

UNIDAD V

Levantamiento de Supuestos

¿Qué es levantamiento de supuestos?



“La Estadística demuestra que lo “bien hecho” siempre es mejor que “lo bien dicho”


I Ching

- **¿Qué es Multicolinealidad? ¿Cómo se presenta? ¿Cuáles son sus consecuencias y métodos para detectarlo? ¿Cuáles son los métodos para corregirla?**
- **¿Qué es la autocorrelación? ¿Cuáles son las causas de su procedencia y sus consecuencias? ¿Cuáles son los métodos para detectarlo?**
- **¿Qué es heteroscedasticidad, sus consecuencias y su detección?**

LECCIÓN 1

INFERENCIA EN EL MODELO LINEAL

ESQUEMA CONCEPTUAL



COMPETENCIAS A LOGRAR

CONCEPTUAL	PROCEDIMENTAL	ACTITUDINAL
Explica los conceptos de multicolinealidad, autocorrelación y heterocedasticidad, como se detecta y los métodos para corregirlos	Identifica y aplica los métodos para corregir la multicolinealidad, la autocorrelación y la heterocedasticidad en los modelos.	Asume como importante el uso de estos métodos para resolver problemas en los estudios de los modelos.

CONCEPTOS –CLAVE

Multicolinealidad, Autocorrelación y Heterocedasticidad

LECCIÓN 1

MULTICOLINEALIDAD

La multicolinealidad es un problema que aparece cuando las variables explicativas de un modelo están correlacionadas entre sí. En la práctica sucede cuando uno introduce variables que siendo importantes para explicar el modelo se encuentran relacionadas entre sí, por lo que no será necesario incluir a todas ellas para explicar el comportamiento de la variable dependiente, bastará con incluir a unas cuantas explicativas las cuales representarán el comportamiento de las otras. Por ejemplo el modelo del consumo en función de ingreso y la riqueza, estas variables igualmente están relacionadas pero es importante en algunos casos incluir las dos.

1. PROBLEMAS DE LA MULTICOLINEALIDAD

- Los parámetros se encuentran distorsionados debido a que los valores de los mismos se han mezclado, luego no se pueden utilizar para medir el verdadero impacto de las variables explicativas en el modelo.
- Los estadísticos “t” no son significativos porque las desviaciones estándar son innecesariamente más grandes que aquellas que se obtendrían con una previa corrección de la multicolinealidad.

2. COMO SE PRESENTA LA MULTICOLINEALIDAD

Supongamos en el siguiente modelo:

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3$$

El cual no presenta el problema de multicolinealidad; si se incorpora la variable X_4 , donde $\text{Cov}(X_4, X_2) \neq 0$.

$$\text{O si no: } X_4 = f(X_2, X_3), X_2 = f(X_4, X_3), X_3 = f(X_4, X_2)$$

Por lo tanto, con la inclusión de X_4 al modelo estaremos ante la presencia de **multicolinealidad**.

Lo anteriormente mencionado puede servir para entender el significado de lo que es la multicolinealidad, sin embargo no es tan fácil detectarla. Una manera de hacerlo sería a partir de los estadísticos “t” los cuales ante la presencia de multicolinealidad tienden a no ser significativos.

3. CLASES DE MULTICOLINEALIDAD

- Multicolinealidad Perfecta $Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \mu_i$ $X_3 = kX_2$
- Multicolinealidad Imperfecta $Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \mu_i$ $X_3 = kX_2 + \mu_i$

4. CONSECUENCIAS DE LA MULTICOLINEALIDAD

a. Multicolinealidad Perfecta

Se presenta cuando un modelo presenta la forma:

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \mu_i \quad X_3 = kX_2$$

$$\hat{\beta} = (X'X)^{-1} X'Y \quad (X'X) = \begin{bmatrix} n & \sum X_{i2} & \sum X_{i3} \\ \sum X_{i2} & \sum X_{i2}^2 & \sum X_{i2}X_{i3} \\ \sum X_{i3} & \sum X_{i2}X_{i3} & \sum X_{i3}^2 \end{bmatrix}$$

Reemplazando: $X_3 = k X_2$ tendremos:

$$(X'X) = \begin{bmatrix} n & \sum X_{i2} & k \sum X_{i2} \\ \sum X_{i2} & \sum X_{i2}^2 & k \sum X_{i2}^2 \\ \sum X_{i3} & \sum X_{i2}X_{i3} & k^2 \sum X_{i2}^2 \end{bmatrix}$$

De donde se obtendrá que $\det(X'X) = 0$, por lo tanto no podrá estimarse $\hat{\beta}$ ya que $(X'X)$ no tiene inversa.

b. Multicolinealidad Imperfecta

En este caso el $\det(X'X)$ es muy próximo a cero (nunca es cero), por lo que los parámetros se pueden estimar. Sin embargo los valores de la matriz se vuelven muy pequeños, lo que hace que las desviaciones estándar de los estimadores se vuelvan pequeñas. Entonces, la situación a darse será:

R^2 alto (en E-Views se observa un R-squared considerablemente alto).

Al analizar la significancia de las variables en forma conjunta en el modelo se tendrá que $F_c > F_t$ (en E-Views se representa este hecho por el valor de “Prob (F-statistic)” menor que el nivel de significancia considerado).

Al analizar la significancia de cada una de las variables usadas en el modelo se tendrá que $t_c < t_{n-k,\alpha/2}$ (tabla), donde: $t_c = \frac{\hat{\beta}_i}{\hat{\sigma}_{\beta_i}}$ (en E-Views el valor de las columnas “Prob” en todas las variables son mayores que el nivel de significancia considerado).

5. MÉTODOS PARA DETECTAR LA MULTICOLINEALIDAD

a. Regla práctica

Comparando con un mismo nivel de significancia se observa:

- R^2 alto
- F_c es $>$ del F_t ,
- Las pruebas “t” de significancia individual no son significativos
- Los parámetros van cambiando de signo al incorporar nuevas variables

b. Evaluación con el coeficiente de determinación R^2

Sea el modelo: $Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_i X_i + \dots + \beta_k X_k + \mu$

Si el $R^2_{\text{con } X_i} \cong R^2_{\text{sin } X_i}$ entonces se pueden dar dos posibilidades:

- X_i no explica a Y .
- El efecto de X_i ya está incorporado en las otras variables.

En el primer caso habría que hacer alguna regresión $Y = f(X_i)$ y observar el R^2 :

Si el R^2 es bajo entonces, efectivamente el X_i no explica Y , es decir $Y \neq f(X_i)$.

Si el R^2 es alto entonces, el efecto de X_i ha sido incorporado en el modelo.

c. Cálculo de la matriz de correlación

A partir del cálculo de la matriz de correlaciones de las variables independientes se podrá tener una idea inicial acerca del grado de asociación lineal entre cada par de regresores, en el caso de que alguno de sus valores sea cercano a ± 1 será un indicativo de la presencia de una multicolinealidad imperfecta.

d. Significación individual y conjunta de los regresores

Por lo general cuando se presenta un problema de multicolinealidad aproximada los regresores de manera individual no son significativos, pero al considerarlos de manera conjunta son significativos, esto se debe a que la multicolinealidad aproximada influye en la significación individual de los regresores pero no en su significación conjunta.

6. METODOS PARA CORREGIR LA MULTICOLINEALIDAD

a. Devolver X_i al término de perturbación.

Omitir del modelo una de las variables colineales; si es que el modelo tiene muchas variables explicativas. Pero al omitir una variable se podría incurrir en un sesgo de especificación o error de especificación (especificación incorrecta del modelo).

b. Datos nuevos o ampliando el tamaño de la muestra.

A veces aumentando el tamaño de la muestra, se puede atenuar el problema de la colinealidad (relación entre variables).

c. Utilizando información a priori.

Supóngase que se considera el modelo: $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \mu_i$

Donde:

Y : Consumo; X_2 : Ingreso; X_3 : Riqueza

Como se sabe las variables: ingreso y riqueza; tienden a ser altamente colineales. Pero supóngase que a priori, se cree que $\beta_3 = 0.10\beta_2$. Se puede efectuar entonces la siguiente regresión:

$$Y_i = \beta_1 + \beta_2 X_{2i} + 0.10\beta_2 X_{3i} + \mu_i$$

$$Y_i = \beta_1 + \beta_2 X_i + \mu_i$$

Donde: $X_i = X_{2i} + 0.10X_{3i}$. Una vez que se ha obtenido $\hat{\beta}_2$, se puede estimar $\hat{\beta}_3$ a partir de la relación postulada entre β_2 y β_3 .

Se tiene el siguiente modelo: $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \mu_i$, el cual presenta el problema de multicolinealidad. Para corregir se desea mantener 2 variables explicativas, se intuye la correlación lineal $\beta_2 = 3\beta_3$, por lo tanto $\beta_3 = 0.33\beta_2$.

Realizando las operaciones necesarias, la ecuación de regresión será:

$$Y_i = \beta_1 + \beta_2 X_{2i} + 0.33\beta_2 X_{3i} + \mu_i$$

$$Y_i = \beta_1 + \beta_2 X_i$$

Donde $X_i = X_{2i} + 0.33X_{3i}$

d. Transformación de Variables.

Supóngase que se tiene información de series de tiempo sobre el gasto de consumo, el ingreso y la riqueza. Una razón para la alta multicolinealidad entre el ingreso y la riqueza es que en el tiempo las dos variables tienden a moverse en la misma dirección. Una forma de minimizarla, es proceder de la siguiente manera.

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \mu_t \quad \dots (1)$$

Si la relación anterior se cumple en el periodo "t", también debe cumplirse en el periodo "t-1" puesto que el origen del tiempo es arbitrario. Por consiguiente se tiene:

$$Y_{t-1} = \beta_1 + \beta_2 X_{2,t-1} + \beta_3 X_{3,t-1} + \mu_{t-1} \quad \dots (2)$$

Si se resta (1) – (2), se obtiene:

$$Y_t - Y_{t-1} = \beta_2 (X_{2t} - X_{2,t-1}) + \beta_3 (X_{3t} - X_{3,t-1}) + \varepsilon_t \quad \dots (3)$$

Donde: $\varepsilon_t = \mu_t - \mu_{t-1}$

A esta última ecuación se le conoce como la forma en primeras diferencias porque no se está corrigiendo la regresión sobre las variables originales, sino sobre las diferencias de los valores sucesivos de dichas variables.

Con este procedimiento se reduce la severidad de la multicolinealidad. Sin embargo, la transformación crea algunos problemas adicionales. El término de error ε_t puede no satisfacer uno de los supuestos del modelo clásico de regresión lineal, pues las perturbaciones están serialmente correlacionadas.

Tres transformaciones alternativas son:

Realizar las regresiones entre las variaciones en términos relativos.

Las variaciones porcentuales nos muestran la dinámica en el corto plazo, y no necesariamente podrían tener un patrón de multicolinealidad

Transformar a logaritmo natural cada una de las variables.

El comportamiento se transforma a una forma de tipo geométrica o exponencial a partir del cual manteniendo las relaciones entre las variables, no necesariamente pueden tener multicolinealidad las variables explicativas.

Combinando las variables que ocasionan la multicolinealidad, a través de la elaboración de indicadores.

Por ejemplo una relación ingreso riqueza, es decir que porcentaje de la riqueza representa el ingreso, es igualmente una alternativa.

Ejercicio Ilustrativo 1:

En el modelo planteado anteriormente para la inflación¹: $LIPC = \beta_1 + \beta_2 CIRPROM + \beta_3 LTC$, para detectar el denominado “caso clásico” de multicolinealidad, debemos observar simultáneamente lo siguiente:

- “t” estadísticos no significativos.
- R^2 alto.
- Signos de los parámetros contrarios a los esperados.

Un indicador adicional de la posible existencia de multicolinealidad es la existencia de un coeficiente de correlación muy alto entre las variables exógenas.

Los resultados de nuestra estimación nos dicen que:

- Todas las pruebas “t” de significancia individual son “significativas”.
- El R^2 es alto. ($R^2 = 0.9937$)
- Los signos de los parámetros son los esperados.

Dado que no se satisfacen los tres requisitos simultáneamente, concluimos que no se presenta, en este modelo, el caso clásico de multicolinealidad.

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.

¹ Ver Ejercicio Aplicativo 1 de la Unidad III

	LCIRPROM	LTC
LCIRPROM	0.000181	-0.000330
LTC	-0.000330	0.000708

De la matriz de correlaciones del modelo de inflación confirmamos la no presencia de multicolinealidad.

Ejercicio Ilustrativo 2²:

Aplicación del Análisis multivariado en el análisis de regresión: la Elaboración de Indicadores Sintéticos a fin de corregir el problema de multicolinealidad.

Supongamos que se quisiera relacionar los problemas de la salud en función a las condiciones del medio ambiente. ¿Como relacionar temas multidimensionales tanto para las variables explicativas como las variables dependientes?

Un trabajo realizado con información al año 2001 a nivel departamental para Perú permitió analizar las relaciones existentes entre variables asociadas al medio ambiente con aquellas referidas a la salud de la población.

Habiéndose en primer lugar, evaluado las **variables de salud** se consideró finalmente la incorporación de las siguientes 5 variables:

- Prevalencia de la diarrea en niños menores de 5 años.
- Tos y respiración rápida en las 2 últimas semanas (%).
- Tasa de Mortalidad Infantil por cada mil niños menores de 1 año.
- IRA (por cada mil niños menores de 5 años).
- Malaria

Se decidió elegir estas variables porque la **matriz de correlaciones entre sus indicadores simples fue significativa**. En efecto, de las correlaciones entre las variables se pueden deducir importantes conclusiones respecto a los indicadores. Se puede apreciar que la “Prevalencia de la diarrea en niños menores de 5 años” presenta correlación positiva con la “Tasa de Mortalidad Infantil por cada mil niños menores de 1 año” (0.548), es decir, que en las ciudades donde aumenta el la prevalencia de diarrea en menores de 5 años, esto es por cada mil niños, también aumentaría la tasa de mortalidad infantil.

Es de mencionar que el indicar sintético de salud se elaboró de tal forma que cuanto menor sea éste, mejor era la situación, en el campo de la salud, de un determinado departamento.

Habiéndose evaluado las **variables de medio ambiente** se consideró finalmente la incorporación de las siguientes variables:


² Análisis de la Relación entre Indicadores de Salud y Medio Ambiente

- Vivienda con hacinamiento.
- Parque automotor por cada 10 000 habitantes.
- Densidad Poblacional (personas por km²).
- Población Rural %.
- Uso de Kerosene
- Uso de Leña y Carbón
- Vivienda sin servicio higiénico
- Vivienda sin servicio de agua por red publica

La decisión de elegir estas variables, se tomó porque la matriz de correlaciones entre sus indicadores simples fue significativa. En efecto, de las correlaciones entre las variables se pueden deducir importantes conclusiones respecto a los indicadores. Se puede apreciar que el “Uso de leña y carbón” presenta correlación positiva con “Viviendas con hacinamiento” (0.614), es decir, que en las ciudades donde existe mayor presencia de viviendas con hacinamiento, el uso de la leña y carbón aumenta. Otra correlación importante se aprecia entre el “Uso de kerosene” y la “Población rural (%)” (-0.65), es decir que en ciudades donde la población rural aumenta, el uso de kerosene disminuiría. Por otro lado tenemos la correlación entre el ”Uso de la leña y carbón” y ”La población rural (%)” (0.88), es decir que a mayores ciudades con población rural (%), el consumo de leña y carbón aumenta.

Con los indicadores sintéticos de ambos ítems se realizaron un estudio de sus correlaciones, y se pudo apreciar que ambos indicadores tenían una correlación directa.

En el gráfico se aprecia una asociación lineal directa entre el indicador sintético de la salud y el indicador sintético del medio ambiente, cuyo coeficiente de correlación es igual a 0.66, es decir cuando el indicador del medio ambiente tienda a subir entonces el indicador de la salud tendrá una tendencia ascendente.



La visualización gráfica de los datos departamentales nos muestra una relación positiva entre los indicadores sintéticos de la salud y el medio ambiente. Es decir, cuanto mayor es el Indicador de medio ambiente, mayor será el indicador de la salud.

A continuación se corre el modelo entre 2 variables que sintetiza el tema de la salud y el medio ambiente:

Departamentos	Indicador Sintético de la Salud	Indicador Sintético del Medio Ambiente	Departamentos	Indicador Sintético de la Salud	Indicador Sintético del Medio Ambiente
Lima 1/	17.3	1.6	S. Martin.	51.7	71.3
Tacna.	7.1	21.5	Puno	47.6	73.1
Arequipa.	23.0	21.6	Loreto.	98.1	74.6
Moquegua.	0.5	35.2	Ucayali.	59.1	75.7
Ica	17.9	36.6	Cusco.	53.0	78.3
Lambayeque.	47.8	47.2	Apurimac.	42.9	79.3
La Libertad.	25.5	50.3	Pasco.	52.2	79.4
Tumbes.	31.8	53.7	Amazonas.	41.0	83.6
Junin.	47.6	58.9	Ayacucho.	47.2	83.7
Ancash.	39.6	59.6	Cajamarca.	51.3	85.1
Piura.	51.2	63.1	Huanuco.	50.0	88.4
M. Dios	20.6	69.2	Huancavelica.	42.7	98.6

El modelo de regresión hallado, utilizando estos indicadores es:

$$\hat{Y}_i = 6.571 + 0.543 * X_i \quad \text{Donde:}$$

Y: Indicador Sintético de la Salud

X: Indicador Sintético del Medio Ambiente

Analizando la significancia del modelo, se obtuvo que la probabilidad asociada a la constante es mayor al nivel de significancia de 5% (0.466). Por lo tanto no es significativo para el modelo. En cambio, el indicador sintético de la salud es significativo para el modelo, ya que su probabilidad asociada (0.000) es inferior al 5%.

Además, se tiene que el R^2 del modelo es bajo (0.405) y a la vez el F-estadístico (0.000) indica la significancia conjunta del modelo.

Evaluando nuevamente el modelo, pero sin el intercepto, se obtiene el siguiente modelo:

$$\hat{Y}_i = 0.635 * X_i$$

Las salidas de este nuevo modelo muestran que el modelo es significativo, ya que la prueba F (0.000) es menor al nivel de significancia de 5%, aunado a una prueba t que indica la significancia de la variable, así como un R^2 alto (0.887).

En conclusión, el estado de salud de las personas está influenciado fuertemente por un conjunto de factores relacionados con el medio ambiente.

Ejercicio Ilustrativo 3:

Según el siguiente modelo tenemos a las cantidades demandadas de productos lácteos en el Perú en función de los precios e ingreso:

$$\text{Imp} = \beta_1 * \beta_2 \text{PP} * \beta_3 \text{IP} * \beta_4 \text{ICV} * \beta_5 \text{YNN}$$

Siendo:

Imp : Cantidades importadas por Perú, en miles de toneladas

PP : Precios promedios al detalle en Perú de productos lácteos importados de Argentina.

NIP : Números índices de los precios promedios al detalle en Perú de productos lácteos no importados de Argentina

ICV : Índice del costo de vida

YNN: Ingreso nacional neto a costo de factores

La transformación conveniente para establecer la ecuación logarítmica, es:

$$\text{Log Imp} = \beta_1 + \beta_2 \text{Lg PP} + \beta_3 \text{Lg NIP} + \beta_4 \text{Lg ICV} + \beta_5 \text{Lg YNN}$$

Los datos transformados son los siguientes:

AÑO	LImp	LPP	LNIP	LICV	LYNN
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

1. Regresión del modelo y evaluación de los parámetros.

Dependent Variable: LIMP				
Method: Least Squares				
Date: 11/03/04 Time: 09:34				
Sample: 1984 2000				
Included observations: 17				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
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
C	2.187357	1.556175	1.405598	0.1852
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	

Se observa del resultado anterior que algunos parámetros no son significativos con un 95% de confianza como es el caso de LPP y LNIP.

El estadístico F es bastante alto con lo cual la variabilidad de la variable endógena queda bien explicada por el modelo, esto es corroborado por el R^2 de la regresión el cual ha alcanzando un 97%, por lo cual el modelo considerado es aceptable.

2. Evaluación de los Signos de los Parámetros

$\hat{\beta}_1 = 2.187357$, indica el nivel promedio de las cantidades importadas por Perú de productos lácteos de Argentina (consumo mínimo o autónomo), cuando el resto de parámetros son cero.

$\hat{\beta}_2 = -0.701950$, este resultado nos muestra la elasticidad de la cantidad demandada respecto al precio, pues si el precio promedio varía en 1 %, la cantidad importada varía en 70.1950%

$\hat{\beta}_3 = 0.029628$, este resultado nos muestra la elasticidad de la cantidad de demandada respecto al índice de precio promedio; Pues si éste varía en 1%, la cantidad importada varía en 2.9628%.

$\hat{\beta}_4 = -1.098483$, este resultado nos muestra la elasticidad de la cantidad demandada respecto al índice de costo de vida; Pues si éste varía en 1%, la cantidad importada disminuirá en 9.8483%

$\hat{\beta}_5 = 1.172611$, este resultado nos muestra la elasticidad de la cantidad demandada respecto al Ingreso Nacional Neto. Si este varía en 1%, la cantidad importada aumentará en 17.2611%.

3. Evaluación de Multicolinealidad en el Modelo

Si existe multicolinealidad porque:

- Tres de los coeficientes no son significativos a un nivel de significancia de 5%.
- El R^2 es casi igual a 1 lo cual nos indica un alineamiento casi perfecto de los datos.
- Existen parámetros con signo cambiado al que se esperaba, como por ejemplo el parámetro LNIP debería resultar con signo negativo y sin embargo tiene signo positivo.

Otra forma es por el método de la matriz de correlaciones de las variables:

	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

Se puede observar que existe una alta correlación entre las variables LICV-LNIP, LICV-LPP además de LNIP-LPP. De donde se observa que LNIP-LPP presenta casi un 99% de asociación lineal.

Al regresionar el modelo resulta un R^2 de 97.7%, el cual es bastante alto lo que indica un considerable grado de correlación existente entre estas variables.

4. Efectos de la multicolinealidad

Los parámetros se encuentran distorsionados (estadísticamente no significativos) dado que existe una combinación lineal entre las variables explicativas.

La colinealidad está referida a la existencia de una sola relación lineal entre las variables explicativas y, por lo tanto, la multicolinealidad se refiere a la existencia de más de una relación lineal. Es importante anotar que la multicolinealidad se refiere sólo a relaciones lineales entre las variables independientes y no a cualquier otro tipo de relación.

5. Predicción en Presencia de Multicolinealidad

El problema de multicolinealidad no es teórico sino de grado, en todo modelo econométrico tenderá a presentarse este problema, en algunos casos la severidad del problema será mayor. Esto quiere decir que existe interdependencia entre las variables económicas por lo cual no se puede eliminar.

El grado, se refiere a la severidad de la correlación entre las variables explicativas, la correlación entre una o más variables independientes puede ser perfecta. Se puede afirmar que para el caso de series de tiempo económicas, siempre se tendrá un grado relativamente alto de multicolinealidad.

6. Modelo Recomendado en Presencia de multicolinealidad

Las variables LNIP y LPP están altamente correlacionadas por lo tanto se irá eliminando del modelo hasta obtener valores de R^2 más bajos y que los coeficientes sean más significativos.

De preferencia se recomienda trabajar con el modelo más sencillo posible pero que sea altamente explicativo, con el fin de evitar el problema de multicolinealidad.

Eliminamos del modelo la variable LPP y regresionamos:

Dependent Variable: LIMP				
Method: Least Squares				
Date: 11/03/04 Time: 09:40				
Sample: 1984 2000				
Included observations: 17				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
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
C	4.810229	0.792733	6.067903	0.0000
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	

Como podemos ver todos los t-statistics son significativos al 95% de confianza; por lo tanto, tiene un mejor ajuste y la variable LNIP ahora está con signo negativo que es como se esperaba, además tenemos un R^2 de 97% de éxito del modelo estimado y el F-statistics es bastante alto por lo tanto se tendrá que las variables independientes explican al modelo en su conjunto.

Conclusión: el modelo con que se recomienda trabajar es:

$$\text{LIMP} = 4.810 - 0.823 \text{LNIP} - 1.1614 \text{LICV} + 0.9742 \text{LYNN}$$

LECCIÓN 2

MÍNIMOS CUADRADOS GENERALIZADOS

Cuando se estima un modelo con el método de mínimos cuadrados ordinarios uno de los supuestos se refiere a la matriz de varianzas y covarianzas del término de perturbación, que es una matriz cuya diagonal principal es un escalar. Ello expresa en resumen la presencia de 2 supuestos: El supuesto de **homocedasticidad**, donde la varianza del término de perturbación permanece constante. El segundo supuesto se refiere a la ausencia de **autocorrelación** entre dichas variables. Al cumplimiento simultáneo de estos supuestos también se le reconoce como aceptar que las perturbaciones “u” son esféricas³.

No obstante, en la práctica puede darse situaciones diferentes.

Una de estas situaciones se produce cuando la varianza del término de perturbaciones es diferente de unas observaciones a otras. A esta situación se le conoce con el nombre de **Heteroscedasticidad**.

$$\text{Var}(\mu_i) = \sigma_i^2$$

Una segunda situación ocurre cuando los términos de error correspondientes a diferentes observaciones no son independientes entre sí, es decir,

$$\text{Cov}(\mu_i, \mu_j) \neq 0, \text{ para } i \neq j$$

Ello hace que los elementos fuera de la diagonal principal en la matriz no serán iguales a cero. A esta situación se le denomina **Autocorrelación**

Supongamos lo siguiente:

$$Y = X\beta + \hat{u} \quad E(\hat{u}) = 0 \quad V(\hat{u}) = \sigma^2 \Omega$$

Ω es una matriz simétrica, positiva definida y conocida.

Donde:

$$\Omega = \begin{bmatrix} a_1 & \dots & 0 \\ 0 & \dots & a_n \end{bmatrix}$$

A continuación se debe encontrar una matriz $P_{n,n}$, tal que:

$$\Omega = PP' \Rightarrow P^{-1}\Omega = P' \Rightarrow P^{-1}\Omega(P^{-1})' = I$$

Luego:

$$Y^* = P^{-1}Y = P^{-1}X\beta + P^{-1}\mu \quad X^* = P^{-1}X \quad \mu^* = P^{-1}\mu$$

³ Esta denominación se debe a que se considera como parte del supuesto a la variable aleatoria de cada una de las unidades de observación “u_i” como una variable que se distribuye normalmente con media “0” y varianza “1”.

$$\begin{aligned} \text{Se pasa a un nuevo modelo } \Rightarrow Y^* &= X^* \beta + \mu^* & V(\mu^*) &= \sigma^2 I \\ E(\mu^*) &= 0 & \mu^* &\sim N \end{aligned}$$

$$\begin{aligned} E(\mu^*) &= E(P^{-1}\mu) = 0 \\ V(\mu^*) &= (P^{-1})(\sigma^2\Omega)(P^{-1}) = \sigma^2 I \end{aligned}$$

1. ESTIMADOR MÍNIMOS CUADRADOS GENERALIZADOS

Los estimadores lineales e insesgados de mínima varianza (dentro de una clase) de los parámetros β dado por:

$$\begin{aligned} \hat{\beta} &= (X^{*'}X^*)^{-1}X^{*'}Y^* \\ \hat{\beta} &= (X'(P^{-1})'P^{-1}X)^{-1}X'(P^{-1})'P^{-1}Y \end{aligned}$$

Como $\Omega = PP'$, entonces: $\Omega^{-1} = (P^{-1})'P^{-1}$

$$\hat{\beta}_{\text{MCG}} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y \quad \text{Estimadores Mínimos Cuadrados Generalizados}$$

2. VARIANZAS Y COVARIANZAS

No obstante si se estimara el modelo con presencia de algunos de los problemas antes mencionados con la fórmula a partir de los MCO. Es decir con: $\hat{\beta} = (X'X)^{-1}X'Y$

La fórmula correcta para estimar la varianza sería la siguiente:

$$\text{Var}(\hat{\beta}) = \sigma^2 (X'(P^{-1})'P^{-1}X)^{-1} = \sigma^2 (X'\Omega^{-1}X)^{-1}$$

Si se estima con la fórmula habitual correspondiente a los MCO se produciría un sesgo que induciría a un error de interpretación.

Luego planteado los problemas de heterocedasticidad o autocorrelación las fórmulas adecuadas corresponden a las variables transformadas.

$$\hat{\beta} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y \quad \text{Estimadores Mínimos Cuadrados Generalizados}$$

$$\text{Var}(\hat{\beta}_{\text{MCG}}) = \sigma^2 (X'\Omega^{-1}X)^{-1}$$

LECCIÓN 3

AUTOCORRELACIÓN

La autocorrelación es la relación que se da entre las variables perturbadoras (μ), contraviniendo uno de los supuestos para estimar el modelo a partir de la independencia que debería existir entre estas variables. Este problema se presenta fundamentalmente cuando se realizan estudios econométricos de series históricas. En este caso, en cada periodo, las variables independientes deberían ser las únicas que expliquen el modelo, y no lo que ha sucedido en periodos anteriores. Es decir, ni los fenómenos ocurridos anteriormente, o la tendencia o ciclo de la variable debería afectar, en dicho periodo, el comportamiento de la variable dependiente.

La matriz de varianzas covarianzas de las perturbaciones, en presencia de autocorrelación, tiene la forma siguiente:

$$E(\mu\mu') = \sigma_{\mu}^2 \begin{pmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & \cdot & \cdot & \cdot & \cdot \\ \rho^2 & \cdot & \cdot & \cdot & \cdot \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho^{n-1} & \cdot & \cdot & \cdot & 1 \end{pmatrix}$$

La cual como se observa posee “n” columnas y una diagonal principal, la misma que contiene la varianzas de cada perturbación, mientras que los valores que están afuera de la diagonal constituyen las covarianzas asociadas a su correspondiente perturbación. El término σ_{μ}^2 representa la varianzas de cada residual, la cual como lo planteado inicialmente para un modelo lineal general es constante.

En el contexto de la regresión, el modelo clásico de regresión supone que no existe tal autocorrelación en las perturbaciones, lo cual se representa simbólicamente como:

$$E(\mu_i\mu_j) = 0$$

Significando que el término de perturbación no se encuentra influenciado por otra de éstas; en el caso de que tal dependencia exista se está ante una autocorrelación la cual se representa simbólicamente por:

$$E(\mu_i\mu_j) \neq 0$$

Entonces, en esta lección se considerará que la matriz de varianzas covarianzas del término de perturbación no es escalar; buscándose analizar la naturaleza y las complicaciones asociadas a esta presencia. Asimismo, se mostrará las estrategias necesarias para poder enfrentar este problema.

Antes de analizar las causas frecuentes de la presencia de este tipo de problema, se mostrará algunos patrones de la autocorrelación y no autocorrelación. La figura siguiente (A-1) nos permite determinar la existencia o no de la autocorrelación; en las figuras (a) y (d) se observa la presencia de un patrón distinguible entre las perturbaciones, siendo en la figura (a) un patrón cíclico mientras que en la figura (d) se

puede advertir la presencia de términos de tendencia lineal y cuadrática. En las otras 2 figuras se tiene una presencia lineal hacia el origen (b) y hacia abajo (c) de las perturbaciones.




Figura. A-1

1. CAUSAS DE LA PROCEDENCIA DE AUTOCORRELACION

- a. La inercia de los procesos económicos, es decir, la variable debe crecer en el tiempo.
- b. El sesgo de especificación, se da cuando se excluye a una variable importante o la forma funcional del modelo no es la correcta. En el primer caso:

$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \mu$, es difícil especializar el fenómeno.

- c. Rezagos en los modelos:

$$C_t = \beta_1 + \beta_2 Y_t + \beta_3 C_{t-1} + \mu_t$$

$$C_{t-1} = \beta_1 + \beta_2 Y_{t-1} + \beta_3 C_{t-2} + \mu_{t-1}$$

Cuando se habla de rezagos puede haber autocorrelación.

- d. Existencia de ciclos y tendencias, si la autocorrelación es positiva, un valor alto de μ_t genera un valor de Y_t , por encima de su promedio, y en consecuencia una elevada probabilidad debe ir seguido de un valor alto de μ_{t+1} , y de un valor de Y_{t+1} por encima de su promedio; lo mismo ocurriría para valores de Y_t por debajo de su promedio.

- e. La autocorrelación positiva está asociada a la existencia de rachas de valores altos y bajos de Y_t . (Fig. A -2)
- f. El conjunto de variables explicativas del modelo no explican adecuadamente dicho comportamiento, entonces el término de error incorporará dicha tendencia, y esto conduce a la existencia de autocorrelación positiva. Un conjunto de residuos negativos seguida por otro conjunto de residuos positivos. (Fig. A -3)
- g. Manipulación de datos, en especial cuando se realiza la interpolación (es obtener un valor dentro de la muestra) y extrapolación (es un valor fuera de la muestra) de la información muestral.




Figura. A-2. Autocorrelación producida por un ciclo




Figura. A-3. Autocorrelación producida por una tendencia

2. CONSECUENCIAS DE LA AUTOCORRELACION

Los estimadores de Mínimos Cuadrados Ordinarios (MCO) tendrán las siguientes propiedades:

- a. Son insesgados en muestras repetidas sus valores medios son iguales a los verdaderos valores reales.
- b. Son consistentes a medida que el tamaño de la muestra se aproxime al tamaño de la población.
- c. Como en el caso de heterocedasticidad ya no son eficientes (mínima varianza) ni para muestras pequeñas ni grandes.

Por lo tanto ante la presencia de autocorrelación se debe tener presente que:

- Aunque se tenga en cuenta la correlación serial en los estimadores mínimos cuadrados ordinarios (MCO) y se utilice la fórmula de varianza con autocorrelación los estimadores serán menos eficientes. En consecuencia los intervalos de confianza son más anchos de lo necesario y la prueba de significancia pierden fuerza.

Si se ignora el problema de autocorrelación y se aplica la fórmula clásica de MCO (bajo el supuesto de ausencia de correlación) las consecuencias son

todavía más serias y la varianza residual tiende a subestimar la varianza verdadera.

- Incluso si la varianza residual (σ_μ) estuviera subestimada las varianzas y los errores estándar de los estimadores MCO (σ_β y σ_β^2) tienden a subestimar las verdaderas varianzas de los parámetros estimados.
- En consecuencia las pruebas de significancia pierden validez y si se aplican tienden a dar conclusiones erróneas.

Planteadas las ideas iniciales, un modelo que presente autocorrelación, tendrá la forma siguiente:

$$Y = X\beta + \mu$$

Siendo $E(\mu) = 0$ y $E(\mu\mu') = \sigma_\mu^2 \Omega$

En la práctica, usualmente se supone que las μ_t siguen el esquema autorregresivo de primer orden⁴ :

$$\mu_t = \rho\mu_{t-1} + \varepsilon_t$$

Donde $|\rho| < 1$ y donde las ε_t siguen los supuestos MCO de valor esperado cero, varianza constante y no autocorrelación, es decir:

$$\begin{aligned} E(\varepsilon_t) &= 0 \\ \text{Var}(\varepsilon_t) &= \sigma^2 \\ \text{Cov}(\varepsilon_t, \varepsilon_{t+s}) &= 0, s \neq 0 \end{aligned}$$

Además si se observa de manera individual, se tendrá que los diferentes valores de las perturbaciones μ para cada instante de tiempo originaran una varianza igual a:

$$\text{Var}(\mu_t) = \sigma_\mu^2 = E(\mu_t^2) = \frac{\sigma_\varepsilon^2}{1 - \rho^2}$$

Algo similar ocurre con la covarianza, la cual cambia entre los términos de error que están a “s” periodos distantes:

$$\text{cov}(\mu_t, \mu_{t+s}) = (E(\mu_t \mu_{t+s})) = \rho^s \frac{\sigma_\varepsilon^2}{1 - \rho^2} = \rho^s \sigma_\mu^2$$

3. DETECCIÓN DE AUTOCORRELACION

El supuesto de no autocorrelación del modelo clásico se relaciona con las perturbaciones poblacionales μ_t , las cuales no pueden ser observadas directamente. En su lugar, se dispone de sus valores aproximados, los residuales $\hat{\mu}_t$ que pueden obtenerse a partir del procedimiento usual MCO. Aunque las $\hat{\mu}_t$ no son lo mismo que las μ_t , con

⁴ La autocorrelación será de orden “p” cuando el subíndice de μ sea “t-p”

mucha frecuencia un examen visual de las $\hat{\mu}_t$ nos da algunas claves sobre la posible presencia de autocorrelación en las μ_t .

a. Prueba de Durbin Watson

Se construye la dócima de hipótesis:

$H_0: \rho = 0$ (no existe autocorrelación de orden 1)

$H_1: \rho \neq 0$ (existe autocorrelación de orden 1)

Se utiliza el estadístico de **Durbin Watson**:

$$d = \frac{\sum_{t=2}^n (\hat{\mu}_t - \hat{\mu}_{t-1})^2}{\sum_{t=2}^n \hat{\mu}_t^2}$$

Con lo cual: $d = 2(1 - \hat{\rho}) \Rightarrow \hat{\rho} = \frac{2-d}{2}$

Por lo que:

$\hat{\rho} = -1 \Rightarrow d = 4$ Autocorrelación negativa

$\hat{\rho} = 1 \Rightarrow d = 0$ Autocorrelación positiva

$\hat{\rho} = 0 \Rightarrow d = 2$ No existe autocorrelación.

Ejercicio Ilustrativo 1:

En el modelo de inflación, especificado anteriormente, probamos la existencia de autocorrelación. De las salidas de la regresión tenemos que:

Durbin-Watson stat	0.628449
--------------------	----------

Esto nos indica que **existe autocorrelación positiva de orden 1**. Sin embargo, podría darse el caso que exista autocorrelación de mayor orden, por lo que este test no es el adecuado, pues sólo permite identificar autocorrelación de orden 1.

b. Detección de Autocorrelación cuando el Modelo tiene una Variable Endógena Rezagada (Y_{t-1})

Cuando se tiene un modelo con una variable rezagada entre las explicativas, esta variable rezagada generalmente se refiere a la variable dependiente.

En este otro caso, para detectar autocorrelación, el estadístico propuesto por Durbin Watson, es el estadístico h , y se calcula como:

$$h = \hat{\rho} \sqrt{\frac{n}{1 - n\hat{\sigma}_{\hat{\beta}_1}^2}}$$

Donde:

$\hat{\beta}_1$: Estimador de la variable endógena rezagada (del primer retardo). Es decir es el coeficiente de Y_{t-1} en la regresión mínimo-cuadrática (MCO):

$$Y_t = a_1 X_{1t} + a_2 X_{2t} + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + u_t$$

$\hat{\sigma}_{\hat{\beta}_1}^2$: Es la estimación de la varianza muestral de $\hat{\beta}_1$.

Es utilizable sólo para $n\hat{\sigma}_{\hat{\beta}_1}^2 \leq 1$, siendo $\hat{\rho}$ el coeficiente estimado de autocorrelación de primer orden de los residuos (ρ), calculable a partir del valor de:

$$\hat{\rho} \sim 1 - \frac{1}{2}d$$

$H_0 : \hat{\rho} = 0$

$H_1 : \hat{\rho} < 0 \text{ ó } \hat{\rho} > 0$

$d = \frac{\sum_{t=2}^T (\mu_t - \mu_{t-1})^2}{\sum_{t=1}^T \mu_t^2}$ es el estadístico de contraste.

El contraste de h se realiza a partir de su consideración de variable distribuida normalmente con parámetros (0,1). Así, con un nivel de significación del 5%, si $|h| > 1.645$ debe rechazarse la hipótesis de autocorrelación nula (Fig. A-4).



Figura. A-4

Ejercicio Ilustrativo 2:

En un modelo que contiene una variable explicativa rezagada, se ha detectado que el $d = 1.75$, $n = 50$, $\hat{\sigma}_{\beta_1} = 0.15$. Se pide determinar si el modelo presenta problemas de autocorrelación.

Entonces, se debe hallar el “h”:

$$\hat{\rho} = 1 - \frac{1}{2}d = 1 - \frac{1}{2}(1.75) = 0.125$$

$$h = \hat{\rho} \sqrt{\frac{n}{1 - n\hat{\sigma}_{\beta_1}^2}}$$

$$\text{Entonces: } h = 0.125 \sqrt{\frac{50}{1 - 25(0.0225)}} = 1.89$$

Luego, para un nivel de significancia del 5%, tenemos:

Como $h = 1.89$, entonces se cumple la desigualdad, $|h| > 1.645$. Por lo tanto, tenemos evidencias para rechazar la hipótesis nula de ausencia de autocorrelación.

c. Contraste de Autocorrelación en Base al Multiplicador de Lagrange (LM)

El procedimiento del multiplicador de Lagrange es usado para la detección de autocorrelación entre los residuos de una ecuación. El contraste es adecuado para los casos de indeterminación al usar el estadístico “d” de Durbin-Watson, o imposibilidad de obtención del “h” de Durbin⁵. Sin embargo, es importante señalar que su uso no debe limitarse a dichos casos. Para su aplicación se debe considerar un estadístico de prueba $LM = nR^2$, donde n es el tamaño muestral el cual sigue aproximadamente una distribución Chi-cuadrado con “p” grados de libertad (χ_p^2), es decir:

$$M \sim \chi_p^2 \quad ; \text{ p grados de Libertad (autocorrelación de orden p)}$$

La regla de decisión para una autocorrelación de orden p es:

Si $LM > \chi_p^2$: Existe autocorrelación significativa de orden p.

Si $LM < \chi_p^2$: No existe autocorrelación significativa de orden p.

Ejercicio Ilustrativo 3:

En el modelo de inflación aplicamos el test LM. El paquete E-Views calcula este test, el cual permite identificar la presencia de autocorrelación de cualquier orden.

En este caso se calculará la autocorrelación de orden 2, obteniendo los siguientes resultados:

⁵ Sin embargo, es importante que el lector no interprete que su uso se limita a dichos casos. El contraste LM se puede y debe quizás aplicar como complemento a los demás.

Breusch-Godfrey Serial Correlation LM Test:				
F-statistic	33.50958	Probability	0.000000	
Obs*R-squared	38.55391	Probability	0.000000	
Test Equation:				
Dependent Variable: RESID				
Method: Least Squares				
Date: 09/22/02 Time: 09:38				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.060917	0.062686	0.971787	0.3341
LCIRPROM	-0.009815	0.010168	-0.965219	0.3374
LTC	0.016273	0.020029	0.812500	0.4189
RESID(-1)	0.694486	0.115892	5.992536	0.0000
RESID(-2)	0.016642	0.117288	0.141892	0.8875
R-squared	0.458975	Mean dependent var	1.50E-15	
Adjusted R-squared	0.431581	S.D. dependent var	0.025635	
S.E. of regression	0.019327	Akaike info criterion	-4.996966	
Sum squared resid	0.029509	Schwarz criterion	-4.852275	
Log likelihood	214.8726	F-statistic	16.75479	
Durbin-Watson stat	1.896173	Prob(F-statistic)	0.000000	

La hipótesis nula es: no existe autocorrelación de orden (p). En este caso, la hipótesis nula es que no existe autocorrelación de orden 2. Analizando los resultados obtenidos, rechazamos la hipótesis nula al 99% de confianza ($\alpha=0.01$). Entonces, concluimos que existe autocorrelación de orden 2.

d. El Contraste de Ljung y Box

El estadístico de Ljung y Box (1978), al igual que el contraste anterior, sirve para contrastar esquemas generales de autocorrelación en la perturbación. La Hipótesis nula, indica la ausencia de autocorrelación serial. El estadístico es el siguiente:

$$Q^* = n(n+2) \left[\frac{\rho_1^2}{(n-1)} + \frac{\rho_2^2}{(n-2)} + \dots + \frac{\rho_p^2}{(n-p)} \right] \sim \chi_p^2$$

donde $\rho_1, \rho_2, \dots, \rho_p$ son los coeficientes de autocorrelación de orden 1, 2 y p, cuyas expresiones son conocidas.


La hipótesis de autocorrelación significativa de orden p es aceptada si el valor calculado del estadístico supera al valor crítico de la tabla con p grados de libertad.

Un aspecto importante, es que los estadísticos de contraste Ljung y Box detectan el grado de autocorrelación de orden p, de manera discontinua. Esto permite afirmar que si por ejemplo $\hat{\rho}_4$ es significativamente elevado eso no implica que $\hat{\rho}_1, \hat{\rho}_2$ y $\hat{\rho}_3$ también lo sean, a no ser que de manera complementaria se demuestre lo contrario.

Ejercicio Ilustrativo 4:

En el modelo de inflación, probamos la existencia de autocorrelación mediante el Contraste de Ljung y Box, hasta un orden establecido con este

La hipótesis nula es que no existe autocorrelación hasta el orden (n). Del paquete E-Views, se obtiene el siguiente gráfico:



Al analizar el estadístico Q tenemos que:

- Rechazamos la hipótesis nula de no autocorrelación hasta el orden 1 al 99% de confianza. (nivel de significación $\alpha = 0.01$)
- Rechazamos la hipótesis nula de no autocorrelación hasta el orden 2 al 99% de confianza. Es decir, puede existir autocorrelación de orden 1 ó 2.
- Rechazamos la hipótesis nula de no autocorrelación hasta el orden 3 al 99% de confianza. Es decir, puede existir autocorrelación de orden 1, 2 ó 3.

Este proceso continúa hasta:

- Rechazar la hipótesis nula de no autocorrelación del orden 20 al 99% de confianza. Es decir, puede existir autocorrelación de orden 1, 2, 3, 4,..., 19 ó 20.

Para saber cuál es el orden de autocorrelación analizamos el comportamiento de los coeficientes de autocorrelación parcial (Partial Correlation). El orden de autocorrelación estará determinado por el orden del último coeficiente que está fuera de las bandas de confianza. En este caso, se trata del coeficiente de autocorrelación parcial de orden 13 ya que es el último que está fuera de las bandas. Por lo tanto, concluimos que existe autocorrelación de orden 13.

4. CORRECCIÓN DE AUTOCORRELACION

Forma General

Puesto que las perturbaciones μ_t no son observables, la naturaleza de la correlación serial es frecuentemente un asunto de especulación o de exigencias prácticas. En la práctica, usualmente se supone que las μ_t siguen el esquema autorregresivo de primer orden, es decir:

$$\mu_t = \rho\mu_{t-1} + \varepsilon_t \quad \dots(1)$$

Donde $|\rho| < 1$ y donde las ε_t siguen los supuestos MCO: de valor esperado cero, varianza constante y no autocorrelación, es decir:

$$\begin{aligned} E(\varepsilon_t) &= 0 \\ \text{Var}(\varepsilon_t) &= \sigma^2 \\ \text{Cov}(\varepsilon_t, \varepsilon_{t+s}) &= 0, s \neq 0 \end{aligned}$$

Si se supone la validez de (1), el problema de correlación serial puede ser resuelto satisfactoriamente si se conoce ρ , el coeficiente de autocorrelación. Analizando para un modelo con dos variables².

$$Y_t = \beta_1 + \beta_2 X_t + \mu_t \quad \dots(2)$$

Si (2) es cierta en el tiempo t , también es cierta en el tiempo $t-1$. Por lo tanto,

$$Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + \mu_{t-1} \quad \dots(3)$$

Multiplicando (3) por ρ a ambos lados, se obtiene

$$\rho Y_{t-1} = \rho\beta_1 + \rho\beta_2 X_{t-1} + \rho\mu_{t-1} \quad \dots(4)$$

Restando (4) de (2) se obtiene

$$\begin{aligned} (Y_t - \rho Y_{t-1}) &= (\beta_1 - \rho\beta_1) + (\beta_2 X_t - \rho\beta_2 X_{t-1}) + (\mu_t - \rho\mu_{t-1}) \\ Y_t - \rho Y_{t-1} &= \beta_1(1 - \rho) + \beta_2(X_t - \rho X_{t-1}) + \varepsilon_t \quad \dots(5) \end{aligned}$$

donde en el último paso, se hace uso de la relación (1) : $\varepsilon_t = \mu_t - \rho\mu_{t-1}$

Se puede expresar (5) como

$$Y_t^* = \beta_1^* + \beta_2^* X_t^* + \varepsilon_t \quad \dots(6)$$

² No importa si el modelo tiene más de una variable explicativa porque la autocorrelación es una propiedad de los μ_t

Donde:

$$\beta_1^* = \beta_1(1-\rho), Y_t^* = (Y_t - \rho Y_{t-1}) \text{ y } X_t^* = (X_t - \rho X_{t-1})$$

Puesto que ε_t satisface todos los supuestos MCO, se puede proceder a aplicar MCO sobre las variables transformadas Y^* y X^* y obtener estimadores con todas las propiedades óptimas.

La regresión (5) se conoce por el nombre de **ecuación en diferencia generalizada**. Esta consiste en regresar Y sobre X , no en la forma original, sino en forma de diferencia, lo cual se logra restando una proporción (de valor igual a “ ρ ”) del valor de una variable en el período de tiempo anterior de su valor en el período de tiempo actual. En este procedimiento de diferenciación se pierde una observación puesto que la primera observación no tiene precedente. Para evitar esta pérdida de una observación, la primera observación sobre Y y X es transformada por una de las siguientes formas³:

$$\sqrt{1-\rho^2} \quad , \quad Y_1\sqrt{1-\rho^2} \quad \text{y} \quad X_1\sqrt{1-\rho^2}$$

Esta transformación es conocida como la **transformación de Prais-Winsten**.

a. Procedimiento de Durbin –Watson

Este procedimiento está basado en la relación entre los estadísticos d y ρ según Durbin y Watson.

Dicha relación es la siguiente: $d \sim 2(1-\hat{\rho})$

Puede despejarse $\hat{\rho}$ en función de una metodología estimada, y así obtener de manera indirecta, y también aproximada el valor de $\hat{\rho}$:

$$\hat{\rho}_{dw} \sim 1 - \frac{d}{2}$$

Es decir, consiste en obtener el grado de autocorrelación habiendo obtenido previamente el estadístico de Durbin-Watson de detección de la misma, a partir de la relación aproximadamente señalada. En síntesis, 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.**

³ La pérdida de una observación puede no ser muy grave en una muestra grande, pero puede constituir una diferencia sustancial en los resultados en una muestra pequeña.

Los supuestos en los cuales se basa son:

- El modelo de regresión incluye el término de intercepto. Si dicho término no está presente, como es el caso de la regresión a través del origen, es esencial efectuar nuevamente la regresión incluyendo el término del intercepto para obtener la SCR.
- Las variables explicativas X, son no estocásticas, es decir, son fijas en muestreo repetido.
- Las perturbaciones μ_t del modelo original se generan mediante un modelo que relaciona el error de un periodo temporal con el siguiente (esquema autorregresivo de primer orden):

$$\mu_t = \rho\mu_{t-1} + \varepsilon_t$$

donde ρ es la correlación de los errores del modelo original y ε_t es el término de error aleatorio en la predicción de los errores, es decir, mide el error que se comete cuando se trata de estimar el error en el modelo original a partir del modelo planteado.

- El modelo de regresión no incluye valor(es) rezagado(s) de la variable dependiente como una de las variables explicativas. Por tanto, la prueba es inaplicable a modelos del siguiente tipo:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_k X_{kt} + \gamma Y_{t-1} + \mu_t$$

donde Y_{t-1} es el valor de Y rezagado un período.

Tales modelos se conocen como **modelos autoregresivos**.

- No hay observaciones faltantes en los datos.

b. Procedimiento Iterativo de Cochran – Orcutt

Sin duda alguna, se trata del procedimiento más usado y uno de los más importantes para el tratamiento de la autocorrelación, dado que está basado en la estimación de ρ como coeficiente de autocorrelación propiamente dicho, en base a la expresión:

$$\rho = \frac{\sum \mu_t \mu_{t-1}}{\sum \mu_t^2}$$

Asimismo, se puede estimar con el modelo $\mu_t = \rho\mu_{t-1} + \varepsilon_t$

Los procedimientos para estimar “ ρ ” son los siguientes:

Primera Etapa

Estimación 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, de la siguiente forma:

Retrasando un período y multiplicando por ρ :

$$\rho Y_{t-1} = \beta_1 \rho + \beta_2 \rho X_{2t-1} + \dots + \beta_k \rho X_{kt-1} + \rho \mu_{t-1} \quad (2)$$

restando (2) de (1) :

$$Y_t - \rho Y_{t-1} = \beta_1(1-\rho) + \beta_2(X_{2t} - \rho X_{2t-1}) + \dots + \beta_k(X_{kt} - \rho X_{kt-1}) + (\mu_t - \rho \mu_{t-1})$$

Segunda Etapa

A partir de los residuos de la ecuación de diferencias de la primera etapa, obtener un nuevo estimador de Cochran-Orcutt, tal como:

$$\hat{\rho}^* = \frac{\sum \mu_t^* \mu_{t-1}^*}{\sum \mu_t^{*2}}$$

el mismo que se reemplaza en una nueva ecuación de diferencias:

$$Y_t - \hat{\rho}^* Y_{t-1} = \beta_1(1 - \hat{\rho}^*) + \beta_2(X_{1t} - \hat{\rho}^* X_{1t-1}) + \dots + \varepsilon_t^*$$

siendo ε_t el error que se comete cuando se trata de estimar el error en el modelo de la segunda etapa a partir del modelo obtenido por diferencias al igual que en la primera etapa.

Alternativamente se estima “ ρ^* ” en el modelo:

$$\mu_t^* = \rho^* \mu_{t-1}^* + \varepsilon_t^*$$

Tercera Etapa y Etapas Sucesivas

De los residuos de la ecuación de diferencias anterior (segunda etapa), puede lograrse una nueva estimación del coeficiente de autocorrelación, tal como:

$$\hat{\rho}^{**} = \frac{\sum \mu_t^{**} \mu_{t-1}^{**}}{\sum \mu_t^{**2}}$$

Forma alternativa para estimar ρ^{**} :

$$\mu_t^{**} = \rho^{**} \mu_{t-1}^{**} + \varepsilon_t^{**}$$

De esta manera se reemplaza en una nueva ecuación de diferencias, y así sucesivamente. El proceso puede repetirse hasta que las estimaciones sucesivas de ρ no difieran significativamente entre sí, pudiendo lograrse 2, 5, 10 ó más iteraciones.

Entre las ventajas de este procedimiento destacan las vinculadas a las propiedades estimativas, dado que estas descansan sobre sólidas bases metodológicas al facultarse la estimación del grado de autocorrelación como el coeficiente de correlación entre residuos sucesivos, lo cual es acorde con la definición de autocorrelación de primer orden.

Sin embargo, también debe tenerse en cuenta que muchas veces un elevado número de iteraciones, cercano al número de observaciones, transforma la información original, dificultando notablemente la interpretación lógica de las relaciones entre las variables.

c. Tratamiento de Autocorrelación de Orden “p” (Cochrane – Orcutt)

Ante la existencia de autocorrelación en un orden mayor al primero, pueden generalizarse las metodologías.

Es factible obtener los diversos grados de autocorrelación ante los diversos órdenes de la misma. Así, se obtiene el $\hat{\rho}_p$

$$\hat{\rho}_p = \frac{\sum \hat{\mu}_t \hat{\mu}_{t-p}}{\sum \hat{\mu}_t^2} \quad \text{grado de autocorrelacion de orden p}$$

Entonces, utilizando el procedimiento iterativo de Cochrane – Orcutt y partiendo de una ecuación de tipo:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \dots + \beta_k X_{kt} + \mu_t$$

En el cual existe un proceso de autocorrelación de orden p como el siguiente:

$$\mu_t = \rho_1 \mu_{t-1} + \rho_2 \mu_{t-2} + \dots + \rho_p \mu_{t-p} + \varepsilon_t \quad \text{AR}(p)$$

puede aplicarse una ecuación de diferencias generalizadas como la que sigue:

$$\begin{aligned} (Y_t - \rho_1 Y_{t-1} - \dots - \rho_p Y_{t-p}) = & \beta_1 (1 - \rho_1 - \dots - \rho_p) + \beta_2 (X_{2t} - \rho_1 X_{2t-1} - \dots - \rho_p X_{2t-p}) + \dots \\ & + \beta_k (X_{kt} - \rho_1 X_{kt-1} - \dots - \rho_p X_{kt-p}) + (\mu_t - \rho_1 \mu_{t-1} - \dots - \rho_p \mu_{t-p}) \end{aligned}$$

donde $\rho_1 \rho_2 \dots \rho_p$ serán estimados mediante el proceso iterativo explicado con anterioridad.

5. PREDICCIÓN CON AUTOCORRELACION O COVARIANZAS NO NULAS

Como se recordará, cuando se detecta este problema se puede corregir aplicando mínimos cuadrados ordinarios al modelo original utilizando la información modificada (es decir MCG):

$$N^*_t = N_t - \hat{\rho} N_{t-1}$$

en donde $\hat{\rho}$ podría obtenerse a través de la fórmula $\hat{\rho} = \frac{\sum_{t=2}^n \hat{\mu}_t \hat{\mu}_{t-1}}{\sum_{t=2}^n \hat{\mu}_{t-1}^2}$.

La técnica permite conseguir estimadores de los parámetros β_i con las características deseadas.

Para utilizar el modelo estimado por MCG en predicción se requerirá ajustar los valores proyectados de todas las variables exógenas X_{t+1} , a los valores corregidos proyectados de ellas mismas. Con esos valores se podrá obtener el predictor \hat{Y}_{t+1}^* :

$$X_{t+1}^* = X_{t+1} - \hat{\rho}X_t \quad \hat{Y}_{t+1}^* = \hat{Y}_{t+1} - \hat{\rho}Y_t$$

El esquema del predictor puntual del valor futuro de Y_t :

$$\hat{Y}_{t+1}^* = \hat{\beta}_1^* + \hat{\beta}^* X_{t+1}^*$$

$$\hat{Y}_{t+1} = \hat{\beta}_1^* + \hat{\beta}^* (X_{t+1} - \hat{\rho}X_t) + \hat{\rho}Y_t$$

Esto significa que en la predicción por intervalo, los límites que son fijados por:

$$\hat{Y}_{t+1} \pm t_{\text{tab}} \sqrt{\hat{\sigma}_{\mu\text{MCG}}^2}$$

Dependerán del nivel de confianza y del número de grados de libertad de la estimación por MCG. Para determinar el valor $\hat{\sigma}_{\mu\text{MCG}}^2$ se utilizará la varianza de los estimadores obtenidos con la información muestral modificada para la aplicación de MCG.

Ejercicio Ilustrativo 5:

Se presenta un modelo cuya variable dependiente son las importaciones en función de la formación bruta de capitales a valores constantes de 1979, del periodo de 1979 – 1998.

$$M=C(1)+C(2)*FBK$$

Se desea analizar el problema de autocorrelación para el modelo anteriormente descrito, para el cual se realizará:

1. Detección de autocorrelación método Durbin Watson.
2. Corrección con el procedimiento Durbin Watson.
3. Contraste de autocorrelación con el multiplicador de Lagrange.
4. Corrección con el procedimiento de Cochran-Orcutt

Resultados del Eviews:

Dependent Variable: M				
Method: Least Squares				
Sample: 1979 1998				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-72.10892	75.26001	-0.958131	0.3507
FBK	1.002990	0.079313	12.64599	0.0000
R-squared	0.898832	Mean dependent var	846.7770	
Adjusted R-squared	0.893211	S.D. dependent var	268.2676	
S.E. of regression	87.66604	Akaike info criterion	11.87959	
Sum squared resid	138336.0	Schwarz criterion	11.97916	
Log likelihood	-116.7959	F-statistic	159.9210	
Durbin-Watson stat	0.783378	Prob(F-statistic)	0.000000	

1. Prueba de Durbin Watson

El modelo que estamos analizando presenta una R^2 del 90% aproximadamente lo que le da una buena bondad de ajuste al modelo, con un buen nivel de significancia del parámetro de la FBK y con una prueba F que asegura su significancia global; es decir tenemos un modelo que explica de una buena manera las importaciones en función de la formación bruta de capital.

Para la prueba de Durbin Watson utilizaremos un nivel de significancia del 5%, con un grado de libertad igual a 1.

$$dl=1.201 \quad 4-dl=2.589$$

$$du=1.411 \quad 4-du=2.79$$

La conclusión de esta prueba es que el modelo muestra autocorrelación positiva (D-W: $0.783378 < 1.201$).

2. Corrección Durbin Watson.

Hallamos ρ a través del valor de Durbin Watson:

$$\rho = 1 - (\text{Durbin Watson}/2) = 0.608311$$

Corregimos las variables con el coeficiente de autocorrelación hallado, el cual se muestra en la tabla siguiente:

Obs	M1	FBK1	Obs	M1	FBK1
1979	528.7780	600.6792	1989	94.47736	57.60925
1980	462.4510	570.4242	1990	259.4790	315.2691
1981	477.9764	615.1930	1991	336.8414	339.0263
1982	416.1886	395.8117	1992	360.7952	284.7985
1983	98.00196	3.732050	1993	313.8694	371.2941
1984	151.7961	206.0035	1994	496.0415	552.5263
1985	180.5833	178.1658	1995	623.5556	600.4738
1986	321.8671	405.8461	1996	483.1665	425.6563
1987	351.5099	503.8133	1997	603.6439	605.4949
1988	225.7588	285.9143	1998	530.7962	492.1347

Luego hallamos el siguiente modelo:

$$M1=C(1)+C(2)*FBK1$$

Dependent Variable: M1				
Method: Least Squares				
Sample: 1979 1998			Included observations: 20	
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	47.62736	33.48209	1.422473	0.1720
FBK1	0.814999	0.077968	10.45302	0.0000
R-squared	0.858564	Mean dependent var	365.8789	
Adjusted R-squared	0.850706	S.D. dependent var	161.2517	
S.E. of regression	62.30537	Akaike info criterion	11.19661	
Sum squared resid	69875.27	Schwarz criterion	11.29619	
Log likelihood	-109.9661	F-statistic	109.2656	
Durbin-Watson stat	1.072147	Prob(F-statistic)	0.000000	

Efectuada la corrección se nota que aún tenemos un test de Durbin Watson que presenta autocorrelación positiva. Efectuemos la corrección de nuevo.

$$\rho = 1 - (\text{Durbin Watson}/2) = 0.570718$$

obs	M2	FBK2	obs	M2	FBK2
1979	434.2040	493.2454	1989	-34.36723	-105.5672
1980	160.6679	227.6057	1990	205.5591	282.3905
1981	214.0472	289.6417	1991	188.7520	159.0966
1982	143.3989	44.71001	1992	168.5538	91.31010
1983	-139.5244	-222.1648	1993	107.9571	208.7545
1984	95.86459	203.8735	1994	316.9105	340.6221
1985	93.95055	60.59586	1995	340.4558	285.1371
1986	218.8049	304.1637	1996	127.2921	82.95506
1987	167.8145	272.1896	1997	327.8921	362.5652
1988	25.14577	-1.621064	1998	186.2857	146.5679

El modelo:

$$M2=C(1)+C(2)*FBK2$$

Dependent Variable: M2				
Method: Least Squares				
Sample: 1979 1998			Included observations: 20	
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	42.01530	17.46538	2.405634	0.0271
FBK2	0.711659	0.072289	9.844579	0.0000
R-squared	0.843363	Mean dependent var	167.4833	
Adjusted R-squared	0.834661	S.D. dependent var	131.3406	
S.E. of regression	53.40551	Akaike info criterion	10.88834	
Sum squared resid	51338.68	Schwarz criterion	10.98792	
Log likelihood	-106.8834	F-statistic	96.91574	
Durbin-Watson stat	1.897048	Prob(F-statistic)	0.000000	

Con este nuevo modelo la autocorrelación queda resuelta, pues observamos que queda un valor de Durbin Watson mayor que el valor crítico d, razón por la cual la autocorrelación no existe.

3. Contraste de Autocorrelación de Lagrange

De Primer Orden

Para el contraste debemos analizar el modelo en el que la variable independiente serán los residuos del modelo inicial $M=C(1)+C(2)*FBK$ y que se describe como un modelo autorregresivo; el modelo a regresionar es el siguiente:

$$RES0=C(1)+C(2)*FBK+C(3)*RES0(-1)$$

Dependent Variable: RES0				
Method: Least Squares				
Date: 10/02/00 Time: 15:48				
Sample(adjusted): 1980 1998				
Included observations: 19 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	23.72669	65.89525	0.360067	0.7235
FBK	-0.020123	0.068673	-0.293031	0.7733
RES0(-1)	0.629883	0.214244	2.940033	0.0096
R-squared	0.350797	Mean dependent var	1.091793	
Adjusted R-squared	0.269647	S.D. dependent var	87.52240	
S.E. of regression	74.79727	Akaike info criterion	11.61138	
Sum squared resid	89514.11	Schwarz criterion	11.76050	
Log likelihood	-107.3081	F-statistic	4.322801	
Durbin-Watson stat	1.493070	Prob(F-statistic)	0.031553	

RES0 : Residual del modelo inicial.

RES0(-1) : Residual del modelo inicial rezagado un periodo.

Lagrange : $n(\text{numero de datos}) * R^2$.

Chi cuadrada : (1 gl, 5%)

Obs	LAGR1	CHI1
1979	7.015940	0.301084

El test de lagrange nos muestra que existe autocorrelación en el modelo, pues el estadístico tiene un valor mucho mayor al valor de Chi cuadrado con

Segundo Orden

Para el contraste de segundo orden tendremos el modelo anterior con dos rezagos de los residuos.

$$RES0=C(1)+C(2)*FBK+C(3)*RES0(-1)+C(4)*RES0(-2)$$

Dependent Variable: RES0				
Method: Least Squares				
Date: 10/02/00 Time: 16:05				
Sample(adjusted): 1981 1998				
Included observations: 18 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-26.91815	71.54782	-0.376226	0.7124
FBK	0.035988	0.074240	0.484750	0.6354
RES0(-1)	0.815376	0.248688	3.278712	0.0055
RES0(-2)	-0.404311	0.286234	-1.412519	0.1796
R-squared	0.440875	Mean dependent var	6.377633	
Adjusted R-squared	0.321063	S.D. dependent var	86.88314	
S.E. of regression	71.58966	Akaike info criterion	11.57291	
Sum squared resid	71751.10	Schwarz criterion	11.77077	
Log likelihood	-100.1562	F-statistic	3.679712	
Durbin-Watson stat	2.037373	Prob(F-statistic)	0.038296	

RES0 : Residual del modelo inicial.
RES0(-1) : Residual del modelo inicial rezagado un periodo.
RES0(-2) : Residual del modelo inicial rezagado dos periodo.

Obs	LAGR2	CHI2
1979	8.817500	0.147621

Al igual que en la prueba de primer orden en la salida de segundo orden se nota que existe autocorrelación.

4. Corrección con el procedimiento de Cochran-Orcutt

El primer paso consiste en hallar el modelo y buscar si existe autocorrelación; para este modelo ya se ha demostrado la existencia de autocorrelación, por lo que pasaremos a hallar el coeficiente de autocorrelación según la definición dada para el término.

Modelo estimado : $M=C(1)+C(2)*FBK+\mu_t$

Modelo planteado : $M^*=C(1)+C(2)*FBK$

Por lo tanto : $\mu_t = M - M^*$

El cálculo del ρ será a partir de:

$$\rho = \frac{\sum_{t=1}^{20} \mu_t \mu_{t-1}}{\sum_{t=1}^{20} \mu_t^2}$$

Según esto para hallar ρ debemos de calcular el modelo siguiente:

$$RES0=C(1)*RES0(-1)$$

Dependent Variable: RES0				
Method: Least Squares				
Date: 10/02/00 Time: 17:32				
Sample(adjusted): 1980 1998				
Included observations: 19 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
RES0(-1)	0.619525	0.201704	3.071456	0.0066
R-squared	0.343768	Mean dependent var	1.091793	
Adjusted R-squared	0.343768	S.D. dependent var	87.52240	
S.E. of regression	70.90026	Akaike info criterion	11.41162	
Sum squared resid	90483.24	Schwarz criterion	11.46133	
Log likelihood	-107.4104	Durbin-Watson stat	1.516000	

Por lo tanto el ρ será 0.619525

Corregimos las variables importaciones y formación bruta de capitales (M y FBK) con el coeficiente de autocorrelación hallado, luego se estima el modelo:

$$M1=C(1)+C(2)*FBK1$$

Donde M1 y FBK1 son los nuevos valores para M y FBK

Dependent Variable: M1				
Method: Least Squares				
Date: 10/02/00 Time: 17:39				
Sample: 1979 1998				
Included observations: 20				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	43.12060	17.79588	2.423067	0.0262
FBK1	0.738521	0.067116	11.00359	0.0000
R-squared	0.870577	Mean dependent var	187.0030	
Adjusted R-squared	0.863387	S.D. dependent var	146.0555	
S.E. of regression	53.98386	Akaike info criterion	10.90989	
Sum squared resid	52456.63	Schwarz criterion	11.00946	
Log likelihood	-107.0989	F-statistic	121.0791	
Durbin-Watson stat	1.422102	Prob(F-statistic)	0.000000	

De esta corrección tenemos que la autocorrelación desaparece pues el estadístico Durbin Watson se encuentra en la zona de no autocorrelación.

Ejercicio ilustrativo 6:

De la siguiente información estadística, referido a las Importaciones, Producto Bruto Interno e Índice de Precios al Consumidor, para el Perú en el periodo 1970-2000:

AÑO	PBI	IPC	IMPORT	AÑO	PBI	IPC	IMPORT
1970	62,022.00	0.00000019	9,491.00	1986	99,267.00	0.00016300	10,607.00
1971	64,627.00	0.00000021	9,920.00	1987	107,208.00	0.00030200	12,182.00
1972	66,501.00	0.00000022	9,892.00	1988	97,881.00	0.00231900	11,091.00
1973	70,092.00	0.00000024	11,110.00	1989	86,429.00	0.08100000	8,287.00
1974	76,611.00	0.00000028	14,127.00	1990	81,983.00	6.15000000	9,270.00
1975	79,215.00	0.00000035	13,724.00	1991	83,760.00	31.35000000	11,130.00
1976	80,800.00	0.00000047	11,995.00	1992	83,401.00	54.39	12,113.00
1977	81,123.00	0.00000064	12,037.00	1993	87,375.00	80.82	12,572.00
1978	81,366.00	0.00000102	9,103.00	1994	98,577.00	100.00	15,922.00
1979	86,086.00	0.00000170	10,860.00	1995	107,039.00	111.13	20,232.00
1980	90,562.00	0.00000271	14,144.00	1996	109,709.00	123.97	20,259.00
1981	95,181.00	0.00000480	16,395.00	1997	117,110.00	134.56	22,724.00
1982	94,610.00	0.00000780	16,758.00	1998	116,485.00	144.32	23,251.00
1983	83,446.00	0.00001650	11,791.00	1999	117,590.00	149.33	19,724.00
1984	87,785.00	0.00003470	9,647.00	2000	121,267.00	154.94	20,428.00
1985	90,243.00	0.00009150	8,812.00				

Se estima el modelo:

IMPORT = f(PBI, IPC)

IMPORT = $\beta_0 + \beta_1 \text{PBI} + \beta_2 \text{IPC}$

Siendo:

IMPORT = Importaciones. (En millones de nuevos soles de 1994)

PBI = Producto Bruto Interno. (En millones de nuevos soles de 1994)

IPC = Índice de Precios al Consumidor. (Base 1994 = 100)

1. Cálculo e interpretación del modelo por M.C.O.

ls importaciones c pbi ipc

Dependent Variable: IMPORT					
Method: Least Squares					
Date: 09/05/02 Time: 21:12					
Sample: 1970 2000					
Included observations: 31					
Variable	Coefficient	Std. Error	t-Statistic	Prob.	
C	3427.817	3293.850	1.040672	0.3069	
IPC	45.02326	11.06852	4.067687	0.0004	
PBI	0.094182	0.039275	2.398012	0.0234	
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	

Ecuación estimada: $IMPORT = \beta_0 + \beta_1 \text{PBI} + \beta_2 \text{IPC}$

$IMPORT = 3427.817007 + 45.0232614 \cdot \text{IPC} + 0.0941819102 \cdot \text{PBI}$

Interpretación:

- Los parámetros son significativos, a excepción del intercepto, a un nivel de significancia del 5%. El estadístico F refleja que la variable dependiente es explicado por el modelo en su conjunto y la bondad de ajuste es de 75.58%.
- Las Importaciones, autónoma del IPC y PBI asciende en promedio a 3427.817 millones de nuevos soles.
- Ante una variación de 1 millón de nuevos soles en el IPC, las importaciones se incrementará en un 45.0.23 millones de nuevos soles, manteniendo las demás variables constantes.
- Ante una variación de 1 millón de nuevos soles en el PBI, las importaciones se incrementarían en 0.09418191 millones de nuevos soles, manteniendo las demás variables constantes.

2. Significancia individual y conjunta del Modelo.

Individualmente el modelo es significativo demostrado mediante la prueba t, cuyas probabilidades son menores que 0.05 a excepción del intercepto.

En conjunto el modelo es significativo, demostrado por la prueba F al ser su probabilidad menor a 0.05. Sin embargo, la bondad de ajuste, medida a través del R^2 y R^2 ajustado, demuestra regular ajuste. (73% a 75%).

3. Especificación del Modelo

Test de Reset Ramsey

H0 : El Modelo esta correcta especificado.

H1 : El Modelo no esta correcta especificado.

Ramsey RESET Test:				
F-statistic	1.988089	Probability	0.157240	
Log likelihood ratio	4.411501	Probability	0.110168	
Test Equation:				
Dependent Variable: IMPORT				
Method: Least Squares				
Date: 09/05/02 Time: 22:22				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	22336.85	10694.62	2.088607	0.0467
IPC	-667.4942	420.3267	-1.588037	0.1244
PBI	-1.281869	0.825272	-1.553268	0.1324
FITTED^2	0.000976	0.000607	1.607575	0.1200
FITTED^3	-1.99E-08	1.30E-08	-1.526744	0.1389
R-squared	0.788244	Mean dependent var	13535.42	
Adjusted R-squared	0.755666	S.D. dependent var	4362.854	
S.E. of regression	2156.563	Akaike info criterion	18.33711	
Sum squared resid	1.21E+08	Schwarz criterion	18.56840	
Log likelihood	-279.2252	F-statistic	24.19574	
Durbin-Watson stat	0.721749	Prob(F-statistic)	0.000000	

Como la probabilidad asociada este estadístico es $\text{Prob.} = 0.157240 > 0.05$. Entonces se acepta la hipótesis nula. Es decir el Modelo esta correctamente especificado, con un nivel de significancia del 5%.


4. Detección de Autocorrelación

a. Estadístico Durbin Watson

Como sabemos el estadístico Durbin Watson mide la autocorrelación de primer grado.

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%.

b. Test de Lagrange

H_0 : El Modelo no tiene autocorrelación de orden p ($p = 2$).

H_1 : 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.= 0.000042 < 0.05. Entonces se rechaza la hipótesis nula. Es decir el Modelo tiene problemas de autocorrelación con una probabilidad del 95%.

c. Test Estadístico Ljung y Box

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

Debido a que las probabilidades son menores a 0.05 se puede decir que existe autocorrelación de orden 1,2,3 ...15 o 16, con una probabilidad del 95%

5. Corrección de la Autocorrelación

a. Estadístico Durbin Watson

Analizaremos la autocorrelación de primer orden

Primer cambio de variable.

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

Así corregimos nuevamente con $d = 0.655933$

Además:

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

$$\rho = 0.6720335$$

Así generando nuevas variables:

1. $\text{importd} = \text{import} - 0.6720335 * \text{import}(-1)$, de 1971 –2000
2. $\text{pbid} = \text{pbi} - 0.6720335 * \text{pbi}(-1)$, de 1971 –2000
3. $\text{ipcd} = \text{ipc} - 0.6720335 * \text{ipc}(-1)$, de 1971 –2000

1. $\text{importd} = ((1 - 0.6720335^2)^{1/2}) * \text{import}$, de 1970.
2. $\text{pbid} = ((1 - 0.6720335^2)^{1/2}) * \text{pbi}$, de 1970.
3. $\text{ipcd} = ((1 - 0.6720335^2)^{1/2}) * \text{ipc}$, de 1970.

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

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. $\text{importd1p} = \text{importd} - 0.3364065 * \text{importd}(-1)$, de 1971 –2000
2. $\text{pbid1} = \text{pbid} - 0.3364065 * \text{pbid}(-1)$, de 1971 –2000
3. $\text{ipcd1} = \text{ipcd} - 0.3364065 * \text{ipcd}(-1)$, de 1971 –2000

1. $\text{importd1} = ((1 - 0.3364065^2)^{1/2}) * \text{importd}$, de 1970.
2. $\text{pbid1} = ((1 - 0.3364065^2)^{1/2}) * \text{pbid}$, de 1970.
3. $\text{ipcd1} = ((1 - 0.3364065^2)^{1/2}) * \text{ipcd}$, de 1970.

Dependent Variable: IMPORTD1				
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


$$\Rightarrow D_{k'; n; \alpha} = D_{2'; 31; 0.05}$$

$$D_L = 1.297$$

$$4 - D_L = 2.703$$

$$D_U = 1.570$$

$$4 - D_U = 2.430$$



Se observa que estadístico Durbin Watson es 1.947398, encontrándose en la zona de no autocorrelación y tiene un valor cercano a 2 por lo tanto se puede afirmar que modelo ya no tiene problemas de autocorrelación. Sin embargo la variable IPCD1 pierde significancia individual, así como pierde bondad de ajuste, aun cuando el modelo en conjunto sigue explicando a la variable dependiente (Prueba F).

b. Procedimiento Iterativo de Cochran Orcutt

Mediante el proceso Cochran Orcutt lo que se pretende es obtener una estimación para la autocorrelación, el cual esta basado en la estimación del ρ como coeficiente de autocorrelación propiamente dicha.

$$\rho = \frac{\sum \mu_t \mu_{t-1}}{\sum \mu_t^2}$$

Asimismo se puede estimar con el modelo:

$$\mu_t = \mu_{t-1} + \varepsilon$$

Primera Etapa: Regresionamos el modelo por MCO:

Dependent Variable: RESID1				
Method: Least Squares				
Date: 09/19/02 Time: 12:29				
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 RESID1 rezagada es 0.674691 el cual aproximamos como un $\hat{\rho} = 0.674691$, cuyo valor servirá para corregir a las variables. Para ello debo generar nuevas variables:

Así generando nuevas variables:

1. import2 = import-0.674691*import(-1) , de 1971 –2000
2. pbi2 = pbi-0.674691*pbi(-1) , de 1971 –2000
3. ipc2 = ipc-0.674691*ipc(-1) , de 1971 –2000

1. import2 = ((1-0.674691^2)^(1/2))*import , de 1970.
2. pbi2 = ((1-0.674691^2)^(1/2))*pbi , de 1970.
3. ipc2 = ((1-0.674691^2)^(1/2))*ipc , de 1970.

Haciendo la regresión:

Dependent Variable: IMPORT2				
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 último modelo: $u^* t = \rho * u^* t-1 + \varepsilon^* t$

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.- $import2a = import2 - 0.331815 * import2(-1)$, de 1971 –2000
- 2.- $pbi2a = pbi2 - 0.331815 * pbi2(-1)$, de 1971 –2000
- 3.- $ipc2a = ipc2 - 0.331815 * ipc2(-1)$, de 1971 –2000

- 1.- $import2a = ((1 - 0.331815^2)^{(1/2)}) * import2$, 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: IMPORT2A				
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

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: $u^{**} t = \rho^{**} u^{**} t-1 + \varepsilon^{**} t$

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.- $import2b = import2a - 0.021544 * import2a(-1)$, de 1971 –2000
- 2.- $pbi2b = pbi2a - 0.021544 * pbi2a(-1)$, de 1971 –2000
- 3.- $ipc2b = ipc2a - 0.021544 * ipc2a(-1)$, de 1971 –2000

- 1.- $import2b = ((1 - 0.021544^2)^{1/2}) * import2a$, 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: IMPORT2B				
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 superó el problema de autocorrelación, seguir otra etapa significaría reducir (ligeramente) la significancia de los parámetros.


6. Predicción

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

a. **Para el Modelo:** ls importd c pbid ipcd



Año	importdp
2001	7418.589
2002	7515.985
2003	7627.905
2004	7634.972
2005	7639.592

b. Para el Modelo: ls importd1 c pbid1 ipcd1



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	Importd1p
2001	4806.349
2002	4980.457
2003	5059.087
2004	5031.870
2005	5030.988

7. 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.

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	

Utilizar los coeficientes estimados de las variables explicadas resid1(-1) y resid1(-2), para transformar las variables:

Así generando nuevas variables:

$$1.-import2o = import - 0.943024 * import(-1) + 0.407993 * import(-2), \text{ de } 1971 - 2000$$

$$2.-pbi2o = pbi - 0.943024 * pbi(-1) + 0.407993 * pbi(-2), \text{ de } 1971 - 2000$$

$$3.-ipc2o = ipc - 0.943024 * ipc(-1) + 0.407993 * ipc(-2), \text{ de } 1971 - 2000$$

$$1.-import2o = ((1 - 0.407993^2)^{(1/2)}) * import, \text{ de } 1971.$$

$$2.-pbi2o = ((1 - 0.407993^2)^{(1/2)}) * pbi, \text{ de } 1971.$$

$$3.-ipc2o = ((1 - 0.407993^2)^{(1/2)}) * ipc, \text{ de } 1971.$$

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.

8. Predicción (autocorrelación de orden 2)


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:

$$\text{import2oP}_{2001} = \text{import}_{2001} - 0.943024 * \text{import}_{2000} + 0.407993 * \text{import}_{1999}$$

$$\text{import}_{2001} = \text{import2oP}_{2001} + 0.943024 * \text{import}_{2000} - 0.407993 * \text{import}_{1999}$$

$$\text{import}_{2001} = (10129.56) + 0.943024 * (20428) - 0.407993 * (19724)$$

$$\text{import}_{2001} = 21346.40$$

LECCIÓN 4

HETEROSCEDASTICIDAD

La utilización del modelo lineal general se refiere a que las varianzas de las perturbaciones sean las mismas (homocedasticidad). Hablar del problema de heterocedasticidad significa decir que las varianzas de las perturbaciones son diferentes, su presencia afecta a la elaboración de la banda de confianza para precisar la predicción de la variable endógena.

La heterocedasticidad se presenta generalmente en estudios de corte transversal y cuando se analizan modelos en los cuales las variables que intervienen tienen diferenciaciones como consecuencias de la estratificación de las unidades de observación. Por ejemplo: análisis de ventas, costos, utilidades, ahorro, niveles de productividad por tamaño de la empresa (número de personal ocupado - Valor del producto). Cuando se estudia el consumo, ahorro, etc. por estrato de ingreso del hogar

Planteamiento matricial de la presencia de heterocedasticidad:

$$E(\mu\mu') = \sigma^2\Omega = \sigma^2 \begin{bmatrix} 1/\lambda_1 & 0 & \dots & 0 \\ 0 & 1/\lambda_2 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1/\lambda_n \end{bmatrix}$$

1. CONSECUENCIAS DE LA HETEROCEDASTICIDAD

- a. Los estimadores por MCO (Mínimos Cuadrados Ordinarios) siguen siendo insesgados consistentes, pero ya no son eficientes para un tipo de muestra, grande o pequeña.
- b. Si se usa la fórmula de la varianza del modelo con heterocedasticidad en lugar del modelo lineal general, el intervalo para β_i es innecesariamente ancho y la prueba de significancia tiene menos fuerza.
- c. El problema empeora si en lugar de utilizar la fórmula para heterocedasticidad (MCO), se usa la fórmula tradicional.

La fórmula correcta para estimar la varianza en presencia de heterocedasticidad (MCO) es la siguiente:

$$\text{Var}(\hat{\beta}_i) = \frac{\sum X_i^2 \sigma_i^2}{(\sum X_i^2)^2}; \text{ para un solo parámetro.}$$

$$\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1} X' \Omega (X'X)^{-1}; \text{ para todos los parámetros.}$$

Como consecuencia de lo anterior, si en condiciones de heterocedasticidad continuamos aplicando equivocadamente la fórmula de MCO las pruebas t y F tienden a exagerar la significancia estadística de los parámetros estimados t y F.

2. DETECCIÓN DE HETEROSCEDASTICIDAD

a. Test de Goldfeld – Quandt

Este método es aplicable si se supone que la varianza heterocedástica σ_i^2 está relacionada positivamente con una de las variables explicativas en el modelo de regresión. Por tanto se efectúa a partir de la siguiente hipótesis de trabajo:

- Si existe heterocedasticidad ella se debe a que la varianza de la μ_s es una función monótona de una de las X_s .
- Inicialmente es necesario realizar gráficos de los residuales con respecto a la variable Y, y a cada uno de las X_s .
- Si observa que el residual (el residual es un estimador del término de perturbación) tiene comportamientos ascendentes o decrecientes con respecto a Y se puede suponer que existe heterocedasticidad.
- Se puede suponer que si la variable X tiene este problema, es la que estaría ocasionando la heterocedasticidad, y es con esta con la cual se trabaja el test de Goldfeld – Quant.

Entonces el test consiste en verificar que la varianza de μ no es función monótona de las X_s , en cuyo caso no habría heterocedasticidad.

Pasos:

- 1) 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 heterocedasticidad.
- 2) Se toma dos grupos en los extremos estimándose para cada uno su respectiva varianza.

Grupo I	Grupo II
$\hat{\sigma}_{\mu_1}^2 = \frac{\mu'_1 \mu_1}{n_1 - k}$	$\hat{\sigma}_{\mu_2}^2 = \frac{\mu'_2 \mu_2}{n_2 - k}$

$$\frac{\hat{\sigma}_{\mu_2}^2}{\hat{\sigma}_{\mu_1}^2} = F_c \sim F_{(n_1-k, n_2-k; \alpha)}$$

- 3) Omitir c observaciones centrales, donde c se ha especificado a priori, y dividir las observaciones restantes (n-c) en dos grupos, cada uno de (n-2)/2 observaciones.

	Grupo I	Grupo II
Número de observaciones	$n_1 = \frac{(n-c)}{2}$	$n_2 = \frac{(n-c)}{2}$

4) Realizar regresiones separadas por MCO para cada grupo y se obtendrá:

$$\hat{\beta}_I = (X_I' X_I)^{-1} X_I' Y_I$$

$$\hat{\beta}_{II} = (X_{II}' X_{II})^{-1} X_{II}' Y_{II}$$

La primera regresión para los datos asociados con variables bajas de X y la segunda asociada con valores altos de X.

Cada regresión implicará $(n-c)/2$ piezas de datos y $((n-c)/2)-k$ grados de libertad, c debe ser lo bastante pequeño para asegurar que se dispone de suficientes grados de libertad para permitir la estimación apropiada de cada una de las regresiones por separadas.

5) Obtener las respectivas sumas residuales de cuadrados ($\mu_I' \mu_I$ y $\mu_{II}' \mu_{II}$) para cada uno de los grupos:

Grupo	Suma Residual de Cuadrados (SCR)
Grupo I	$\mu_I' \mu_I = SCR_I = Y_I' Y_I - \hat{\beta}_I' X_I' Y_I$
Grupo II	$\mu_{II}' \mu_{II} = SCR_{II} = Y_{II}' Y_{II} - \hat{\beta}_{II}' X_{II}' Y_{II}$

Donde los grados de libertad para cada una de ellas, es:

	Grupo I	Grupo II
Grados de libertad (g.l.)	$n_1 - k$	$n_2 - k$

Además se sabe que k es el número de parámetros que deben ser estimados, incluyendo el intercepto. Por tanto:

$$\mu_I' \mu_I \sim \chi^2 \text{ con } n_1 - k \text{ g.l.}$$

$$\mu_{II}' \mu_{II} \sim \chi^2 \text{ con } n_2 - k \text{ g.l.}$$

6) A continuación se construye el estadístico F_c , del cociente de las dos distribuciones Chi – cuadrado, dividido por sus grados de libertad. Este será:

$$F_c = \frac{\mu_{II}' \mu_{II} / \text{g.l.}}{\mu_I' \mu_I / \text{g.l.}}$$

el cual, definido el nivel de significación, se contrasta con el Estadístico (F)

7) Dócima de Hipótesis

H_0 : No existe heterocedasticidad (Homocedasticidad)

H_1 : Existe Heterocedasticidad.

Si en una aplicación el F_c es superior al F al nivel de significancia seleccionado, se puede rechazar la hipótesis de homocedasticidad (hipótesis nula), es decir, se puede afirmar que la presencia de heterocedasticidad es muy probable.

Simplificando tenemos, si:

$F_c > F \Rightarrow$ se rechaza H_0 (Existe Heterocedasticidad)

$F_c < F \Rightarrow$ se acepta H_0 (No existe Heterocedasticidad)

Ejercicio ilustrativo 1:

Una empresa de transporte interprovincial PEGASO desea estimar las ventas anuales de pasajes (Y), en función de los gastos realizados para la mejora en la calidad del servicio (X_2) y publicidad (X_3).

Para ello se cuenta con la siguiente información (miles de nuevos soles):

Y	X ₂	X ₃
119	10	1
133.2	11	5
148.1	12	7
174.7	15	6
204	18	4
230	20	9
288.4	25	16
319.9	30	3
284.3	26	2
182.1	16	9
392.2	32	10
388.4	36	12
371.6	34	8
418.3	40	3
453	42	9
501.4	48	6
550.4	52	5
615	60	1
612	58	6
636	62	2

Solución

Se tiene que $n = 20$ datos, además $c = 6$.

Ordenando los datos (en forma ascendente) en función a la variable X_2 (la cual supuestamente produce Heterocedasticidad, se tiene los datos para la primera y segunda regresión:

Y	X ₂	X ₃
119	10	1
133.2	11	5
148.1	12	7
174.7	15	6
182.1	16	9
204	18	4
230	20	9
288.4	25	16
284.3	26	2
319.9	30	3
392.2	32	10
371.6	34	8
388.4	36	12
418.3	40	3
453	42	9
501.4	48	6
550.4	52	5
612	58	6
615	60	1
636	62	2

Observaciones para la primera regresión: $(n-c)/2 = 7$

Observaciones omitidas = 6

Observaciones para la segunda regresión: $(n-c)/2 = 7$

De la primera regresión, obtenemos:

Dependent Variable: Y ₁				
Method: Least Squares				
Date: 07/02/02 Time: 09:50				
Sample: 1 7				
Included observations: 7				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	17.02864	5.260470	3.237095	0.0318
X ₂₁	10.22867	0.432883	23.62918	0.0000
X ₃₁	0.696960	0.566639	1.229990	0.2861
R-squared	0.995609	Mean dependent var	170.1571	
Adjusted R-squared	0.993414	S.D. dependent var	39.49510	
S.E. of regression	3.205136	Akaike info criterion	5.464913	
Sum squared resid	41.09158	Schwarz criterion	5.441732	
Log likelihood	-16.12720	F-statistic	453.5277	
Durbin-Watson stat	1.857907	Prob(F-statistic)	0.000019	

$$\mu'_1 \mu_1 = \sum \mu_1^2 = 41.09158$$

De la segunda regresión, obtenemos:

Dependent Variable: Y _{II}				
Method: Least Squares				
Date: 07/02/02 Time: 10:16				
Sample: 14 20				
Included observations: 7				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.517561	14.96996	-0.034573	0.9741
X _{2II}	10.21966	0.245228	41.67402	0.0000
X _{3II}	2.818984	0.777417	3.626091	0.0222
R-squared	0.998195	Mean dependent var	540.8714	
Adjusted R-squared	0.997292	S.D. dependent var	85.63264	
S.E. of regresión	4.456230	Akaike info criterion	6.124010	
Sum squared resid	79.43195	Schwarz criterion	6.100829	
Log likelihood	-18.43404	F-statistic	1105.808	
Durbin-Watson stat	2.132042	Prob(F-statistic)	0.000003	

$$\mu'_{II} \mu_{II} = \sum \mu_{II}^2 = 79.43195$$

Seguidamente se realiza la d6cimo de hip6tesis:

H₀ : Las varianzas en el modelo considerado son iguales (homocedasticidad)

H₁ : Las varianzas en el modelo considerado no son iguales

$$F_{cal} = \frac{\mu'_{II} \mu_{II} / g. l.}{\mu'_I \mu_I / g. l.} = \frac{\mu'_{II} \mu_{II}}{\mu'_I \mu_I} = \frac{79.43195}{41.09158} = 1.93304687$$

Se observa que el F calculado (F_c=1.933) es menor al F cr6tico (F = 6.39), entonces no se rechaza la hip6tesis nula, es decir, no existe heterocedasticidad en el modelo al 95% de confianza.

b. Test de White

El test de White es un contraste general que no requiere la elecci6n de una variable que explique la volatilidad de los residuos. En particular, esta prueba supone que dicha varianza es una funci6n lineal de los regresores originales del modelo, sus cuadrados y productos cruzados.

$$\mu^2 = f(\beta, X_2, \dots, X_n, X_2^2, \dots, X_n^2, X_2 X_3, \dots, X_{n-1} X_n)$$

La aplicaci6n del test involucra la estimaci6n de una regresi6n auxiliar del cuadrado de los residuos sobre las variables originales del modelo y las transformaciones mencionadas l6neas arriba.

De lo anterior se deduce que conforme mayor sea el grado de ajuste de esta regresi6n auxiliar, mayor ser6 la posibilidad de rechazar la hip6tesis nula de la homocedasticidad. En otras palabras, en la medida en que alguno de los regresores

originales o su transformación expliquen adecuadamente a la varianza del error, no podemos concluir que ésta sea constante.

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

En este test no es necesario especificar la forma que adopta la heterocedasticidad.

3. CORRECCIÓN DE HETEROCEDASTICIDAD

Después de haber detectado que el modelo tiene una variación en la dispersión por cada término de perturbación, es decir:

$$E(\mu'\mu) = \sigma_{\mu}^2 \Omega$$

Donde:

$$\Omega = \begin{bmatrix} a_1 & \dots & 0 \\ 0 & \dots & a_n \end{bmatrix}$$

A continuación se debe encontrar una matriz $P_{n,n}$, tal que $P^{-1}\Omega(P^{-1})' = I$

Por ejemplo en el caso que un valor de la diagonal de la matriz Ω fuera igual a 4 ($a_i=4$), entonces $P_i^{-1} = \frac{1}{\sqrt{4}}$, porque $P^{-1}\Omega(P^{-1})' = I$

En general si cada elemento de Ω tuviera un valor a_i , entonces $P_i^{-1} = 1/\sqrt{a_i}$ donde a_i puede ser $X_i, X_i^2, \sqrt{X_i}, \beta_1 + \beta_2 X_i$, etc.

Una vez hallado P, se procede a corregir los valores originales a partir de una transformación del modelo original:

$$\begin{aligned} Y^* &= P^{-1}Y \\ X^* &= P^{-1}X \end{aligned}$$

Con lo cual para pasar al modelo transformado se tiene que dividir las observaciones de todas las variables por $\sqrt{a_i}$, es decir, por la desviación típica de las perturbaciones

$$\frac{Y_i}{\sqrt{a_i}} = \frac{\beta_1}{\sqrt{a_i}} + \beta_2 \frac{X_{2i}}{\sqrt{a_i}} + \dots + \frac{\beta_k X_{ki}}{\sqrt{a_i}} + \frac{\mu_i}{\sqrt{a_i}}$$

Para obtener los nuevos estimados bastará con reemplazar los valores transformados, obteniéndose:

$$\hat{\beta}_{MCG} = (X'\Omega^{-1}X)^{-1} X'\Omega^{-1}Y$$

$$\text{Var}(\hat{\beta}_{\text{MCG}}) = \sigma_{\mu}^2 (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1} \quad \sigma_{\text{MCG}}^2 = \frac{\hat{\mu}'_{\text{MCG}}\Omega^{-1}\hat{\mu}_{\text{MCG}}}{n-k}$$

Por ejemplo, se tiene el siguiente modelo, el cual presenta el problema de heterocedasticidad:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + \mu_i$$

$$E(\mu_i^2) = \sigma_{\mu}^2 a_i$$

Entonces:

$$\frac{Y_1}{\sqrt{a_1}} = \frac{\beta_1}{\sqrt{a_1}} + \beta_2 \frac{X_{21}}{\sqrt{a_1}} + \dots + \beta_k \frac{X_{k1}}{\sqrt{a_1}} + \frac{\mu_1}{\sqrt{a_1}}$$

$$\frac{Y_n}{\sqrt{a_n}} = \frac{\beta_1}{\sqrt{a_n}} + \beta_2 \frac{X_{2n}}{\sqrt{a_n}} + \dots + \beta_{kn} \frac{X_{kn}}{\sqrt{a_n}} + \frac{\mu_n}{\sqrt{a_n}}$$

En el E-Views se genera una nueva variable, dividiendo entre $\sqrt{a_i}$.

Se tiene los datos de un modelo con 2 variables explicativas (X_2 y X_3):

También: $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \mu_i$ con $E(\mu_i^2) = \sigma_{\mu}^2 a_i$ y $a_i = 10$

Y	X ₂	X ₃
119	10	1
113.2	11	5
⋮	⋮	⋮
⋮	⋮	⋮
636	62	2

Y _T	X _{2T}	X _{3T}	P _T
119/√10	10/√10	1/√10	1/√10
113.2/√11	11/√11	5/√11	1/√11
⋮	⋮	⋮	⋮
636/√62	62/√62	2/√62	1/√62

Ahora, con $Y_i = \beta_T + \beta_2 X_{2T} + \beta_3 X_{3T}$; $E(\mu^2) = \sigma_{\mu}^2 X_2^2$, se tendría lo siguiente:

Y _T	X _{2T}	X _{3T}	P _T
119/10	10/10	1/10	1/10
113.2/11	11/11	5/11	1/11
⋮	⋮	⋮	⋮
636/62	62/62	2/62	1/62

Ejercicio ilustrativo 2 -Heterocedasticidad

Dado el siguiente modelo:

$$INV = \gamma_1 + \gamma_2 PBI + \gamma_3 r + \gamma_4 IPINV + \gamma_5 PR + \mu$$

Donde:

INV = Inversión

PBI = Producto Bruto Interno

r = Tasa de interés real

IPINV = Índice de precios de las inversiones

PR = Precios relativos del PBI con respecto a las inversiones

AÑO	IMPORT	FBK INV	PBI PBI	Tasa interés	IPINV IPINV	IPPBI PR
				real r		
1970	9,491	10,306	62,022	3.500	0.00000035	0.00000036
1971	9,920	11,630	64,627	1.600	0.00000039	0.00000038
1972	9,892	12,069	66,501	4.900	0.00000042	0.00000041
1973	11,110	16,176	70,092	-3.900	0.00000043	0.00000047
1974	14,127	20,066	76,611	-8.300	0.00000049	0.00000054
1975	13,724	20,572	79,215	-11.900	0.00000064	0.00000067
1976	11,995	18,451	80,800	-2.300	0.00000085	0.00000086
1977	12,037	16,413	81,123	-13.800	0.00000119	0.00000117
1978	9,103	14,954	81,366	-30.000	0.00000204	0.00000186
1979	10,860	17,103	86,086	-17.000	0.00000357	0.00000323
1980	14,144	20,846	90,562	-14.600	0.00000567	0.00000528
1981	16,395	24,205	95,181	-6.100	0.00000961	0.00000900
1982	16,758	23,680	94,610	-6.500	0.00001735	0.00001510
1983	11,791	16,545	83,446	-27.600	0.00003857	0.00003140
1984	9,647	15,530	87,785	-21.200	0.00009039	0.00006680
1985	8,812	13,777	90,243	-34.700	0.00027008	0.00017900
1986	10,607	16,303	99,267	-39.900	0.00039877	0.00030900
1987	12,182	19,338	107,208	-41.500	0.00062688	0.00056300
1988	11,091	16,646	97,881	-88.400	0.00529875	0.00410700
1989	8,287	13,349	86,429	-20.370	0.14000000	0.10800000
1990	9,270	13,625	81,983	-18.000	7.61000000	6.75000000
1991	11,130	13,929	83,760	-2.000	31.70000000	31.86000000
1992	12,113	14,060	83,401	-0.280	52.70000000	56.95000000
1993	12,572	15,627	87,375	-0.262	81.10000000	82.16000000
1994	15,922	20,901	98,577	-0.195	100.00000000	100.00000000
1995	20,232	25,468	107,039	-0.505	113.80000000	112.80000000
1996	20,259	24,738	109,709	-0.530	124.70000000	124.70000000
1997	22,724	28,518	117,110	-0.403	131.20000000	134.20000000
1998	23,251	28,110	116,485	0.442	138.90000000	143.30000000
1999	19,724	24,984	117,590	1.439	153.50000000	148.58000000
2000	20,428	23,731	121,267	1.312	159.40000000	154.00000000

Regresionando el modelo:

$$INV = \gamma_1 + \gamma_2 \text{ PBI} + \gamma_3 r + \gamma_4 \text{ IPINV} + \gamma_5 \text{ PR} + \mu$$

Dependent Variable: INV				
Method: Least Squares				
Date: 09/10/02 Time: 15:51				
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
R	116.7644	36.94933	3.160122	0.0040
IPINV	-270.8711	263.4286	-1.028253	0.3133
PR	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	

$\hat{\gamma}_1 = -10954.63$, indica el nivel promedio de las inversiones, cuando el resto de parámetros son cero.

$\hat{\gamma}_2 = 0.353642$, este resultado nos muestra que si el PBI varía en 1%, la inversión varía en 35.3642%

$\hat{\gamma}_3 = 116.7644$, este resultado nos muestra que si la tasa de interés real varía en 1%, la inversión aumentará en 16.7644%

$\hat{\gamma}_4 = -270.871$, este resultado nos muestra que si el índice de precio de las inversiones varía en una unidad, la inversión disminuirá en -270.8711 .

$\hat{\gamma}_5 = 239.2287$, este resultado nos muestra que si los precios relativos del PBI respecto de las inversiones varían en una unidad, la inversión aumentará en 239.2287.

1. TEST DE WHITE (considerando el efecto producido entre regresores)

Ho : Las varianzas en el modelo considerado son iguales (homocedasticidad)

H₁ : Las varianzas en el modelo considerado no son iguales

En este caso se observa que la probabilidad asociada al test de White es de 0.77, la cual es mayor al nivel de significancia escogido (0.05), por lo que se concluye que en un modelo donde no se ha considerado los efectos entre las variables no se presenta homocedasticidad a un nivel de confianza del 95%.

White Heteroskedasticity Test:				
F-statistic	0.596246	Probability	0.770678	
Obs*R-squared	5.523690	Probability	0.700414	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 09/10/02 Time: 16:12				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-15199469	69035028	-0.220170	0.8278
PBI	477.3539	1645.729	0.290056	0.7745
PBI^2	-0.002694	0.009590	-0.280897	0.7814
R	-67263.34	257532.2	-0.261184	0.7964
R^2	-165.3252	2723.256	-0.060709	0.9521
IPINV	-3528052.	2789103.	-1.264941	0.2191
IPINV^2	12724.18	9988.453	1.273889	0.2160
PR	3523473.	2737062.	1.287319	0.2114
PR^2	-12835.23	9849.387	-1.303150	0.2060
R-squared	0.178184	Mean dependent var	5791501.	
Adjusted R-squared	-0.120659	S.D. dependent var	6579776.	
S.E. of regression	6965428.	Akaike info criterion	34.58852	
Sum squared resid	1.07E+15	Schwarz criterion	35.00484	
Log likelihood	-527.1220	F-statistic	0.596246	
Durbin-Watson stat	1.099102	Prob(F-statistic)	0.770678	

2. TEST DE WHITE (Términos cruzados :considerando el efecto producido entre regresores)

Ho: Modelo no presenta heterocedasticidad

H₁: Modelo presenta heterocedasticidad

En este caso se observa que la probabilidad asociada al test de White es de 0.89, la cual es mayor al nivel de significancia escogido (0.05), por lo que se concluye que un modelo donde se considera los efectos entre las variables no se presenta heterocedasticidad a un nivel de confianza del 95%.

White Heteroskedasticity Test:				
F-statistic	0.501012	Probability	0.894325	
Obs*R-squared	8.587010	Probability	0.803371	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 09/10/02 Time: 16:17				
Sample: 1970 2000				
Included observations: 31				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.75E+08	1.73E+08	-1.011368	0.3260
PBI	4660.078	4460.731	1.044689	0.3108
PBI^2	-0.029535	0.028199	-1.047358	0.3096
PBI*R	-25.58410	28.04803	-0.912153	0.3744
PBI*IPINV	541.5411	906.8817	0.597146	0.5583
PBI*PR	-511.7080	894.9488	-0.571774	0.5750
R	2091313.	2411013.	0.867400	0.3978
R^2	-3064.552	4271.637	-0.717419	0.4829
R*IPINV	340891.2	966929.2	0.352550	0.7288
R*PR	-289683.8	977041.4	-0.296491	0.7704
IPINV	-37198665	57450567	-0.647490	0.5260
IPINV^2	-176651.7	342416.2	-0.515898	0.6126
IPINV*PR	167992.1	337804.6	0.497305	0.6253
PR	35194137	56709187	0.620607	0.5431
R-squared	0.277000	Mean dependent var	5791501.	
Adjusted R-squared	-0.275882	S.D. dependent var	6579776.	
S.E. of regression	7432182.	Akaike info criterion	34.78299	
Sum squared resid	9.39E+14	Schwarz criterion	35.43060	
Log likelihood	-525.1363	F-statistic	0.501012	
Durbin-Watson stat	1.187606	Prob(F-statistic)	0.894325	

3. PRUEBA DE GOLDFELD-QUANDT

Se omitirán 11 observaciones centrales y 2 grupos de 10 observaciones cada uno (los datos están ordenados en orden creciente para las variables IPINV, PR).

Se obtiene el estadístico de los residuales:

$$F_c = 9706682 / 18308626 = 0.53016988 \text{ (F-Statistics)}$$

Se realiza la hipótesis:

H_0 : Las varianzas en el modelo considerado son iguales (homocedasticidad)

H_1 : Las varianzas en el modelo considerado no son iguales

El F obtenido de tablas es 5.05, y como su valor es mayor al calculado, se acepta la H_0 , y se concluye que el modelo no presenta problemas de heterocedasticidad.

Regresión sobre el primer grupo:

Dependent Variable: INV				
Method: Least Squares				
Date: 09/10/02 Time: 17:26				
Sample: 1970 1979				
Included observations: 10				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PBI	0.398393	0.279491	1.425422	0.2134
R	26.34102	106.4741	0.247394	0.8144
IPINV	-3.07E+10	3.94E+10	-0.779222	0.4711
PR	3.31E+10	4.58E+10	0.721350	0.5030
C	-14895.39	16213.61	-0.918697	0.4004
R-squared	0.837135	Mean dependent var		15774.00
Adjusted R-squared	0.706842	S.D. dependent var		3534.210
S.E. of regression	1913.563	Akaike info criterion		18.25817
Sum squared resid	18308626	Schwarz criterion		18.40947
Log likelihood	-86.29087	F-statistic		6.425054
Durbin-Watson stat	1.177442	Prob(F-statistic)		0.033108

Regresión sobre el segundo grupo

Dependent Variable: INV				
Method: Least Squares				
Date: 09/10/02 Time: 17:27				
Sample: 1991 2000				
Included observations: 10				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PBI	0.216057	0.153920	1.403694	0.2194
R	-2255.303	1027.193	-2.195597	0.0795
IPINV	-290.1799	168.5920	-1.721196	0.1458
PR	388.3896	159.3789	2.436895	0.0589
C	-11470.34	9260.306	-1.238657	0.2704
R-squared	0.965487	Mean dependent var		22006.60
Adjusted R-squared	0.937877	S.D. dependent var		5590.149
S.E. of regression	1393.319	Akaike info criterion		17.62362
Sum squared resid	9706682.	Schwarz criterion		17.77491
Log likelihood	-83.11809	F-statistic		34.96833
Durbin-Watson stat	2.216423	Prob(F-statistic)		0.000755

LABORATORIO

Con la siguiente información elaboraremos un modelo que explique la relación entre las variables:

$$PBI_{\text{construcción}} = f(\text{VENTA}_{\text{cemento}}, \text{VENTA}_{\text{barra de acero}})$$

$$PBI_{\text{construcción}} = PBI_{\text{co}}$$

$$\text{VENTA}_{\text{cemento}} = VT_{\text{Acem}}$$

$$\text{VENTA}_{\text{barra de acero}} = VT_{\text{Abarra}}$$


$$PBI_{\text{co}} = f(VT_{\text{Acem}}; VT_{\text{Abarra}})$$



Utilizaremos la siguiente información estadística:

<i>Obs</i>	Mes	vtacem	vtabarra	pbi construcción (soles)	<i>Obs</i>	mes	vtacem	vtabarra	pbi construcción (soles)
1	199201	183213	16925	18.3	49	199601	307481	27176	28.8
2	199202	194484	12929	17.0	50	199602	296386	24772	26.3
3	199203	176178	12175	17.3	51	199603	298544	26345	28.5
4	199204	178918	10119	16.7	52	199604	295281	26058	25.3
5	199205	158561	11013	15.4	53	199605	321715	32333	28.1
6	199206	160630	10018	15.0	54	199606	289842	28467	24.9
7	199207	172372	11052	16.1	55	199607	325212	30775	27.3
8	199208	178754	13178	17.3	56	199608	336051	31945	29.3
9	199209	197417	11799	17.9	57	199609	334620	30488	28.4
10	199210	201507	12311	18.2	58	199610	351596	31664	31.3
11	199211	183455	11871	16.2	59	199611	335806	34078	29.9
12	199212	196976	13841	18.6	60	199612	345818	29146	32.6
13	199301	165602	12341	17.1	61	199701	351193	37124	34.0
14	199302	180878	12730	16.8	62	199702	328424	34671	30.5
15	199303	201011	15306	18.5	63	199703	314409	30290	30.2
16	199304	198593	12756	17.9	64	199704	336822	25696	31.8
17	199305	183761	12059	17.0	65	199705	346085	16278	32.1
18	199306	186465	14113	18.5	66	199706	326683	27268	30.7
19	199307	189744	15644	19.2	67	199707	346447	40558	32.8
20	199308	232517	17988	22.2	68	199708	373488	34893	34.1
21	199309	231768	15301	21.4	69	199709	391529	35262	37.5
22	199310	227776	15075	20.3	70	199710	403797	34510	42.3
23	199311	219757	16718	21.0	71	199711	374946	33476	37.5
24	199312	230442	16226	23.5	72	199712	395240	34404	36.5
25	199401	213194	18287	21.9	73	199801	361198	32896	35.1
26	199402	208455	18404	19.9	74	199802	332984	33305	32.8
27	199403	231596	19733	23.5	75	199803	359779	31045	35.4
28	199404	220376	18092	22.4	76	199804	331183	28486	32.4
29	199405	235017	18136	22.7	77	199805	321998	23684	31.1
30	199406	233380	19054	23.5	78	199806	344054	33549	33.5
31	199407	246724	17217	24.0	79	199807	372117	36077	36.1
32	199408	299957	23004	27.6	80	199808	425734	36791	38.2
33	199409	317009	23204	29.8	81	199809	397771	38757	37.5

Obs	Mes	vtacem	vtabarra	pbi construcción (soles)	Obs	mes	vtacem	vtabarra	pbi construcción (soles)
34	199410	320803	23613	30.1	82	199810	353001	32837	36.6
35	199411	333757	18895	29.5	83	199811	348144	25179	34.4
36	199412	318943	21024	31.2	84	199812	343260	23133	32.3
37	199501	292259	26109	28.8	85	199901	311203	29896	30.5
38	199502	285689	23562	27.2	86	199902	273058	25760	27.6
39	199503	315214	24692	29.8	87	199903	331499	27957	30.8
40	199504	293054	25080	28.2	88	199904	284956	24050	27.5
41	199505	326852	23499	32.3	89	199905	278223	24667	25.1
42	199506	296535	26479	29.4	90	199906	285707	25501	26.4
43	199507	302599	25651	28.7	91	199907	300335	27220	28.2
44	199508	335925	26872	31.8	92	199908	324273	32619	31.4
45	199509	328595	26406	30.6	93	199909	339146	34993	32.8
46	199510	338925	26564	32.1	94	199910	343501	34588	36.1
47	199511	327876	27194	30.2	95	199911	353612	30587	35.3
48	199512	306074	24807	29.5	96	199912	350593	27946	32.8
					97	200001	312532	31391	32.0

1. En primer lugar se analiza la información estadística, mediante su evolución en el tiempo:





Del análisis de la serie de las variables en el tiempo podemos comentar lo siguiente:

- El Producto Bruto interno del sector construcción y la Venta de Cemento muestran comportamientos similares en su evolución mensual desde 1992 hasta enero del 2001, es decir a primera vista existe una relación directa e importante entre las dos variables.
- Coinciden los periodos de mayores niveles registrados en el PBI Construcción y la venta de Cemento. Las cuales fueron en enero de 1997 y enero de 1998.
- La tendencia (Lineal) observada en las tres variables son crecientes
- Se puede observar en la serie de ventas de barras, que a partir de la observación 60 (principios de 1997), el comportamiento de dicha variable es bastante irregular pero que no se reflejaría en forma gravitante el comportamiento del PBI construcción, puesto a primera vista mantiene una mayor relación con la variable Venta de Cemento.

2. Estimación del Modelo Lineal

$$\begin{aligned}
 \text{PBIco} &= f(\text{VTAcem}; \text{VTAbarra}) \\
 \text{PBIco} &= C(1) + C(2)*\text{VTAcem} + C(3)*\text{VTAbarra}
 \end{aligned}$$

Dependent Variable: PBICO				
Method: Least Squares				
Date: 09/18/02 Time: 23:23				
Sample: 1 97		Included observations: 97		
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.359737	0.667219	0.539158	0.5911
VTACEM	9.02E-05	4.84E-06	18.61325	0.0000
VTABARRA	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	

3. Especificación del modelo: Test de Reset Ramsey

Ramsey RESET Test:				
F-statistic	0.245591	Probability	0.782753	
Log likelihood ratio	0.516500	Probability	0.772402	
Test Equation:				
Dependent Variable: PBICO				
Method: Least Squares				
Date: 09/19/02 Time: 22:55				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.740340	9.829252	0.075320	0.9401
VTACEM	9.16E-05	0.000108	0.846452	0.3995
VTABARRA	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	

La probabilidad asociada a este estadístico nos señala que a un nivel de significancia del 5% no se debe rechazar la H_0 , es decir que el modelo está correctamente especificado. Esta conclusión errónea que contradice el planteamiento inicial, nos conduce a especificar que hay problemas de multicolinealidad y lo primero que debe hacerse es plantear la solución del problema de multicolinealidad

4. Detectando la Multicolinealidad

Analizando la Matriz de Correlación entre las variables independientes:

	VTACEM	VTABARRA
VTACEM	1.000000	0.905848
VTABARRA	0.905848	1.000000

Se observa que las variables VTACEM están correlacionada con la variable VTABARRA

Probando los siguientes modelos:

Dependent Variable: PBICO				
Method: Least Squares				
Date: 09/19/02 Time: 00:23				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.081367	0.609807	0.133431	0.8941
VTACEM	9.47E-05	2.05E-06	46.12258	0.0000
R-squared	0.957251	Mean dependent var		27.47113
Adjusted R-squared	0.956801	S.D. dependent var		6.567644
S.E. of regression	1.365038	Akaike info criterion		3.480644
Sum squared resid	177.0161	Schwarz criterion		3.533731
Log likelihood	-166.8112	F-statistic		2127.293
Durbin-Watson stat	1.048183	Prob(F-statistic)		0.000000

Dependent Variable: PBICO				
Method: Least Squares				
Date: 09/19/02 Time: 00:32				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	9.612641	0.958264	10.03131	0.0000
VTABARRA	0.000734	3.74E-05	19.61101	0.0000
R-squared	0.801915	Mean dependent var		27.47113
Adjusted R-squared	0.799830	S.D. dependent var		6.567644
S.E. of regression	2.938390	Akaike info criterion		5.014004
Sum squared resid	820.2430	Schwarz criterion		5.067091
Log likelihood	-241.1792	F-statistic		384.5916
Durbin-Watson stat	0.940910	Prob(F-statistic)		0.000000

Se ratifica la apreciación inicial que la variable VTAcem es la que mejor se ajusta, pero existen problemas de autocorrelación que es necesario corregir; sin embargo ambas variables son significativas

Por lo tanto la ecuación estimada sería:

$$PBICO = C(1) + C(2)*VTACEM + C(3)*VTABARRA$$

$$PBICO = 0.3597366667 + 9.015568921E-05*VTACEM + 4.213246486E-05*VTABARRA$$

Interpretación:

El intercepto de la ecuación es 0.3597

Ante una variación de 1 nuevo sol en los PBICO, las ventas de cemento se incrementarán en 9.01556E-05 nuevos soles. y las ventas de barras de acero se incrementarían en 4.21324E-05 nuevos soles

Significancia individual y conjunta del Modelo.

Individualmente el modelo es significativo demostrado mediante la prueba T, cuyas probabilidades son menores que 0.05, tanto del coeficiente de ingresos como del intercepto.

En conjunto el modelo es significativo, demostrado por la prueba F al ser su probabilidad menor a 0.05. Asimismo, la bondad de ajuste, medida a través del R^2 y R^2 ajustado, demuestra un buen ajuste. (Alrededor del 95%).

5. Detección de la Heterocedasticidad.

a. Contraste 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

H_0 : El Modelo es homoscedástico.

H_1 : El Modelo no es homoscedástico.

White Heteroskedasticity Test:				
F-statistic	3.313768	Probability	0.013903	
Obs*R-squared	12.21549	Probability	0.015819	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Sample: 1 97				
			Included observations: 97	
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6.734537	5.976135	1.126905	0.2627
VTACEM	-9.79E-05	7.00E-05	-1.398090	0.1654
VTACEM^2	1.58E-10	1.15E-10	1.369796	0.1741
VTABARRA	0.000623	0.000470	1.324816	0.1885
VTABARRA^2	-8.63E-09	8.56E-09	-1.008019	0.3161
R-squared	0.125933	Mean dependent var	1.804675	
Adjusted R-squared	0.087930	S.D. dependent var	3.080460	
S.E. of regression	2.941912	Akaike info criterion	5.046167	
Sum squared resid	796.2458	Schwarz criterion	5.178884	
Log likelihood	-239.7391	F-statistic	3.313768	
Durbin-Watson stat	1.477165	Prob(F-statistic)	0.013903	

Como Prob.= 0.010805 < 0.05. Entonces se rechaza la hipótesis nula. Es decir el Modelo es no homoscedástico, es decir existen problemas de heteroscedasticidad, con un nivel de confianza del 95%.

b. 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.

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.

<i>GRUPO I</i>	<i>GRUPO II</i>
$\hat{\sigma}_{\mu_I}^2 = \frac{e_I' e_I}{n_1 - k}$	$\hat{\sigma}_{\mu_{II}}^2 = \frac{e_{II}' e_{II}}{n_2 - k}$

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

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

En el Eviews:

- En el Excel ordenar las observaciones de la serie en orden creciente, tomando como referencia los datos de la variable exógena.
- Omitir $c = 33$ observaciones centrales, y dividir las observaciones restantes $(n-c)$ en dos grupos, cada uno de $(n-33)/2 = 32$ 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 (PBICOSORT e VTACEMSORT, VTABARRASORT).
- Regresionar el modelo $ls\ pbicosort\ c\ vtacemsort\ vtabarrasort$. En el Workfile se selecciona las variables $pbicosord$, $vtacemsort$, $vtabarrasort$. 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 32 y OK.
- Se obtiene los siguientes resultados:

Dependent Variable: PBICOSORT				
Method: Least Squares				
Sample: 1 32				
Included observations: 32				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.280431	1.479442	1.541414	0.1341
VTACEMSORT	7.10E-05	1.25E-05	5.688875	0.0000
VTABARRASORT	0.000177	9.68E-05	1.831155	0.0774
R-squared	0.881644	Mean dependent var		19.38125
Adjusted R-squared	0.873482	S.D. dependent var		2.834401
S.E. of regression	1.008179	Akaike info criterion		2.943229
Sum squared resid	29.47634	Schwarz criterion		3.080642
Log likelihood	-44.09166	F-statistic		108.0121
Durbin-Watson stat	1.240423	Prob(F-statistic)		0.000000

Regresionar el modelo $ls\ pbicosort\ c\ vracemsort\ vtabarrasort$. Con la muestra de 65 97.

Dependent Variable: PBICOSORT				
Method: Least Squares				
Sample: 65 97				
Included observations: 33				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.874702	3.337960	1.460384	0.1546
VTACEMSORT	7.73E-05	1.11E-05	6.999134	0.0000
VTABARRASORT	6.24E-05	5.28E-05	1.182145	0.2464
R-squared	0.734387	Mean dependent var		34.11212
Adjusted R-squared	0.716680	S.D. dependent var		2.605494
S.E. of regression	1.386848	Akaike info criterion		3.578453
Sum squared resid	57.70045	Schwarz criterion		3.714499
Log likelihood	-56.04447	F-statistic		41.47317
Durbin-Watson stat	2.071584	Prob(F-statistic)		0.000000

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

$$F_{\text{cal}} = \frac{e'_{II}e_{II} / g.l.}{e'_I e_I / g.l.} = \frac{e'_{II}e_{II}}{e'_I e_I} = \frac{57.70045}{29.47634} = 1.955752$$

A continuación se realiza la hipótesis

Ho: No Existe heteroscedasticidad

H₁: Existe heteroscedasticidad

- El F_(29,5) de tablas a un nivel del 5% de significancia es 3.33 , como el F de la tabla es mayor al F calculado, entonces se acepta la Ho. Se concluye que el modelo no presenta problemas de Heteroscedasticidad.

6. Detección de la Autocorrelación


Dependent Variable: PBICO				
Method: Least Squares				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.359737	0.667219	0.539158	0.5911
VTACEM	9.02E-05	4.84E-06	18.61325	0.0000
VTABARRA	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

a. Estadístico DURBIN WATSON

Como sabemos el estadístico Durbin Watson mide la autocorrelación de primer grado.

Del modelo:

k = 3	⇒	D _L = 1.623
n = 97		4 - D _L = 2.377
α = 0.05		D _U = 1.709
		4 - D _U = 2.291



Del Output tenemos que el indicador Durbin Watson es 0.988372, por lo tanto podemos afirmar que existen problemas de autocorrelación positiva de primer orden con un nivel de significancia del 5%.

c. Test de LAGRANGE

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	15.97282	Probability	0.000001	
Obs*R-squared	25.00070	Probability	0.000004	
Test Equation:				
Dependent Variable: RESID				
Method: Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.271809	0.584724	0.464850	0.6431
VTACEM	-4.15E-06	4.32E-06	-0.960251	0.3394
VTABARRA	3.86E-05	3.67E-05	1.052314	0.2954
RESID(-1)	0.495633	0.106093	4.671671	0.0000
RESID(-2)	0.051753	0.106989	0.483723	0.6297
R-squared	0.257739	Mean dependent var	3.31E-15	
Adjusted R-squared	0.225467	S.D. dependent var	1.350361	
S.E. of regression	1.188420	Akaike info criterion	3.233296	
Sum squared resid	129.9354	Schwarz criterion	3.366013	
Log likelihood	-151.8149	F-statistic	7.986412	
Durbin-Watson stat	1.955360	Prob(F-statistic)	0.000014	

Como Prob.= 0.000042 < 0.05. Entonces se rechaza la hipótesis nula. Es decir el Modelo tiene problemas de autocorrelación con una probabilidad del 95%.

d. Test Estadístico Ljung y Box

H0 : El Modelo no tiene autocorrelación hasta el orden p(p =2).

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

Date: 09/20/02 Time: 10:37						
Sample: 1 97						
Included observations: 97						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. ****	. ****	1	0.491	0.491	24.143	0.000
. **	. .	2	0.275	0.045	31.800	0.000
. **	. **	3	0.325	0.230	42.611	0.000
. **	. .	4	0.239	-0.008	48.522	0.000
. **	. *	5	0.199	0.069	52.669	0.000
. *	. .	6	0.153	-0.028	55.138	0.000
. *	. .	7	0.095	-0.018	56.106	0.000
. .	. *	8	0.041	-0.060	56.283	0.000
. *	. *	9	0.111	0.115	57.625	0.000
. .	. *	10	0.008	-0.136	57.632	0.000
. .	. *	11	0.026	0.099	57.709	0.000
. *	. *	12	0.180	0.154	61.357	0.000
. .	**	13	-0.042	-0.247	61.563	0.000
**	**	14	-0.202	-0.189	66.296	0.000
. *	. .	15	-0.111	0.008	67.751	0.000
**	. *	16	-0.193	-0.171	72.160	0.000
**	. .	17	-0.192	0.042	76.565	0.000
. *	. .	18	-0.128	0.027	78.543	0.000
. *	. .	19	-0.145	0.028	81.117	0.000
. *	. .	20	-0.162	-0.025	84.384	0.000
. *	. .	21	-0.095	0.001	85.518	0.000
. *	. .	22	-0.060	0.061	85.974	0.000
. .	. .	23	-0.036	0.052	86.141	0.000
. .	. *	24	0.010	-0.077	86.154	0.000
. *	. *	25	-0.151	-0.123	89.189	0.000
**	. *	26	-0.244	-0.107	97.216	0.000
. *	. *	27	-0.187	-0.118	102.02	0.000
. *	. .	28	-0.182	0.002	106.63	0.000
**	. *	29	-0.208	-0.060	112.74	0.000
. *	. .	30	-0.164	-0.037	116.58	0.000
. *	. .	31	-0.140	0.008	119.44	0.000
. *	. .	32	-0.118	0.024	121.50	0.000
. .	. *	33	0.027	0.165	121.61	0.000
. .	. .	34	0.029	-0.008	121.74	0.000
. *	. *	35	-0.064	-0.150	122.37	0.000
. .	. .	36	-0.048	-0.040	122.73	0.000

Debido a que las probabilidades son menores a 0.05 se puede decir que existe autocorrelación de orden 1,2,3 ...15 o 36. con una probabilidad del 95%

7. Corrección de la Autocorrelación

a. Estadístico Durbin Watson

Analizaremos la autocorrelación de primer orden

PRIMER CAMBIO DE VARIABLE.

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

Así corregimos nuevamente con $d = 0.988372$

Además:

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

$$\rho = 0.505814$$

Así generando nuevas variables:

1. $pbicod = pbico - 0.505814 * pbico(-1)$, de 1 - 97
2. $vtacemd = vtacem - 0.505814 * vtacem(-1)$, de 1 - 97
3. $vtabarrad = vtabarra - 0.505814 * vtabarra(-1)$, de 1 - 97

1. $pbicod = ((1 - 0.505814^2)^{1/2}) * pbico$, de 1.
2. $vtacemd = ((1 - 0.505814^2)^{1/2}) * vtacem$, de 1.
3. $vtabarrad = ((1 - 0.505814^2)^{1/2}) * vtabarra$, de 1.

eqprimercambio

Dependent Variable: PBICOD				
Method: Least Squares				
Date: 09/20/02 Time: 11:04				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.658307	0.509521	1.292012	0.1995
VTACEMD	8.19E-05	4.99E-06	16.42719	0.0000
VTABARRAD	0.000103	3.85E-05	2.683052	0.0086
R-squared	0.886550	Mean dependent var		13.74272
Adjusted R-squared	0.884136	S.D. dependent var		3.549567
S.E. of regression	1.208231	Akaike info criterion		3.246630
Sum squared resid	137.2232	Schwarz criterion		3.326261
Log likelihood	-154.4616	F-statistic		367.2785
Durbin-Watson stat	1.914361	Prob(F-statistic)		0.000000

Se observa que se ha corregido el problema de autocorrelación, por lo tanto ya no sería necesario realizar un segundo cambio de variable. El modelo es significativo individualmente y grupalmente sus probabilidades son menores que 0.05 nivel de significancia; así como, también su nivel de ajuste es bueno 88.86%.

SEGUNDO CAMBIO DE VARIABLE

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

Así corregimos nuevamente con $d = 1.914361$

Además:

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

$$\rho = 0.0428195$$

Así generando nuevas variables:

1. $pbicod1 = pbicod - 0.0428195 * pbicod(-1)$, de 1 - 97
 2. $vtacemd1 = vtacemd - 0.0428195 * vtacemd(-1)$, de 1 - 97
 3. $vtabarrad1 = vtabarrad - 0.0428195 * vtabarrad(-1)$, de 1 - 97
-
1. $pbicod1 = ((1 - 0.0428195^2)^{1/2}) * pbicod$, de 1.
 2. $vtacemd1 = ((1 - 0.0428195^2)^{1/2}) * vtacemd$, de 1.
 3. $vtabarrad1 = ((1 - 0.0428195^2)^{1/2}) * vtabarrad$, de 1.


eqsegundocambio

Dependent Variable: PBICOD1				
Method: Least Squares				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.632366	0.503292	1.256460	0.2121
VTACEMD1	8.17E-05	5.03E-06	16.24054	0.0000
VTABARRAD1	0.000106	3.85E-05	2.765122	0.0068
R-squared	0.879736	Mean dependent var		13.16089
Adjusted R-squared	0.877177	S.D. dependent var		3.453524
S.E. of regression	1.210325	Akaike info criterion		3.250095
Sum squared resid	137.6994	Schwarz criterion		3.329725
Log likelihood	-154.6296	F-statistic		343.8069
Durbin-Watson stat	1.990701	Prob(F-statistic)		0.000000

Se observa que ha mejorado mas aun la autocorrelación obteniéndose un valor de Durbin Watson alrededor de 2 las variables son significativas tanto individualmente y gradualmente. Lo que implica que ya no existen problemas de autocorrelación

Midiendo la autocorrelación de primer orden:

Donde:	$D_L = 1.297$
k' = numero de variables explicativas	$\Rightarrow 4 - D_L = 2.703$
(numero de parámetros menos 1)	$D_U = 1.570$
n = numero de observaciones	$4 - D_U = 2.430$
	$D_{k'; n, \alpha} = D_{2'; 97; 0.05}$



Se observa que estadístico Durbin Watson es 1.990701, encontrándose en la zona de no autocorrelación y tiene un valor cercano a 2 por lo tanto se puede afirmar que modelo ya no tiene problemas de autocorrelación. Sin embargo pierde ligeramente bondad de ajuste, aun cuando el modelo en conjunto sigue explicando a la variable dependiente (Prueba F).

b. Procedimiento Iterativo De Cochran Orcutt

Mediante el proceso Cochran Orcutt lo que se pretende es obtener una estimación para la autocorrelación, el cual esta basado en la estimación del ρ como coeficiente de autocorrelación propiamente dicha.

$$\rho = \frac{\sum \mu_t \mu_{t-1}}{\sum \mu_t^2}$$

Asimismo se puede estimar con el modelo:

$$\mu_t = \rho \mu_{t-1} + \varepsilon_t$$

PRIMERA ETAPA: Regresionamos el modelo por MCO:

Eqreisduo2

Dependent Variable: RESID1				
Method: Least Squares				
Sample(adjusted): 2 97				
Included observations: 96 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.003863	0.120577	0.032035	0.9745
RESID1(-1)	0.504543	0.090485	5.575963	0.0000
R-squared	0.248549	Mean dependent var		-0.007390
Adjusted R-squared	0.240555	S.D. dependent var		1.355476
S.E. of regression	1.181245	Akaike info criterion		3.191628
Sum squared resid	131.1619	Schwarz criterion		3.245052
Log likelihood	-151.1981	F-statistic		31.09137
Durbin-Watson stat	1.949211	Prob(F-statistic)		0.000000

El coeficiente estimado de la variable RESID1 rezagada es 0.504543 el cual aproximamos como un $\hat{\rho} = 0.504543$, cuyo valor servirá para corregir a las variables. Para ello debo generar nuevas variables:

Así generando nuevas variables:

1. pbico2 = pbico - 0.504543 * pbico(-1) , de 1 - 97
2. vtacem2 = vtacem - 0.504543 * vtacem(-1) , de 1 - 97
3. vtabarra2 = vtabarra - 0.504543 * vtabarra(-1) , de 1 - 97

1. pbico2 = ((1 - 0.504543²)^(1/2)) * pbico , de 1.
2. vtacem2 = ((1 - 0.504543²)^(1/2)) * vtacem , de 1.
3. vtabarra2 = ((1 - 0.504543²)^(1/2)) * vtabarra , de 1.

Haciendo la regresión:

Eqcochran2

Dependent Variable: PBICO2				
Method: Least Squares				
Sample: 1 97				
Included observations: 97				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.471690	0.846490	2.919926	0.0044
VTACEM2	2.71E-05	3.98E-06	6.816105	0.0000
VTABARRA2	0.000285	5.84E-05	4.888779	0.0000
R-squared	0.708297	Mean dependent var		13.75144
Adjusted R-squared	0.702091	S.D. dependent var		3.531647
S.E. of regression	1.927611	Akaike info criterion		4.180879
Sum squared resid	349.2743	Schwarz criterion		4.260510
Log likelihood	-199.7727	F-statistic		114.1228
Durbin-Watson stat	2.065389	Prob(F-statistic)		0.000000

Se puede seguir haciendo una segunda da etapa pero el modelo esta significativamente bien representado por sus variables tanto individualmente como colectivamente. Asimismo, el indicador de autocorrelación esta prácticamente tiene el valor de 2 y la bondad de ajuste es regular


8. Predicción

De acuerdo a lo resultados de loa modelos podemos realizar la predicción. Como ejercicio podemos realizar una predicción para todo el año 2001 con los siguientes datos. Asumimos la proyección de ventas de cemento y barras de acero las mismas del año anterior en sus respectivos meses.

Obs	mes	vtacem	vtabarra	pbi construcción (soles)
98	200002	273058	25760	
99	200003	331499	27957	
100	200004	284956	24050	
101	200005	278223	24667	
102	200006	285707	25501	
103	200007	300335	27220	
104	200008	324273	32619	
105	200009	339146	34993	
106	200010	343501	34588	
107	200011	353612	30587	
108	200012	350593	27946	

ls pbicod c vtacemd vtabarrad

- vtacemd = vtacem-0.505814*vtacem(-1) , de 1 - 108
- vtabarrad = vtabarra -0.505814* vtabarra(-1) , de 1 - 108




Se puede observar que el coeficiente de Thiel es 0.04701 un valor bajo por lo que podemos decir que este modelo es bueno para predecir

Obs	MES	PBICO (Proyectado)
98	200002	11.09940
99	200003	18.04491
100	200004	11.29099
101	200005	12.93600
102	200006	13.88217
103	200007	14.90450
104	200008	16.72722
105	200009	16.91694
106	200010	16.49161
107	200011	16.74780
108	200012	16.01764

Similarmente para el modelo para el modelo: ls pbico2 c vtacem2 vtabarra2

1. $vtacem2 = vtacem - 0.504543 * vtacem(-1)$, de 1 – 108
2. $vtabarra2 = vtabarra - 0.504543 * vtabarra(-1)$, de 1 – 108




Se observa que el coeficiente de Thiel es de 0.40632 un valor bajo por lo tanto podemos decir también que es bueno para la predicción

Obs	MES	PBICO (Proyectado)
98	200002	11.11225
99	200003	18.03578
100	200004	11.30535
101	200005	12.93555
102	200006	13.87940
103	200007	14.89795
104	200008	16.70553
105	200009	16.89987
106	200010	16.48244
107	200011	16.75377
108	200012	16.02631

También podemos realizar para el siguiente modelo ls pbico3 c vtacem3 vtabarra3

1. $vtacem3 = vtacem - 0.5072557 * vtacem(-1)$, de 1 – 108
2. $vtabarra3 = vtabarra - 0.5072557 * vtabarra(-1)$, de 1 – 108



Se observa que el coeficiente de Thiel es de 0.040843 un valor bajo por lo tanto podemos decir también que es bueno para la predicción

Obs	MES	PBICO (Proyectado)
98	200002	11.03173
99	200003	17.96265
100	200004	11.22143
101	200005	12.86271
102	200006	13.80746
103	200007	14.82383
104	200008	16.62779
105	200009	16.81514
106	200010	16.39360
107	200011	16.66291
108	200012	15.93456

Se observa que los valores son bastante semejantes por lo que existe buena consistencia en la predicción, podemos escoger el modelo que tiene el menor coeficiente de Thiel, en este caso segundo modelo.

Como las variables que se han mostrado son variables transformadas, entonces para realizar las proyecciones de la variable dependiente original simplemente se despeja de las ecuaciones siguientes

$$pbicodf = pbico - 0.505814 * pbico(-1)$$

$$pbicod2f = pbico - 0.504543 * pbico(-1)$$

$$pbicod3f = pbico - 0.507256 * pbico(-1)$$

Reemplazando y calculando podemos obtener las predicciones para cada observación

Ejercicio de autoconocimiento

¿Porqué hacer un Levantamiento de Supuestos?

	SI	NO	NO SÉ
1. Considero útil para resolver problemas que se presentan cuando se hace un estudio.			
2. Porque permitirá hacer un análisis de los modelos en cuanto a las variables que intervienen			
3. Porque mediante su detección y su corrección permitirá dar buenas conclusiones.			
4. Para que exista una eficacia en la evaluación de los coeficientes.			
5. Para dar soluciones alternativas a los problemas.			
6. Porque permite hacer recomendaciones para el comportamiento de las variables dependientes.			
7. Para determinar si el modelo presenta problemas de autocorrelación, de multicolinealidad y/o de heteroscedasticidad.			
8. Para que el responsable de la gestión empresarial pueda corregir dichos problemas.			
9. Para resolver problemas y solucionarlos			
10. Porque al usar el levantamiento de supuestos se recomendará el modelo apropiado a trabajar.			

CALIFICACION

Puntuar con un punto cada respuesta "SI".

Si obtienes de 1 - 3 puntos tienes pocas expectativas de hacer un buen levantamiento de supuestos.

Si tienes entre 4 - 7, tienes buenas expectativas de hacer un buen levantamiento de supuestos.

Y si tienes entre 8 - 10, denotas excelentes expectativas de hacer un buen levantamiento de supuestos.

RESUMEN

La multicolinealidad es un problema que aparece cuando las variables explicativas de un modelo están correlacionadas entre sí.

Hay dos de Clases de muticolinealidad:

-Multicolinealidad Perfecta	$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \mu_i$	$X_3 = kX_2$
-Multicolinealidad Imperfecta	$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \mu_i$	$X_3 = kX_2 + \mu_i$

La autocorrelación es la relación que se da entre las variables perturbadoras (μ), contraviniendo uno de los supuestos para estimar el modelo a partir de la independencia que debería existir entre estas variables.

Este problema se presenta fundamentalmente cuando se realizan estudios econométricos de series históricas.

La heterocedasticidad es un caso particular que se presenta en un modelo cuando la varianza de error no es constante, es uno de los supuestos iniciales que se plantean al elaborar un modelo lineal general

EXPLORACIÓN ON LINE

1. El Problema de la Multicolinealidad. Detección de la multicolinealidad.
www.monografias.com/trabajos10/promu/promu.shtml - 54k

2. Multicolinealidad en el modelo de regresión lineal múltiple.
www.udc.es/dep/mate/estadistica2/sec9_2.html - 57k -

3. Multicolinealidad. Autocorrelación
www.stockssite.com/pf/17_Autocorrelacion.htm - 35k -

4. Autocorrelación. El método de Durbin Watson .
www.stockssite.com/pf/17_Autocorrelacion.htm - 35k -

LECTURA: Problema de Multicolinealidad

Uno de los supuestos del modelo de regresión lineal, es que no debe haber un alto grado de correlación entre las variables predeterminadas, pues esto, trae serias consecuencias que podemos resumir así:

Los estimadores por mínimos cuadrados ordinarios siguen siendo lineales, insesgados y óptimos pero las estimaciones tienen varianzas y covarianzas grandes.

Las razones t de uno o más coeficientes tienden a ser estadísticamente no significativas, con lo que se pierde de perspectiva el análisis.

Aun cuando la razón t de uno o más coeficientes, es estadísticamente no significativa, el coeficiente de determinación tiende a ser elevado, con lo que se demuestra que no se puede separar el efecto individual de cada variable predeterminada hacia la endógena.

Luego entonces, es necesario que luego de estimado un modelo, tengamos que determinar la existencia o no de un alto grado de correlación entre las variables predeterminadas.

Los métodos de detección de multicolinealidad son:

1.- Método de la relación entre t y R^2

Mediante este método podemos determinar la existencia de multicolinealidad observando las razones t y si estas no son estadísticamente significativas y contamos con un coeficiente de determinación elevado (superior a 0.80), podemos estar ante un síntoma claro de multicolinealidad.

2.- Método de la matriz de correlación

Como el problema de multicolinealidad es un problema con las variables predeterminadas, establecemos una matriz de correlación entre aquellas

3.- Método de la prueba F

En un modelo de $K-1$ variables predeterminadas, es conveniente determinar cual de las mencionadas variables X esta correlacionada con las restantes para lo cual hay necesidad de hacer regresiones auxiliares de cada X con las restantes y obtener el R^2 correspondiente.

4.- Método de los valores propios e índice de condición

El tema de los valores propios es uno puramente matemático, que tiene que ver con el álgebra matricial y que de alguna manera ponemos de manifiesto en el apéndice y que son calculados por los paquetes econométricos y matemáticos del caso. En todo caso, partiendo de los valores propios de la matriz $X'X$, que es la que contiene las variables predeterminadas, se establece lo que se conoce como número de condición (K).

Javier Uriol Chávez

ACTIVIDADES

1. ¿Cuál de los siguientes enunciados van de acuerdo a la definición de multicolinealidad?
 - a. Se presentan con frecuencia en los problemas econométricos y no incumplen ninguna suposición del modelo lineal clásico.
 - b. Un tamaño de muestra considerable ($n > 100$) asegura la no existencia de multicolinealidad
 - c. La varianza de los estimadores decrece a medida que el determinante de la matriz $(X'X)$ este más alejado de 1.
 - d. Los estimadores obtenidos son significativos ya que en presencia de multicolinealidad se obtienen estimadores de varianza mínima.

2. Para explicar el comportamiento del ahorro neto familiar (ANF) se ha considerado conveniente considerar a la renta disponible familiar (RDF) y los impuestos directos pagados por las familias (IPF) Por lo que la función de ahorro familiar es:

$$ANF = \beta_1 + \beta_2 RDF + \beta_3 IPF$$

Matriz de Correlación			
	AFN	RDF	IPF
AFN	1	0.97284	0.96297
RDF	0.97284	1	0.99243
IPF	0.96297	0.99243	1

Dependent Variable: AFN				
Method: Least Squares				
Date: 11/11/04 Time: 11:51				
Sample: 1982 2002				
Included observations: 23				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
RDF	0.0919	0.0268	3.4278	0.0017
IPF	-0.0936	0.1870	0.2351	0.6202
C	29327.910	124724.6	0.2351	0.8156
R-squared	0.946834	Mean dependent var		1540511.0
Adjusted R-squared	0.943511	S.D. dependent var		1429436.0
S.E. of regresión	339740.7	Akaike info criterion		28.3916
Sum squared resid	3.69E+12	Schwarz criterion		28.5249
Log likelihood	-493.8525	F-statistic		284.9423
Durbin-Watson stat	1.72674	Prob(F-statistic)		0.0000

Dependent Variable: Y AFN

Method: Least Squares				
Date:09/29/04 Time: 11:59				
Sample: 1982 2002				
Included observations: 23				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
IPF	0.5425	0.0264	20.5182	0.0000
C	368624.500	87373.6700	4.2189	0.0002
R-squared	0.927312	Mean dependent var	1540511.0	
Adjusted R-squared	0.925109	S.D. dependent var	1429436.0	
S.E. of regresión	391181.6	Akaike info criterion	28.6472	
Sum squared resid	5.05E+12	Schwarz criterion	28.7361	
Log likelihood	-499.3256	F-statistic	420.9957	
Durbin-Watson stat	1.775222	Prob(F-statistic)	0.0000	

De acuerdo a las tablas mostradas, ¿El modelo propuesto inicialmente es adecuado para explicar la variabilidad del ahorro? Si no lo es ¿cuál cree que lo será?

3. Considere un modelo que trata de explicar el número de tarjetas de crédito por familia, para lo cual se propone:

Y : Número de tarjetas de crédito por familia

X_1 : Número de miembros por familia

X_2 : Renta familiar

X_3 : Número de vehículos por familia

Identificar qué problema que se presenta por considerar las variables anteriormente mencionadas

4. Con relación a la heterocedasticidad que afirmación es correcta
 - a. No se produce una pérdida de eficiencia en el estimador de mínimos cuadrados.
 - b. Por lo general no se presentan en muestras cuyos datos son valores que se han obtenido agregando o promediando datos individuales.
 - c. No es una violación una de las hipótesis sobre las que se asienta el modelo de regresión lineal clásico.
 - d. Los contrastes estadísticos usados no plantean la hipótesis nula si un modelo presenta o no heterocedasticidad, si no la presencia de homocedasticidad.

AUTOEVALUACIÓN

Encierra en un círculo la letra que contenga la alternativa correcta.

1. La multicolinealidad aparece cuando las variables..... de un modelo están correlacionadas entre sí.
 - a. Independientes
 - b. Dependientes
 - c. Explicadas
 - d. Explicativas

2. Las clases de multicolinealidad son:
 - a. Simple y compuesta
 - b. Variable y fija
 - c. Perfecta e imperfecta
 - d. Ninguna de las anteriores

3. Una de las reglas prácticas para detectar la multicolinealidad es:
 - a. R^2 es alto, no existe significancia individual de los regresores pero sí conjunta.
 - b. Existe significancia conjunta de todos los regresores
 - c. Modelo no es significativo con un R^2 elevado
 - d. Ninguna de las anteriores

4. Uno de los métodos para corregir la multicolinealidad sería:
 - a. Anular dos variables explicativas
 - b. Ampliando el tamaño la muestra
 - c. Ampliando la población
 - d. Ninguna de las anteriores

5. La autocorrelación se presenta fundamentalmente cuando se realizan estudios econométricos de:
 - a. Series históricas
 - b. Estudios de corte transversal
 - c. Modelos significativos
 - d. Ninguna de las anteriores

5. Para poder describir el ahorro neto familiar se ha considerado a la renta neta disponible (RNDFAM) y los impuestos directos pagados por las familias (TDFAM). Para tal fin se ha considerado el modelo siguiente:

$$SNF = \beta_1 + \beta_2 RNDFAM + \beta_3 TDFAM + \mu$$

Matriz de Correlación

	SNFAM	RNDFAM	TDFAM
SNFAM	1.0000	0.9728	0.9630
RNDFAM	0.9728	1.0000	0.9924
TDFAM	0.9630	0.9924	1.0000

Modelo de Regresión Inicial

Dependent Variable: SNFAM				
Method: Least Squares				
Sample: 1964 1998		Included observations: 35		
Variable	Coefficient	Std. Error	t-Statistic	Prob.
RNDFAM	0.091864	0.0268	3.42779	0.0017
TDFAM	-0.093563	0.186988	-0.500366	0.6202
C	29327.91	124724.6	0.235141	0.8156
R-squared	0.946834	Mean dependent var	1540511	
Adjusted R-squared	0.943511	S.D. dependent var	1429436	
S.E. of regression	339740.7	Akaike info criterion	28.39157	
Sum squared resid	3.69E+12	Schwarz criterion	28.52489	
Log likelihood	-493.8525	F-statistic	284.9423	
Durbin-Watson stat	1.72674	Prob(F-statistic)	0.00000	

Modelo de Regresión usando a TDFAM como única regresora

Dependent Variable: SNFAM				
Method: Least Squares				
Sample: 1964 1998		Included observations: 35		
Variable	Coefficient	Std. Error	t-Statistic	Prob.
TDFAM	0.54	0.0264	20.5182	0.00
C	368624.50	87373.6700	4.2189	0.00
R-squared	0.927312	Mean dependent var	1540511.000	
Adjusted R-squared	0.925109	S.D. dependent var	1429436.000	
S.E. of regression	391181.6	Akaike info criterion	28.647	
Sum squared resid	5.05E+12	Schwarz criterion	28.736	
Log likelihood	-499.3256	F-statistic	420.996	
Durbin-Watson stat	1.775222	Prob(F-statistic)	0.000	

Modelo de Regresión usando a RNDFAM como única regresora

Dependent Variable: SNFAM				
Method: Least Squares				
Sample: 1964 1998		Included observations: 35		
Variable	Coefficient	Std. Error	t-Statistic	Prob.
RNDFAM	0.079	0.003	24.143	0.000
C	75433.000	83098.950	0.908	0.371
R-squared	0.946418	Mean dependent var	1540511.000	
Adjusted R-squared	0.944794	S.D. dependent var	1429436.000	
Sum squared resid	3.72E+12	Schwarz criterion	28.431	
Log likelihood	-493.9889	F-statistic	582.875	
Durbin-Watson stat	1.801663	Prob(F-statistic)	0.000	

De acuerdo a los resultados siguientes que modelo considera que es el más conveniente para explicar las variaciones en el ahorro neto disponible

- a. $SNF = \beta_1 + \beta_2 RNFAM + \beta_3 TDFAM + \mu$
 - b. $SNF = \beta_1 + \beta_3 TDFAM + \mu$
 - c. $SNF = \beta_1 + \beta_2 RNFAM + \mu$
 - d. $SNF = \beta_1 RNFAM + \beta_2 TDFAM + \mu$
6. Se ha recogido información acerca de 50 empresas dedicadas a la producción y distribución de verduras, la información obtenida es concerniente a las ventas, sus recursos propios, personal que labora en la empresa y el número de puntos de venta. Con la información disponible se pretende explicar el comportamiento de las ventas en función las otras variables mencionadas, por tal motivo lo que se pretende es analizar al significación individual y conjunta de las variables. Un paso inicial fue elaborar las pruebas siguientes con fin de garantizar los resultados que se obtienen por mínimos cuadrados ordinarios:

Dependent Variable: VENTAS				
Method: Least Squares				
Sample: 1 50		Included observations: 50		
Variable	Coefficient	Std. Error	t-Statistic	Prob.
RECURSOS	2.487487	0.20379	12.20612	0.0000
EMPLEO	13.25027	1.579404	8.389411	0.0000
TIENDAS	84.77498	17.34995	4.886181	0.0000
C	3330.98	4730.742	0.704114	0.4849
R-squared	0.956122	Mean dependent var		80419.7000
Adjusted R-squared	9.53E-01	S.D. dependent var		118268.6000
S.E. of regression	25568.84	Akaike info criterion		23.2128
Sum squared resid	3.01E+10	Schwarz criterion		23.3657
Log likelihood	-576.3189	F-statistic		334.1221
Durbin-Watson stat	2.026817	Prob(F-statistic)		0.0000

Donde:

Ventas : Total de ventas producidas por cada empresa

Recursos : Recursos propios

Empleo : Personal que labora en la empresa

Tiendas : Número de puntos de venta

White Heteroskedasticity Test:			
F-statistic	6.137897	Probability	0.000022
Obs*R-squared	29.00066	Probability	0.000648

Constraste Goldfed y Quandt			
	sample	S.E. of regression	
Primera muestra	1 a 19	5286.5198	
Primera muestra	32 a 50	42723.3127	
F-statistic	65.3115	Probability	0.0000

De los resultados mostrados a partir del uso de E-Views, indicar la alternativa correcta:

- a. No existe heterocedasticidad.
 - b. Existe heterocedasticidad.
 - c. No se puede afirmar nada al respecto.
 - d. Se posee información insuficiente.
7. Se desea construir un modelo el cual sea capaz de explicar la inversión en función del PBI a precios de 1990 y el grado de utilización de la capacidad productiva. Para cumplir con tal fin se dispone de información anual desde 1964 hasta 1998.

Dependent Variable: I80				
Method: Least Squares				
Sample: 1964 1998 Includ observations: 35				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PIBCF80	0.278864	0.014243	19.57922	0.0000
CU	7563351	2028877	3.727852	0.0007
C	-6445864	1742946	-3.698258	0.0008
R-squared	0.928005	Mean dependent var		3776977
Adjusted R-squared	0.923505	S.D. dependent var		1163356
S.E. of regression	321758	Akaike info criterion		28.2828
Sum squared resid	3.31E+12	Schwarz criterion		28.41612
Log likelihood	-491.9491	F-statistic		206.2367
Durbin-Watson stat	0.338568	Prob(F-statistic)		0.0000

Durbin-Watson Test	
ρ	0.661432
d	0.338568
d_L	1.584
d_U	1.343

De los resultados mostrados, indicar la alternativa correcta:

- a. No existe Autocorrelación
- b. Existe Autocorrelación
- c. Se posee información insuficiente.
- d. Existe una Autocorrelación negativa.

RESPUESTAS DE CONTROL

1. d, 2. c, 3. a, 4. b, 5. a, 6.c 7.c 8.b