

Heteroscdasticidad y MCG

Walter Sosa-Escudero

May 16, 2020

Modelo lineal clasico:

- 1 Linealidad: $Y = X\beta + u$.
- 2 Exogeneidad: $E(u) = 0$
- 3 No Multicolinealidad: $\rho(X) = K$.
- 4 No heteroscedasticidad ni correlacion serial: $V(u) = \sigma^2 I_n$.


Teorema de Gauss/Markov $\hat{\beta} = (X'X)^{-1}X'Y$ es el mejor estimador lineal insesgado.

$\hat{V}(\hat{\beta}) = S^2(X'X)^{-1}$ es insesgado para $V(\hat{\beta}) = \sigma^2(X'X)^{-1}$.

Heterocedasticidad?

- $\hat{\beta}$ lineal e insesgado (por que?).
- Gauss Markov?
- $\hat{V}(\hat{\beta}) = S^2(X'X)^{-1}$ **sesgado**. Invalida 't' y 'F'.

Intuición:



- Heterocedasticidad no altera la posición 'central' de la línea de MCO (insesgadez).
- MCO pondera a todas las observaciones por igual. Mas razonable prestar mas atención a aquellas en donde la varianza es mas chica.

Que hacer con la heterocedasticidad?.

- 1 Antes de abandonar MCO: **tests de heterocedasticidad**.
- 2 *Estrategia 1:* **Minimos cuadrados ponderados**. Estimador insesgado y eficiente para β bajo heterocedasticidad. Estima insesgadamente la varianza.
- 3 *Estrategia 2:* **Varianza robusta**: Mantener MCO (insesgado), reemplazar la varianza por una 'correcta' bajo heterocedasticidad.

Chequea si **ciertas** variables causan heterocedasticidad.

$$Y = X\beta + u, u_i \sim N, \text{ con } E(u) = 0 \text{ y}$$

$$V(u_i) = h(\alpha_1 + \alpha_2 Z_{2i} + \alpha_3 Z_{3i} + \dots + \alpha_p Z_{pi})$$

$h(\)$ es *cualquier* funcion positiva con dos derivadas.

$\alpha_2 = \dots = \alpha_p = 0, V(u_i) = h(\alpha_1), \text{ constante!!}$

Homocedasticidad $\iff H_0 : \alpha_2 = \alpha_3 = \dots = \alpha_p = 0, \text{ y}$

Heterocedasticidad: $H_A : \alpha_2 \neq 0 \vee \alpha_3 \neq 0 \vee \dots \vee \alpha_p \neq 0.$

El test:

- 1 Estimar por MCO y guardar residuos al cuadrado, e_i^2 .
- 2 Regresar e_i^2 en las variables Z_{ik} , $k = 2, \dots, p$ obtener (SCE).
El estadístico es:

$$\frac{1}{2}SCE \sim \chi^2(p - 1)$$

bajo H_0 , asintóticamente. Rechazar si demasiado grande.

- Intuición: modelo auxiliar modela la varianza del error. Si su R^2 es alto: se puede explicar la varianza, ergo no es constante.
- Aceptar la H_0 no implica que homocedasticidad. Por que?
- Muestras grandes.
- Koenker (1980) propone usar nR_A^2 , que además es válido si los errores son no-normales.

H_0 : homocedasticidad, H_A : heterocedasticidad de alguna forma.

Caso simple, con $K = 3$:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i \quad 1, \dots, n$$

Pasos para implementar el test:

- 1 Estimar por MCO, guardar los residuos al cuadrado e^2 .
- 2 Regresar e^2 en todas las variables, sus cuadrados y todos los posibles productos cruzados no redundantes. En nuestro caso, regresar e^2 en $1, X_2, X_3, X_2^2, X_3^2, X_2X_3$, obtener el R^2 de esta regresion auxiliar.
- 3 Bajo H_0 , $nR^2 \sim \chi^2(p)$. $p =$ numero de variables explicativas en el modelo auxiliar, menos una.
- 4 Rechazar H_0 si nR^2 es demasiado grande.

- Intuición: misma que BPGK
- Hipotesis nula más general que el de BPGK.
- Informativo si no se rechaza la hipótesis nula (no heterocedasticidad).
- Si rechaza H_0 : hay heterocedasticidad. No tenemos información de que la causa.

Caso de dos variables

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

Bajo **heteroscedasticidad**:

$$V(u_i) = \sigma_i^2, \quad i = 1, \dots, n$$

Valen todos los otros supuestos clasicos .


Dividamos cada observacion por σ_i :

$$\begin{aligned}\frac{Y_i}{\sigma_i} &= \beta_1 \frac{1}{\sigma_i} + \beta_2 \frac{X_i}{\sigma_i} + \frac{u_i}{\sigma_i} \\ Y_i^* &= \beta_1 X_{1i}^* + \beta_2 X_{2i}^* + u_i^*\end{aligned}$$

Notar que $V(u_i^*) = V(u_i/\sigma_i) = 1$: los residuos del modelo transformado son *homocedasticos*

Minimos cuadrados ponderados: el MELI es simplemente el estimador de MCO usando las variables transformadas.

Intuición:



MCO pondera a todas las observaciones por igual. MCP pondera por la inversa del desvío estandar (menor varianza).

Un modelo implementable

Problema: σ_i^2 desconocido. $Y_i = \beta_1 + \beta_2 X_i + u_i$. Supongamos:

$$V(u_i) = \sigma^2 X_i^2$$

X es la causa de la heterocedasticidad. Dividamos todas las observaciones por X_i

$$\frac{Y_i}{X_i} = \beta_1 \frac{1}{X_i} + \beta_2 + \frac{u_i}{X_i}$$

$$Y_i^* = \beta_1 X_{0i}^* + \beta_2 + u_i^*$$

Notar que $E(u_i^*) = E(u_i/X_i) = \sigma^2 \frac{X_i^2}{X_i^2} = \sigma^2$

Los errores del modelo transformado son homocedaticos: MCO en el modelo transformado!

- No hace falta conocer σ^2 . Hemos dividido solo por la parte del error estandar que varia con las obervaciones X_i .
- **Cuidado con las interpretaciones.** El intercepto de este modelo transformado es la *pendiente* del original y la pendiente del transformado es el intercepto del original.

Otro caso: **b)** $V(u) = \sigma^2 X_i$

$$\frac{Y_i}{\sqrt{X_i}} = \beta_1 \frac{1}{\sqrt{X_i}} + \beta_2 \sqrt{X_i} + \frac{u_i}{\sqrt{X_i}}$$

$$Y_i^* = \beta_1 X_{0i}^* + \beta_2 X_{1i}^* + u_i^*$$

Este modelo transformado no tiene intercepto, y el coeficiente de la primera variable explicativa se corresponde con el intercepto y la segunda con la pendiente del modelo original.

Problema con MCP: es muy difícil encontrar una forma exacta de heterocedasticidad.

Estrategia alternativa: retener MCO (insesgado pero no eficiente) y buscar un estimador válido para la varianza.

Bajo heterocedasticidad, la varianza de $\hat{\beta}_{MCO}$ es:

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

$$\Omega = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2).$$

White (1980): un estimador valido para $X'\Omega X$ es $X'DX$,
 $D = \text{diag}(e_1^2, e_2^2, \dots, e_n^2)$, e_i 's son los residuos de MCO.

Entonces, un estimador *consistente bajo heteroscedasticidad* para la varianza es:

$$\hat{V}(\hat{\beta}_{MCO})_{HC} = (X'X)^{-1}X'DX(X'X)^{-1}$$

Estrategia: usar MCO pero reemplazar $S^2(X'X)^{-1}$ por el estimador de White. Esta estrategia no es eficiente, pero no requiere supuestos acerca de la estructura de la heterocedasticidad.

Resumen

- Heterocedasticidad: MCO ineficiente, invalida el estimador estandar de la varianza, y los procesos inferenciales estandar (t tests, F tests, etc.).
- MCP es eficiente e insesgado, pero su implementacion depende de conocer la estructura de varianza.
- En la practica es mas comun mantener MCO y reemplazar el estimador de la varianza por el de White, que no requiere supuestos.

Minimos cuadrados generalizados

En general, valen todos los supuestos clasicos valen, pero ahora

- $V(u) = \sigma^2\Omega$ en donde Ω es cualquier matriz simetrica $n \times n$ y positiva definida.

Permiteo **heterocedasticidad** y/o **correlacion serial**, de cualquier forma.

Plan

- 1 Consecuencias de relajar $V(u) = \sigma^2 I_n$.
- 2 Estimador optimo (MCG).

- $\hat{\beta}$ lineal e insesgado, Gauss Markov no vale.
- $V(\hat{\beta})$ es ahora $\sigma^2(X'X)^{-1}\Omega(X'X)^{-1}$.
- $S^2(X'X)^{-1}$ es **sesgado** para $V(\hat{\beta})$.
- Tests t ni F funcionan.

Entonces, ignorar heterocedasticidad o correlacion serial (usar $\hat{\beta}$ y $\hat{V}(\hat{\beta}|X) = S^2(X'X)^{-1}$), preserva insesadez, inferencia estandar deja de ser valida. Eficiencia?

Resultado simple: si Ω es $n \times n$ simetrica y pd, entonces existe una matriz $n \times n$, C , no singular tal que:

$$\Omega^{-1} = C' C$$

Que significa esto, intuitivamente?

Consideremos el siguiente modelo transformado

$$Y^* = X^* \beta + u^*$$

con $Y^* = CY$, $X^* = CX$ y $u^* = Cu$.

Es facil verificar:

- 1 $Y^* = X^*\beta + u^*$, el modelo transformado es trivialmente lineal.
- 2 $E(u^*) = CE(u) = 0$
- 3 $\rho(X^*) = \rho(CX) = K$,
- 4 $V(u^*) =$

$$\begin{aligned} V(Cu|X) &= E(Cuu'C'|X) = CE(uu'|X)C' \\ &= C\sigma^2\Omega C' \\ &= \sigma^2C[\Omega^{-1}]^{-1}C' \\ &= \sigma^2C[(C'C)^{-1}]^{-1}C \\ &= \sigma^2I_n \end{aligned}$$

Entonces...?

Vale el Teorema de Gauss-Markov Theorem *para el modelo transformado*, entonces, el MELI es:

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

Este es el **estimador de minimos cuadrados generalizado**

- MCG es un estimador MCO para un modelo transformado.
- MELI bajo heterocedasticidad o correlacion serial.
- Ahoa es claro en que sentido $\hat{\beta}$ es ineficiente.
- Importante: las propiedades estadisticas dependen de la estructura subyacente (no son propiedades del estimador *per-se*).

Notar que

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

- Cuando $\Omega = I_n$, $\hat{\beta}_{gls} = \hat{\beta}$.
- La implementación práctica de $\hat{\beta}_{gls}$ requiere conocer Ω (si bien no σ^2 .)
- Es fácil chequear que $V(\hat{\beta}_{gls}) = \sigma^2 (X^{*'} X^*)^{-1}$.
- Mínimos cuadrados ponderados: $\Omega = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2)$, entonces, $C = \text{diag}(\sigma_1^{-1}, \sigma_2^{-1}, \dots, \sigma_n^{-1})$

Supongamos que existe un estimador para Ω , que llamaremos $\hat{\Omega}$. Entonces, reemplazando Ω por $\hat{\Omega}$:

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

Este es el estimador de **MCG factible**.

Es lineal e insesgado? Eficiente?