

Heteroscdasticidad y MCG

Walter Sosa-Escudero

May 24, 2009

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

Que sucede si relajamos el supuesto de homocedasticidad?

- $\hat{\beta}$ (el estimador MCO) es lineal e insesgado (porque?).
- Pero no es mas el de minima varianza.
- $\hat{V}(\hat{\beta}) = S^2(X'X)^{-1}$ es **sesgado**. Invalida los estadisticos 't' y 'F'.

Intuition:



- La presencia de heterocedasticidad no altera la posición 'central' de la línea de MCO (insesgadez).
- MCO pondera a todas las observaciones por igual. Pero en este caso parece más razonable prestar más atención a aquellas en donde la varianza es más chica.

Plan: que hacer con la heterocedasticidad?.

- 1 Antes de abandonar MCO: **tests de heterocedasticidad**.
- 2 *Estrategia 1*: Proponer otro estimador insesgado y eficiente para β (**minimos cuadrados ponderados (WLS)**) y un estimador apropiado para su varianza.
- 3 *Estrategia 2*: Mantener OLS (es insesgado, si bien ineficiente), pero reemplazar la varianza (la estandar es sesgada bajo heterocedasticidad).

Tests de Heterocedasticidad

a) Test de Breusch-Pagan/Godfrey/Koenker

Chequea si *ciertas* variables causan heterocedasticidad.

Consideremos el siguiente modelo heterocedastico:

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

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

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

Cuando $\alpha_2 = \dots = \alpha_p = 0$, $V(u_i) = h(\alpha_1)$, una constante!!

Entonces, homocedasticidad $\iff H_0 : \alpha_2 = \alpha_3 = \dots = \alpha_p = 0$, y
 $H_A : \alpha_2 \neq 0 \vee \alpha_3 \neq 0 \vee \dots \vee \alpha_p \neq 0$.

Pasos para implementar el test:

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

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

bajo H_0 , asintoticamente. Rechazamos si es demasiado grande.

Comentarios:

- Intuición: El modelo auxiliar puede ser visto como un intento de modelar la varianza del termino de error. Si el R^2 de esta regresion es alto, entonces se puede explicar el comportamiento de los residuos al cuadrado, lo cual es compatible con que la varianza no es constante.
- Aceptar la hipotesis nula no implica que no haya heterocedasticidad. Porque?
- Test de muestras grandes.
- Koenker (1980) propone usar nR_A^2 , que ademas es valido si los errores son no-normales.

b) Test de White

H_0 : no heteroscedasticidad, H_A : heterocedasticidad de alguna forma.

Consideremos un 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.

Comentarios:

- Intucion: hipotesis nula mas general que el de BPK.
- Informativo si no se rechaza la hipotesis nula (no heterocedasticidad).
- Si rechaza H_0 : hay heterocedasticidad. No tenemos informacion de que la causa.

Estimacion e inferencia bajo heterocedasticidad

Por simplicidad, consideremos el caso de dos variables

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

en donde ahora el termino de error es **heteroscedastico**, esto es

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

Supondremos que todos los otros supuestos clasicos valen.

Dividamos cada observacion por σ_i :

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

Notar que $V(u_i^*) = V(u_i/\sigma_i) = 1$, entonces, los residuos de este modelo transformado son *homoscedasticos*.

Entonces, si conocemos σ_i^2 , el MELI es simplemente el estimador de MCO usando las variables transformadas.

En nuestro caso, el estimador MCO del modelo transformado es

$$\hat{\beta}_{2,wls} = \frac{\sum_{i=1}^n x_i^* y_i^*}{\sum_{i=1}^n x_i^{*2}}$$

$$\hat{\beta}_{1,wls} = \bar{Y}^* - \hat{\beta}_{2,wls} \bar{X}^*$$

con $Y_i^* = Y_i/\sigma_i$, $X_i^* = X_i/\sigma_i$, y las letras minusculas indican diferencias con respecto a las medias muestrales.

Este es el estimador de **minimos cuadrados ponderados**.

El nombre **minimos cuadrados ponderados** viene del hecho de que este estimador se puede obtener resolviendo el siguiente problema de minimizacion:

$$\min \sum_{i=1}^n \frac{1}{\sigma_i^2} e_i^2,$$

esto es, los errores entran en la SRC ponderados por la inversa de la varianza de cada observacion: estamos prestando mas atencion a las observaciones con menor varianza.

Problema: en la practica no conocemos σ_i^2 . Esto conduce a dos estrategias.

- 1 **Usas WLS:** Pros: estimaciones insesgadas y eficientes.
Contra: es necesario saber las varianzas de antemano (o realizar supuestos)
- 2 **Mantener MCO pero cambiar la estimacion de la varianza:**
Pensemos en los efectos de la heterocedasticidad. MCO es insesgado pero ineficiente (not esta tan mal...). But, $S^2(X'X)^{-1}$ is biased, which invalidates inference (this is bad!). Then, a second strategy: keeping OLS for β and look for a valid estimator for its variance. Pros: no hacen falta supuestos, unbiased. Cons: perdermos eficiencia, pero con respecto a WLS (si esta disponible).

1) Varianza conocida: WLS

Consideremos el caso simple con dos variables:

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

Estrategia: suponer alguna forma particular de heterocedasticidad.

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

σ^2 es una constante desconocida. 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 homocedasticos: MCO en

- No hace falta conocer σ^2 . Hemos dividido solo por la parte del error estandar que varia con las obervaciones, X_i .
- Esta estrategia provee una estimacion WLS.
- **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.

$$b) V(u) = \sigma^2 X_i$$

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

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

Con respecto a la implementacion e interpretacion, notar que este modelo transformado no tiene intercepto, y que el coeficiente de la primera variable explicativa se corresponde con el intercepto y la segunda con la pendiente del modelo original.

Problema con estas estrategias: es muy dificil encontrar una forma exacta de heterocedasticidad.

2) Estructura de varianza desconocida

Estrategia alternativa: retener MCO (insesgado pero no eficiente) y buscar un estimador valido para la varianza. Bajo heterocedasticidad, la varianza de $\hat{\beta}_{OLS}$ 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 *consistentente* 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 heteroscedasticity* para la varianza es:

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

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

Resumen

- La heterocedasticidad hace que MCO sea ineficiente e invalida el estimador estandar de la varianza, y por consiguiente, los procesos inferenciales estandar (t tests, F tests, etc.).
- El estimador WLS es eficiente e insesgado, pero depende de conocer la estructura de varianza. En la practica es muy raro que este disponible.
- En la practica es mas comun mantener el esimador MCO y reemplazar el estimador de la varianza pr el de White, que no requiere supuestos.

El model generalizado y MCG

Supongamos que todos los supuestos clasicos valen, pero ahora

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

Estamos permitiendo **heterocedasticidad** y/o **correlacion serial**, pero no estamos imponiendo ninguna estrucutra sobre Ω .

Plan

- 1 Consecuencias de relajar $V(u|X) = \sigma^2I_n$.
- 2 Entontrar un estimador optimo (MCG).

Consecuencias de relajar $V(u|X) = \sigma^2 I_n$

- $\hat{\beta}$ lineal e insesgado, Gauss Markov Theorem no vale.
- $V(\hat{\beta}|X)$ es ahora $\sigma^2(X'X)^{-1}\Omega(X'X)^{-1}$ (probar este resultado).
- $S^2(X'X)^{-1}$ es **sesgado** para $V(\hat{\beta})$.
- Los tests t no tienen distribucion t . Los tests F tampoco son validos.

Entonces, ignorar heterocedasticidad o correlacion serial, esto es, usar $\hat{\beta}$ y $\hat{V}(\hat{\beta}|X) = S^2(X'X)^{-1}$, prserva la propiedad de insesadez, perdiendo eficiencia, pero la inferencia estandar deja de ser valida.

Minimos Cuadrados Generalizados

Necesitamos primero un resultado simple: si Ω es $n \times n$ simetrica y pod, 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 $Y^* = X^*\beta + u^*$, so the transformed model is trivially linear.
- ② $E(u^*|X) = CE(u|X) = 0$
- ③ $\rho(X^*) = \rho(CX) = K$, w.p.1. (CX is a rank preserving transformation of X !).
- ④ $V(u^*|X) =$

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

Entonces...?

Dado que el modelo transformado satisface todos los supuestos clasicos, 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**

- Cuidado: el estimador de MCG es un estimador MCO para un modelo transformado.
- Provee un MELI bajo heterocedasticidad o correlacion serial.
- Ahoa es claro en que sentido $\hat{\beta}$ es ineficiente.
- Es importante ver que 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 implementacion practica de $\hat{\beta}_{gls}$ requiere conocer Ω (si bien no σ^2 .)
- Es facil chequear que $V(\hat{\beta}_{gls}) = \sigma^2 (X^{*'} X^*)^{-1}$.

MGC Factible

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?