

Modelos básicos de datos en panel

Gabriel Montes-Rojas

3 tipos de estructuras de datos

- **Corte transversal (Cross section)** Muestra de individuos, hogares, firmas, países, etc. que se toman en un momento dado del tiempo.

$\{y_i, x_i\}_{i=1}^N$, donde i representa individuos.

Ej.: EPH de 2013, datos de PBI en 2013 para muchos países.

- **Serie de tiempo** Muestra por varios periodos del mismo individuo, país, firma, etc.

$\{y_t, x_t\}_{t=1}^T$, donde t es tiempo.

Ej.: Inflación en la Argentina.

- **Datos en panel** Combinación de las dos anteriores.

$\{y_{it}, x_{it}\}_{i=1, t=1}^{N, T}$, donde i representa individuos y t tiempo.

1. **Cortes transversales independientes**
2. **Muestras longitudinales**

Modelos

En un panel longitudinal el mismo individuo es observado a lo largo del tiempo. $i = 1, 2, \dots, N$ es el índice de individuos (firmas, familias, hogares, países), $t = 1, 2, \dots, T$ es el índice de tiempo. Supongamos los siguientes modelos:

- 1 $y_{it} = \alpha + X_{it}'\beta + u_{it}$, α es un escalar, β es un vector $K \times 1$, X_{it} es la observación it de las K variables explicativas. **Pooled OLS.**
- 2 $y_{it} = \alpha_{it} + X_{it}'\beta_{it} + u_{it}$, α_{it} es un escalar específico para cada it , β_{it} es un vector $K \times 1$ específico para cada it , X_{it} es la observación it de las K variables explicativas. **Modelo imposible de identificar, igual cantidad de parámetros que de observaciones.**
- 3 $y_{it} = \alpha_i + X_{it}'\beta_i + u_{it}$, α_i es un escalar específico para cada i , β_i es un vector $K \times 1$ específico para cada i , X_{it} es la observación it de las K variables explicativas. **SUREG, Paneles heterogéneos.**
- 4 $y_{it} = \alpha_t + X_{it}'\beta_t + u_{it}$, α_t es un escalar específico para cada t , β_t es un vector $K \times 1$ específico para cada t , X_{it} es la observación it de las K variables explicativas.

One-way error components model

$$y_{it} = \alpha + X'_{it}\beta + u_{it}$$

α es un escalar, β es $K \times 1$, X_{it} es la observación it de las K variables explicativas. El error tiene esta estructura:

$$u_{it} = \mu_i + v_{it}$$

es el **error compuesto**. En inglés: **one-way error components model**.

- μ_i : efecto individual no observado que captura todos los factores constantes a lo largo del tiempo en y_{it} ,
- v_{it} : errores idiosincráticos o shocks.

One-way error components model

En notación matricial

$$y = \alpha \iota_{NT} + X\beta + u = Z\delta + u,$$

donde y y u son vectores $NT \times 1$, X es una matriz $NT \times K$, $Z = [\iota'_{NT}, X']'$, $\delta' = [\alpha, \beta']$ y ι_{NT} es un vector de 1s con dimensión $NT \times 1$

$$u = Z_{\mu}\mu + v$$

donde $Z_{\mu} = I_N \otimes \iota_T$ es una matriz $NT \times N$ de 1s y 0s, \otimes es el producto de Kronecker, ι_T es un vector de 1s de dimensión T , $\mu = [\mu_1, \dots, \mu_N]'$ es un vector $N \times 1$ que contiene los efectos individuales, y v es un vector $NT \times 1$ con los errores. De esta manera $Z_{\mu}\mu$ es un vector también $NT \times 1$.

Notar que Z_{μ} es una matriz de dummies para todos los individuos $i = 1, 2, \dots, N$. Es decir, contiene una dummy para cada i .

Two-way error components model

Consideremos el modelo

$$y_{it} = \alpha + X'_{it}\beta + u_{it}$$

α es un escalar, β es $K \times 1$, X_{it} es la observación it de las K variables explicativas.

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

es el **error compuesto**. *En inglés: two-way error components model.*

- μ_i : efecto individual no observado que captura todos los factores constantes a lo largo del tiempo en y_{it} ,
- λ_t : efecto temporal no observado que captura todos los factores constantes a lo de los individuos en y_{it} ,
- v_{it} : errores idiosincráticos o shocks.

Two-way error components model

En notación matricial

$$u = Z_{\mu}\mu + Z_{\lambda}\lambda + v,$$

donde $Z_{\lambda} = \iota_N \otimes I_T$ es una matriz $NT \times T$ de 1s y 0s, ι_N es un vector de 1s de dimensión N , $\lambda = [\lambda_1, \dots, \lambda_T]'$ es un vector $T \times 1$ que contiene los efectos temporales.

Paneles multi-dimensionales

- Los modelos anteriores se pueden extender a una mayor cantidad de dimensiones.
- Ejemplos de 3 dimensiones (i, j, t):
 - 1 Modelos de comercio exterior podrían tener efectos por exportador, importador, tiempo, etc.
 - 2 Modelos de inmigración podrían tener efectos por país de origen, país de destino, año de inmigración, etc.

En ambos casos podríamos tener efectos para cada elemento,

$$u_{ijt} = \mu_i + \alpha_j + \lambda_t + v_{ijt},$$

o efectos bilaterales, donde nos importan los efectos de a pares,

$$u_{ijt} = \mu_{ij} + \lambda_t + v_{ijt}$$

- Un caso particular es el de los modelos anidados. Por ejemplo, si evaluamos políticas educativas, tendríamos un efecto por alumno (i), que pertenece a una determinada clase (j), de una escuela (k) a lo largo del tiempo (t). Así podríamos pensar en una estructura de errores:

$$u_{ijkt} = \mu_i + \alpha_j + \gamma_k + \lambda_t + v_{ijkt}$$

- Ver el libro de Laszlo Matyas (<http://www.metrixmdp.eu>)

Inconsistencia de OLS

Si $cov(x_{it}, \mu_i) \neq 0 \Rightarrow$ OLS es sesgado e inconsistente. ¿Por qué?
Supongamos un modelo de regresión simple:

$$y_{it} = \beta_0 + \beta_1 x_{it} + \mu_i + v_{it} \quad i = 1, 2, \dots, N, t = 1, 2, \dots, T,$$

donde $E[v_{it}|x_{it}] = 0, \forall i, t$.


Probar:

- $$\hat{\beta}_1^{OLS} = \frac{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})(y_{it} - \bar{y})}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})^2} = \beta_1 + \frac{\sum_{i=1}^N T \mu_i (\bar{x}_i - \bar{x}) + \sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})(v_{it} - \bar{v})}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})^2}$$

$\xrightarrow{p} \beta_1 + \frac{cov(x_{it}, \mu_i)}{var x_{it}}$ cuando $N, T \rightarrow \infty$ y donde $\bar{x}_i = \frac{1}{T} \sum_{t=1}^T x_{it}$.
- $$E[\hat{\beta}_1^{OLS} | X] = \beta_1 + \frac{\sum_{i=1}^N \sum_{t=1}^T E[\mu_i | X] (x_{it} - \bar{x})}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x})^2}.$$

Inconsistencia de OLS

Panel data



Los siguientes estimadores se proponen como soluciones a este problema:

- **Estimador en primeras diferencias**
- **Efectos fijos**

Estimador en primeras diferencias (first differences, FD)

$$y_{it} = \beta_0 + \beta_1 x_{it} + \mu_i + v_{it}$$

$$y_{it-1} = \beta_0 + \beta_1 x_{it-1} + \mu_i + v_{it-1}$$

$$\Rightarrow \Delta y_{it} = \beta_1 \Delta x_{it} + \Delta v_{it}$$

donde Δ es el operador de diferencias, $\Delta y_{it} = y_{it} - y_{it-1}$.

Definamos $\hat{\beta}_1^{FD} = \frac{\sum_{i=1}^N \sum_{t=1}^T \Delta x_{it} \Delta y_{it}}{\sum_{i=1}^N \sum_{t=1}^T \Delta x_{it}^2}$. Probar que es un estimador insesgado y consistente cuando $N, T \rightarrow \infty$.

¡Lo que pasa es que μ_i desaparece, entonces se acaba el problema!

Efectos fijos (fixed-effects, FE)

$$y_{it} = \beta_0 + \beta_1 x_{it} + \mu_i + v_{it}$$

$$\bar{y}_i = \beta_0 + \beta_1 \bar{x}_i + \bar{\mu}_i + \bar{v}_i$$

$$\Rightarrow \tilde{y}_{it} = \beta_1 \tilde{x}_{it} + \tilde{v}_{i,t}$$

donde $\tilde{\cdot}$ es una transformación que se aplica a cada individuo (se usa en inglés **within transformation**), $\tilde{y}_{it} = y_{it} - \bar{y}_i$, $\tilde{y}_{it} = T^{-1} \sum_{t=1}^T y_{it}$.

Definamos $\hat{\beta}_1^{FE} = \frac{\sum_{i=1}^N \sum_{t=1}^T \tilde{x}_{it} \tilde{y}_{it}}{\sum_{i=1}^N \sum_{t=1}^T \tilde{x}_{it}^2}$. Probar que es un estimador insesgado y consistente cuando $N, T \rightarrow \infty$.

¡Otra vez desaparece μ_i ! (porque $\bar{\mu}_i = T^{-1} \sum_{t=1}^T \mu_i = T^{-1} T \mu_i = \mu_i$)

Efectos fijos (fixed-effects, FE)

En los estimadores de efectos fijos μ_i se asumen como **parámetros fijos a ser estimados** y $v_{it} \sim IID(0, \sigma_v^2)$. $x_{it} \perp v_{it}, \forall i, t$.

Otro modo de ver los modelos FE es $E(v_{it}|x_{it}) \neq 0$ pero que $E(v_{it}|x_{it}, \mu_i) = 0$.
Entonces necesitamos estimar μ_i .

Efectos fijos (fixed-effects, FE)

- En notación matricial

$$y = \alpha \iota_{NT} + X\beta + Z_{\mu}\mu + v = Z\delta + Z_{\mu}\mu + v$$

- Definamos $P_{\mu} = Z_{\mu}(Z'_{\mu}Z_{\mu})^{-1}Z'_{\mu}$ como la matriz de proyección en Z_{μ} , el subespacio de dummies por individuo. $Z_{\mu}Z'_{\mu} = I_N \otimes J_T$. Entonces $P_{\mu} = Z_{\mu}(Z'_{\mu}Z_{\mu})^{-1}Z'_{\mu} = I_N \otimes \overline{J_T}$ donde $\overline{J_T} = J_T / T$.
- P_{μ} es una matriz que promedia las observaciones para los individuos. Así $P_{\mu}y$ tiene elementos $\bar{y}_i = 1/T \sum_{t=1}^T y_{it}$ repetido T veces para cada i .
- Probar que P_{μ} es simétrica ($P'_{\mu} = P_{\mu}$) e idempotente ($P_{\mu} \times P_{\mu} = P_{\mu}$) por lo que $rank(P_{\mu}) = tr(P_{\mu}) = N$.

Efectos fijos (fixed-effects, FE)

- Definamos también el complemento $Q_\mu = I_{NT} - P_\mu$. Q_μ se define entonces como las desviaciones con respecto a las medias (en inglés within-group operator): $\tilde{y}_{it} = y_{it} - \bar{y}_i$.
- Probar que Q_μ es simétrica e idempotente, y que $P_\mu Q_\mu = 0_{NT}$, por lo que $\text{rank}(Q_\mu) = \text{tr}(Q_\mu) = N(T - 1)$.
- Entonces,

$$Q_\mu y = Q_\mu X\beta + Q_\mu v, \Rightarrow \hat{\beta}_{FE} = (X' Q_\mu X)^{-1} X' Q_\mu y$$

- ¿Qué tipo de variables quedan excluidas?

Efectos fijos (fixed-effects, FE)

Notar que $\hat{\beta}_{FE}$ es equivalente a un modelo OLS con una dummy para cada individuo i , $\hat{\beta}_{LSDV}$.

La prueba es una aplicación del Teorema de **Frisch-Waugh-Lovell**.

Nota: $\hat{\beta}_{FE} = (\sum_{i=1}^N (X_i'(I_T - \bar{J}_T)X_i))^{-1} \sum_{i=1}^N (X_i'(I_T - \bar{J}_T)y_i)$.

Teorema de Frisch-Waugh-Lovell

Consideremos los siguientes modelos de regresión:

$$A. y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_K x_K + u$$

$$B. y = \gamma_2 x_2 + \gamma_3 x_3 + \dots + \gamma_K x_K + v$$

$$C. x_1 = \delta_2 x_2 + \delta_3 x_3 + \dots + \delta_K x_K + e$$

- Computar los residuos del modelo B (\hat{v}) y C (\hat{e}).
- Correr la siguiente regresión auxiliar: $\hat{v} = \alpha_0 + \alpha_1 \hat{e} + \text{residuo}$
- Chequear que $\hat{\alpha}_1 = \hat{\beta}_1$
- ¿Cómo se interpreta este resultado?

Teorema de Frisch-Waugh-Lovell

En notación matricial

$$\mathbf{y} = \mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{X}_2\boldsymbol{\beta}_2 + \mathbf{u}$$

y consideremos $\hat{\boldsymbol{\beta}} = [\hat{\boldsymbol{\beta}}_1 \ \hat{\boldsymbol{\beta}}_2]'$.

Ahora construyamos $\mathbf{M}_2\mathbf{y} = \mathbf{M}_2\mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{M}_2\mathbf{u}$ donde \mathbf{M}_2 es la proyección residual de \mathbf{X}_2 . El teorema de FWL muestra que

$$\hat{\boldsymbol{\beta}}_1 = (\mathbf{X}_1'\mathbf{M}_2\mathbf{X}_1)^{-1}\mathbf{X}_1'\mathbf{M}_2\mathbf{y}$$

Prueba: Consideremos $\mathbf{y} = \mathbf{P}_X\mathbf{y} + \mathbf{M}_X\mathbf{y} = \mathbf{X}_1\hat{\boldsymbol{\beta}}_1 + \mathbf{X}_2\hat{\boldsymbol{\beta}}_2 + \mathbf{M}_X\mathbf{y}$. Multipliquemos ambos lados por $\mathbf{X}_1'\mathbf{M}_2$ y obtenemos $\mathbf{X}_1'\mathbf{M}_2\mathbf{y} = \mathbf{X}_1'\mathbf{M}_2\mathbf{X}_1\hat{\boldsymbol{\beta}}_1$. (Usamos el resultado $\mathbf{M}_2\mathbf{X}_2 = \mathbf{0}$ y $\mathbf{M}_X\mathbf{M}_2\mathbf{X}_1 = \mathbf{0}$). Resolver por $\hat{\boldsymbol{\beta}}_1$,

$$\hat{\boldsymbol{\beta}}_1 = (\mathbf{X}_1'\mathbf{M}_2\mathbf{X}_1)^{-1}\mathbf{X}_1'\mathbf{M}_2\mathbf{y}$$

Si tomamos que \mathbf{X}_2 es el conjunto de las dummies por individuo y \mathbf{X}_1 son las variables de control, se puede demostrar que la matriz $\mathbf{M}_2 = \mathbf{Q}_\mu$ realiza la transformación within de las variables. Entonces nos queda una regresión MCO de $\mathbf{M}_2\mathbf{y}$ en $\mathbf{M}_2\mathbf{X}_1$.

Algebra de MCO (nota para la slide anterior)

Proyección ortogonal: Definamos la matriz $\mathbf{P}_X \equiv \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ como la matriz que proyecta y en el espacio generado por \mathbf{X} . Tenemos que $\hat{y} = \mathbf{P}_X y$, los valores precedidos.

Proyección residual: Definamos la matriz $\mathbf{M}_X \equiv \mathbf{I}_N - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ como la proyección de y en el complemento del espacio de \mathbf{X} . Notemos que $\hat{u} = \mathbf{M}_X y$, residuos de la regresión.

Notar que $\mathbf{P}_X \mathbf{M}_X = \mathbf{0}$. Además ambas matrices son idempotentes:
 $\mathbf{P}_X \mathbf{P}_X = \mathbf{P}_X, \mathbf{M}_X \mathbf{M}_X = \mathbf{M}_X$.

Efectos fijos (fixed-effects, FE)

Probar que el estimador FE es un promedio ponderado de los estimadores OLS individuales. Es decir, $\hat{\beta}_{FE} = \sum_{i=1}^N \omega_i \hat{\beta}_{OLS}^i$ donde $\omega_i \geq 0, i = 1, 2, \dots, N$ es un ponderador tal que $\sum_{i=1}^N \omega_i = 1$ y $\hat{\beta}_{OLS}^i$ son los estimadores de OLS de cada individuo i por separado.

Resolvamos el caso para la regresión simple. $y_{it} = \beta_0 + \beta_1 x_{it} + \mu_i + v_{it}$.

Supongamos que corremos una regresión para cada i por separado, usando solamente las T observaciones. Entonces, tenemos $\hat{\beta}_1^{MCO,i} = \frac{\sum_{t=1}^T (x_{it} - \bar{x}_i)(y_{it} - \bar{y}_i)}{\sum_{t=1}^T (x_{it} - \bar{x}_i)^2}$.

Ahora, el estimador FE es

$$\begin{aligned} \hat{\beta}_1^{FE} &= \frac{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)(y_{it} - \bar{y}_i)}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)^2} = \frac{\sum_{i=1}^N \sum_{t=1}^T \frac{\sum_{t=1}^T (x_{it} - \bar{x}_i)^2}{\sum_{t=1}^T (x_{it} - \bar{x}_i)^2} (x_{it} - \bar{x}_i)(y_{it} - \bar{y}_i)}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)^2} \\ &= \frac{\sum_{i=1}^N \sum_{t=1}^T \left(\sum_{t=1}^T (x_{it} - \bar{x}_i)^2 \right) \hat{\beta}_1^{MCO,i}}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)^2} = \sum_{i=1}^N \omega_i \hat{\beta}_1^{MCO,i}, \end{aligned}$$

donde $\omega_i = \frac{\sum_{t=1}^T (x_{it} - \bar{x}_i)^2}{\sum_{i=1}^N \sum_{t=1}^T (x_{it} - \bar{x}_i)^2}$.

Efectos fijos (fixed-effects, FE)

- Notar que $\text{var}(\hat{\beta}_{FE}) = \sigma_v^2 (\mathbf{X}' \mathbf{Q}_\mu \mathbf{X})^{-1}$.
- Podemos plantear $\hat{\mu}_i = \bar{y}_i - \hat{\beta}_{FE} \bar{x}_i$ o $\hat{\mu}_{FE} = P_\mu y - \hat{\beta}_{FE} P_\mu X$ como el estimador de los “efectos fijos”.
- Si $T \rightarrow \infty$, $(\hat{\mu}_{FE}, \hat{\beta}_{FE})$ son estimadores consistentes e insesgados.
- Pero si T está fijo y $N \rightarrow \infty$, sólo $\hat{\beta}_{FE}$ es consistente, aunque ambos son insesgados. El problema es conocido como el problema de parámetros incidentales de Neyman y Scott (1948).
- Contraste de efectos fijos: correr el modelo LSDV, y contrastar conjuntamente por la significatividad de las dummies.

Efectos fijos (fixed-effects, FE)-two-way

Para el modelo two-way tenemos $Z_\lambda Z'_\lambda = J_N \otimes I_T$. Entonces

$$P_\lambda = Z_\lambda (Z'_\lambda Z_\lambda)^{-1} Z'_\lambda = \overline{J_N} \otimes I_T \text{ donde } \overline{J_N} = J_N / N.$$

Definamos la proyección residual

$$Q_{\mu\lambda} = E_N \otimes E_T = I_N \otimes I_T - I_N \otimes \overline{J_T} + \overline{J_N} \otimes I_T + \overline{J_N} \otimes \overline{J_T}$$

donde $E_N = I_N - \overline{J_N}$ y $E_T = I_T - \overline{J_T}$. Esta transformación elimina los efectos de μ_i y λ_t simultáneamente. La matriz $Q_{\mu\lambda}$ hace la siguiente transformación:
 $y_{it} - \bar{y}_i - \bar{y}_t + \bar{y}$. Entonces,

$$Q_{\mu\lambda} y = Q_{\mu\lambda} X \beta + Q_{\mu\lambda} v, \Rightarrow \hat{\beta}_{FE-2} = (X' Q_{\mu\lambda} X)^{-1} X' Q_{\mu\lambda} y$$

¿Qué tipo de variables quedan excluidas?

Efectos fijos (fixed-effects, FE)

Usar efectos fijos tiene algunas desventajas:

- Hay un costo en comparación con OLS sin controlar por las dummies por individuo. La transformación within es equivalente a estimar una dummy para cada individuo. O sea estimar $N - 1$ parámetros adicionales (en el modelo one-way). Más parámetros significa menos precisión.
- Entonces eso afecta los grados de libertad y por ende la precisión de lo que estimamos. Los grados de libertad son $NT - N - K$, comparado con $NT - 1 - K$
- También la transformación within (y first-differences) elimina TODO aquello que esta fijo para cada individuo. Entonces no se puede medir por ejemplo el efecto de SEXO, para individuos, o CONTINENTE para países.

Efectos fijos (fixed-effects, FE)

Comparando FE con FD (Baltagi, p.17):

- FE es más eficiente que FD cuando $v_{it} \sim iid(0, \sigma_v^2)$.
- FD es más eficiente que FE cuando v_{it} es un paseo aleatorio (random walk).

Efectos aleatorios (random-effects, RE)

Un modelo alternativo es el de efectos aleatorios. Tiene un supuesto MUY importante y restrictivo: $cov(X, \mu) = 0$.

Consideremos el modelo

$$y_{it} = \beta_0 + \beta_1 x_{it} + u_{it} = \beta_0 + \beta_1 x_{it} + \mu_i + v_{it}.$$

En este caso hay **correlación serial**:

$Cov(u_{it}, u_{is}) = Cov(\mu_i + v_{it}, \mu_i + v_{is}) = Var(\mu_i) \neq 0$ para $t \neq s$. El estimador de efectos aleatorios (RE) tiene en cuenta esta particularidad y produce un estimador eficiente GLS:

$$\hat{\beta}_{RE} = (X' \Omega^{-1} X)^{-1} (X' \Omega^{-1} y),$$

donde $\Omega = E(uu')$ es la matriz de varianzas-covarianzas de los errores compuestos. Una de las ventajas de RE es que se pueden reincorporar variables fijas por individuos:

$$y_{it} = \beta_0 + \beta_1 x_{it} + \beta_2 z_i + \mu_i + v_{it},$$

donde z captura todas las variables que están fijas para cada individuo y que se pueden observar.

Efectos aleatorios (random-effects, RE)

En el modelo RE $\mu_i \sim iid(0, \sigma_\mu^2)$, $v_{it} \sim iid(0, \sigma_v^2)$, $\mu_i \perp v_{it}$. Además tenemos $X_{it} \perp \mu_i$ y $X_{it} \perp v_{it}$ para todo i y t .

$$\Omega = E(uu') = Z_\mu E(\mu\mu')Z_\mu' + E(vv') = \sigma_\mu^2(I_N \otimes J_T) + \sigma_v^2(I_N \otimes I_T).$$

Ω tiene esta estructura:

$$\begin{aligned} \text{cov}(u_{it}, u_{js}) &= \sigma_\mu^2 + \sigma_v^2 && \text{para } i = j, t = s \\ &= \sigma_\mu^2 && \text{para } i = j, t \neq s \\ &= 0 && \text{para } i \neq j \end{aligned}$$

Otra forma de verlo es como un modelo de **equicorrelación** intra cluster:

$$\begin{aligned} \text{correl}(u_{it}, u_{js}) &= 1 && \text{para } i = j, t = s \\ &= \sigma_\mu^2 / (\sigma_\mu^2 + \sigma_v^2) := \rho && \text{para } i = j, t \neq s \\ &= 0 && \text{para } i \neq j, t \neq s \end{aligned}$$

Efectos aleatorios (random-effects, RE)

Más en detalles, tenemos $\Omega =$

$$E \begin{bmatrix} (\mu_1 + v_{11})^2 & (\mu_1 + v_{11})(\mu_1 + v_{12}) & \dots & (\mu_1 + v_{11})(\mu_1 + v_{1r}) & (\mu_1 + v_{11})(\mu_2 + v_{21}) & (\mu_1 + v_{11})(\mu_2 + v_{22}) & \dots & (\mu_1 + v_{11})(\mu_2 + v_{2r}) & \dots \\ (\mu_1 + v_{12})(\mu_1 + v_{11}) & (\mu_1 + v_{12})^2 & \dots & (\mu_1 + v_{12})(\mu_1 + v_{1r}) & (\mu_1 + v_{12})(\mu_2 + v_{21}) & (\mu_1 + v_{12})(\mu_2 + v_{22}) & \dots & (\mu_1 + v_{12})(\mu_2 + v_{2r}) & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ (\mu_1 + v_{1r})(\mu_1 + v_{11}) & (\mu_1 + v_{1r})(\mu_1 + v_{12}) & \dots & (\mu_1 + v_{1r})^2 & (\mu_1 + v_{1r})(\mu_2 + v_{21}) & (\mu_1 + v_{1r})(\mu_2 + v_{22}) & \dots & (\mu_1 + v_{1r})(\mu_2 + v_{2r}) & \dots \\ (\mu_2 + v_{21})(\mu_1 + v_{11}) & (\mu_2 + v_{21})(\mu_1 + v_{12}) & \dots & (\mu_2 + v_{21})(\mu_1 + v_{1r}) & (\mu_2 + v_{21})^2 & (\mu_2 + v_{21})(\mu_2 + v_{22}) & \dots & (\mu_2 + v_{21})(\mu_2 + v_{2r}) & \dots \\ (\mu_2 + v_{22})(\mu_1 + v_{11}) & (\mu_2 + v_{22})(\mu_1 + v_{12}) & \dots & (\mu_2 + v_{22})(\mu_1 + v_{1r}) & (\mu_2 + v_{22})(\mu_2 + v_{21}) & (\mu_2 + v_{22})^2 & \dots & (\mu_2 + v_{22})(\mu_2 + v_{2r}) & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ (\mu_2 + v_{2r})(\mu_1 + v_{11}) & (\mu_2 + v_{2r})(\mu_1 + v_{12}) & \dots & (\mu_2 + v_{2r})(\mu_1 + v_{1r}) & (\mu_2 + v_{2r})(\mu_2 + v_{21}) & (\mu_2 + v_{2r})(\mu_2 + v_{22}) & \dots & (\mu_2 + v_{2r})^2 & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ (\mu_N + v_{N1})(\mu_1 + v_{11}) & (\mu_N + v_{N1})(\mu_1 + v_{12}) & \dots & (\mu_N + v_{N1})(\mu_1 + v_{1r}) & (\mu_N + v_{N1})(\mu_2 + v_{21}) & (\mu_N + v_{N1})(\mu_2 + v_{22}) & \dots & (\mu_N + v_{N1})(\mu_2 + v_{2r}) & \dots \\ (\mu_N + v_{N2})(\mu_1 + v_{11}) & (\mu_N + v_{N2})(\mu_1 + v_{12}) & \dots & (\mu_N + v_{N2})(\mu_1 + v_{1r}) & (\mu_N + v_{N2})(\mu_2 + v_{21}) & (\mu_N + v_{N2})(\mu_2 + v_{22}) & \dots & (\mu_N + v_{N2})(\mu_2 + v_{2r}) & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ (\mu_N + v_{Nr})(\mu_1 + v_{11}) & (\mu_N + v_{Nr})(\mu_1 + v_{12}) & \dots & (\mu_N + v_{Nr})(\mu_1 + v_{1r}) & (\mu_N + v_{Nr})(\mu_2 + v_{21}) & (\mu_N + v_{Nr})(\mu_2 + v_{22}) & \dots & (\mu_N + v_{Nr})(\mu_2 + v_{2r}) & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \end{bmatrix}$$

Efectos aleatorios (random-effects, RE)

Más en detalles, tenemos $\Omega =$

$$\begin{bmatrix} \sigma_{\mu}^2 + \sigma_{\nu}^2 & \sigma_{\mu}^2 & \dots & \sigma_{\mu}^2 & 0 & 0 & \dots & 0 & \dots & 0 & 0 & \dots & 0 \\ \sigma_{\nu}^2 & \sigma_{\mu}^2 + \sigma_{\nu}^2 & \dots & \sigma_{\nu}^2 & 0 & 0 & \dots & 0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \sigma_{\nu}^2 & \sigma_{\mu}^2 & \dots & \sigma_{\mu}^2 + \sigma_{\nu}^2 & 0 & 0 & \dots & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & \sigma_{\mu}^2 + \sigma_{\nu}^2 & \sigma_{\mu}^2 & \dots & \sigma_{\mu}^2 & \dots & 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & \sigma_{\mu}^2 & \sigma_{\mu}^2 + \sigma_{\nu}^2 & \dots & \sigma_{\mu}^2 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 0 & \sigma_{\mu}^2 & \sigma_{\mu}^2 & \dots & \sigma_{\mu}^2 + \sigma_{\nu}^2 & \dots & 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & 0 & 0 & \dots & 0 & \dots & \sigma_{\mu}^2 + \sigma_{\nu}^2 & 0 & \dots & \sigma_{\mu}^2 \\ 0 & 0 & \dots & 0 & 0 & 0 & \dots & 0 & \dots & \sigma_{\mu}^2 & \sigma_{\mu}^2 + \sigma_{\nu}^2 & \dots & \sigma_{\mu}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 0 & 0 & 0 & \dots & 0 & \dots & \sigma_{\nu}^2 & \sigma_{\mu}^2 & \dots & \sigma_{\mu}^2 + \sigma_{\nu}^2 \end{bmatrix}$$

Notar la estructura de **diagonal por bloques**.

Efectos aleatorios (random-effects, RE)

¿Cuáles serían las consecuencias de ignorar la correlación serial?

Supongamos el siguiente modelo de regresión univariada: $y_{it} = \beta x_{it} + \mu_i + v_{it}$, donde $\mu_i \sim iid(0, \sigma_\mu^2)$, $v_{it} \sim iid(0, \sigma_v^2)$, $\mu_i \perp v_{it}$. Además tenemos $x_{it} \perp \mu_i$ y $x_{it} \perp v_{it}$ para todo i y t .

- Por un lado se puede probar que el estimador OLS $\hat{\beta}_{OLS} = \frac{\sum_{i=1}^N \sum_{t=1}^T y_{it} x_{it}}{\sum_{i=1}^N \sum_{t=1}^T x_{it}^2}$ es insesgado y consistente.
- Sin embargo, la varianza de OLS estimada (bajo los supuestos de independencia de los errores que es lo que estimaríamos al ignorar la correlación entre observaciones del mismo individuo) es

$$\text{var}(\hat{\beta}_{OLS.est}) = (\sigma_\mu^2 + \sigma_v^2) \frac{1}{\sum_{i=1}^N \sum_{t=1}^T x_{it}^2},$$

pero la varianza correcta es

$$\text{var}(\hat{\beta}_{OLS}) = (\sigma_\mu^2 + \sigma_v^2) \frac{1}{\sum_{i=1}^N \sum_{t=1}^T x_{it}^2} + \sigma_\mu^2 \frac{\sum_{i=1}^N \sum_{t=1}^T \sum_{s=1, t \neq s}^T x_{it} x_{is}}{(\sum_{i=1}^N \sum_{t=1}^T x_{it}^2)^2}.$$

- El resultado es que los errores estándar que estima STATA por default son incorrectos, por lo que toda la inferencia es incorrecta.
- Esta diferencia se llama el “factor de Moulton”. Notar que depende de la **correlación intra-individuo** de las Xs. En particular si las Xs no están relacionadas entre sí para un mismo individuo, o sea $\text{Cov}(x_{it}, x_{is}) = 0$, $t \neq s$, entonces la varianza estándar es correcta.

Efectos aleatorios (random-effects, RE)

Prueba de la diapositiva anterior:

Consideremos la varianza condicional en x . Esto simplifica las pruebas.

$$\text{var}(\hat{\beta}_{OLS}) = \text{var} \left(\frac{\sum_{i=1}^N \sum_{t=1}^T x_{it} y_{it}}{\sum_{i=1}^N \sum_{t=1}^T x_{it}^2} \right) = \text{var} \left(\frac{\sum_{i=1}^N \sum_{t=1}^T x_{it} (\beta x_{it} + \mu_i + v_{it})}{\sum_{i=1}^N \sum_{t=1}^T x_{it}^2} \right) = \frac{\text{var} \left(\sum_{i=1}^N \sum_{t=1}^T \mu_i x_{it} + \sum_{i=1}^N \sum_{t=1}^T v_{it} x_{it} \right)}{\left(\sum_{i=1}^N \sum_{t=1}^T x_{it}^2 \right)^2}$$

Ahora hay que considerar que la varianza de la suma es la suma de las varianzas más todas las covarianzas. Como se asume independencia entre individuos $i = 1, 2, \dots, N$, y también entre μ_i y v_{it} , podemos escribir

$$= \frac{\sum_{i=1}^N \text{var} \left(\sum_{t=1}^T \mu_i x_{it} \right) + \sum_{i=1}^N \text{var} \left(\sum_{t=1}^T v_{it} x_{it} \right)}{\left(\sum_{i=1}^N \sum_{t=1}^T x_{it}^2 \right)^2}$$

El punto central aparece ahora. Por un lado, $\text{var} \left(\sum_{t=1}^T v_{it} x_{it} \right) = \sum_{t=1}^T \text{var} (v_{it} x_{it}) = \sum_{t=1}^T \sigma_v^2 x_{it}^2$, ya que se asume que no hay correlación serial en v_{it} . Por otro lado,

$\text{var} \left(\sum_{t=1}^T \mu_i x_{it} \right) = \sum_{t=1}^T \text{var}(\mu_i) x_{it}^2 + \sum_{t=1}^T \sum_{s=1, s \neq t}^T \text{cov}(\mu_i x_{it}, \mu_i x_{is})$, ya que aquí hay covarianzas que no son

zero. En particular, $\text{cov}(\mu_i x_{it}, \mu_i x_{is}) = \text{var}(\mu_i) x_{it} x_{is} = \sigma_\mu^2 x_{it} x_{is}$.

Entonces, usando estos resultados tenemos

$$\text{var}(\hat{\beta}_{OLS}) = (\sigma_\mu^2 + \sigma_v^2) \frac{1}{\sum_{i=1}^N \sum_{t=1}^T x_{it}^2} + \sigma_\mu^2 \frac{\sum_{i=1}^N \sum_{t=1}^T \sum_{s=1, t \neq s}^T x_{it} x_{is}}{\left(\sum_{i=1}^N \sum_{t=1}^T x_{it}^2 \right)^2}.$$

Efectos aleatorios (random-effects, RE)

Análisis de la diapositiva anterior:

El término adicional a considerar es $\hat{C}_X = \frac{1}{NT(T-1)} \sum_{i=1}^N \sum_{t=1}^T \sum_{s=1, t \neq s}^T x_{it} x_{is}$.

- Notar que \hat{C}_X lo podemos definir como un estimador de la covarianza intra-individuo de las X_s .
- Si $\hat{C}_X = 0$, entonces la varianza con los supuestos de Gauss-Markov es correcta. Esto implica que no solo hay que considerar la covarianza intra-individuo o **intra-cluster** en los errores, sino también de las X_s .

Tomemos ahora $\hat{V}_X = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T x_{it}^2$.

- Notar que \hat{V}_X lo podemos definir como un estimador de la varianza intra-individuo de las X_s .
- Si $\hat{V}_X > 0$, tiene que haber variabilidad en las X_s .

Ahora definimos $\hat{\rho}_X = \frac{\hat{C}_X}{\hat{V}_X}$, como la correlación intra-individuo o **intra-cluster** de las X_s .

Entonces,

$$\text{var}(\hat{\beta}_{OLS}) = \frac{(\sigma_\mu^2 + \sigma_v^2)}{NT\hat{V}_X} + \frac{(T-1)}{NT\hat{V}_X} \sigma_\mu^2 \hat{\rho}_X = \text{var}(\hat{\beta}_{OLS.est}) + \frac{(T-1)}{NT\hat{V}_X} \sigma_\mu^2 \hat{\rho}_X$$

Efectos aleatorios (random-effects, RE)

Para estimarlo vamos a tratar el problema como GLS (generalized least squares) donde se estima Ω .

- Siguiendo a Wansbeek y Kapteyn (1982,1983), Baltagi p.18, reemplacemos J_T por $T\overline{J_T}$, y I_T por $(E_T + \overline{J_T})$, donde por definición $E_T = I_T - \overline{J_T}$. Entonces reagrupando términos tenemos

$$\begin{aligned}\Omega &= T\sigma_\mu^2(I_N \otimes \overline{J_T}) + \sigma_v^2(I_N \otimes E_T) + \sigma_v^2(I_N \otimes \overline{J_T}) \\ &= (T\sigma_\mu^2 + \sigma_v^2)(I_N \otimes \overline{J_T}) + \sigma_v^2(I_N \otimes E_T) = \sigma_1^2 P_\mu + \sigma_v^2 Q_\mu\end{aligned}$$

donde $\sigma_1^2 = (T\sigma_\mu^2 + \sigma_v^2)$.

- Esta es la descomposición espectral de Ω donde σ_1^2 (de multiplicidad N) y σ_v^2 (de multiplicidad $N(T-1)$) son las raíces características de Ω .
- Esto permite hallar $\Omega^r = \sigma_1^{2r} P + \sigma_v^{2r} Q$ para todo r (en particular $r = -1$).
[¿Por qué? Probar que es cierto.]

Efectos aleatorios (random-effects, RE)

- Entonces, surgen los siguientes estimadores

$$\hat{\sigma}_1^2 = \frac{u' P_\mu u}{\text{tr}(P_\mu)} = T \sum_{i=1}^N \bar{u}_i^2 / N$$

$$\hat{\sigma}_v^2 = \frac{u' Q_\mu u}{\text{tr}(Q_\mu)} = \frac{\sum_{t=1}^T \sum_{i=1}^N (u_{it} - \bar{u}_i)^2}{N(T-1)}$$

- Notar que u no es observado... hay diferentes alternativas, todas ellas consistentes: (i) usar los residuos OLS, (ii) los residuos de FE, y (iii) otras.

Efectos aleatorios (random-effects, RE)

El estimador RE es entonces

$$\begin{aligned}\hat{\beta}_{RE} &= [(X'Q_{\mu}X/\sigma_v^2) + (X'(P_{\mu} - \bar{J}_{NT})X/\sigma_1^2)]^{-1}[(X'Q_{\mu}y/\sigma_v^2) + (X'(P_{\mu} - \bar{J}_{NT})y/\sigma_1^2)] \\ &= [W_{XX} + \phi^2 B_{XX}]^{-1}[W_{Xy} + \phi^2 B_{Xy}]\end{aligned}$$

donde $W_{XX} = X'Q_{\mu}X$, $B_{XX} = X'(P_{\mu} - \bar{J}_{NT})X$, $\phi^2 = \sigma_v^2/\sigma_1^2$. También $\text{var}(\hat{\beta}_{RE}) = \sigma_v^2[W_{XX} + \phi^2 B_{XX}]^{-1}$.

Por otro lado $\hat{\beta}_{FE} = W_{XX}^{-1}W_{Xy}$ y $\hat{\beta}_{BE} = B_{XX}^{-1}B_{Xy}$, FE: fixed-effects-within; BE: between (regresión de los promedios intra-individuo solamente). Entonces, $\hat{\beta}_{RE} = W_1\hat{\beta}_{FE} + W_2\hat{\beta}_{BE}$ donde $W_1 = [W_{XX} + \phi^2 B_{XX}]^{-1}W_{XX}$ y $W_2 = [W_{XX} + \phi^2 B_{XX}]^{-1}\phi^2 B_{XX} = I - W_1$, es decir, RE es un promedio ponderado de FE y BE.

Nota: Análisis cuando $T \rightarrow \infty$, $N \rightarrow \infty$, $(\sigma_v^2, \sigma_{\mu}^2) \rightarrow 0, \infty$.

Efectos aleatorios (random-effects, RE)-two-way

En el modelo RE two-way $\mu_i \sim iid(0, \sigma_\mu^2)$, $\lambda_t \sim iid(0, \sigma_\lambda^2)$, $v_{it} \sim iid(0, \sigma_v^2)$, $\mu_i \perp v_{it}$, $\lambda_i \perp v_{it}$. Además tenemos $X_{it} \perp \mu_i$, $X_{it} \perp \lambda_t$ y $X_{it} \perp v_{it}$ para todo i y t .

$$\begin{aligned}\Omega = E(uu') &= Z_\mu E(\mu\mu')Z_\mu' + Z_\mu E(\lambda\lambda')Z_\mu' + E(vv') = \\ &\sigma_\mu^2(I_N \otimes J_T) + \sigma_\lambda^2(J_N \otimes I_T) + \sigma_v^2(I_N \otimes I_T).\end{aligned}$$

Ω tiene esta estructura:

$$\begin{aligned}\text{cov}(u_{it}, u_{js}) &= \sigma_\mu^2 + \sigma_\lambda^2 + \sigma_v^2 && \text{para } i = j, t = s \\ &= \sigma_\mu^2 && \text{para } i = j, t \neq s \\ &= \sigma_\lambda^2 && \text{para } i \neq j, t = s \\ &= 0 && \text{para } i \neq j\end{aligned}$$

Efectos aleatorios (random-effects, RE)-two-way

Más en detalles, tenemos $\Omega = E...$

$(\mu_1 + \lambda_1 + \nu_{11})^2$	$(\mu_1 + \lambda_1 + \nu_{11})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_1 + \lambda_1 + \nu_{11})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_1 + \lambda_1 + \nu_{11})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_1 + \lambda_1 + \nu_{11})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_1 + \lambda_1 + \nu_{11})(\mu_2 + \lambda_r + \nu_{2r})$
$(\mu_1 + \lambda_2 + \nu_{12})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_1 + \lambda_2 + \nu_{12})^2$...	$(\mu_1 + \lambda_2 + \nu_{12})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_1 + \lambda_2 + \nu_{12})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_1 + \lambda_2 + \nu_{12})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_1 + \lambda_2 + \nu_{12})(\mu_2 + \lambda_r + \nu_{2r})$
.
.
$(\mu_1 + \lambda_r + \nu_{1r})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_1 + \lambda_r + \nu_{1r})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_1 + \lambda_r + \nu_{1r})^2$	$(\mu_1 + \lambda_r + \nu_{1r})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_1 + \lambda_r + \nu_{1r})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_1 + \lambda_r + \nu_{1r})(\mu_2 + \lambda_r + \nu_{2r})$
$(\mu_2 + \lambda_1 + \nu_{21})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_2 + \lambda_1 + \nu_{21})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_2 + \lambda_1 + \nu_{21})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_2 + \lambda_1 + \nu_{21})^2$	$(\mu_2 + \lambda_1 + \nu_{21})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_2 + \lambda_1 + \nu_{21})(\mu_2 + \lambda_r + \nu_{2r})$
$(\mu_2 + \lambda_2 + \nu_{22})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_2 + \lambda_2 + \nu_{22})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_2 + \lambda_2 + \nu_{22})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_2 + \lambda_2 + \nu_{22})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_2 + \lambda_2 + \nu_{22})^2$...	$(\mu_2 + \lambda_2 + \nu_{22})(\mu_2 + \lambda_r + \nu_{2r})$
.
.
$(\mu_2 + \lambda_r + \nu_{2r})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_2 + \lambda_r + \nu_{2r})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_2 + \lambda_r + \nu_{2r})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_2 + \lambda_r + \nu_{2r})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_2 + \lambda_r + \nu_{2r})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_2 + \lambda_r + \nu_{2r})^2$
.
.
$(\mu_w + \lambda_1 + \nu_{w1})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_w + \lambda_1 + \nu_{w1})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_w + \lambda_1 + \nu_{w1})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_w + \lambda_1 + \nu_{w1})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_w + \lambda_1 + \nu_{w1})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_w + \lambda_1 + \nu_{w1})(\mu_2 + \lambda_r + \nu_{2r})$
$(\mu_w + \lambda_2 + \nu_{w2})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_w + \lambda_2 + \nu_{w2})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_w + \lambda_2 + \nu_{w2})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_w + \lambda_2 + \nu_{w2})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_w + \lambda_2 + \nu_{w2})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_w + \lambda_2 + \nu_{w2})(\mu_2 + \lambda_r + \nu_{2r})$
.
.
$(\mu_w + \lambda_r + \nu_{wr})(\mu_1 + \lambda_1 + \nu_{11})$	$(\mu_w + \lambda_r + \nu_{wr})(\mu_1 + \lambda_2 + \nu_{12})$...	$(\mu_w + \lambda_r + \nu_{wr})(\mu_1 + \lambda_r + \nu_{1r})$	$(\mu_w + \lambda_r + \nu_{wr})(\mu_2 + \lambda_1 + \nu_{21})$	$(\mu_w + \lambda_r + \nu_{wr})(\mu_2 + \lambda_2 + \nu_{22})$...	$(\mu_w + \lambda_r + \nu_{wr})(\mu_2 + \lambda_r + \nu_{2r})$
.
.

Efectos aleatorios (random-effects, RE)-two-way

Para estimarlo vamos a tratar el problema como GLS (generalized least squares) donde se estima Ω .

- Baltagi p.37, reemplazar J_N por $N\overline{J}_N$, I_N por $E_N + \overline{J}_N$, J_T por $T\overline{J}_T$, I_T por $E_T + \overline{J}_T$, entonces

$$\Omega = \sum_{j=1}^4 \eta_j Q_j$$

donde $\eta_1 = \sigma_v^2$, $\eta_2 = T\sigma_\mu^2 + \sigma_v^2$, $\eta_3 = N\sigma_\lambda^2 + \sigma_v^2$, y $\eta_4 = T\sigma_\mu^2 + N\sigma_v^2 + \sigma_v^2$, $Q_1 = E_N \otimes E_T$, $Q_2 = E_N \otimes \overline{J}_T$, $Q_3 = \overline{J}_N \otimes E_T$, y $Q_4 = \overline{J}_N \otimes \overline{J}_T$. Esta es la descomposición espectral de Ω donde η_j son las raíces características. Cada Q_j es simétrica e idempotente.

- Entonces, surgen los siguientes estimadores

$$\hat{\eta}_j = \frac{u' Q_j u}{\text{tr}(Q_j)}, j = 1, 2, 3, 4$$

Efectos aleatorios (random-effects, RE)-two-way

El estimador RE es entonces

$$\begin{aligned}\hat{\beta}_{RE} &= [(X'Q_1X/\sigma_v^2) + (X'Q_2X/\eta_2) + (X'Q_3X/\eta_3)]^{-1} \\ &\quad [(X'Q_1y/\sigma_v^2) + (X'Q_2y/\eta_2) + (X'Q_3y/\eta_3)] \\ &= [W_{XX} + \phi_2^2 B_{XX} + \phi_3^2 C_{XX}]^{-1} [W_{Xy} + \phi_2^2 B_{Xy} + \phi_3^2 C_{Xy}]\end{aligned}$$

donde $W_{XX} = X'Q_1X$, $B_{XX} = X'Q_2X$, $C_{XX} = X'Q_3X$, $\phi_j^2 = \sigma_v^2/\eta_j$, $j = 2, 3$. También $\text{var}(\hat{\beta}_{RE}) = \sigma_v^2 [W_{XX} + \phi_2^2 B_{XX} + \phi_3^2 C_{XX}]^{-1}$.

Entonces, $\hat{\beta}_{RE} = W_1 \hat{\beta}_{FE} + W_2 \hat{\beta}_{BE1} + W_3 \hat{\beta}_{BE2}$ donde
 $W_1 = [W_{XX} + \phi_2^2 B_{XX} + \phi_3^2 C_{XX}]^{-1} W_{XX}$, $W_2 = [W_{XX} + \phi_2^2 B_{XX} + \phi_3^2 C_{XX}]^{-1} \phi_2^2 B_{XX}$, y
 $W_3 = [W_{XX} + \phi_2^2 B_{XX} + \phi_3^2 C_{XX}]^{-1} \phi_3^2 C_{XX}$.

[Probar que en este caso también el estimador es un promedio ponderado de tres estimadores. Análisis cuando $T \rightarrow \infty$, $N \rightarrow \infty$, $(\sigma_v^2, \sigma_\mu^2, \sigma_\lambda^2) \rightarrow 0, \infty$.]

Contraste de Hausman

- Un contraste de la validez de efectos aleatorios es

$$H_0 : Cov(X, \mu) = 0$$

$$H_A : Cov(X, \mu) \neq 0$$

La hipótesis nula es que las variables X no están relacionadas con los efectos individuales, μ .

- Para evaluar este contraste se compara $\hat{\beta}_{FE}$ con $\hat{\beta}_{RE}$. El estimador FE es siempre **consistente**. Sin embargo, el de RE es válido si las X s no están correlacionadas con μ .

$$H_0 : \beta_{FE} - \beta_{RE} = 0$$

$$H_A : \beta_{FE} - \beta_{RE} \neq 0$$

- Entonces, si la diferencia es aproximadamente 0 no hay evidencia suficiente para que H_0 sea rechazada. Si por el contrario $\hat{\beta}_{FE} - \hat{\beta}_{RE} \neq 0$ entonces sí hay que rechazar la nula. Este es el llamado **contraste de Hausman**.

Contraste de Hausman

- Notemos que el estimador RE es GLS, entonces es el de menor varianza. Por lo tanto $var(\hat{\beta}_{FE}) - var(\hat{\beta}_{RE})$ es una matriz definida positiva. Para demostrarlo notemos que tanto W_{XX} como B_{XX} son matrices definidas positivas (formas cuadráticas), mientras que $\phi^2 > 0$. Entonces $[W_{XX} + \phi^2 B_{XX}] - W_{XX}$ es definida positiva, por lo que $[W_{XX} + \phi^2 B_{XX}]^{-1} - W_{XX}^{-1}$ es definida negativa, o $var(\hat{\beta}_{RE}) - var(\hat{\beta}_{FE})$ es definida negativa.
- Se puede probar que $var(\hat{\beta}_{FE} - \hat{\beta}_{RE}) = var(\hat{\beta}_{FE}) - var(\hat{\beta}_{RE})$.
- Entonces, definamos

$$H = (\hat{\beta}_{FE} - \hat{\beta}_{RE})' [var(\hat{\beta}_{FE}) - var(\hat{\beta}_{RE})]^{-1} (\hat{\beta}_{FE} - \hat{\beta}_{RE})$$

- El estadístico H una distribución χ_K^2 bajo la nula. Se rechaza H_0 si $H > \chi_K^2(1 - \alpha)$ (valor crítico).

Contraste de Mundlak

(Hsiao, 2003, sec. 3.2; Wooldridge, 2012, sec. 10.7.3)

- Mundlak (1978) propone usar un modelo de regresión que contenga los promedios de individuos i de las variables que varían en i y t :

$$y_{it} = \beta_0 + \beta_1 x_{it} + \beta_2 z_i + \beta_3 \bar{x}_i + \mu_i + v_{it}$$

- Entonces un contraste de $H_0 : \beta_3 = 0$ es un contraste por la validez de RE.

Contrastes para efectos aleatorios

Breusch-Pagan (1980)

- Breusch, T.S. and Pagan, A. (1980). "The Lagrange Multiplier Test and its Applications to Model Specification in Econometrics." *Review of Economic Studies* 47(1), 239–253.

(ver Baltagi, pp-63-65)

Supongamos la función de logaritmo de verosimilitud

$$L(\beta, \theta) = \text{constant} - \frac{1}{2} \log|\Omega| - \frac{1}{2} u' \Omega^{-1} u,$$

donde $u = y - X\beta$, $\theta' = (\sigma_\mu^2, \sigma_\delta^2, \sigma_v^2)$, y

$$\Omega = \sigma_\mu^2 (I_N \otimes J_T) + \sigma_\delta^2 (J_N \otimes I_T) + \sigma_v^2 (I_N \otimes I_T).$$

Las hipótesis de interés son

- $H_0^{\sigma_\mu^2, \sigma_\delta^2} : \sigma_\mu^2 = \sigma_\delta^2 = 0$. Contraste por la ausencia de efectos aleatorios en ambos niveles.
- $H_0^{\sigma_\mu^2} : \sigma_\mu^2 = 0$. Contraste por la ausencia de efectos aleatorios al nivel individual.
- $H_0^{\sigma_\delta^2} : \sigma_\delta^2 = 0$. Contraste por la ausencia de efectos aleatorios al nivel temporal.

Contrastes para efectos aleatorios

Breusch-Pagan (1980)

La matriz de información es diagonal por bloques en cuanto a β y θ . Es implica que sólo tenemos que considerar las derivadas con respecto a θ .

Consideremos las derivadas

$$\partial L / \partial \theta_r = \frac{1}{2} \text{tr}[\Omega^{-1} \partial \Omega / \partial \theta_r] + \frac{1}{2} [u' \Omega^{-1} \partial \Omega / \partial \theta_r \Omega^{-1} u],$$

para $r = 1, 2, 3$.

La matriz de información tiene elementos

$$J_{rs}(\theta) = E\left[\frac{\partial^2 L}{\partial \theta_r \partial \theta_s}\right] = \frac{1}{2} \text{tr}[\Omega^{-1} \partial \Omega / \partial \theta_r \Omega^{-1} \partial \Omega / \partial \theta_s].$$

El contraste de Breusch-Pagan es un contraste LM (multiplicadores de Lagrange), entonces sólo necesita estimar bajo la hipótesis nula conjunta $\hat{\sigma}_v^2 = \hat{u}' \hat{u} / NT$, \hat{u} los residuos OLS. El contraste es

$$LM = \hat{D}' \hat{J}^{-1} \hat{D}$$

donde D son los scores (derivadas). $LM \sim \chi^2_2$ bajo la hipótesis nula $H_0^{\sigma_\mu^2, \sigma_\delta^2}$. Por otro lado $LM = LM_1 + LM_2$ donde LM_1 y LM_2 son los contrastes LM marginales para $H_0^{\sigma_\mu^2}$ y $H_0^{\sigma_\delta^2}$, respectivamente.

¿Cómo implementar paneles en STATA?

- Los datos hay que organizarlos:

id	tiempo	YVAR	XVAR
1	1	y ₁₁	x ₁₁
1	2	y ₁₂	x ₁₂
1	3	y ₁₃	x ₁₃
2	1	y ₂₁	x ₂₁
2	2	y ₂₂	x ₂₂
2	3	y ₂₃	x ₂₃

Es muy importante que no haya valores repetidos. En el ejemplo se representa un panel balanceado. Podrá ser desbalanceado si tuviera gaps (ej., la obs. $i = 1, t = 2$ no está).

- Primero STATA tiene que identificar que se trata de datos en paneles. Para eso se necesita una variable numérica, ej. `id`, que identifica el individuo. Luego, `iis id`
- Pero si se tiene una muestra longitudinal con una estructura de series de tiempo, con una variable `tiempo`, `tsset id tiempo`
- Nota: la variable de tiempo tiene que ser en números discretos consecutivos. O sea, $t = -2, -1, 0, 1, \dots$ o $t = 1980, 1981, 1982, \dots$

¿Cómo implementar paneles en STATA?

- Entonces estamos listos para usar datos en paneles:
- `reg D.y D.x1 D.x2 D.x3` (modelo en diferencias, sólo con `tsset`)
- `xtreg y x1 x2 x3, fe` (modelo de efectos fijos)
- `xi: reg y x1 x2 x3 i.id` (lo mismo pero implementado “a mano” con dummies para id) [Nota: comparar con una regresión de las variables transformadas within. ¿Cuál sería el problema con este modelo?]
- `areg y x1 x2 x3, abs(id)` (no reporta las dummies)
- `xtreg y x1 x2 x3, re` (modelo de efectos aleatorios)
- `xtreg y x1 x2 x3, be` (modelo between)
- `xi: xtreg y x1 x2 x3 i.tiempo, fe` (modelo de efectos fijos, two-way)

¿Cómo implementar paneles en STATA?

- Contraste de Hausman test
xtreg y x1 x2 x3, fe
est store fe
xtreg y x1 x2 x3, re
est store re
hausman fe re