI} \quad \text{sample}$$

1970

e. Con las variables transformadas se regresiona el siguiente modelo:

ls cp1 c d2 pbi1 d1pbi1

Dependent Variable: CP1				
Method: Least Squares				
Date: 07/18/03 Time: 16:41				
Sample: 1970 2001				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3411.789	1623.703	2.101239	0.0447
D2	2256.042	3155.555	0.714943	0.4806
PBI1	0.676875	0.027895	24.26539	0.0000
D1PBI1	-0.022766	0.048858	-0.465955	0.6449
R-squared	0.958048	Mean dependent var	41462.05	
Adjusted R-squared	0.953554	S.D. dependent var	6887.250	
S.E. of regression	1484.301	Akaike info criterion	17.55974	
Sum squared resid	61688160	Schwarz criterion	17.74296	
Log likelihood	-276.9559	F-statistic	213.1453	
Durbin-Watson stat	1.380383	Prob(F-statistic)	0.000000	

En este cuarto caso, podemos observar que las variables D2, PBI1 y D1PBI1 son significativas, bajo un nivel de confianza del 6%, es decir que el período de hiperinflación si tuvieron influencia en el consumo privado.

Si observamos los R^2 y el $R^2_{ajustado}$, estas fueron del 97.0% y 96.7% respectivamente. Para efectos de predicción se escogerá a este modelo.

Explicación del modelo

En el periodo comprendido entre 1970 y 1987 y entre 1992 y 2001 el modelo resulta de la Combinación del Caso 2 y Caso 3 (Modelo Aditivo y Multiplicativo) y con la corrección de autocorrelación (procedimiento iterativo de ITERATIVO DE COCHRAN – ORCUTT)

$$CP1_t = 2792.015 - 18028.41 * D2_t + 0.678750 * PBI1_t + 0.211543 * D1PBI1_t$$

Si fuera en época de hiperinflación el modelo quedaría

$$E(CP1_t/D1_t = 1) = -6672.233 + 0.890293 * PBI1_t - 0.100491 * PBI_{t-1}$$

Para el año 1988, el modelo quedaría alterado de la siguiente forma:

$$E(CP1_t/D1_t = 1) = -15236.395 + 0.890318 * PBI1_t$$

En época de inflación moderada, el modelo será:

$$E(CP1_t/D1_t = 0) = 2792.015 + 0.678750 * PBI1_t$$

Para el año 1992, el modelo quedaría alterado de la siguiente forma:

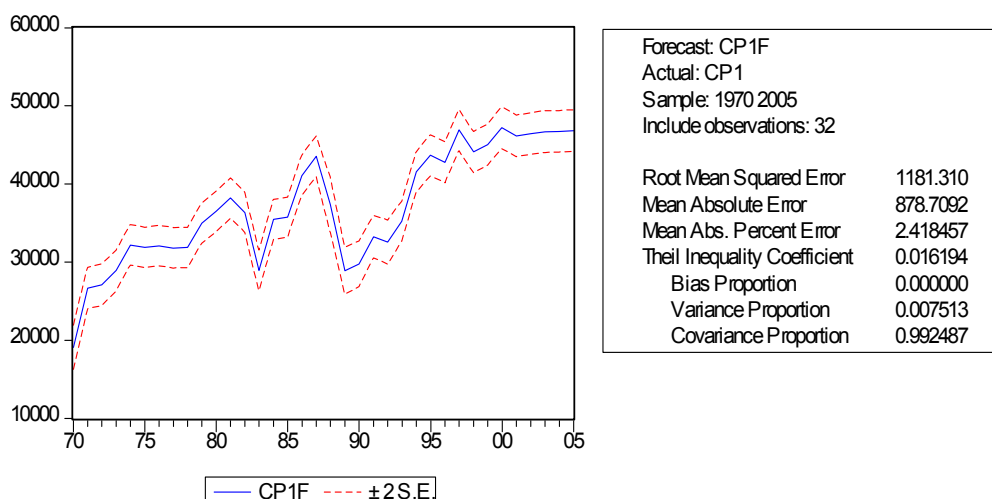
$$E(CP1_t/D1_t = 0) = 11356.18 + 0.678750 * PBI1_t - 0.100491 * PBI_{t-1}$$

PREDICCIÓN

Estimar el Consumo Privado, si se sabe que la inflación se mantendrá con un crecimiento estable y que el PBI se modificará de la siguiente manera:

OBS	PBI
2002	122,036
2003	122,657
2004	122,975
2005	123,278

- a. Expandiendo el rango y el tamaño de la muestra (hasta 2005) y luego ingresando los datos del PBI y de la variable Dummy, obtenemos la siguiente predicción:



- b. El programa arrojará los resultados de la variable predicha, pero esta será de la variable transformada (CPF):

AÑO	CP1F
2002	46451.79
2003	46697.25
2004	46712.86
2005	46815.99

Para hallar la predicción del consumo privado simplemente se debe despejar el consumo privado de la ecuación siguiente:

$$CP1F = CP - 0.475037 * CP(-1)$$

$$CP = CP1F + 0.475037 * CP(-1)$$

Operando, se obtiene las siguientes predicciones para el consumo privado:

AÑO	CP
2002	87975.25
2003	88488.75
2004	88748.29
2005	88974.71

LABORATORIO 10**MODELO LOGIT Y PROBIT**

Se tiene la información de un conjunto de empresas que producen un determinado artículo, los cuales toman la decisión de invertir o no en un mayor número de maquinarias dependiendo de sus ventas (demanda).

obs	INVIERTE	DEMANDA	obs	INVIERTE	DEMANDA
1	0.000000	810.0000	21	1.000000	2200.000
2	1.000000	1400.000	22	1.000000	1623.000
3	1.000000	1080.000	23	0.000000	1240.000
4	0.000000	1120.000	24	0.000000	1110.000
5	0.000000	1240.000	25	1.000000	1615.000
6	1.000000	1900.000	26	0.000000	1120.000
7	1.000000	2000.000	27	1.000000	2030.000
8	0.000000	1360.000	28	1.000000	1810.000
9	0.000000	930.0000	29	0.000000	1125.000
10	0.000000	1035.000	30	0.000000	1000.000
11	1.000000	1710.000	31	1.000000	1730.000
12	1.000000	1820.000	32	0.000000	1360.000
13	0.000000	1400.000	33	1.000000	2120.000
14	1.000000	2000.000	34	1.000000	2035.000
15	0.000000	635.0000	35	0.000000	1150.000
16	1.000000	1960.000	36	0.000000	843.0000
17	1.000000	1630.000	37	1.000000	1760.000
18	0.000000	106.0000	38	1.000000	1615.000
19	0.000000	864.0000	39	0.000000	730.0000
20	1.000000	1870.000	40	1.000000	1705.000

Se estimará el siguiente modelo:

$$\text{Invierte} = f(\text{Demanda})$$

MODELO LINEAL DE PROBABILIDAD:

Definamos la variable dicotómica, en un análisis de quiebra de empresas,

$$y' = \begin{cases} 1 & \text{si la firma está en bancarrota} \\ 0 & \text{si no lo está} \end{cases}$$

Luego, el modelo se describe como

$$Y_i = \beta_1 + \beta_2 X_i + \mu_i$$

Donde

$$E(Y_i \mid X_i) = \beta_1 + \beta_2 X_i = P_i$$

PROCEDIMIENTO:

- ◆ Regresionar el modelo por MCO. En la barra de comandos digitar:
ls invierte c demanda

Dependent Variable: INVIERTE				
Method: Least Squares				
Date: 08/14/02 Time: 00:20				
Sample: 1 40				
Included observations: 40				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.689094	0.146331	-4.709133	0.0000
DEMANDA	0.000855	9.77E-05	8.753474	0.0000
R-squared	0.668479	Mean dependent var	0.525000	
Adjusted R-squared	0.659755	S.D. dependent var	0.505736	
S.E. of regression	0.294999	Akaike info criterion	0.445015	
Sum squared resid	3.306919	Schwarz criterion	0.529459	
Log likelihood	-6.900291	F-statistic	76.62330	
Durbin-Watson stat	1.863350	Prob(F-statistic)	0.000000	

Se observa que los parámetros del modelo son significativos y que la variable exógena explica a la variable dependiente.

Estando en la salidas de la regresión, y mediante la opción **View/Actual Fitted,residual/Actual Fitted,residual table**, podemos ver los valore reales y proyectados de la variable dependiente (Y: INVIERTE):

obs	Y _{observado}	Y _{estimado}	obs	Y _{observado}	Y _{estimado}
1	0.00000	0.00356	21	1.00000	1.19220
2	1.00000	0.50809	22	1.00000	0.69878
3	1.00000	0.23445	23	0.00000	0.37127
4	0.00000	0.26865	24	0.00000	0.26010
5	0.00000	0.37127	25	1.00000	0.69194
6	1.00000	0.93566	26	0.00000	0.26865
7	1.00000	1.02117	27	1.00000	1.04682
8	0.00000	0.47388	28	1.00000	0.85869
9	0.00000	0.10618	29	0.00000	0.27293
10	0.00000	0.19597	30	0.00000	0.16604
11	1.00000	0.77318	31	1.00000	0.79028
12	1.00000	0.86725	32	0.00000	0.47388
13	0.00000	0.50809	33	1.00000	1.12378
14	1.00000	1.02117	34	1.00000	1.05110
15	0.00000	-0.14609	35	0.00000	0.29431
16	1.00000	0.98696	36	0.00000	0.03178
17	1.00000	0.70477	37	1.00000	0.81594
18	0.00000	-0.59845	38	1.00000	0.69194
19	0.00000	0.04974	39	0.00000	-0.06485
20	1.00000	0.91000	40	1.00000	0.76890

Como se observa, éstos son en algunos casos negativos, con lo cual se estaría contradiciendo la teoría, ya que las probabilidades no deben ser negativas, ni mayores a 1.

MODELO LOGIT: Es un modelo de regresión en los cuales la variable dependiente o de respuesta es de naturaleza dicotómica, es decir toma valores de 0 o de 1.

Función de Distribución Logística:

$$P_i = \frac{1}{1 + e^{-Z_i}} \quad \text{donde} \quad Z_i = \beta_0 + \sum_{j=1}^k \beta_j x_{ij}$$

Estimación del modelo Logit:

$$L_i = \ln\left(\frac{P_i}{1-P_i}\right) = Z_i = \beta_0 + \beta_1 X_i + \mu_i$$

PROCEDIMIENTO:

- ◆ En el workfile, hacer clic en la opción OBJECTS/ NEW OBJECT/ EQUATION
- ◆ Digitar el nombre se que se le va asignar al modelo a regresionar.
- ◆ Aparecerá una caja de dialogo en donde se debe digitar la regresión:
invierte c demanda
- ◆ En la misma caja de dialogo, escoger el siguiente método de estimación:
BINARY CHOICE (LOGIT, PROBIT, EXTREME VALUE)
- ◆ Hacer clic en Logit y OK

Dependent Variable: INVIERTE				
Method: ML - Binary Logit				
Date: 08/14/02 Time: 00:21				
Sample: 1 40				
Included observations: 40				
Convergence achieved after 8 iterations				
Covariance matrix computed using second derivatives				
Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	-14.88436	5.094123	-2.921868	0.0035
DEMANDA	0.010660	0.003653	2.918310	0.0035
Mean dependent var	0.525000	S.D. dependent var		0.505736
S.E. of regression	0.221230	Akaike info criterion		0.450602
Sum squared resid	1.859831	Schwarz criterion		0.535046
Log likelihood	-7.012033	Hannan-Quinn criter.		0.481134
Restr. log likelihood	-27.67587	Avg. log likelihood		-0.175301
LR statistic (1 df)	41.32767	McFadden R-squared		0.746637
Probability(LR stat)	1.29E-10			
Obs with Dep=1	19	Total obs		40
Obs with Dep=0	21			

Del output de la regresión podemos observar que los parámetros del modelo son significativos, sus probabilidades asociadas al F estadístico son menores a 0.05 por lo tanto se rechaza la H_0 de no significancia de los parámetros.

Seguidamente, se evaluará la calidad del modelo con otro método distinto al R^2 , ya que el R^2 obtenido en la regresión no es eficiente para calcular la eficiencia del modelo:

PROCEDIMIENTO:

- ◆ Estando en las salidas de la regresión, hacer clic en VIEW/EXPECTATION PREDICTION TABLE.
- ◆ Aparecerá una caja de dialogo en donde se debe digitar un valor límite de probabilidad (en este ejemplo se escogió 0.5)
- ◆ Obtenemos los siguientes resultados:

Dependent Variable: INVIERTE						
Method: ML - Binary Logit						
Date: 08/14/02 Time: 00:21						
Sample: 1 40						
Included observations: 40						
Prediction Evaluation (success cutoff C = 0.5)						
	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)≤C	18	1	19	0	0	0
P(Dep=1)>C	1	20	21	19	21	40
Total	19	21	40	19	21	40
Correct	18	20	38	0	21	21
% Correct	94.74	95.24	95.00	0.00	100.00	52.50
% Incorrect	5.26	4.76	5.00	100.00	0.00	47.50
Total Gain*	94.74	-4.76	42.50			
Percent Gain**	94.74	NA	89.47			
	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	17.05	1.95	19.00	9.03	9.97	19.00
E(# of Dep=1)	1.95	19.05	21.00	9.97	11.03	21.00
Total	19.00	21.00	40.00	19.00	21.00	40.00
Correct	17.05	19.05	36.09	9.03	11.03	20.05
% Correct	89.72	90.70	90.24	47.50	52.50	50.12
% Incorrect	10.28	9.30	9.76	52.50	47.50	49.88
Total Gain*	42.22	38.20	40.11			
Percent Gain**	80.42	80.42	80.42			

Se observa que existen, de un total de 19 casos que no decidieron invertir, 18 casos se encuentran dentro de las bandas de confianza y de un total de 21 casos que no decidieron invertir 20 están dentro de las bandas de confianza, es decir que 38 casos se encuentran dentro

del intervalo establecido, es decir que es el 95%, este valor representa el grado de ajuste del modelo.

MODELO PROBIT: El modelo de estimación que surge de una FDA (función de densidad de probabilidad acumulada) normal, es comúnmente conocido como el modelo probit.

$$P_i = \Pr(Y=1) = \Pr(I_i^* \leq I_i) = F(I_i) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{I_i} e^{-t^2/2} dt$$

$$= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\beta_1 + \beta_2 X_i} e^{-t^2/2} dt$$

PROCEDIMIENTO:

- ◆ En el workfile, hacer clic en la opción OBJECTS/ NEW OBJECT/ EQUATION
- ◆ Digitar el nombre se que se le va asignar al modelo a regresionar (en el ejercicio: mprobitnv)
- ◆ Aparecerá una caja de dialogo en donde se debe digitar el modelo:
invierte c demanda
- ◆ En la misma caja de dialogo, escoger el método de estimación BINARY CHOICE (LOGIT, PROBIT, EXTREME VALUE)
- ◆ Hacer clic en Probit y OK

Dependent Variable: INVIERTE				
Method: ML - Binary Probit				
Date: 08/14/02 Time: 00:23				
Sample: 1 40				
Included observations: 40				
Convergence achieved after 8 iterations				
Covariance matrix computed using second derivatives				
Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	-7.873860	2.270601	-3.467743	0.0005
DEMANDA	0.005694	0.001671	3.407646	0.0007
Mean dependent var	0.525000	S.D. dependent var		0.505736
S.E. of regression	0.227663	Akaike info criterion		0.456164
Sum squared resid	1.969549	Schwarz criterion		0.540608
Log likelihood	-7.123274	Hannan-Quinn criter.		0.486696
Restr. log likelihood	-27.67587	Avg. log likelihood		-0.178082
LR statistic (1 df)	41.10519	McFadden R-squared		0.742618
Probability(LR stat)	1.44E-10			
Obs with Dep=1	19	Total obs		40
Obs with Dep=0	21			

Observamos en las salidas de la regresión que tanto la variable demanda como la constante son significativas en el modelo.

Seguidamente se analizará la calidad del modelo:

PROCEDIMIENTO:

- ◆ Estando en las salidas de la regresión, hacer clic en VIEW/EXPECTATION PREDICTION TABLE.
- ◆ Aparecerá una caja de dialogo en donde se debe digitar un valor límite de probabilidad (en este ejemplo se escogió 0.5)
- ◆ Obtenemos el siguiente cuadro:

Dependent Variable: INVIERTE						
Method: ML - Binary Probit						
Date: 08/14/02 Time: 00:23						
Sample: 1 40						
Included observations: 40						
Prediction Evaluation (success cutoff C = 0.5)						
	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)≤C	18	1	19	0	0	0
P(Dep=1)>C	1	20	21	19	21	40
Total	19	21	40	19	21	40
Correct	18	20	38	0	21	21
% Correct	94.74	95.24	95.00	0.00	100.00	52.50
% Incorrect	5.26	4.76	5.00	100.00	0.00	47.50
Total Gain*	94.74	-4.76	42.50			
Percent Gain**	94.74	NA	89.47			
	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	16.74	1.89	18.64	9.03	9.97	19.00
E(# of Dep=1)	2.26	19.11	21.36	9.97	11.03	21.00
Total	19.00	21.00	40.00	19.00	21.00	40.00
Correct	16.74	19.11	35.85	9.03	11.03	20.05
% Correct	88.13	90.98	89.62	47.50	52.50	50.12
% Incorrect	11.87	9.02	10.38	52.50	47.50	49.88
Total Gain*	40.63	38.48	39.50			
Percent Gain**	77.39	81.01	79.20			

Este modelo al igual que el modelo logit, tiene 38 observaciones que se encuentran dentro del intervalo de confianza, por lo tanto el modelo es explicado en un 95%.

PREDICCIÓN


Se tiene los siguientes observaciones referidas a la demanda que tienen otras empresas, determinar la probabilidad de que inviertan o no en maquinarias.

OBS	DEMANDA
41	1720
42	538
43	987
44	1456
45	1569

PROCEDIMIENTO:

- ◆ Expandir el rango y el tamaño de la muestra
- ◆ Ingresar a las variables independientes e introducir los nuevos valores
- ◆ Ingresar al Output de la regresión Logit (Probit) y hacer clic en FORECAST
- ◆ Se generará automáticamente una nueva variable (INVIERTEF) en el workfile, el cual será los valores estimados y proyectados de la variable dependiente.

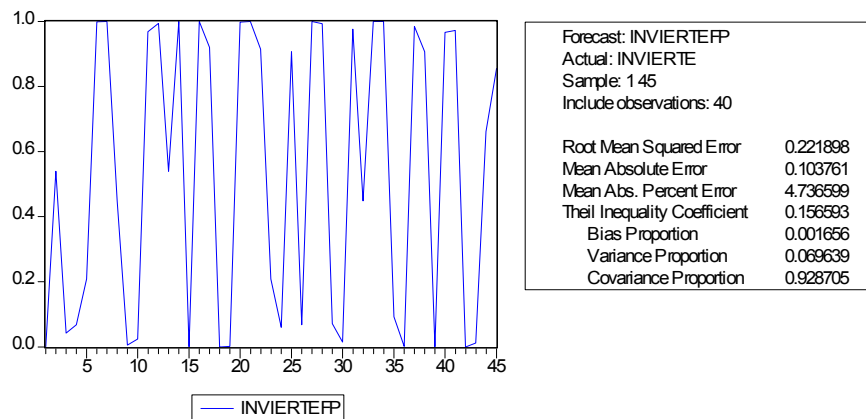
PREDICCIÓN CON EL MODELO LOGIT



La probabilidad de que inviertan o no (evaluado con el modelo LOGIT) será:

OBS	INVIERTEFL
41	0.969245
42	0.000106
43	0.012578
44	0.653911
45	0.863047

PREDICCIÓN CON EL MODELO LOGIT



La probabilidad de que inviertan o no (evaluado con el modelo PROBIT) será:

OBS	INVIERTEFP
41	0.972540
42	7.52E-07
43	0.012096
44	0.661419
45	0.855369

LABORATORIO 11**ECUACIONES SIMULTÁNEAS**

Se tiene el siguiente modelo de ecuaciones simultáneas:

$$CP_t = \beta_1 + \beta_2 * PBI_t + \beta_3 * CP_{t-1}$$

$$I_t = \beta_4 + \beta_5 * (PBI_{t-1} - PBI_{t-2}) + \beta_6 * PBI_t + \beta_7 * R_{t-4}$$

$$R_t = \beta_8 + \beta_9 * PBI_t + \beta_{10} * (PBI_t - PBI_{t-1}) + \beta_{11} * (M_t - M_{t-1}) + \beta_{12} * (R_{t-1} - R_{t-2})$$

$$PBI_t = CP_t + I_t + G_t$$

Donde:

CP: Consumo Privado

I: Inversión





PBI: Producto Bruto Interno



CG: Consumo de Gobierno

M: Liquidez Bancaria

R: Tasa de interés (relativo)

Las gráficas de estas variables son las siguientes:

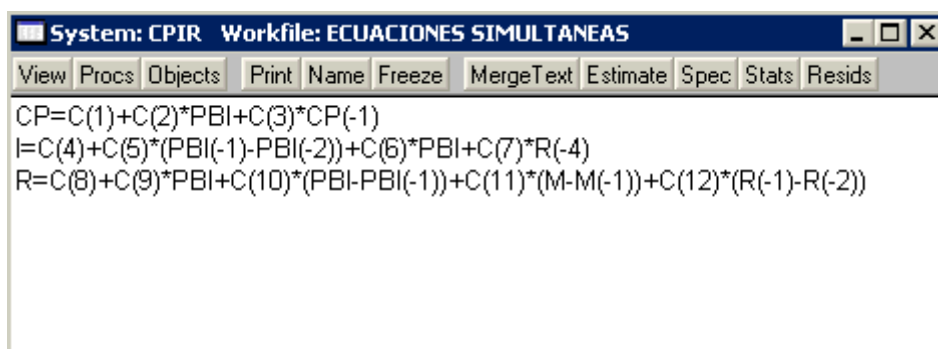




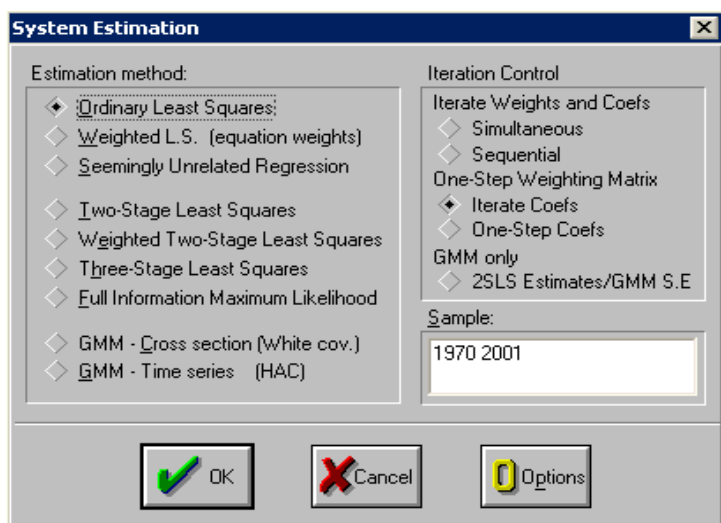
ESTIMACIÓN POR MÍNIMOS CUADRADOS ORDINARIOS:

PROCEDIMIENTO:

- ❖ En el workfile, hacer clic en OBJECTS/ NEW OBJECTS/SYSTEM/.
- ❖ Escribir el nombre del nuevo objeto (MCOCPPIR) y luego OK
- ❖ Aparecerá una caja de dialogo en la cual se debe digitar el sistema de ecuaciones.



- ❖ Para determinar el método de estimación del sistema, hacer clic en ESTIMATE. En la caja de dialogo que aparece escoger el método de estimación, en este caso se escogerá ORDINARY LEAST SQUARES.



- ❖ Por último hacer clic en OK y se observará las siguientes salidas:

System: MCOCPIR				
Estimation Method: Least Squares				
Date: 09/12/02				
Time: 17:06				
Sample: 1970 2001				
	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	4239.779	2184.777	1.940601	0.0561
C(2)	0.486147	0.043880	11.07890	0.0000
C(3)	0.265336	0.067772	3.915124	0.0002
C(4)	-8640.821	3773.845	-2.289660	0.0249
C(5)	0.079118	0.076934	1.028388	0.3071
C(6)	0.289735	0.037670	7.691346	0.0000
C(7)	-1925.118	1840.865	-1.045768	0.2990
C(8)	0.179052	0.262546	0.681985	0.4973
C(9)	6.25E-06	2.69E-06	2.326080	0.0227
C(10)	6.18E-06	7.10E-06	0.871249	0.3864
C(11)	1.77E-05	9.64E-06	1.837704	0.0701
C(12)	0.410317	0.236440	1.735392	0.0868
Determinant residual covariance		2.70E+11		
Equation: CP=C(1)+C(2)*PBI+C(3)*CP(-1)				
Observations: 31				
R-squared	0.971453	Mean dependent var	68170.55	
Adjusted R-squared	0.969414	S.D. dependent var	10681.85	
S.E. of regression	1868.123	Sum squared resid	97716690	
Durbin-Watson stat	0.753402			
Equation: I=C(4)+C(5)*(PBI(-1)-PBI(-2))+C(6)*PBI+C(7)*R(-4)				
Observations: 27				
R-squared	0.790245	Mean dependent var	18466.11	
Adjusted R-squared	0.762886	S.D. dependent var	5182.378	
S.E. of regression	2523.525	Sum squared resid	1.46E+08	
Durbin-Watson stat	0.558215			
Equation: R=C(8)+C(9)*PBI+C(10)*(PBI-PBI(-1))+C(11)*(M-M(-1))+C(12)*(R(-1)-R(-2))				
Observations: 29				
R-squared	0.526987	Mean dependent var	0.795517	
Adjusted R-squared	0.448152	S.D. dependent var	0.279471	
S.E. of regression	0.207609	Sum squared resid	1.034440	
Durbin-Watson stat	0.515675			

MÍNIMOS CUADRADOS ORDINARIOS EN DOS ESTAPAS:

PROCEDIMIENTO:

- ❖ En el workfile, hacer clic en OBJECTS/ NEW OBJECTS/SYSTEM/.
- ❖ Escribir el nombre del nuevo objeto (MCO2ECPIR) y hacer clic en OK
- ❖ Aparecerá una caja de dialogo en la cual se debe digitar el sistema de ecuaciones.
- ❖ También se deben digitar las variables instrumentales seguido de un @, como se muestra en la siguiente imagen:

```

System: MCO2ECPIR Workfile: ECUACIONES SIMULTANEAS
View Procs Objects Print Name Freeze MergeText Estimate Spec Stats Resids
CP=C(1)+C(2)*PBI+C(3)*CP(-1) @ (PBI(-1)-PBI(-2)) (M-M(-1)) (R(-1)-R(-2)) R(-4)
CP(-1) PBI(-1) CG
I=C(4)+C(5)*(PBI(-1)-PBI(-2))+C(6)*PBI+C(7)*R(-4) @ (PBI(-1)-PBI(-2)) (M-M(-1))
(R(-1)-R(-2)) R(-4) CP(-1) PBI(-1) CG

```

Variables instrumentales:

(PBI(-1)-PBI(-2)), (M-M(-1)), (R(-1)-R(-2)), R(-4), CP(-1), PBI(-1), CG

Así no se digite, el programa considera una constante como variable instrumental.

- ❖ Luego hacer clic en ESTIMATE. En la caja de dialogo que aparece escoger el método de estimación: WEIGHTED TWO-STAGE LEAST SQUARES. Luego hacer clic en OK y se obtendrá las siguientes salidas:

System: MCO2ECPIR				
Estimation Method: Weighted Two-Stage Least Squares				
Date: 09/12/02				
Time: 17:09				
Sample: 1970 2001				
	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	4316.567	2859.706	1.509444	0.1379
C(2)	0.457377	0.054384	8.410124	0.0000
C(3)	0.305027	0.083759	3.641699	0.0007
C(4)	-7099.303	3676.675	-1.930903	0.0595
C(5)	0.094896	0.072248	1.313463	0.1954
C(6)	0.272934	0.037033	7.369972	0.0000
C(7)	-1820.298	1708.108	-1.065681	0.2920
Determinant residual covariance		9.56E+12		
Equation: CP = C(1)+C(2)* PBI + C(3)* CP(-1)				
Observations: 27				
R-squared	0.958570	Mean dependent var	70371.26	
Adjusted R-squared	0.955117	S.D. dependent var	9547.838	
S.E. of regression	2022.765	Sum squared resid	98197877	
Durbin-Watson stat	0.823736			
Equation: I = C(4)+C(5)*(PBI(-1)- PBI(-2))+ C(6)*PBI + C(7)*R(-4)				
Observations: 27				
R-squared	0.788431	Mean dependent var	18466.11	
Adjusted R-squared	0.760835	S.D. dependent var	5182.378	
S.E. of regression	2534.415	Sum squared resid	1.48E+08	
Durbin-Watson stat	0.587321			

En las salidas de la regresión se observa que a excepción del intercepto y el PBI, las variables no son significativos en el modelo a un nivel de confianza del 95%.

En la segunda ecuación se observa que existen problemas de autocorrelación positiva de primer orden, ya que el Durbin Watson es 0.603733.

Si obviamos el término independiente en la segunda ecuación, obtenemos los siguientes

resultados:

System: MCO2E02				
Estimation Method: Two-Stage Least Squares				
Date: 09/12/02				
Time: 17:05				
Sample: 1970 2001				
	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	4316.567	3033.176	1.423118	0.1612
C(2)	0.457377	0.057683	7.929141	0.0000
C(3)	0.305027	0.088840	3.433426	0.0012
C(4)	0.145209	0.078954	1.839166	0.0721
C(5)	0.206852	0.016579	12.47706	0.0000
C(6)	-2586.798	1946.531	-1.328928	0.1902
Determinant residual covariance		1.49E+13		
Equation: CP=C(1)+C(2)*PBI+C(3)*CP(-1)				
Observations: 27				
R-squared	0.958570	Mean dependent var	70371.26	
Adjusted R-squared	0.955117	S.D. dependent var	9547.838	
S.E. of regression	2022.765	Sum squared resid	98197877	
Durbin-Watson stat	0.823736			
Equation: I=C(4)*(PBI(-1)-PBI(-2))+C(5)*PBI+C(6)*R(-4)				
Observations: 27				
R-squared	0.741831	Mean dependent var	18466.11	
Adjusted R-squared	0.720317	S.D. dependent var	5182.378	
S.E. of regression	2740.705	Sum squared resid	1.80E+08	
Durbin-Watson stat	0.643850			

System: MCO2ECPIR				
Estimation Method: Two-Stage Least Squares				
Date: 09/12/02				
Time: 18:17				
Sample: 1970 2001				
	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	4316.567	3033.176	1.423118	0.1592
C(2)	0.457377	0.057683	7.929141	0.0000
C(3)	0.305027	0.088840	3.433426	0.0010
C(4)	-7099.303	3983.577	-1.782143	0.0791
C(5)	0.094896	0.078279	1.212272	0.2295
C(6)	0.272934	0.040124	6.802176	0.0000
C(7)	-1820.298	1850.689	-0.983579	0.3288
C(8)	-0.092910	0.303908	-0.305717	0.7607
C(9)	8.81E-06	3.04E-06	2.899165	0.0050
C(10)	9.29E-06	1.20E-05	0.772139	0.4427
C(11)	1.32E-05	1.18E-05	1.118058	0.2674
C(12)	0.336552	0.276132	1.218807	0.2271
Determinant residual covariance		3.16E+11		
Equation: CP=C(1)+C(2)*PBI+C(3)*CP(-1)				
Observations: 27				
R-squared	0.958570	Mean dependent var	70371.26	
Adjusted R-squared	0.955117	S.D. dependent var	9547.838	
S.E. of regression	2022.765	Sum squared resid	98197877	
Durbin-Watson stat	0.823736			
Equation: I=C(4)+C(5)*(PBI(-1)-PBI(-2))+C(6)*PBI+C(7)*R(-4)				
Observations: 27				
R-squared	0.788431	Mean dependent var	18466.11	
Adjusted R-squared	0.760835	S.D. dependent var	5182.378	
S.E. of regression	2534.415	Sum squared resid	1.48E+08	
Durbin-Watson stat	0.587321			
Equation: R=C(8)+C(9)*PBI+C(10)*(PBI-PBI(-1))+C(11)*(M-M(-1))+C(12)*(R(-1)-R(-2))				
Observations: 27				
R-squared	0.556259	Mean dependent var	0.783704	
Adjusted R-squared	0.475579	S.D. dependent var	0.286291	
S.E. of regression	0.207323	Sum squared resid	0.945624	
Durbin-Watson stat	0.589179			

MÍNIMOS CUADRADOS ORDINARIOS EN TRES ESTAPAS:

System: MCO				
Estimation Method: Three-Stage Least Squares				
Date: 09/12/02				
Time: 17:53				
Sample: 1970 2001				
	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	6464.065	2750.706	2.349966	0.0216
C(2)	0.547054	0.043488	12.57932	0.0000
C(3)	0.146952	0.060846	2.415161	0.0184
C(4)	-8224.952	3465.305	-2.373514	0.0204
C(5)	0.060661	0.052202	1.162034	0.2492
C(6)	0.280959	0.034906	8.049048	0.0000
C(7)	-1305.044	1178.261	-1.107602	0.2719
C(8)	-0.108219	0.273759	-0.395307	0.6938
C(9)	8.91E-06	2.74E-06	3.254311	0.0018
C(10)	1.27E-05	1.06E-05	1.199146	0.2346
C(11)	1.01E-05	1.04E-05	0.963979	0.3384
C(12)	0.306565	0.242737	1.262953	0.2109
Determinant residual covariance		9.89E+10		
Equation: CP=C(1)+C(2)*PBI+C(3)*CP(-1)				
Observations: 27				
R-squared	0.955871	Mean dependent var	70371.26	
Adjusted R-squared	0.952194	S.D. dependent var	9547.838	
S.E. of regression	2087.594	Sum squared resid	1.05E+08	
Durbin-Watson stat	0.504423			
Equation: I=C(4)+C(5)*(PBI(-1)-PBI(-2))+C(6)*PBI+C(7)*R(-4)				
Observations: 27				
R-squared	0.786979	Mean dependent var	18466.11	
Adjusted R-squared	0.759193	S.D. dependent var	5182.378	
S.E. of regression	2543.100	Sum squared resid	1.49E+08	
Durbin-Watson stat	0.510388			
Equation: R=C(8)+C(9)*PBI+C(10)*(PBI-PBI(-1))+C(11)*(M-M(-1))				
+C(12)*(R(-1)-R(-2))				
Observations: 27				
R-squared	0.533254	Mean dependent var	0.783704	
Adjusted R-squared	0.448392	S.D. dependent var	0.286291	
S.E. of regression	0.212629	Sum squared resid	0.994649	
Durbin-Watson stat	0.652339			