

# ECONOMETRÍA I

## Tema 6: Heterocedasticidad

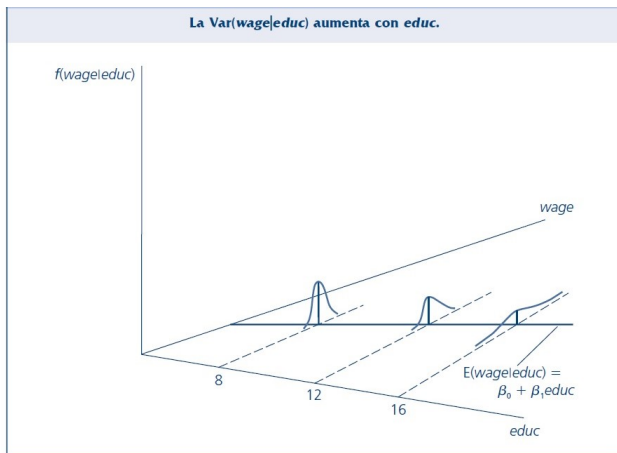
Patricia Moreno

Juan Manuel Rodríguez Poo

Alexandra Soberon

Departamento de Economía

- El supuesto de **homocedasticidad** implica que, condicionando en las variables explicativas, la varianza del término de error no observado es constante.
- Sin embargo, en diversos análisis económicos este supuesto no es cierto y es necesario relajarlo. Por ejemplo, cuando estimamos la relación entre la educación y la habilidad (no observable) suponer que la habilidad es constante para cualquier nivel educativo es demasiado estricto.
- **Heterocedasticidad**: la varianza del error es diferente para cada valor de  $x$ . Los errores son heterocedásticos.



Fuente: Wooldridge (2005)

- Los estimadores MCO siguen siguiendo insesgados y consistentes.
- Bajo heterocedasticidad, los errores estándar de los estimadores están sesgados.
- **Problema:** en presencia de heterocedasticidad los estadísticos habituales empleados en las pruebas de hipótesis bajo los supuestos de Gauss-Markov ya no son válidos.
- Como  $Var(u|X)$  ya no es constante, el estimador MCO ya no es MELI y el estimador MCO ya no es asintóticamente eficiente.
- En presencia de heterocedasticidad es posible hallar estimadores que sean más eficientes que el estimador MCO, aunque es necesario conocer la forma de la heterocedasticidad.

- Para un modelo de regresión simple en el que se cumplen **RLM.1-RLM.4**, el estimador MCO es

$$\hat{\beta}_1 = \beta_1 + \frac{\sum_{i=1}^n (X_i - \bar{X}) u_i}{\sum_{i=1}^n (X_i - \bar{X})^2}.$$

- Asumiendo  $Var(u_i|X_i) = \sigma_i^2$ , la varianza del estimador es

$$Var(\hat{\beta}_j) = \frac{\sum_{i=1}^n (X_i - \bar{X})^2 \sigma_i^2}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2 \sigma_i^2}{SST_x^2}.$$

- Cuando  $\sigma_i^2 \neq \sigma^2$ , un estimador válido de  $Var(\hat{\beta}_1)$  es

$$\frac{\sum_{i=1}^n (X_i - \bar{X})^2 \hat{u}_i^2}{SSC_x^2},$$

donde  $\hat{u}_i$  son los residuos MCO.

- De manera general, un estimador válido de  $Var(\hat{\beta}_j)$  con heterocedasticidad para un modelo de regresión múltiple es

$$\widehat{Var}(\hat{\beta}_j) = \frac{\sum_{i=1}^n \hat{r}_{ij} \hat{u}_i^2}{SST_j^2},$$

donde  $\hat{r}_{ij}$  es el residuo *ith* de la regresión de  $X_j$  sobre el resto de variables independientes y  $SST_j$  es la suma de los residuos al cuadrado de esta regresión.

- Dados los supuestos de Gauss-Markov obtenemos

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)},$$

donde

- $SST_j = \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2$ .
- $R_j^2$  es el  $R^2$  resultante de regresar  $X_j$  sobre el resto de explicativas.

PRUEBA:

$$Y = X_j\beta_j + X_s\beta_s + u,$$
$$\hat{\beta}_j = (X_j' M_s X_j)^{-1} X_j' M_s Y.$$

$$\text{Var}(\hat{\beta}_j) = \sigma_u^2 (X_j' M_s X_j)^{-1}$$

$$\begin{aligned} \text{Var}(\hat{\beta}_j) = \sigma_u^2 (X_j' M_s X_j)^{-1} &= \frac{\sigma_u^2}{\sum_{i=1}^n (X_{ij} - \bar{X}_j)^2 (1 - R_j^2)} \\ &= \text{Var}(\hat{\beta}_j) \frac{1}{1 - R_j^2}. \end{aligned}$$



- **Error estándar robusto:** raíz cuadrada del estimador consistente de la varianza.
- Una vez obtenidos los errores estándar robustos a heterocedasticidad es posible construir un estadístico  $t$  robusto a heterocedasticidad.
- Normalmente la varianza estimada suele ser corregida por los grados de libertad. Para ello, la multiplicamos por  $n/(n - k - 1)$ .

¿Por qué calculamos los errores estándar habituales?

- Bajo homocedasticidad, los errores se distribuyen normalmente y los estadísticos  $t$  tienen distribuciones  $t$  exactas, sin importar el tamaño muestral.
- Los errores estándar robustos y los estadísticos  $t$  robustos sólo se justifican si el tamaño de la muestra es grande.
- Con tamaño muestral pequeño el  $t$  robusto puede tener distribuciones alejadas de la distribución  $t$  invalidando la inferencia.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + u$$

- Hipótesis nula:  $H_0 : \beta_3 = 0, \beta_4 = 0$ . LM es aproximadamente  $\chi_q^2$ .
- Obtenemos los residuos del modelo restringido ( $\tilde{u}$ ).
- Regresamos cada una de las variables independientes excluidas bajo la  $H_0$  sobre todas las variables incluidas ( $q$  regresiones distintas). Guardamos los residuos  $\tilde{r}_1, \tilde{r}_2, \dots, \tilde{r}_q$ .
- Regresamos variable unitaria sobre  $\tilde{r}_1 \tilde{u}, \tilde{r}_2 \tilde{u}, \dots, \tilde{r}_q \tilde{u}$  sin intercepto.
- **Estadístico LM:**  $LM = n - SSR_1$ , donde  $SSR_1$  es la suma de cuadrados de los residuos de la última regresión.

- **Objetivo:** contrastar el supuesto de homocedasticidad,

$$H_0 : \text{Var}(u|X_1, X_2, \dots, X_k) = \sigma^2,$$

que es equivalente a  $H_0 : E(u^2|X_1, X_2, \dots, X_k) = E(u^2) = \sigma^2$ .

- Si rechazamos  $H_0$  el valor esperado de  $u^2$ , dadas las variables independientes, puede ser prácticamente cualquier función de  $X_j$ .
- ¿Por qué contrastar heterocedasticidad? Bajo los supuestos del modelo lineal clásico,
  - los estadísticos  $t$  usuales tienen distribuciones  $t$  exactas.
  - los estimadores MCO ya no son MELI en presencia de heterocedasticidad.
- **Tipos de contrastes:** Breusch-Pagan y White.

# Test de Breusch-Pagan

- Si asumimos que existe una relación entre  $u^2$  y  $X_j$  que puede ser lineal, es posible contrastar una restricción del tipo

$$u^2 = \delta_0 + \delta_1 X_1 + \dots + \delta_k X_k + v.$$

- **Contraste:**  $H_0 : \delta_1 = \delta_2 = \dots = \delta_k = 0.$
- Problema: el término de error no es observable, pero podemos utilizar los residuos MCO para esta regresión.
- Después de regresar  $\hat{u}^2$  sobre todas las  $X$  podemos usar el  $R^2$  para contruir el estadístico.
- El estadístico  $F$  es igual que el estadístico que contrasta la significatividad global de la regresión,  $F = \frac{R^2/k}{(1-R^2)/(n-k-1)} \sim F_{k,n-k-1}.$
- El estadístico LM es  $LM = nR^2 \sim \chi_k^2.$

- Problema: el test de Breusch-Pagan sólo detecta formas lineales de heterocedasticidad.
- Para resolverlo, el test de White permite contrastar no linealidades utilizando los cuadrados y los productos cruzados de todos los regresores. Si  $k = 3$ ,

$$\begin{aligned}\hat{u}^2 &= \delta_0 + \delta_1 X_1 + \delta_2 X_2 + \delta_3 X_3 + \delta_4 X_1^2 + \delta_5 X_2^2 + \delta_6 X_3^2 \\ &+ \delta_7 X_1 X_2 + \delta_8 X_1 X_3 + \delta_9 X_2 X_3 + v\end{aligned}$$

- **Contraste:**  $H_0 : \delta_1 = \delta_2 = \dots = \delta_9 = 0$ .
- El estadístico F y el LM nos permiten contrastar si todas las  $X_j$ ,  $X_j^2$  y  $X_j X_h$  son conjuntamente significativas.

# Test de White modificado

- La abundancia de regresores es una debilidad del test de White. Sin embargo, es posible obtener una prueba que preserve mejor los grados de libertad.
- Para ello obtenemos los residuos MCO y los valores ajustados y estimamos

$$\hat{u}^2 = \delta_0 + \delta_1 \hat{y} + \delta_2 \hat{y}^2 + \epsilon,$$

donde  $\hat{y}$  y  $\hat{y}^2$  pueden aproximar  $X_j$ ,  $X_j^2$  y  $X_j X_h$ .

- Destacar que gracias a este procedimiento sólo contrastamos 2 restricciones.
- Utilizamos el  $R^2$  resultante para calcular el estadístico F o el LM.

- En presencia de heterocedasticidad, MCO ya no es el mejor estimador lineal insesgado.
- Si se conoce la forma de la heterocedasticidad puede usarse la estimación por Mínimos Cuadrados Ponderados (MCP) para obtener estimadores más eficientes que los de MCO.
- Los estimadores MCP nos conducen a nuevos estadísticos  $t$  y  $F$  que tienen distribuciones  $t$  y  $F$ , respectivamente.
- La idea básica del procedimiento de Mínimos Cuadrados Ponderados se basa en transformar el modelo cierto para que el término de error sea homocedástico.



- Siendo el modelo a estimar

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_k X_{ki} + u_i.$$

- Suponemos que la varianza se puede modelizar como

$$\text{Var}(u|X) = \sigma^2 h(X),$$

donde  $h(X) = h_i$  determina la heterocedasticidad.

- Si dividimos el modelo por  $\sqrt{h_i}$  obtenemos un modelo transformado de la forma

$$Y_1^* = \beta_0 + \beta_1 X_{1i}^* + \beta_2 X_{2i}^* + \cdots + \beta_k X_{ki}^* + u_i^*,$$

donde  $Y_i^* = Y_i/\sqrt{h_i}$  y  $X_{ji}^* = X_{ji}/\sqrt{h_i}$ , para  $j = 2, \dots, k$ .

- Los errores de este modelo son homocedásticos dado que
  - $E(u_i^*|X) = E\left(\frac{u_i}{\sqrt{h_i}}|X\right) = \frac{E(u_i|X)}{\sqrt{h_i}} = 0$ .
  - $Var(u_i^*) = E\left(\frac{E(u_i^2|X)}{h_i}\right) = \frac{\sigma^2 h_i}{h_i} = \sigma^2$ .

Recuerda  $Var(u|X) = \sigma^2 h_i$ .

- Estimar el modelo transformado por MCO es un ejemplo del método de Mínimos Cuadrados Generalizados (GLS).
- Dado que la ecuación transformada satisface los supuestos del modelo lineal clásico, RLM.1-RLM.6, a excepción del supuesto de homocedasticidad el estimador GLS es MELI.
- El procedimiento GLS es un método de MCP donde cada residuo al cuadrado es ponderado por la inversa de  $Var(u_i|X_i)$ , i.e.

$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_{1i} - \dots - \beta_k X_{ki})^2 / h_i.$$

- GLS es muy útil cuando conocemos la forma de  $Var(u_i|X_i)$ . Sin embargo, en los estudios empíricos esto no es muy habitual.
- Para resolver esta situación se desarrolla un procedimiento basado en la estimación de  $h(X_i)$  conocido como Mínimos Cuadrados Generalizados Factibles (FGLS).
- Partimos del supuesto de que la heterocedasticidad se puede modelizar como

$$Var(u|X) = \sigma^2 \exp(\delta_1 + \delta_2 X_2 + \delta_3 X_3 + \dots + \delta_k X_k)$$

donde los parámetros  $\delta$  deben ser estimados

- Para estimar el modelo transformamos la ecuación en una forma lineal que puede ser estimada por MCO,

$$u^2 = \sigma^2 \exp(\delta_1 + \delta_2 X_2 + \delta_3 X_3 + \cdots + \delta_k X_k) v,$$

donde  $E(v|X) = 1$  si  $E(v) = 1$ .

- Como  $v$  es independiente de  $X$ ,

$$\log(u^2) = \alpha_1 + \delta_2 X_2 + \cdots + \delta_k X_k + e,$$

donde  $E(e) = 1$  y es independiente de  $X$ .

Para obtener el estimador FGLS:

- Regresamos  $Y$  sobre todos los  $X$  y obtenemos los residuos  $\hat{u}$ . Calculamos  $\log(\hat{u}^2)$ .
- Regresamos  $\log(\hat{u}^2)$  sobre todos los residuos  $X$  obteniendo los valores ajustados:  $\hat{g}_i = \widehat{\log(\hat{u}^2)}$ .
- Estimamos el modelo cierto por GLS utilizando  $1/\exp(\hat{g})$  como ponderación.

- El estimador FGLS ya no es insesgado, pero sigue siendo consistente y asintóticamente eficiente.
- Los estadísticos usuales,  $t$  y  $F$ , de la regresión MCP son asintóticamente válidos.
- Recuerda que usamos MCP por motivos de eficiencia. Los estimadores MCO siguen siendo insesgados y consistentes.
- Los estimadores aún serán diferentes debido a un error muestral. Si son muy diferentes es probable que algún supuesto más de Gauss-Markov es falso.