

Lección 3. Regresión con constantes diferentes.



Teodosio Pérez Amaral,
Universidad Complutense
Telefónica, mayo 2005

1. Introducción

- Si se rechaza la homogeneidad, una forma simple y útil de recoger la heterogeneidad es usar un modelo con constantes diferentes para cada individuo.



- Constantes diferentes para cada individuo recogen (condicionales en los valores de las explicativas):
 - - A. Variables individuales que no varían en el tiempo, (raza, origen)
 - B. Variables temporales que no varían por individuos, (tipos interés, precios)
 - C. Variables que varían por individuos y tiempo, (ventas, beneficios).



- Los modelos de constantes diferentes recogen la heterogeneidad con diferentes constantes que pueden representar:
 - A. Las numerosas variables omitidas que varían a lo largo del tiempo que son individualmente poco importantes, pero colectivamente significativas.



- B. El efecto de las variables omitidas que no varían en el tiempo y
- C. El efecto de otras variables que no varían en el corte transversal,



2. Modelos de efectos fijos: mínimos cuadrados con variables ficticias.

$$y_{it} = \alpha_i^* + \beta' x_{it} + u_{it}$$

- α_i^* es un escalar
- β es un vector $1 \times k$ de constantes desconocidas que no varían en i y t .




- $t=1, \dots, T$; tiempo
- $i=1, \dots, N$; individuos
- $k=1, \dots, K$; variables explicativas

- Se supone que no hay correlación entre las x_i y los errores u_{it} .
- $u_{it} \sim \text{niid}(0, \sigma^2)$



- Modelo de análisis de covarianza: analiza los factores cuantitativos y cualitativos.


- Usando una ficticia de constante para cada individuo, podemos estimar por mínimos cuadrados ordinarios, MCO, que es ELIO, estimador insesgado y óptimo.



$$\hat{\beta}_{CV} = \left[\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)(x_{it} - \bar{x}_i)' \right]^{-1} \left[\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)(y_{it} - \bar{y}_i)' \right]$$

$$\hat{\alpha}_i^* = \bar{y}_i - \beta' \bar{x}, \quad i = 1, \dots, N.$$

DATOS DE PANEL LECCION 3. REGRESION CON CONSTANTES DIFERENTES 9



- Sea la matriz idempotente de transformación de covarianzas Q

$$Q = I_T - \frac{1}{T} ee'$$

- Que elimina los efectos individuales, midiendo las variables en desviaciones con respecto a su media muestral.

DATOS DE PANEL LECCION 3. REGRESION CON CONSTANTES DIFERENTES 10



- Aplicando MCO al modelo en desviaciones con respecto a las medias individuales.

$$\hat{\beta}_{CV} = \left[\sum_{i=1}^N X_i' Q X_i \right]^{-1} \left[\sum_{i=1}^N X_i' Q y_i \right]$$



Propiedades estimador covarianzas

- Existencia.
- Unicidad.
- Insesgadez $E(\hat{\beta}_{CV}) = \beta$
- Consistencia, $\hat{\beta}_{CV} \rightarrow \beta$ cuando N, T o ambos tienden a infinito.
- Eficiencia. Teorema de Gauss-Markov.



+Propiedades

- Matriz de varianzas y covarianzas


$$\text{Var}(\hat{\beta}_{CV}) = \sigma_u^2 \left[\sum_{i=1}^N X_i' Q X_i \right]^{-1}$$

- Estimador efectos fijos, insesgado

$$E(\hat{\alpha}_i^*) = \alpha_i$$

- Estimador efectos fijos, solo consistente si $T \rightarrow \infty$.

$$p \lim(\hat{\alpha}_i^*) = \alpha_i$$



3. Modelo de efectos aleatorios. Modelos de componentes del error.

- Suponemos que el error v_{it} tiene tres componentes

$$v_{it} = \alpha_i + \lambda_t + u_{it}$$

$$E(\alpha_i) = E(\lambda_t) = E(u_{it}) = 0$$

$$E(\alpha_i \lambda_t) = E(\alpha_i u_{it}) = E(\lambda_t u_{it}) = 0$$



- Covarianzas de los componentes del error iguales a cero.
- Y ausencia de correlación entre los regresores y los componentes del error.

- $$E(\alpha_i x'_{it}) = E(\lambda_t x'_{it}) = E(u_{it} x'_{it}) = 0'$$



- La varianza de y_{it} condicional en las x_{it} .

$$\sigma^2_y = \sigma^2_\alpha + \sigma^2_\lambda + \sigma^2_u$$

- Y la ecuación

$$\begin{array}{ccccccc} y_i & = & \tilde{X}_i & \delta & + & v_i & \\ T \times 1 & & T \times (k+1) & (k+1) \times 1 & & T \times 1 & \end{array}$$

- V es la matriz de varianzas y covarianzas de los errores v_i

$$E v_i v_i' = \sigma_u^2 I_T + \sigma_\alpha^2 e e' = V$$

$$V^{-1} = \frac{1}{\sigma_u^2} \left[I_T - \frac{\sigma_\alpha^2}{\sigma_u^2 + T \sigma_\alpha^2} e e' \right]$$

3.1 Estimación por covarianzas

- El α_i produce correlación serial entre los errores del mismo individuo.
- Pero se puede eliminar con la transformación Q.
- Sean fijos o aleatorios los efectos, los β se pueden estimar por CV y el estimador es insesgado y consistente con N, T o ambos tendiendo a infinito.



- Pero $\hat{\beta}_{CV}$ es ELIO bajo efectos fijos, pero no lo es bajo efectos aleatorios.
- En caso de efectos aleatorios sería óptimo (más eficiente, más preciso) el estimador de Mínimos Cuadrados Generalizados.



3.2 Estimador entre grupos (between, corte transversal)

- Un estimador alternativo que usa solamente la variación entre grupos

$$\hat{\beta}_b = \left[\sum_{i=1}^N (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})' \right]^{-1} \left[\sum_{i=1}^N (\bar{x}_i - \bar{x})(\bar{y}_i - \bar{y}) \right]$$



- 1. Se calcula la **media** muestral de cada una de las variables, endógena y explicativas de **cada individuo** del panel.
- 2. Se estima un modelo de regresión por MCO con datos de corte transversal. Con una observación por individuo.
- 3. El resultado es el estimador between, entregrupos. Usa solo la variación entre grupos.



3.1. Estimación por generalizados


$$\hat{\beta}_{GLS} = \left[\frac{1}{T} \sum_{i=1}^N X_i' Q X_i + \Psi \sum_{i=1}^N (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})' \right]^{-1} \left[\frac{1}{T} \sum_{i=1}^N X_i' Q y_i + \Psi \sum_{i=1}^N (\bar{x}_i - \bar{x})(\bar{y}_i - \bar{y}) \right]$$

$$\Psi = \frac{\sigma_u^2}{\sigma_u^2 + T\sigma_\alpha^2}$$



CARACTERISTICAS DE MC GENERALIZADOS.

- Aprovecha estructura matriz covarianzas errores.
- Combina la variación intragrupos y entregrupos de las variables.
- El estimador es una combinación de los estimadores intragrupos y entregrupos.


$$\hat{\beta}_{GLS} = \Delta \hat{\beta}_b + (I_k - \Delta) \hat{\beta}_{cv}$$

- Δ son ponderaciones que dependen de los datos (Hsiao, p. 37).
- Si $\Psi \rightarrow 1$, MCG converge a MCO, del modelo conjunto.
- Si $\Psi \rightarrow 0$, MCG de β converge al intragrupos.



- Ψ es el peso que se da a la variación entre grupos.
- Efectos aleatorios es un intermedio entre tratar a todos los efectos iguales o todos diferentes.



$$\text{Var}(\hat{\beta}_{GLS}) = \sigma_u^2 \left[\sum_{i=1}^N X_i' Q X_i + T \Psi \sum_{i=1}^N (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})' \right]^{-1}$$

- La diferencia entre las matrices de varianzas y covarianzas de $\hat{\beta}_{CV}$ y $\hat{\beta}_{GLS}$ es positiva semidefinida.
- $\hat{\beta}_{GLS}$ más eficiente que $\hat{\beta}_{CV}$



- Estimación: por mínimos cuadrados generalizados en dos etapas.
- 1. Pseudo diferencias $(1 - \psi^{1/2})$,
- 2. MCO.
- Como no se conocen, hay que estimar

$$\hat{\sigma}_u^2 = \frac{\sum_{i=1}^N \sum_{t=1}^T [(y_{it} - \bar{y}_i) - \hat{\beta}'_{CV} (x_{it} - \bar{x}_i)]^2}{N(T-1) - K}$$



- Y usando el estimador entregrupos, between, podemos estimar

$$\hat{\sigma}_\alpha^2 = \frac{\sum_{i=1}^N (\bar{y}_i - \tilde{\mu} - \tilde{\beta}' \bar{x}_i)^2}{N - (K + 1)} - \frac{1}{T} \hat{\sigma}_u^2$$

3.2 Estimación por máxima verosimilitud del modelo de efectos aleatorios.

- Forma de estimar tradicional.
- Especificar distribución.
- Si suponemos normalidad de α_i y u_{it} .

$$\log L = -\frac{NT}{2} \log 2\pi - \frac{N}{2} \log |V| - \frac{1}{2} \sum_{i=1}^N (y_i - e\mu - X_i\beta)' V^{-1} (y_i - e\mu - X_i\beta)$$

$$\begin{aligned} &= -\frac{NT}{2} \log 2\pi - \frac{N(T-1)}{2} \log \sigma_u^2 - \frac{N}{2} \log(\sigma_u^2 + T\sigma_\alpha^2) \\ &\quad - \frac{1}{2\sigma_u^2} \sum_{i=1}^N (y_i - e\mu - X_i\beta)' Q (y_i - e\mu - X_i\beta) \\ &\quad - \frac{T}{2(\sigma_u^2 + T\sigma_\alpha^2)} \sum_{i=1}^N (\bar{y}_i - \mu - \beta' \bar{x}_i)^2 \end{aligned}$$




- Y derivando LogL con respecto a: β , μ , σ^2_u y σ^2_α
- Obtenemos las ecuaciones normales, que generan las condiciones de ortogonalidad que definen el estimador de Máxima verosimilitud.



- Estimación simultánea es complicada.
- Se puede usar procedimiento iterativo de [Newton-Raphson](#).

$$\tilde{\delta}^{\Xi(j)} = \tilde{\delta}^{\Xi(j-1)} - \left[\frac{\partial^2 \log L}{\partial \tilde{\delta} \partial \tilde{\delta}'} \right]_{\tilde{\delta} = \tilde{\delta}^{\Xi(j-1)}}^{-1} \frac{\partial \log L}{\partial \tilde{\delta}} \Big|_{\tilde{\delta} = \tilde{\delta}^{\Xi(j-1)}}$$

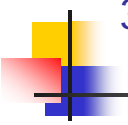
- Que se repite hasta la convergencia.
- Estimador de máxima verosimilitud es consistente y asintóticamente normal,



$$\text{Var}(\sqrt{N}\tilde{\delta}_{\text{MLE}}) = \text{NE} \left[-\frac{\partial^2 \log L}{\partial \tilde{\delta} \partial \tilde{\delta}'} \right]^{-1}$$

$$= \begin{bmatrix} \frac{T}{\sigma^2} & \frac{T}{\sigma^2} \frac{1}{N} \sum_{i=1}^N \bar{x}_i' & 0 & 0 \\ \frac{1}{\sigma^2} \frac{1}{N} \sum_{i=1}^N X_i' \left(I_t - \frac{\sigma_\alpha^2}{\sigma^2} e e' \right) X_i & 0 & 0 & 0 \\ & & \frac{T-1}{2\sigma_u^2} + \frac{1}{2\sigma^4} & \frac{T}{2\sigma^4} \\ & & & \frac{T^2}{2\sigma^4} \end{bmatrix}$$

DATOS DE PANEL LECCION 3. REGRESION CON CONSTANTES DIFERENTES 33

- 
- ### 3.4 Efectos fijos o aleatorios
- **Modelo de efectos fijos:** inferencia condicional en los efectos presentes en la muestra.
 - **Modelos de efectos aleatorios:** inferencia incondicional.
 - El investigador **decide** qué es lo más apropiado.
- DATOS DE PANEL LECCION 3. REGRESION CON CONSTANTES DIFERENTES 34



- Si T grande, estimación por efectos fijos y aleatorios, da resultados similares.
- Con **T finito y N grande**, la elección entre modelos no es fácil, y suele ser **grande la diferencia** entre efectos fijos y aleatorios.



Quando es más apropiado?

- **Modelo de efectos fijos:** la muestra coincide con población, individuos importantes, queremos decir cosas de algunos individuos o grupos. Interés de la inferencia se ciñe solo a los efectos presentes en la muestra.
- **Modelo de efectos aleatorios:** muestra de de una población más amplia. La inferencia se quiere hacer con respecto a una población de efectos de los que los datos son solamente una muestra aleatoria.



- Una vez elegido el modelo, en la práctica suele haber **importantes diferencias** entre los dos modelos, de efectos fijos y aleatorios.
- Posible causa: error especificación.
- Ej: **Correlación entre x_{it} y los α_i .**




$$\begin{aligned}\bar{\beta}_{MCO} &= \left[\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})(x_{it} - \bar{x})' \right]^{-1} \left[\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})(y_{it} - \bar{y}) \right]^{-1} \\ &= \beta + \left[\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})(x_{it} - \bar{x})' \right]^{-1} \left\{ T \sum_{i=1}^N (x_i - \bar{x})(\alpha_i^* - \bar{\alpha}) \right\}\end{aligned}$$



3.4.2.a Formulación de Mundlak


- **Critica** el uso del modelo de **efectos aleatorios** porque, con datos económicos, suele haber correlación entre regresores y efectos individuales.
- Y dice que la diferencia aparente entre efectos fijos y aleatorios se debe a un **error de especificación**.

- 
-
- **Mundlak** afirma que si se corrige la correlación entre efectos y regresores, el estimador apropiado sería el de efectos fijos.
 - **Comentario:** esto es cierto solamente para el modelo lineal, pero no para modelos dinámicos, coeficientes variables o elección discreta.



3.5 Contrastes de especificación.

- Hausman (1978)
- Ayuda a decidir entre **ESTIMAR** por MCO o por MCG un modelo de efectos aleatorios.
- H_0 : No hay correlación entre α_i y las x_i
- H_1 : Hay correlación entre α_i y las x_i

- 
- $H_0: E(\alpha_i|X_i) = 0,$
 - MCG es consistente y eficiente.
 - El estimador de CV es consistente pero ineficiente.
 - $H_1: E(\alpha_i|X_i) \neq 0,$
 - MCG es inconsistente.
 - El estimador de CV es consistente.



- Procedimiento práctico: mide la distancia entre las dos estimaciones: por MCO con variables ficticias(CV) y por MCG.

$$\hat{q} = \hat{\beta}_{CV} - \hat{\beta}_{GLS}$$

- Usando el famoso lema de Hausman.

$$Var(\hat{q}) = Var(\hat{\beta}_{CV}) - Var(\hat{\beta}_{GLS})$$



- Hausman propone el estadístico

$$m = \hat{q}' Var(\hat{q}')^{-1} \hat{q}$$

- Bajo la H_0 de no correlación, el estadístico se distribuye como una Ji-cuadrado con el mismo número de grados de libertad que parámetros que se contrastan.



- Bajo la alternativa, H_1 de correlación, el estadístico m se comporta asintóticamente como una Ji-cuadrado no centrada, con parámetro de no-centralidad, $\bar{q}' Var(\hat{q}')^{-1} \bar{q}$, donde

$$\bar{q} = p \lim(\hat{\beta}_{CV} - \hat{\beta}_{GLS})$$

3.6 Modelos con variables y efectos específicos individuales y temporales.



- Caso 1. Variables individuales específicas

$$y_i = e\mu + Z_i \gamma + X_{it} \beta + e\alpha_i + u_i$$

- $i=1, \dots, N$.
- Donde $Z_i = e z_i'$
- Si los efectos son fijos, tenemos multicolinealidad perfecta.



- No se pueden estimar conjuntamente γ ,
- μ , y α_i .
- Pero si podemos estimar β por CV
- Y para estimar γ podemos escribir

$$\bar{y}_i - \bar{x}_i' \beta = \mu + z_i' \gamma + \alpha_i + \bar{u}_i$$

- Estimamos γ por MCO.



$$\hat{\gamma} = \left[\sum_{i=1}^N (z_i - \bar{z})(z_i - \bar{z})' \right]^{-1} \left[\sum_{i=1}^N (z_i - \bar{z}) [(\bar{y}_i - \bar{y}) - (\bar{x}_i - \bar{x})' \beta] \right]$$

$$\hat{\mu} = \bar{y} - \bar{x}' \beta - \bar{z}' \hat{\gamma}$$



- Estimación.
- Estimamos β por CV.
- Lo sustituimos en las dos fórmulas siguientes.
- Estimamos γ y μ .
- Propiedades.
- β y γ son consistentes cuando $N \rightarrow \infty$.



- Cuando los efectos α_i son aleatorios e incorrelacionados con X_i y Z_i , el estimador CV no es ELIO.
- El estimador ELIO sería el de MCG. Ver Hsiao, p 53.



- Una interpretación de este modelo es que se incluyen variables que no varían a lo largo del tiempo, Z_i para “explicar” los efectos individuales, y esto permite disminuir o eliminar las correlaciones entre los efectos individuales y los regresores.



Caso 2. Modelos con efectos individuales y temporales.


$$y_{it} = \mu + z_i' \gamma + r_t' \rho + x_{it} \beta + \alpha_i + \lambda_t + u_{it}$$

- Si efectos fijos, no se pueden estimar todos los parámetros.
- Si aleatorios, se usa un estimador en varios pasos como el anterior.
- Si aleatorios e incorrelacionados con r , z y x , se usarían MCG, que es ELIO.




3.7 Heteroscedasticidad

- Muchos paneles tienen unidades de tamaño muy diverso. Puede dar lugar a heteroscedasticidad.
- En el caso de componentes del error, la heteroscedasticidad se puede dar porque la varianza, $\sigma^2_{\alpha_i}$ de los α_i varía con i , o bien porque la varianza, $\sigma^2_{u_i}$ de los u_{it} varía con i , o ambos.


- 
- Problema complejo por el número de parámetros. Haciendo simplificaciones.

$$\sigma^2_{u_i} = \frac{1}{T-1} \sum_{t=1}^T (\bar{v}_{it} - \bar{v}_i)^2$$



El estimador de mínimos cuadrados generalizados factibles

$$\delta_{\text{FGLS}} = \left[\sum_{i=1}^N \tilde{X}_i' \tilde{V}_i^{-1} \tilde{X}_i \right]^{-1} \left[\sum_{i=1}^N \tilde{X}_i' \tilde{V}_i^{-1} y_i \right]$$

- 
- Otra alternativa en caso de que haya heteroscedasticidad a lo largo de las unidades y de los errores comunes sería tratar los efectos como fijos y luego aplicar mínimos cuadrados generalizados factibles.
 - Primero se divide cada observación por su desviación típica estimada y luego



- Se estima por covarianzas usando datos transformados.

$$\bar{\beta}_{CV} = \left[\sum_{i=1}^N X_i^* Q X_i^* \right]^{-1} \left[\sum_{i=1}^N X_i^* Q y_i^* \right]$$

- Los estimadores serían ELIO