

# T5. Ampliación del modelo lineal básico

Ana J. López y Rigoberto Pérez

Dpto Economía Aplicada. Universidad de Oviedo

Curso 2010-2011



# Índice



# Ampliación del modelo lineal básico

## Competencias

Los contenidos de este tema suponen una ampliación de los desarrollados en el tema 3 y proporcionan una visión más realista de las variables económicas cuyo comportamiento se pretende modelizar. El objetivo es que los estudiantes lleguen a ser capaces de:

- Identificar los principales problemas asociados al incumplimiento de las hipótesis habituales y tratar de resolverlos
- Interpretar adecuadamente los resultados de los contrastes de homocedasticidad, no autocorrelación y normalidad
- Detectar la presencia de multicolinealidad y sus posibles consecuencias
- Contrastar la existencia de cambios estructurales y estudiar posibles soluciones



## Ampliación del modelo lineal básico: $\mathbf{y} = \mathbf{X}\beta + \mathbf{u}$

Problemas de Especificación	Omisión de variables relevantes, Inclusión de variables irrelevantes, Forma funcional errónea
Violación de hipótesis sobre $\mathbf{u}$	Esperanza no nula, Matriz de Var-Cov no escalar (heterocedasticidad, autocorrelación, no normalidad)
Matriz de regresores $\mathbf{X}$	Regresores estocásticos, Multicolinealidad
Parámetros $\beta$	Cambio estructural



# Errores de especificación

## Sobre las variables

- Omisión de variables relevantes
- Inclusión de variables irrelevantes

## Sobre la forma funcional

- Contrastes sobre la linealidad
  - ▶ Mínimos cuadrados no lineales



# Errores de especificación

## Omisión de variables relevantes

- Modelo correcto:  $\mathbf{y} = \mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{X}_2\boldsymbol{\beta}_2 + \mathbf{u}$
- Modelo propuesto:  $\mathbf{y} = \mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{v}$

Los estimadores MCO son sesgados

$$\hat{\boldsymbol{\beta}}_1 = (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{y}$$

$$\begin{aligned} E(\hat{\boldsymbol{\beta}}_1) &= (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{E}(\mathbf{y}) = (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1(\mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{X}_2\boldsymbol{\beta}_2) = \\ &= \boldsymbol{\beta}_1 + (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{X}_2\boldsymbol{\beta}_2 \end{aligned}$$

Los estimadores serían insesgados si las variables excluidas no están correlacionadas con las incluidas



# Errores de especificación

## Omisión de variables relevantes

- Modelo correcto:  $\mathbf{y} = \mathbf{X}_1\beta_1 + \mathbf{X}_2\beta_2 + \mathbf{u}$
  - Modelo propuesto:  $\mathbf{y} = \mathbf{X}_1\beta_1 + \mathbf{v}$
- Los estimadores MCO son inconsistentes
  - Los residuos son superiores a los del modelo correcto (esto afecta a la capacidad explicativa del modelo y también a la matriz var-cov).

$$S^2(\hat{\beta}) = \frac{\hat{\mathbf{u}}'\hat{\mathbf{u}}}{n-k}(\mathbf{X}'\mathbf{X})^{-1}$$

- Los tests de significación t student son excesivamente exigentes



# Errores de especificación

## Inclusión de variables irrelevantes

- Las consecuencias de incluir en el modelo variables irrelevantes son **menos graves que las de omitir variables relevantes**
- Los Estimadores MCO son **insesgados y consistentes**
- Los Estimadores MCO **dejan de ser eficientes**, y por lo tanto las estimaciones pierden precisión
- Disminuyen los grados de libertad como consecuencia del aumento de  $k$
- Al incorporar nuevas variables podría aparecer multicolinealidad





## Contrastes de especificación

### Omitir variables

**H<sub>0</sub>**: Las r variables seleccionadas pueden ser omitidas (sus coeficientes son nulos)

### Añadir variables

**H<sub>0</sub>**: Las r variables seleccionadas no deben ser añadidas (sus coeficientes son nulos)

$$\left( \frac{\hat{\mathbf{u}}_R' \hat{\mathbf{u}}_R - \hat{\mathbf{u}}' \hat{\mathbf{u}}}{\hat{\mathbf{u}}' \hat{\mathbf{u}}} \right) \frac{n-k}{r} \approx F_{n-k}^r$$

$$LR = -2(\ln L_R - \ln L) = n \ln \left( \frac{\hat{\mathbf{u}}_R' \hat{\mathbf{u}}_R}{\hat{\mathbf{u}}' \hat{\mathbf{u}}} \right) \rightarrow \chi_r^2$$

Test F de restricciones lineales y test LR de razón de verosimilitudes  
Para p bajos se rechaza la nulidad de los coeficientes y se concluye que las variables deben estar en el modelo



# Test para omitir variables

Modelo 1: MCO, usando las observaciones 1987--2008 ( $T = 22$ )  
Variable dependiente: consumopc

	Coefficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.35170	0.348359	-3.8802	0.0010
rentapc	-9.35994e-05	5.13489e-05	-1.8228	0.0841
precios	0.0498576	0.00860015	5.7973	0.0000
$R^2$	0.854650	$R^2$ corregido	0.839351	
Log-verosimilitud	-9.230929	Criterio de Akaike	24.46186	
Criterio de Schwarz	27.73499	Hannan--Quinn	25.23291	

Contrastes Guardar Gráfico

- Omitir variables
- Añadir variables
- Suma de los coeficientes
- Restricciones lineales

Elija las variables a omitir

Variables disponibles	Variables elegidas
const rentapc precios	precios

Estimar el modelo reducido  
 Contraste de Wald basado en la matriz de covarianzas  
 Eliminación secuencial de variables utilizando el valor p a dos colas:



# Test de variables omitidas

Modelo 2: MCO, usando las observaciones 1987--2008 ( $T = 22$ )  
Variable dependiente: consumopc

	Coeficiente	Desv. Típica	Estadístico $t$	Valor p
const	-0.00368661	0.420705	-0.0088	0.9931
rentapc	0.000179742	3.29843e-05	5.4493	0.0000
Media de la vble. dep.	2.163958	D.T. de la vble. dep.	0.988285	
Suma de cuad. residuos	8.254703	D.T. de la regresión	0.642445	
$R^2$	0.597545	$R^2$ corregido	0.577422	
$F(1,20)$	29.69498	Valor p (de $F$ )	0.000025	
Log-verosimilitud	-20.43379	Criterio de Akaike	44.86759	
Criterio de Schwarz	47.04967	Hannan--Quinn	45.38162	
$\hat{\rho}$	0.831284	Durbin--Watson	0.655456	

Comparación entre el modelo 1 y el modelo 2:

Hipótesis nula: el parámetro de regresión es cero para precios

Estadístico de contraste:  $F(1, 19) = 33.6087$ , con valor p =  $1.38425e-05$

**De los 3 estadísticos de selección de modelos, 0 han mejorado.**

# Test de Wald variables omitidas

Variables disponibles		Variables elegidas
const	→	rentapc
precios		
rentapc	←	

Estimar el modelo reducido  
 **Contraste de Wald basado en la matriz de covarianzas**  
 Eliminación secuencial de variables utilizando el valor p a dos colas:   
 Contrastar sólo las variables seleccionadas

**Hipótesis nula:** el parámetro de regresión es cero para rentapc

Estadístico de contraste asintótico:

chi-cuadrado de Wald(1) = 3.32265, con valor p = 0.0683315

forma F: F(1, 19) = 3.32265, con valor p = 0.0841078

Estadístico de Wald( $r=N$ .restricciones):

$$W = n \frac{\hat{u}'_R \hat{u}_R - \hat{u}' \hat{u}}{\hat{u}' \hat{u}} \approx \chi_r^2$$


# Test para añadir variables

Modelo 3: MCO, usando las observaciones 1987--2008 ( $T = 22$ )  
Variable dependiente: consumopc

	Coefficiente	Desv. Típica	Estadístico $t$	Valor $p$
const	-0.00368661	0.420705	-0.0088	0.9931
rentapc	0.000179742	3.29843e-05	5.4493	0.0000
Media de la vble. dep.	2.163958	D.T. de la vble. dep.	0.988285	
Suma de cuad. residuos	8.254703	D.T. de la regresión	0.642445	
$R^2$	0.597545	$R^2$ corregido	0.577422	
$F(1, 20)$	29.69498	Valor $p$ (de $F$ )	0.000025	
Log-verosimilitud	-20.43379	Criterio de Akaike	44.86759	
Criterio de Schwarz	47.04967	Hannan--Quinn	45.38162	
$\hat{\rho}$	0.831284	Durbin--Watson	0.655456	

Contrastes Guardar Gráfico

- Omitir variables
- Añadir variables**
- Suma de los coeficientes
- Restricciones lineales

Elija las variables a añadir

Variables disponibles		Variables elegidas
consumo	→	rentapc
poblacion		
rentapc	←	
pesos		
ipc		



## Test para añadir variables

Modelo 4: MCO, usando las observaciones 1987--2008 ( $T = 22$ )  
Variable dependiente: consumopc

	Coefficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.35170	0.348359	-3.8802	0.0010
rentapc	-9.35994e-05	5.13489e-05	-1.8228	0.0841
precios	0.0498576	0.00860015	5.7973	0.0000
Media de la vble. dep.	2.163958	D.T. de la vble. dep.	0.988285	
Suma de cuad. residuos	2.981244	D.T. de la regresión	0.396116	
$R^2$	0.854650	$R^2$ corregido	0.839351	
$F(2,19)$	55.85969	Valor p (de $F$ )	1.10e-08	
Log-verosimilitud	-9.230929	Criterio de Akaike	24.46186	
Criterio de Schwarz	27.73499	Hannan--Quinn	25.23291	
$\hat{\rho}$	0.264285	Durbin--Watson	1.401145	

Comparación entre el modelo 3 y el modelo 4:

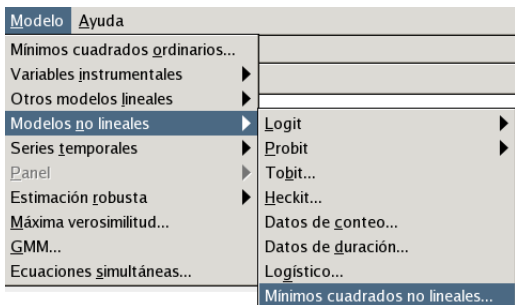
**Hipótesis nula:** el parámetro de regresión es cero para precios

Estadístico de contraste:  $F(1, 19) = 33.6087$ , con valor p = 1.38425e-05

**De los 3 estadísticos de selección de modelos, 3 han mejorado.**

## Forma funcional errónea

- Podemos tener **sospechas de no linealidad**, ligadas a la teoría económica o a la información muestral.
- La especificación errónea de modelos lineales tiene **consecuencias** similares a la omisión de variables relevantes.
- ¿Cómo tratar la no linealidad?



- En caso de no linealidad, la estimación de estos modelos se lleva a cabo por **Mínimos Cuadrados no lineales** (MCNL), que utilizan métodos de aproximación numérica (Gauss-Newton) y coinciden con los EMV.



## Contrastes de linealidad

Se contrasta la hipótesis de linealidad, completando la especificación del modelo propuesto con los logaritmos o los cuadrados de las variables explicativas y contrastando la nulidad de sus coeficientes

Contrastes	Guardar	Gr
Omitir variables		
Añadir variables		
Suma de los coeficientes		
Restricciones lineales		
No linealidad (cuadrados)		
No linealidad (logs)		

Regresión auxiliar para el contraste de no linealidad (términos logarítmicos)\MCO, usando observaciones 1987-2008 (T=22)

Variable dependiente **uhat**

	Coefficiente	Desv.Típica	Estadístico t	Valor p	
const	30.8945	12.6802	2.436	0.0261	**
rentapc	-0.000227443	0.000140966	-1.613	0.1251	
precios	0.165767	0.0360676	4.596	0.0003	***
l_rentapc	5.21124	1.60434	3.248	0.0047	***
l_precios	-20.4815	4.39776	-4.657	0.0002	***

R-cuadrado = 0.561849, Estadístico de contraste:  $TR^2 = 12,3607$ , con valor  $p = P(\chi_2^2 > 12,3607) = 0,00206974$



## Contrastes de linealidad

Regresión auxiliar para el contraste de no linealidad (términos al cuadrado)\MCO, usando las observaciones 1987-2008 (T = 22)\Variable dependiente: uhat

	Coefficiente	Desv.Típica	Estadístico t	Valor p	
const	7.87416	1.56991	5.016	0.0001	***
rentapc	0.000667027	0.000138571	4.814	0.0002	***
precios	-0.231702	0.0386627	-5.993	1.45e-05	***
sq_rentapc	-1.82857e-08	5.39076e-09	-3.392	0.0035	***
sq_precios	0.000929836	0.000150836	6.165	1.04e-05	***

R-cuadrado = 0.692012

Estadístico de contraste:  $TR^2 = 15,2243$ ,

con valor  $p = P(\chi_2^2 > 15,2243) = 0,000494415$

Bajo la hipótesis nula de linealidad los coeficientes de los términos cuadráticos son nulos. Para p bajos se rechaza la nulidad de estos coeficientes y se concluye que existe evidencia de no linealidad



## Test RESET de Ramsey

Detecta errores de especificación en sentido amplio (variables omitidas, forma funcional incorrecta, ...)

Modelo estimado:  $\hat{Y} = \hat{\beta}_1 + \hat{\beta}_2 X_2 + \dots + \hat{\beta}_k X_k$

$$\hat{Y} = \beta_1 + \beta_2 X_2 + \dots + \beta_k X_k + \delta_1 \hat{Y}^2 + \delta_2 \hat{Y}^3 + u$$

**Hipótesis** de especificación correcta:  $H_0 : \delta_1 = 0, \delta_2 = 0$

**Discrepancias:**

$$\left( \frac{\hat{u}'_R \hat{u}_R - \hat{u}' \hat{u}}{\hat{u}' \hat{u}} \right) \frac{n - k - 2}{k + 2} \approx F_{n-k-2}^{k+2} ; \quad LR = n \ln \left( \frac{\hat{u}'_R \hat{u}_R}{\hat{u}' \hat{u}} \right) \rightarrow \chi^2_r$$

Si los tests no conducen al rechazo de la hipótesis, se asume como válida la especificación propuesta. En cambio, si p es bajo deberíamos rechazar el supuesto de especificación correcta



## Hipótesis básicas sobre $\mathbf{u}$

$$E(\mathbf{u}) = \mathbf{0}$$

$$\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \sigma^2 \mathbf{I}$$

$$\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \begin{pmatrix} E(u_1^2) & E(u_1 u_2) & \cdots & E(u_1 u_n) \\ E(u_2 u_1) & E(u_2^2) & \cdots & E(u_2 u_n) \\ \vdots & \vdots & \ddots & \vdots \\ E(u_n u_1) & E(u_n u_2) & \cdots & E(u_n^2) \end{pmatrix} = \begin{pmatrix} \sigma^2 & 0 & \cdots & 0 \\ 0 & \sigma^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma^2 \end{pmatrix}$$

$$\text{Var}(u_i) = E(u_i^2) = \sigma^2 \quad \Rightarrow \quad \text{Homocedasticidad}$$

$$\text{Cov}(u_i, u_j) = E(u_i u_j) = 0 \quad \Rightarrow \quad \text{No autocorrelación}$$

## Hipótesis de normalidad

- $\mathbf{u}$  sigue una distribución normal multivariante:  $\mathbf{u} \approx \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$
- $\mathbf{y}$  sigue una distribución normal multivariante:  $\mathbf{y} \approx \mathcal{N}(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$

## Perturbaciones de media no nula

La principal consecuencia de que las perturbaciones tengan esperanza no nula es la estimación sesgada del término independiente

$$E(\mathbf{u}) \neq \mathbf{0}$$

Esta hipótesis no puede ser contrastada porque la estimación MCO garantiza que los residuos tienen media nula

$$Y = \beta_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u \Rightarrow E(Y) = \beta_1 + E(u) + \beta_2 X_2 + \cdots + \beta_k X_k$$

Problema relacionado con la especificación del modelo ¿Faltan variables explicativas?

$$\mathbf{y} = \mathbf{X}_1 \beta_1 + \mathbf{v}$$

$$\mathbf{y} = \mathbf{X}_1 \beta_1 + \underbrace{\mathbf{X}_2 \beta_2 + \mathbf{u}}$$

$$E(\mathbf{v}) = \mathbf{X}_2 \beta_2$$



## Matriz de varianzas-covarianzas no escalar

$$\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \sigma^2 \mathbf{I} \Rightarrow \begin{cases} E(u_i^2) = \sigma^2 & \forall i = 1, \dots, n & \text{Homocedasticidad} \\ E(u_i u_j) = 0 & \forall i \neq j & \text{No autocorrelación} \end{cases}$$

Matriz de var-cov no escalar:  $\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \sigma^2 \mathbf{\Omega}$

### Estimación por MCO

Estimador	$\hat{\beta}^{MCO} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$
Insesgados	$E(\hat{\beta}^{MCO}) = \beta$
Consistentes	$\lim_{n \rightarrow \infty} \text{Var}(\hat{\beta}^{MCO}) = 0$
No óptimos	La varianza no coincide con la mínima $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$

# Estimador MCO con Var-Cov no escalar

- Insesgado

$$\begin{aligned} E\left(\hat{\beta}^{MCO}\right) &= E\left(\left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\mathbf{y}\right) = E\left(\left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\left(\mathbf{X}\beta + \mathbf{u}\right)\right) \\ &= \beta + \left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'E\left(\mathbf{u}\right) = \beta \end{aligned}$$

- Estimadores MCO no óptimos

$$\begin{aligned} \text{Var}\left(\hat{\beta}^{MCO}\right) &= E\left[\left(\hat{\beta}^{MCO} - \beta\right)\left(\hat{\beta}^{MCO} - \beta\right)'\right] \\ &= E\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\mathbf{u}\left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\mathbf{u}'\right] \\ &= E\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\mathbf{u}\mathbf{u}'\mathbf{X}\left(\mathbf{X}'\mathbf{X}\right)^{-1}\right] \\ &= \left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'E\left[\mathbf{u}\mathbf{u}'\right]\mathbf{X}\left(\mathbf{X}'\mathbf{X}\right)^{-1} \\ &= \sigma^2\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\mathbf{\Omega}\mathbf{X}\left(\mathbf{X}'\mathbf{X}\right)^{-1}\right] \end{aligned}$$



## Utilización de MCO con $E(\mathbf{uu}')$ no escalar

$$\text{Var}(\hat{\beta}^{MCO}) = \sigma^2 \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \Omega \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \right]$$

$$S^2 = \frac{\hat{\mathbf{u}}'\hat{\mathbf{u}}}{\text{tr}(\mathbf{M}\Omega)}$$

$$\mathbf{M} = [\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}']$$

Simétrica:  $\mathbf{M}=\mathbf{M}'$ ; Idempotente:  $\mathbf{M}\mathbf{M}=\mathbf{M}$ ; Traza:  $\text{tr}(\mathbf{M})=n-k$

### Doble sesgo

Modelización de MCO asumiendo  $E(\mathbf{uu}')$  escalar

1  $\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$ , con lo que estamos identificando  $\Omega$ , con la matriz identidad.

2 Estimar  $\sigma^2$  como:  $S^2 = \frac{\hat{\mathbf{u}}'\hat{\mathbf{u}}}{n-k}$



## Estimación robusta de la matriz Var-Cov

La matriz de varianzas covarianzas puede estimarse de forma consistente o robusta mediante la expresión:

$$\hat{S}^2(\hat{\beta}^{MCO}) = S^2 \left[ (X'X)^{-1} X' \hat{\Omega} X (X'X)^{-1} \right] \quad ; \quad \hat{\Omega} = \begin{pmatrix} \hat{u}_1^2 & 0 & \cdots & 0 \\ 0 & \hat{u}_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \hat{u}_n^2 \end{pmatrix}$$



Estima de forma consistente o robusta la matriz de varianzas- covarianzas, lo cual afecta a los contrastes de significación t de student



# Estimación robusta de la matriz Var-Cov

**Modelo 1:** MCO, usando las observaciones 1987--2008 ( $T = 22$ )  
Variable dependiente: consumopc

	Coeficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.35170	0.348359	-3.8802	0.0010
precios	0.0498576	0.00860015	5.7973	0.0000
rentapc	-9.35994e-05	5.13489e-05	-1.8228	0.0841
F(2, 19)	55.85969	Valor p (de F)	1.10e-08	

**Modelo 2:** Desviaciones típicas HAC, con ancho de banda 2

	Coeficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.35170	0.464395	-2.9107	0.0090
precios	0.0498576	0.0116702	4.2722	0.0004
rentapc	-9.35994e-05	5.92050e-05	-1.5809	0.1304
F(2, 19)	31.17168	Valor p (de F)	1.00e-06	

# Mínimos Cuadrados Generalizados (MCG)

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

$$\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \sigma^2\boldsymbol{\Omega}$$

Se transforma el modelo hasta tener matriz Var-Cov escalar

Se busca una matriz  $\mathbf{P}$  cuadrada no singular tal que:  $\mathbf{P}'\mathbf{P} = \boldsymbol{\Omega}^{-1}$

Modelo transformado:  $\mathbf{P}\mathbf{y} = \mathbf{P}\mathbf{X}\boldsymbol{\beta} + \mathbf{P}\mathbf{u}$

## Características

$$E(\mathbf{P}\mathbf{u}) = \mathbf{P}E(\mathbf{u}) = \mathbf{0}$$

$$\text{Cov}(\mathbf{P}\mathbf{u}) = E(\mathbf{P}\mathbf{u}\mathbf{u}'\mathbf{P}') = \mathbf{P}E(\mathbf{u}\mathbf{u}')\mathbf{P}' = \mathbf{P}\sigma^2\boldsymbol{\Omega}\mathbf{P}' = \sigma^2\mathbf{P}\mathbf{P}^{-1}\mathbf{P}'^{-1}\mathbf{P}' = \sigma^2\mathbf{I}$$

## Estimadores MCG

$$\hat{\boldsymbol{\beta}}^{MCG} = [(\mathbf{P}\mathbf{X})'(\mathbf{P}\mathbf{X})]^{-1}(\mathbf{P}\mathbf{X})'\mathbf{P}\mathbf{y}$$

$$= \left[ (\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{X})^{-1} \mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{y} \right]$$

Los estimadores de Mínimos Cuadrados Generalizados (MCG) coinciden con los EMV y son ELIO para el modelo transformado

# Características de los estimadores MCG

Los estimadores MCG son insesgados

$$\begin{aligned}\hat{\beta}^{MCG} &= (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{y} = (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}(\mathbf{X}\beta + \mathbf{u}) \\ &= \beta + (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{u}\end{aligned}$$

$$E(\hat{\beta}^{MCG}) = \beta$$

Los estimadores MCG son consistentes

$$\begin{aligned}\text{Var}(\hat{\beta}^{MCG}) &= E\left[(\hat{\beta}^{MCG} - \beta)(\hat{\beta}^{MCG} - \beta)'\right] \\ &= E\left[((\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{u})((\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{u})'\right] \\ &= E[(\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{u}\mathbf{u}'\Omega^{-1}\mathbf{X}(\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}] = \\ &= (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}E[\mathbf{u}\mathbf{u}']\Omega^{-1}\mathbf{X}(\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1} \\ &= (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\sigma^2\Omega\Omega^{-1}\mathbf{X}(\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1} \\ &= \sigma^2(\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\end{aligned}$$

# Heterocedasticidad

$$\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \begin{pmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_n^2 \end{pmatrix}$$

## Causas

- Mala especificación
- Cambio estructural

## Consecuencias

- Estimadores no óptimos
- Sesgo en las varianzas
- Test de significación no válidos



## Detección

- Análisis gráfico
- Test de White, Breusch-Pagan, Goldfeld-Quandt, Glejser, ...

## Soluciones

- Especificaciones alternativas
- Estimación del modelo por MCP

# Gráficos heterocedasticidad



## Contraste de White

$$\begin{aligned} H_0 &: \sigma_i^2 = \sigma^2 \quad \forall i = 1, \dots, n \\ H_1 &: \sigma_i^2 \neq \sigma_j^2 \quad \text{para algún } i \neq j \end{aligned}$$

- Se estima el modelo propuesto, calculando sus residuos  $\hat{u}$
- Se efectúa una regresión de los residuos cuadráticos sobre las variables y sus cuadrados, incluyendo generalmente también productos cruzados:

$$\hat{u}^2 = \alpha_1 + \alpha_2 X_1 + \alpha_3 X_2 + \alpha_4 X_1^2 + \alpha_5 X_2^2 + \alpha_6 X_1 X_2 + v$$

- Para el coeficiente de determinación de esta regresión auxiliar (con  $m$  regresores) bajo  $H_0$  se cumple:  $nR^2 \approx \chi_m^2$

Si  $p = P(\chi_m^2 > nR^2)$  es bajo se rechaza la homocedasticidad y se concluye que las perturbaciones son heterocedásticas.

# Contraste de White

Heterocedasticidad	▶	Contraste de White
Normalidad de los residuos		Contraste de White (sólo cuadrados)
Observaciones influyentes		Breusch-Pagan
Colinealidad		Koenker

Contraste de heterocedasticidad de White  
 MCO, usando las observaciones 1987-2008 (T = 22)  
 Variable dependiente:  $\hat{u}^2$

	Coeficiente	Desv. Típica	Estadístico t	Valor p	
const	3.92948	2.30350	1.706	0.1074	
precios	-0.0310550	0.0433067	-0.717	0.4837	
rentapc	-0.000359329	0.000177957	-2.019	0.0605	*
sq_precios	-0.00135966	0.000592252	-2.296	0.0355	**
X2_X3	2.11531e-05	9.13833e-06	2.315	0.0342	**
sq_rentapc	-5.96052e-08	2.88298e-08	-2.067	0.0553	*

$$R^2 = 0.501119$$

Estadístico de contraste:  $TR^2 = 11.024629$ ,  
 con valor  $p = P(\chi_5^2 > 11,024629) = 0,050894$



## Contraste de Breusch-Pagan

$$\begin{aligned} H_0 &: \sigma_i^2 = \sigma^2 \quad \forall i = 1, \dots, n \\ H_1 &: \sigma_i^2 \neq \sigma_j^2 \quad \text{para algún } i \neq j \end{aligned}$$

- Se estima el modelo propuesto, calculando sus residuos  $\hat{u}$
- Los residuos cuadráticos se normalizan con EMV de la varianza:  
$$e_i^2 = \frac{\hat{u}_i^2}{\hat{\sigma}^2}$$
- Se efectúa una regresión de estos residuos cuadráticos normalizados o escalados sobre las variables explicativas y se contrasta la nulidad de los coeficientes
- Este contraste se basa en la **Variación Explicada**, que bajo la hipótesis nula sigue una distribución **chi-cuadrado con  $k-1$**  grados de libertad

Se obtiene el nivel crítico, si es bajo se rechaza la homocedasticidad, concluyendo que las perturbaciones son heterocedásticas

## Contraste de Breusch-Pagan

Contraste de heterocedasticidad de Breusch-Pagan

MCO, usando las observaciones 1987-2008 (T = 22)

Variable dependiente:  $\hat{u}^2$  escalado

	Coefficiente	Desv. Típica	Estadístico t	Valor p	
const	-3.16883	1.69508	-1.869	0.0771	*
precios	0.0350232	0.0418476	0.8369	0.4130	
rentapc	7.51488e-05	0.000249859	0.3008	0.7669	

Suma de cuadrados explicada = 29.6793

Estadístico de contraste: LM = 14.839664,  $p = P(\chi_2^2 > 14,839664) = 0,000599$

Variable dependiente:  $\hat{u}^2$  escalado (variante robusta de Koenker)

	Coefficiente	Desv. Típica	Estadístico t	Valor p	
const	-0.564923	0.229703	-2.459	0.0237	**
precios	0.00474603	0.00567081	0.8369	0.4130	
rentapc	1.01835e-05	3.38587e-05	0.3008	0.7669	

Suma de cuadrados explicada = 0.545009

Estadístico de contraste: LM = 6.512092,  $p = P(\chi_2^2 > 6,512092) = 0,038540$

# Resumen de los test de Heterocedasticidad

## **Contraste de heterocedasticidad de White**

Hipótesis nula: No hay heterocedasticidad

Estadístico de contraste: LM = 11.0246

con valor p =  $P(\text{Chi-cuadrado}(5) > 11.0246) = 0.0508938$

## **Contraste de heterocedasticidad de White (cuadrados sólo)**

Hipótesis nula: No hay heterocedasticidad

Estadístico de contraste: LM = 7.34916

con valor p =  $P(\text{Chi-cuadrado}(4) > 7.34916) = 0.118548$

## **Contraste de heterocedasticidad de Breusch-Pagan**

Hipótesis nula: No hay heterocedasticidad

Estadístico de contraste: LM = 14.8397

con valor p =  $P(\text{Chi-cuadrado}(2) > 14.8397) = 0.00059925$

## **Contraste de heterocedasticidad de Breusch-Pagan (variante robusta)**

Hipótesis nula: No hay heterocedasticidad

Estadístico de contraste: LM = 6.51209

con valor p =  $P(\text{Chi-cuadrado}(2) > 6.51209) = 0.0385405$

## Corrección de heterocedasticidad: Mínimos Cuadrados Ponderados (MCP)

La corrección por Mínimos Cuadrados Ponderados (MCP) consiste en buscar una matriz  $\mathbf{P}$  de ponderaciones para el modelo inicial:

$$\mathbf{Py} = \mathbf{PX}\beta + \mathbf{Pu} \quad (\text{Modelo transformado})$$

### Características

$$E(\mathbf{Pu}) = \mathbf{P}E(\mathbf{u}) = \mathbf{0}$$

$$\text{Cov}(\mathbf{Pu}) = E(\mathbf{Pu}\mathbf{u}'\mathbf{P}') = \sigma^2\mathbf{P}\mathbf{P}^{-1}\mathbf{P}'^{-1}\mathbf{P}' = \sigma^2\mathbf{I}$$

Las ponderaciones  $W_i$  que dan lugar a la matriz  $\mathbf{P}$  se aproximan analizando la estructura de la heterocedasticidad

$$W_i = \frac{1}{X_i}; \quad W_i = \frac{1}{\sqrt{X_i}}; \quad W_i = \frac{1}{X_i^2} \quad \text{Varianza creciente con } X$$

$$W_i = X_i; \quad W_i = \sqrt{X_i} \quad \text{Varianza decreciente con } X$$



MCP: Ilustración  $\sigma_i^2 = \sigma^2 X_i$ 

$$E[(W_i u_i)^2] = \sigma^2 \Rightarrow W_i^2 E[u_i^2] = \sigma^2 \Rightarrow$$

$$W_i^2 \sigma^2 X_i = \sigma^2 \Rightarrow W_i = \frac{1}{\sqrt{X_i}}$$

$$P = \begin{pmatrix} \frac{1}{\sqrt{X_1}} & & \\ & \frac{1}{\sqrt{X_2}} & \\ & & \frac{1}{\sqrt{X_n}} \end{pmatrix}$$

Para obtener las ponderaciones  $W_i$  más adecuadas puede ser útil examinar la regresión auxiliar de los test de White o Breusch-Pagan, comprobando qué variables explicativas son más significativas

# Corrección de la heterocedasticidad

Ponderaciones habituales

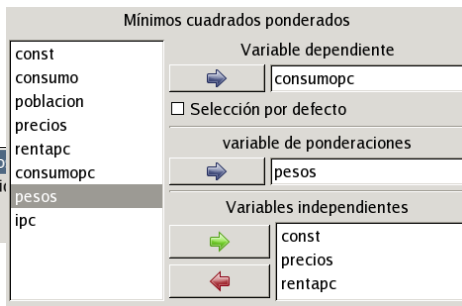

## Dispersión directamente proporcional a X

Regresión auxiliar significativa	Estructura de heterocedasticidad	Ponderaciones
$\hat{u}_i^2 = \hat{\alpha}_1 + \hat{\alpha}_2 X_i$	$\Rightarrow \sigma_i^2 = \sigma^2 X_i$	$\Rightarrow W_i = \frac{1}{\sqrt{X_i}}$
$\hat{u}_i^2 = \hat{\alpha}_1 + \hat{\alpha}_2 X_i^2$	$\Rightarrow \sigma_i^2 = \sigma^2 X_i^2$	$\Rightarrow W_i = \frac{1}{X_i}$

## Dispersión inversamente proporcional a X

Regresión auxiliar significativa	Estructura de heterocedasticidad	Ponderaciones
$\hat{u}_i^2 = \hat{\alpha}_1 + \hat{\alpha}_2 \frac{1}{X_i}$	$\Rightarrow \sigma_i^2 = \frac{\sigma^2}{X_i}$	$\Rightarrow W_i = \sqrt{X_i}$
$\hat{u}_i^2 = \hat{\alpha}_1 + \hat{\alpha}_2 \frac{1}{X_i^2}$	$\Rightarrow \sigma_i^2 = \frac{\sigma^2}{X_i^2}$	$\Rightarrow W_i = X_i$

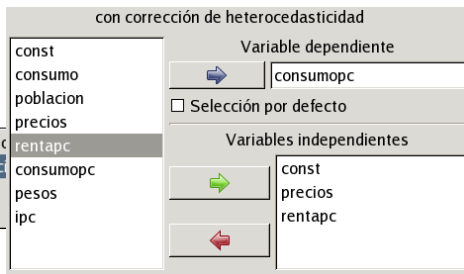

# Estimación de MCP con Gretl



- Se introducen pesos en función de la estructura de heterocedasticidad existente
- Gretl estima el modelo ponderado con estos pesos



# Corrección de heterocedasticidad automática en Gretl



- La corrección automática de Gretl se puede aplicar si no se conoce la estructura de la heterocedasticidad y asigna unas ponderaciones basadas en la regresión auxiliar de los logaritmos de los residuos cuadráticos





# Corrección de heterocedasticidad

Modelo 2: con corrección de heterocedasticidad, usando las observaciones 1987--2008 ( $T = 22$ )  
Variable dependiente: consumopc

	Coefficiente	Desv. Típica	Estadístico $t$	Valor p
const	0.409421	0.332413	1.2317	0.2331
precios	0.00935447	0.00763320	1.2255	0.2354
rentapc	5.82862e-05	3.13488e-05	1.8593	0.0785

Estadísticos basados en los datos ponderados:

Suma de cuad. residuos	35.14886	D.T. de la regresión	1.360125
$R^2$	0.872979	$R^2$ corregido	0.859608
$F(2, 19)$	65.29075	Valor p (de $F$ )	3.07e-09
Log-verosimilitud	-36.37070	Criterio de Akaike	78.74139
Criterio de Schwarz	82.01452	Hannan--Quinn	79.51244
$\hat{\rho}$	0.665251	Durbin--Watson	0.549186

Estadísticos basados en los datos originales:

Media de la vble. dep.	2.163958	D.T. de la vble. dep.	0.988285
Suma de cuad. residuos	9.043910	D.T. de la regresión	0.689924

- Los estadísticos comparables con el modelo inicialmente propuesto son los basados en datos originales (no en datos ponderados).
- La suma de cuadrados de los residuos habrá aumentado en esta estimación ya que los estimadores MCO eran óptimos



# Autocorrelación

$$\text{Cov}(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \begin{pmatrix} \sigma^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{12} & \sigma^2 & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1n} & \sigma_{2n} & \cdots & \sigma^2 \end{pmatrix}$$

## Causas

- Mala especificación, inercia en las variables, cambios estructurales, ...

## Consecuencias

- Ineficiencia de estimadores
- Estimación sesgada de las varianzas y test de significación no válidos

## Detección


- Análisis gráfico de los residuos
- Test de Durbin y Watson
- Otros contrastes (LM, Q, ...)

## Soluciones



- Especificación de modelos autorregresivos AR

# Análisis gráfico de los residuos

## No autocorrelación



## Autocorrelación



## Contraste de Durbin-Watson

Esquema autorregresivo AR(1)

$$\mathbf{u}_t = \rho \mathbf{u}_{t-1} + \boldsymbol{\epsilon}_t ; |\rho| < 1 ; \boldsymbol{\epsilon}_t \approx \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$$

Hipótesis nula: no autocorrelación:

$$H_0 : \rho = 0$$

$$H_1 : \rho \neq 0$$

Información muestral: residuos  $\hat{u}_t$

Discrepancia de Durbin-Watson:

$$d_{DW} = \frac{\sum_{t=2}^T (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^T \hat{u}_t^2}$$



# Contraste de Durbin-Watson

$$\begin{aligned}
 d_{DW} &= \frac{\sum_{t=2}^T (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^T \hat{u}_t^2} \\
 &\approx \frac{2 \sum_{t=1}^T \hat{u}_t^2 - 2 \sum_{t=2}^T \hat{u}_t \hat{u}_{t-1}}{\sum_{t=1}^T \hat{u}_t^2} \\
 &= 2 \left( 1 - \frac{\text{Cov}(\hat{u}_t, \hat{u}_{t-1})}{\text{Var}(\hat{u}_t)} \right) = 2(1 - \hat{\rho})
 \end{aligned}$$

## Valores del DW

- Si existe correlación lineal directa,  $\hat{\rho} = 1 \Rightarrow d_{DW} = 0$
- Si existe correlación lineal inversa,  $\hat{\rho} = -1 \Rightarrow d_{DW} = 4$
- Si no hay autocorrelación  $\hat{\rho} = 0 \Rightarrow d_{DW} = 2$



## Contraste de Durbin-Watson en Gretl

Modelo 1: MCO, usando las observaciones 1987--2008 ( $T = 22$ )

Variable dependiente: consumopc

	Coeficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.35170	0.348359	-3.8802	0.0010
precios	0.0498576	0.00860015	5.7973	0.0000
rentapc	-9.35994e-05	5.13489e-05	-1.8228	0.0841
Media de la vble. dep.	2.163958	D.T. de la vble. dep.	0.988285	
Suma de cuad. residuos	2.981244	D.T. de la regresión	0.396116	
$R^2$	0.854650	$R^2$ corregido	0.839351	
$F(2,19)$	55.85969	Valor p (de $F$ )	1.10e-08	
Log-verosimilitud	-9.230929	Criterio de Akaike	24.46186	
Criterio de Schwarz	27.73499	Hannan--Quinn	25.23291	
$\hat{\rho}$	0.264285	<b>Durbin--Watson</b>	<b>1.401145</b>	

### En la salida del modelo, opción de Contrastes

Estadístico de Durbin-Watson = 1.40115

Valor p = 0.0261283

## Esquema autorregresivo AR(1)

Modelo inicial:  $\mathbf{Y}_t = \beta_1 + \beta_2 \mathbf{X}_t + \mathbf{u}_t$

$$\mathbf{u}_t = \rho \mathbf{u}_{t-1} + \boldsymbol{\epsilon}_t ; |\rho| < 1 ; \boldsymbol{\epsilon}_t \approx \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$$

$$\mathbf{Y}_t = \beta_1 + \beta_2 \mathbf{X}_t + (\rho \mathbf{u}_{t-1} + \boldsymbol{\epsilon}_t)$$

$$\mathbf{Y}_{t-1} = \beta_1 + \beta_2 \mathbf{X}_{t-1} + \mathbf{u}_{t-1} \quad \Rightarrow \quad \rho \mathbf{Y}_{t-1} = \rho \beta_1 + \rho \beta_2 \mathbf{X}_{t-1} + \rho \mathbf{u}_{t-1}$$

$$\mathbf{Y}_t - \rho \mathbf{Y}_{t-1} = \beta_1(1 - \rho) + \beta_2 (\mathbf{X}_t - \rho \mathbf{X}_{t-1}) + \boldsymbol{\epsilon}_t$$

Modelo transformado (perturbaciones incorreladas)

$$\mathbf{Y}_t^* = \beta_1^* + \beta_2 \mathbf{X}_t^* + \boldsymbol{\epsilon}_t$$

Procedimiento iterativo de Cochrane-Orcutt

# Procedimiento de Cochrane-Orcutt

Estimación del modelo original por MCO

Contraste de la hipótesis  $H_0 : \rho = 0$

**NO RECHAZAR**

Estimación válida  
Punto de parada

**RECHAZAR**

Corrección de autocorrelación

- Sobre los residuos  $\hat{u}$  estimación de  $\rho$  y estimación del modelo transformado

$$\mathbf{Y}_t - \rho \mathbf{Y}_{t-1} = \beta_1(1 - \rho) + \beta_2(\mathbf{X}_t - \rho \mathbf{X}_{t-1}) + \epsilon_t$$

- **REPETIR** (procedimiento iterativo)





# Estimación Cochrane-Orcutt

Gretl: Modelos → Series temporales → Cochrane-Orcutt

Realizando el cálculo iterativo de  $\rho$  ...

ITERACIÓN	RHO	SCR
1	0.26428	2.79644
2	0.27012	2.79634
3	0.27036	2.79634

Modelo 2: Cochrane--Orcutt , usando las observaciones 1988--2008 ( $T = 21$ )

Variable dependiente: consumopc  
 $\hat{\rho} = 0.270356$

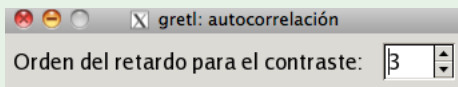
	Coefficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.39891	0.446858	-3.1305	0.0058
precios	0.0506968	0.0104446	4.8539	0.0001
rentapc	-9.50947e-05	6.85507e-05	-1.3872	0.1823

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	2.201685	D.T. de la vble. dep.	0.996326
Suma de cuad. residuos	2.796343	D.T. de la regresión	0.394148
$R^2$	0.859396	$R^2$ corregido	0.843774
$F(2, 18)$	36.45864	Valor p (de $F$ )	4.67e-07
$\hat{\rho}$	0.156240	Durbin--Watson	1.618881

## Otros contrastes de autocorrelación

- Durbin-Watson sólo contrasta la autocorrelación de primer orden y no puede ser aplicado en modelos que contienen como explicativas variables endógenas retardadas
- Para solucionar estos inconvenientes existen otros contrastes como los de Breusch-Godfrey (LM) o Ljung-Box (Q), en los que la hipótesis nula es ausencia de correlación hasta cierto orden de retardos



# Contraste de Autocorrelación

Gretl: Salida de modelo, Contrastes → Autocorrelación

## Contraste Breusch-Godfrey de autocorrelación hasta el orden 3

MCO, usando las observaciones 1987-2008 (T = 22)

Variable dependiente:  $\hat{u}$

	Coeficiente	Desv. Típica	Estadístico t	Valor p	
const	0.591824	0.347077	1.705	0.1075	
precios	-0.0164693	0.00894872	-1.840	0.0843	*
rentapc	7.52747e-05	4.84594e-05	1.553	0.1399	
$\hat{u}_1$	0.209950	0.245743	0.854	0.4055	
$\hat{u}_2$	-0.910259	0.308967	-2.946	0.0095	***
$\hat{u}_3$	-0.105322	0.424803	-0.248	0.8073	

R-cuadrado = 0.490561

Estadístico de contraste:  $LMF = 5,135702$ ,  $p = P(F_{16}^3 > 5,1357) = 0,0112$

Estadístico alternativo:  $TR^2 = 10,792346$ ,  $p = P(\chi_3^2 > 10,7923) = 0,0129$

Ljung-Box  $Q' = 8.71089$ ,  $p = P(\chi_3^2 > 8,71089) = 0,0334$

Rechazamos la hipótesis de que no hay autocorrelación hasta el orden 3

# No Normalidad

## Causas

- Presencia de observaciones atípicas (Outliers)
- Problemas en la especificación del modelo

## Consecuencias

- Se desconoce el modelo probabilístico de los estimadores MCO y de  $\hat{u}$
- Se desconocen las distribuciones necesarias para los procesos inferenciales

## Detección

- Contrastes:
  - ▶ Chi-cuadrado
  - ▶ Otros: Jarque y Bera, Kolmogorov-Smirnov, Shapiro-Wilks, ...

## Soluciones

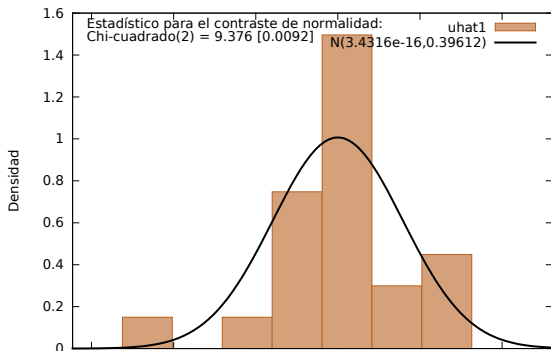
- Introducir variables dummy
- Cambiar la especificación



# Contraste de normalidad en los residuos

Gretl: Salida de modelo, Contrastes → Normalidad de los residuos

- Para contrastar la normalidad se analizan los residuos del modelo estimado, clasificándolos en intervalos y comparando la frecuencia de cada intervalo con la que le correspondería bajo el supuesto de normalidad.
- Los resultados se resumen en una chi-cuadrado con 2 g.l.
- Para niveles críticos bajos se rechaza la normalidad



# Otros contrastes de normalidad

Gretl: Variable  $\rightarrow$  Contraste de normalidad

Guardar los residuos del modelo

Salida del modelo: Guardar  $\rightarrow$  Residuos

**Contraste de normalidad de  $\hat{u}_1$ :**

Contraste de Doornik-Hansen = 9.3757, con valor  $p = 0,00920645$

W de Shapiro-Wilk = 0.897126, con valor  $p = 0,0260504$

Contraste de Lilliefors = 0.182989, con valor  $p \cong 0,05$

Contraste de Jarque-Bera = 9.69534, con valor  $p = 0,00784662$

Todos los test nos llevan a rechazar la hipótesis de normalidad de los residuos



## Causas de la no normalidad de los residuos

- El incumplimiento de la hipótesis de normalidad puede ser debido a problemas en la especificación del modelo o a la presencia de observaciones atípicas (outliers).
- Cuando se identifica algún dato atípico o outlier sobre la serie de la variable dependiente, es aconsejable revisar la información para ver si existen errores en los datos.
- En caso de que el outlier sea debido a comportamientos anómalos como huelgas, accidentes, tormentas, ..., es aconsejable introducir en el modelo una variable dummy asociada a estos hechos.



## Resumen: Problemas con $u$ y soluciones

$$E(\mathbf{u}) \neq 0$$

- **Revisar especificación**

$$\text{Cov}(\mathbf{u}) = \sigma^2 \Omega$$

- **Revisar especificación**
- Estimación consistente de la matriz de Var-Cov
- ¿Heterocedasticidad? Estimación MCP
- ¿Autocorrelación? AR(1)

$u$  no normal

- **Revisar especificación**
- ¿Valores atípicos? Variables dummy





# Regresores $\mathbf{X}$ estocásticos

La matriz  $\mathbf{X}$  tiene carácter estocástico cuando:

- Se incluyen como explicativas variables endógenas retardadas
- Se especifican modelos multiecuacionales

## Consecuencias

- Si la matriz  $\mathbf{X}$  fuese independiente de las perturbaciones  $\mathbf{u}$  entonces los estimadores MCO serían insesgados y consistentes
- En general la matriz  $\mathbf{X}$  estará correlacionada contemporáneamente con  $\mathbf{u}$ , y los estimadores MCO serán sesgados e inconsistentes, por lo que habría que realizar una estimación con **variables instrumentales**



# Matriz $X$ de rango no pleno

## Tamaño muestral $n$ insuficiente (Micronumerosidad)

- Situaciones extremas si  $n=0$
- Problemas con pocos grados de libertad  $n-k$

## Correlación entre variables explicativas (Multicolinealidad)

- Situaciones extremas (Multicolinealidad perfecta):
  - ▶ Variable explicativa constante
  - ▶ Variables explicativas relacionadas linealmente
  - ▶ Excesivas variables cualitativas ("trampa" de v. ficticias)
- Problemas con multicolinealidad aproximada (alto grado de correlación entre las  $X$ )

Las propiedades de estimadores MCO no varían

Hay un aumento de varianzas

Principio de parsimonia



# Multicolinealidad

## Causas

- Existencia de relaciones lineales entre las variables explicativas del modelo

## Consecuencias

- Multicolinealidad perfecta
  - ▶ La matriz  $\mathbf{X}'\mathbf{X}$  es singular, no puede obtenerse el vector de estimadores  $\hat{\beta}$
- Multicolinealidad aproximada
  - ▶ Aumenta la matriz Var-Cov
  - ▶ Modelo inestable
  - ▶ No afecta a la predicción

## Detección

- Analizar:
  - ▶ Contrastes de significación (t y F)
  - ▶ Factores de inflación de la varianza (VIF)
  - ▶ Matriz de correlaciones de las variables  $\mathbf{X}$

## Soluciones

- El problema de la información muestral no tiene una solución concreta
- Recomendaciones: ampliar la información muestral, omitir variables del modelo, ...

# Multicolinealidad

## Consecuencias

- Con multicolinealidad perfecta no es posible calcular los estimadores MCO, ya que la matriz  $\mathbf{X}'\mathbf{X}$  es singular:

$$\rho(\mathbf{X}) < k \Rightarrow \rho(\mathbf{X}'\mathbf{X}) < k \Rightarrow |\mathbf{X}'\mathbf{X}| = 0$$

- Con multicolinealidad aproximada se mantienen las propiedades de los estimadores, pero aumenta la matriz var-cov, con lo que resulta difícil rechazar la nulidad de los coeficientes en los contrastes t.
- Con multicolinealidad el modelo resulta inestable, con lo que se observan alteraciones importantes en los coeficientes estimados y su significación al cambiar el tamaño muestral o la especificación del modelo.
- La multicolinealidad no afecta a las predicciones del modelo

# Detección de la multicolinealidad con Gretl

Modelo 2: MCO, usando las observaciones 1987--2008 ( $T = 22$ )

Variable dependiente: consumopc

	Coeficiente	Desv. Típica	Estadístico $t$	Valor p
const	-1.35103	0.354700	-3.8089	0.0013
precios	0.0283484	0.0386238	0.7340	0.4724
rentapc	-9.30222e-05	5.22930e-05	-1.7789	0.0922
ipc	0.0281372	0.0492098	0.5718	0.5745
Media de la vble. dep.	2.163958	D.T. de la vble. dep.	0.988285	
Suma de cuad. residuos	2.928062	D.T. de la regresión	0.403324	
$R^2$	0.857243	$R^2$ corregido	0.833451	
$F(3,18)$	36.02957	Valor p (de $F$ )	8.10e-08	
Log-verosimilitud	-9.032929	Criterio de Akaike	26.06586	
Criterio de Schwarz	30.43003	Hannan--Quinn	27.09392	
$\hat{\rho}$	0.318925	Durbin--Watson	1.309339	



# Detección de la multicolinealidad con Gretl

## Estabilidad del modelo

$$\widehat{\text{consumopc}} = -1,35103 + 0,0283484 \text{ precios} - 9,30222e-05 \text{ rentapc} + 0,0281372 \text{ ipc}$$

(0,35470)            (0,038624)            (5,2293e-05)            (0,049210)

$$T = 22 \quad \bar{R}^2 = 0,8335 \quad F(3, 18) = 36,030 \quad \hat{\sigma} = 0,40332$$

(Desviaciones típicas entre paréntesis)

$$\widehat{\text{consumopc}} = -1,35170 + 0,0498576 \text{ precios} - 9,35994e-05 \text{ rentapc}$$

(0,34836)            (0,0086001)            (5,1349e-05)

$$T = 22 \quad \bar{R}^2 = 0,8394 \quad F(2, 19) = 55,860 \quad \hat{\sigma} = 0,39612$$

(Desviaciones típicas entre paréntesis)

$$\widehat{\text{consumopc}} = -1,14025 + 0,0127562 \text{ precios} + 0,0298270 \text{ ipc}$$

(0,35285)            (0,039701)            (0,051927)

$$T = 22 \quad \bar{R}^2 = 0,8145 \quad F(2, 19) = 47,097 \quad \hat{\sigma} = 0,42568$$

(Desviaciones típicas entre paréntesis)



# Multicolinealidad en Gretl

Gretl: En la salida del modelo, Contrastes → Colinealidad

## Factores de inflación de varianza (VIF)

Mínimo valor posible = 1.0

Valores mayores que 10.0 pueden indicar un problema de colinealidad

precios	124.024
rentapc	6.377
ipc	117.681

$VIF_j = \frac{1}{1 - R_j^2}$ , donde  $R_j^2$  es el coeficiente de correlación múltiple entre la variable  $j$  y las demás variables independientes

En este caso admitimos que existe multicolinealidad



# Cambio estructural

## Causas

- Existencia de rupturas o cambios en las relaciones entre las variables del modelo

## Consecuencias

- Pérdida de validez del modelo y riesgos de extrapolación

## Detección

- Análisis gráfico
- Contrastes de CUSUM y CUSUMSQ, de Chow, RV de Quandt

## Soluciones

- Especificación de varios modelos diferentes
- Introducción de variables dummy





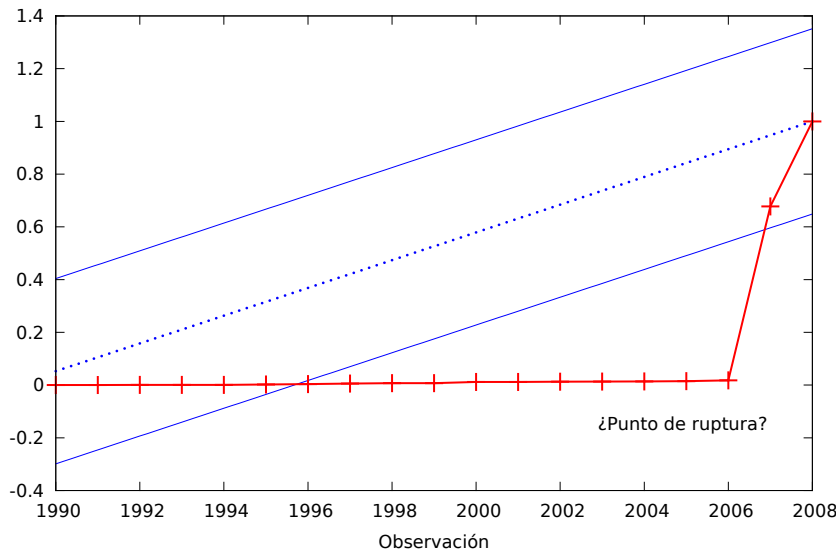
# Test recursivos CUSUM y CUSUMSQ

Contrastes	Guardar	Gráficos	Análisis
Omitir variables			
Añadir variables			
Suma de los coeficientes			
Restricciones lineales			
No linealidad (cuadrados)			
No linealidad (logs)			
Contraste RESET de Ramsey			
Heterocedasticidad			
Normalidad de los residuos			
Observaciones influyentes			
Colinealidad			
Contraste de Chow			
Autocorrelación			
Valor p del estadístico Durbin-Watson			
ARCH			
Contraste de RV de Quandt (QLR)			
Contraste CUSUM			
Contraste CUSUMSQ			

- Se estima inicialmente el modelo para una muestra pequeña  $1, \dots, n_1$
- Se repite la estimación sucesivamente para las muestras  $1, \dots, n_1 + 1; 1, \dots, n_1 + 2; \dots$  y así hasta el periodo global  $1, \dots, n$ .
- Se analizan las sumas acumuladas de residuos (CUSUM) o las sumas acumuladas de residuos cuadráticos (CUSUMSQ).
- **Cambios drásticos en las sumas acumulativas indican posibles puntos de ruptura del modelo**

# Test recursivos CUSUM y CUSUMSQ

Gráfico CUSUM al cuadrado con intervalo de confianza 95%



# Contraste de Chow

Hipótesis: No hay cambio estructural

$$H_0 : \beta_1 = \beta_2 = \beta \quad \sigma_1 = \sigma_2 = \sigma$$

$$H_1 : \beta_1 \neq \beta_2 \quad \sigma_1 \neq \sigma_2$$

Regresiones propuestas

$$\begin{cases} \mathbf{y} = \mathbf{X}\beta + \mathbf{u} & \text{con } \mathbf{u} \approx N(\mathbf{0}, \sigma^2 \mathbf{I}) \\ \mathbf{y}_1 = \mathbf{X}_1\beta_1 + \mathbf{u}_1 & \text{con } \mathbf{u}_1 \approx N(\mathbf{0}, \sigma_1^2 \mathbf{I}) \\ \mathbf{y}_2 = \mathbf{X}_2\beta_2 + \mathbf{u}_2 & \text{con } \mathbf{u}_2 \approx N(\mathbf{0}, \sigma_2^2 \mathbf{I}) \end{cases}$$

$$\frac{\hat{\mathbf{u}}' \hat{\mathbf{u}} - (\hat{\mathbf{u}}_1' \hat{\mathbf{u}}_1 + \hat{\mathbf{u}}_2' \hat{\mathbf{u}}_2)}{k} \approx F_{n_1+n_2-2k}^k$$

$$\frac{\hat{\mathbf{u}}_1' \hat{\mathbf{u}}_1 + \hat{\mathbf{u}}_2' \hat{\mathbf{u}}_2}{n_1+n_2-2k}$$


Rechazamos para valores elevados de  $F$   
(niveles críticos bajos)

**Limitaciones:** Exige conocer punto de ruptura y disponer de suficientes observaciones muestrales



# Contraste de Chow en Gretl

Gretl: En la salida del modelo, Contrastes → Contraste de Chow



- Para contrastar la estabilidad estructural se realizan regresiones ampliadas incluyendo una variable dummy ligada al posible cambio estructural y funciones de las variables explicativas.
- El test contrasta la nulidad de los coeficientes de estas variables añadidas.

Contraste de Chow de cambio estructural en la observación 2006

$F_{16}^3 = 354,652$  con valor  $p = 0,0000$

# Contraste RV de Quandt en Gretl

Gretl: En la salida del modelo, Contrastes → Contraste RV de Quandt (QRV)

Este test se basa en la razón de verosimilitudes y tiene la ventaja de que determina posibles puntos de ruptura

Contraste de razón de verosimilitudes de Quandt para cambio estructural en un punto desconocido, con recorte del 15 por ciento:

El valor máximo de  $F_{16}^3 = 49,9244$  corresponde a la observación 2005  
Significativo al nivel del 1 por ciento (Valor crítico al 1% = 6.02)

Este estadístico no sigue la distribución F estándar; los valores críticos provienen de Stock y Watson (2003).



# Tratamiento del cambio estructural

Una vez detectada una ruptura en un modelo es posible:

- Estimar modelos diferentes antes y después del cambio (permite cambiar la especificación pero exige tamaños muestrales elevados)
- Introducir en el modelo variables cualitativas asociadas a los cambios estructurales

$$W = \begin{cases} 0 & \text{para } t < t^* \\ 1 & \text{para } t \geq t^* \end{cases}$$



# Problemas y soluciones:

## ¿Multicolinealidad?

- Ampliar la muestra actual
- Omitir variables del modelo

## ¿Cambio estructural?

- Especificaciones de modelos diferentes
- Introducción de variables dummy

