

Paneles heterogéneos

Gabriel Montes-Rojas

Paneles heterogéneos

- En los modelos previos, toda la heterogeneidad se modelaba con un intercepto que era específico de cada individuo, y autocorrelación y/o heteroscedasticidad de los errores.
- Paneles heterogéneos trata de modelos con pendientes heterogéneas (slope heterogeneity).
- En general se necesita que $T \rightarrow \infty$ para poder estimar cada ecuación por separado.

Paneles heterogéneos

Dos formas de modelar la heterogeneidad, coeficientes fijos y coeficientes aleatorios.

- Podríamos considerar que cada individuo tiene una estructura de coeficientes única, β_i .

$$y_{it} = x_{it}\beta_i + u_{it}, i = 1, 2, \dots, N; t = 1, 2, \dots, T.$$

Esto se puede modelar usando interacciones de las Xs con las dummies por individuo o estimando un modelo diferente para cada i .

También podríamos tener que algunos coeficientes son específicos de cada individuo i y otros son comunes:

$$y_{it} = x_{it}\beta_i + z_{it}\gamma + u_{it}, i = 1, 2, \dots, N; t = 1, 2, \dots, T.$$

Si todos los coeficientes fueran específicos para cada individuo, el modelo es equivalente a MCO para cada i .

- Otra forma más simple de modelar heterogeneidad es con un **modelo de coeficientes aleatorios**. En este caso, los coeficientes mismos son variables aleatorias, que se asumen estacionarios (misma media y varianza).

SUR

Consideremos las siguientes M regresiones supuestamente no relacionadas (“seemingly unrelated regressions, SUR”)

$$\mathbf{y}_i = \mathbf{X}_i \boldsymbol{\beta}_i + \mathbf{u}_i, \quad i = 1, 2, \dots, M,$$

donde $\mathbf{y}_i = (y_{i1}, y_{i1}, \dots, y_{iT})'$ y $\mathbf{u}_i = (u_{i1}, u_{i1}, \dots, u_{iT})'$ son vectores $T \times 1$, \mathbf{X}_i es una matriz de $T \times K_i$ de K_i variables explicativas, y $\boldsymbol{\beta}_i$ es un vector $K_i \times 1$.

Supuesto 1: El vector $MT \times 1$ de errores tiene media condicional 0:

$$E(\mathbf{u} | \mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M) = \mathbf{0}.$$

Supuesto 2: Los errores no están correlacionados entre observaciones:

$$E(\mathbf{u}_i \mathbf{u}_j' | \mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M) = \sigma_{ij} \mathbf{I}_T.$$

Supuesto 3: Distintos modelos pueden ser considerados para las correlaciones entre errores.

- 1 $E(\mathbf{u}_i \mathbf{u}_j') = 0, \quad i \neq j.$
- 2 $E(\mathbf{u}_i \mathbf{u}_j') = \sigma_{ij} \mathbf{I}_T \neq 0, \quad i \neq j,$ pero $\mathbf{X}_i = \mathbf{X}_j,$ para todo $i, j.$
- 3 $E(\mathbf{u}_i \mathbf{u}_j') = \sigma_{ij} \mathbf{I}_T \neq 0, \quad i \neq j,$ pero $\mathbf{X}_i \neq \mathbf{X}_j,$ para al menos un par $i \neq j.$

SUR

El modelo se puede escribir como

$$\begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_M \end{pmatrix} = \begin{pmatrix} \mathbf{X}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \mathbf{X}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{X}_M \end{pmatrix} \begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_M \end{pmatrix} + \begin{pmatrix} \mathbf{u}_1 \\ \mathbf{u}_2 \\ \vdots \\ \mathbf{u}_M \end{pmatrix}$$

$$= \mathbf{G}\beta + \mathbf{u},$$

donde \mathbf{y} , \mathbf{G} , β y \mathbf{u} tienen dimensiones $MT \times 1$, $MT \times K$, $K \times 1$ y $MT \times 1$, respectivamente, y $K = \sum_{i=1}^M K_i$.

SUR

Los Casos 1 y 2 son equivalentes a estimar una regresión por individuo.
Supongamos el Caso 3, $E(\mathbf{u}_i \mathbf{u}_j') = \sigma_{ij} \mathbf{I}_T \neq 0$, $i \neq j$, pero $\mathbf{X}_i \neq \mathbf{X}_j$, para al menos un par $i \neq j$.

$$E(\mathbf{u}_i \mathbf{u}_j' | \mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M) = \Omega = \Sigma \otimes \mathbf{I}_T,$$

donde $\Sigma = \{\sigma_{ij}\}$ es una matriz simétrica $M \times M$. En particular,

$$\Omega = \Sigma \otimes \mathbf{I}_T = \begin{pmatrix} \sigma_{11} \mathbf{I}_T & \sigma_{12} \mathbf{I}_T & \dots & \sigma_{1M} \mathbf{I}_T \\ \sigma_{12} \mathbf{I}_T & \sigma_{22} \mathbf{I}_T & \dots & \sigma_{2M} \mathbf{I}_T \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1M} \mathbf{I}_T & \sigma_{2M} \mathbf{I}_T & \dots & \sigma_{MM} \mathbf{I}_T \end{pmatrix},$$

y también $\Omega^{-1} = \Sigma^{-1} \otimes \mathbf{I}_T$.

Entonces podemos plantear el MCG,

$$\beta_{MCG} = [\mathbf{G}'(\Sigma^{-1} \otimes \mathbf{I}_T)\mathbf{G}]^{-1} \mathbf{G}'(\Sigma^{-1} \otimes \mathbf{I}_T)\mathbf{y},$$

$$\text{Var}(\beta_{MCG}) = [\mathbf{G}'(\Sigma^{-1} \otimes \mathbf{I}_T)\mathbf{G}]^{-1}$$

En la práctica $\hat{\sigma}_{ij} = \frac{\hat{u}_i \hat{u}_j}{T}$, $i, j = 1, 2, \dots, M$, con los residuos MCO, y se arma $\hat{\Sigma}$.

Paneles heterogéneos

Modelo de Swamy (1970)

$$y_{it} = \mathbf{x}_{it}\boldsymbol{\beta}_i + u_{it}, i = 1, 2, \dots, N; t = 1, 2, \dots, T,$$

$$\boldsymbol{\beta}_i = \boldsymbol{\beta} + \boldsymbol{\eta}_i, E(\boldsymbol{\eta}_i) = 0, E(\mathbf{x}_{it}\boldsymbol{\eta}_i) = 0, u_{it} \sim iid(0, \sigma_i^2)$$

$$E(\boldsymbol{\eta}_i\boldsymbol{\eta}_j') = \begin{cases} \boldsymbol{\Omega}_\eta, & si \quad i = j, \\ \mathbf{0}, & si \quad i \neq j. \end{cases}$$

- En este modelo tenemos K variables explicativas y K parámetros $\boldsymbol{\beta}$ a estimar (un vector $K \times 1$).
- $\boldsymbol{\eta}$ es una variable aleatoria de dimensión $K \times 1$ (la cantidad de variables explicativas).
- En este modelo la aleatoriedad es invariante en el tiempo.
- Nos interesa la media $\boldsymbol{\beta}$ y la función de varianzas-covarianzas de los parámetros.

Paneles heterogéneos

Modelo de Hsiao (1974,1975)

$$y_{it} = \mathbf{x}_{it}\beta_{it} + u_{it}, i = 1, 2, \dots, N; t = 1, 2, \dots, T$$

$$\beta_{it} = \beta + \eta_i + \lambda_t$$

$$E(\eta_i) = 0, E(\lambda_t) = 0, E(\eta_i'\lambda_t) = 0, u_{it} \sim iid(0, \sigma_i^2)$$

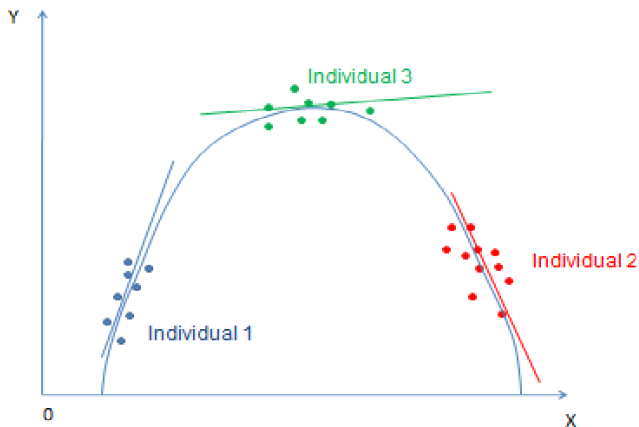
$$E(\mathbf{x}_{it}\eta_i) = 0, E(\mathbf{x}_{it}\lambda_t) = 0$$

$$E(\eta_i\eta_j') = \begin{cases} \Omega_\eta, & si \quad i = j, \\ \mathbf{0}, & si \quad i \neq j. \end{cases}$$

$$E(\lambda_t\lambda_h') = \begin{cases} \Omega_\lambda, & si \quad t = h, \\ \mathbf{0}, & si \quad t \neq h. \end{cases}$$

Paneles heterogéneos

Heterogeneous panels



Consecuencias de obviar heterogeneidad

- Supongamos el siguiente modelo generador de los datos:

$$y_{it} = \mu_i + \beta_i x_{it} + u_{it}, \quad i = 1, 2, \dots, N; \quad t = 1, 2, \dots, T,$$

$$u_{it} \sim iid(0, \sigma_u^2),$$

$$\beta_i = \beta + \eta_i.$$

Este es un modelo de efectos fijos con heterogeneidad en las pendientes.

- Ahora supongamos que se estima el modelo

$$y_{it} = \alpha_i + \delta_x x_{it} + \delta_z z_{it} + v_{it}, \quad i = 1, 2, \dots, N; \quad t = 1, 2, \dots, T,$$

donde z es un regresor adicional que el investigador cree que es necesario, cuando en realidad no lo es.

- $v_{it} \sim iid(0, \sigma_v^2)$, distribuido independientemente de $w_{it} = (x_{it}, z_{it})$ para todo i, t . w_i sigue un proceso estacionario en covarianza con $\Omega_i = \begin{bmatrix} \omega_{ixx} & \omega_{ixz} \\ \omega_{izx} & \omega_{izz} \end{bmatrix}$.
- Consideremos el estimador FE

$$plim_{N, T \rightarrow \infty} \hat{\delta}_{FE} = \left[plim \frac{1}{NT} \sum_{i=1}^N W_i' Q_T W_i \right]^{-1} \left[plim \frac{1}{NT} \sum_{i=1}^N W_i' Q_T (X_i \beta_i) \right],$$

donde $Q_T = I_T - \frac{1}{T} 1_T 1_T'$ (¿qué transformación hace esta matriz?)

Consecuencias de obviar heterogeneidad

- Si $\beta_i = \beta$ entonces $\text{plim}_{N,T \rightarrow \infty} \hat{\delta}_{FE} = (\beta', 0')'$.
- Si los paneles son heterogéneos

$$\text{plim} \frac{1}{NT} \sum_{i=1}^N W_i' Q(X_i \eta_i) = \text{plim} \left(\begin{array}{c} \frac{1}{NT} \sum_{i=1}^N X_i' Q(X_i \eta_i) \\ \frac{1}{NT} \sum_{i=1}^N Z_i' Q(X_i \eta_i) \end{array} \right)$$

- Entonces necesitamos que $\frac{1}{NT} \sum_{i=1}^N \omega_{ixx} \eta_i \xrightarrow{P} 0$ y $\frac{1}{NT} \sum_{i=1}^N \omega_{ixz} \eta_i \xrightarrow{P} 0$. En otras palabras, no tiene que haber correlación sistemática entre los β_i y los **momentos segundos** de los regresores.

●

$$\text{plim} \hat{\delta}_{x,FE} - \beta = \frac{\text{cov}(\omega_{ixx}, \eta_i) E(\omega_{izz}) - E(\omega_{ixz}) \text{cov}(\omega_{ixz}, \eta_i)}{E(\omega_{ixx}) E(\omega_{izz}) - (E(\omega_{ixz}))^2}$$

$$\text{plim} \hat{\delta}_{z,FE} = \frac{\text{cov}(\omega_{ixz}, \eta_i) E(\omega_{ixx}) - E(\omega_{ixz}) \text{cov}(\omega_{ixx}, \eta_i)}{E(\omega_{ixx}) E(\omega_{izz}) - (E(\omega_{ixz}))^2}$$

- Supongamos el modelo $y_{it} = \alpha_i + \delta_x x_{it} + \delta_z x_{it}^2 + v_{it}$. En este caso en general no podemos obtener que FE estima bien a menos que β_i sea proporcional a x_{it} .

Estimador de Swamy (1970)

Consideremos el modelo de Swamy (1970) expuesto anteriormente.

- En el modelo de Swamy, la matriz de varianzas-covarianzas es

$$\Sigma = E(vv') = \begin{bmatrix} \Sigma_1 & 0 & \dots & 0 \\ 0 & \Sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \Sigma_N \end{bmatrix}$$

donde $v_{it} = u_{it} + \mathbf{x}_{it}\eta_i$ y $\Sigma_i = \sigma_i^2 I_T + \mathbf{X}_i \Omega_{\eta} \mathbf{X}_i'$ para $i = 1, 2, \dots, N$.

- Se propone entonces el estimador

$$\hat{\beta}_{SW} = (\mathbf{X}'\Sigma\mathbf{X})^{-1}(\mathbf{X}'\Sigma\mathbf{y}) = \left[\sum_{i=1}^N \mathbf{X}_i' \Sigma_i^{-1} \mathbf{X}_i \right]^{-1} \sum_{i=1}^N \mathbf{X}_i' \Sigma_i^{-1} \mathbf{y}_i$$

Estimador de Swamy (1970)

- Si Ω_η es no singular,

$$\Sigma_i^{-1} = \frac{I_T}{\sigma_i^2} - \frac{\mathbf{X}_i}{\sigma_i^2} \left(\frac{\mathbf{X}_i' \mathbf{X}_i}{\sigma_i^2} + \Omega_\eta^{-1} \right)^{-1} \frac{\mathbf{X}_i'}{\sigma_i^2} = \frac{I_T}{\sigma_i^2} - \frac{\mathbf{X}_i \Omega_\eta}{\sigma_i^2} \left(I_K + \frac{\mathbf{X}_i' \mathbf{X}_i}{\sigma_i^2} \Omega_\eta \right)^{-1} \frac{\mathbf{X}_i'}{\sigma_i^2}$$

(para la última igualdad no necesitamos que sea no singular)

Estimador de Swamy (1970)

- El estimador se puede escribir como:

$$\bar{\hat{\beta}}_{SW} = \sum_{i=1}^N \mathbf{R}_i \hat{\beta}_i$$

donde $\mathbf{R}_i = [\sum_{i=1}^N (\mathbf{\Omega}_\eta + \mathbf{\Sigma}_{\hat{\beta}_i})^{-1}]^{-1} (\mathbf{\Omega}_\eta + \mathbf{\Sigma}_{\hat{\beta}_i})^{-1}$, donde $\hat{\beta}_i = (\mathbf{X}'_i \mathbf{X}_i)^{-1} \mathbf{X}'_i \mathbf{y}_i$ y $\mathbf{\Sigma}_{\hat{\beta}_i} = \sigma_i^2 (\mathbf{X}'_i \mathbf{X}_i)^{-1}$ son los estimadores y sus varianzas, respectivamente, para cada i .

- $Var(\bar{\hat{\beta}}_{SW}) = [\sum_{i=1}^N (\mathbf{\Omega}_\eta + \mathbf{\Sigma}_{\hat{\beta}_i})^{-1}]^{-1}$.
- Para estimar la varianza necesitamos un estimador de $\mathbf{\Omega}_\eta$. Se propone:

$$\hat{\mathbf{\Omega}}_\eta = \frac{1}{N-1} \sum_{i=1}^N (\hat{\beta}_i - \hat{\beta}_{MG})(\hat{\beta}_i - \hat{\beta}_{MG})'$$

donde $\hat{\beta}_{MG}$ se define abajo como el estimador de *mean-group*.

Estimador media de grupos (MG estimator)

- Una alternativa es el mean-group (MG)

$$\hat{\beta}_{MG} = \frac{1}{N} \sum_{i=1}^N \hat{\beta}_i$$

donde $\hat{\beta}_i = (\mathbf{X}'_i \mathbf{X}_i)^{-1} \mathbf{X}'_i \mathbf{y}_i$ son los estimadores OLS de cada i .

- Notar que $\hat{\beta}_i = \beta + \eta_i + \zeta_i$, donde $\zeta_i = (\mathbf{X}'_i \mathbf{X}_i)^{-1} \mathbf{X}'_i \mathbf{u}_i$, entonces $\hat{\beta}_{MG} = \beta + \bar{\eta} + \bar{\zeta}$ con $\bar{\eta} = \frac{1}{N} \sum_{i=1}^N \eta_i$ y $\bar{\zeta} = \frac{1}{N} \sum_{i=1}^N \zeta_i$.
- $var(\hat{\beta}_{MG}) = var(\bar{\eta}) + var(\bar{\zeta}) = \frac{1}{N} \Omega_{\eta} + \frac{1}{N^2} \sum_{i=1}^N \sigma_i^2 E [T(\mathbf{X}'_i \mathbf{X}_i)^{-1}]$

Contrastes para homogeneidad vs. heterogeneidad

- Dadas las potenciales consecuencias negativas de obviar la heterogeneidad es importante chequear por la misma.
- Los test de heterogeneidad se pueden interpretar como de *poolability*, o sea, si se pueden “juntar” los modelos en una misma función lineal.
- Supongamos el siguiente modelo generador de los datos:

$$y_{it} = \mu_i + x_{it}\beta_i + u_{it}, i = 1, 2, \dots, N; t = 1, 2, \dots, T$$

$$u_{it} \sim iid(0, \sigma_i^2)$$

- La hipótesis nula de interés es

$$H_0 : \beta_i = \beta, \forall i$$

y la alternativa

$$H_A : \beta_i \neq \beta_j, i \neq j$$

- Notar que los contrastes de homogeneidad se refieren a las pendientes β , y en general no se contrasta por el intercepto.

Contrastes para homogeneidad vs. heterogeneidad

- F-test de $K(N - 1)$ restricciones. Este contraste funciona para N fijo y $T \rightarrow \infty$ y $\sigma_i^2 = \sigma^2$ (homoscedasticidad):

$$F = \frac{N(T - K - 1)}{K(N - 1)} \frac{RSSR - USSR}{USSR}$$

Este test corresponde a correr una regresión de efectos fijos con las interacciones de cada i con cada variable de control \mathbf{X} , excepto una, más la X sin interactuar, y luego chequear que todas las interacciones son cero. En general tiene un resultado pobre si N es grande y/o la varianza es heteroscedástica.

- **Contraste de Hausman.** Comparar $\hat{\beta}_{MG}$ y $\hat{\beta}_{FE}$. Para poder usar este contraste se necesita:
 - (a) Bajo la hipótesis nula, FE es más eficiente. ¿Por qué? Porque estima sólo un parámetro en ves de N .
 - (b) Bajo la alternativa $\hat{\beta}_{MG} - \hat{\beta}_{FE}$ debería tender a un vector no cero.

Contrastes para homogeneidad vs. heterogeneidad

- **Contraste de Swamy (1970).**

$$\hat{S} = \sum_{i=1}^N (\hat{\beta}_i - \hat{\beta}_{WFE})' \frac{\mathbf{X}_i' \mathbf{Q}_T \mathbf{X}_i}{\hat{\sigma}_i^2} (\hat{\beta}_i - \hat{\beta}_{WFE})$$

donde $\hat{\sigma}_i^2 = \frac{1}{T-K-1} (\mathbf{y}_i - \mathbf{X}_i \hat{\beta}_{WFE})' \mathbf{Q}_T (\mathbf{y}_i - \mathbf{X}_i \hat{\beta}_{WFE})$ y
 $\hat{\beta}_{WFE} = (\sum_{i=1}^N (\mathbf{X}_i' \mathbf{Q}_T \mathbf{X}_i) / \hat{\sigma}_i^2)^{-1} \sum_{i=1}^N (\mathbf{X}_i' \mathbf{Q}_T \mathbf{y}_i) / \hat{\sigma}_i^2$ donde $\mathbf{Q}_T = \mathbf{I}_T - \bar{\mathbf{J}}_T$.

Cuando N está fijo y $T \rightarrow \infty$, bajo la hipótesis nula, $\hat{S} \xrightarrow{d} \chi_{K(N-1)}^2$.

La intuición de este contraste es que nosotros no conocemos el valor de β bajo la hipótesis nula. Sin embargo, si este fuera uno se podría estimar con FE.

Entonces podríamos comparar todas las estimaciones de β_i con esta referencia. Si esa diferencia no es muy grande, entonces podríamos aceptar la nula.

- **Contraste de Pesaran y Yamagata (2008).**

Este contraste parte del de Swamy, pero estandariza el estadístico \hat{S} usando su distribución chi cuadrado.

Reemplazar $\hat{\sigma}_i^2$ por $\tilde{\sigma}_i^2 = \frac{1}{T-1} (\mathbf{y}_i - \mathbf{X}_i \hat{\beta}_{FE})' \mathbf{Q}_T (\mathbf{y}_i - \mathbf{X}_i \hat{\beta}_{FE})$ y usar

$$\Delta = \sqrt{N} \left(\frac{N^{-1} \hat{S} - K}{\sqrt{2K}} \right).$$

Este contraste funciona para $N, T \rightarrow \infty$.

STATA

- Ver comando <https://www.stata.com/manuals13/xtxtrc.pdf>
- Modelo de coeficientes aleatorios de Swamy
xtrc y x1 x2 x3, beta
- Ejemplo:
webuse invest2, clear
xtrc invest market stock, beta