

Datos en Panel

Walter Sosa-Escudero

Variables binarias para categorias multiples

Y (salarios), X (educacion), este, centro, oeste

$$Y_i = \beta_1 + \beta_2 X_i + \delta_1 D_{1i} + \delta_2 D_{2i} + u_i$$

$$D_{1i} = 1[\text{este}], \quad D_{2i} = 1[\text{centro}]$$

$$Y_i | \text{oeste} = \beta_1 + \beta_2 X_i + u_i$$

$$Y_i | \text{este} = \beta_1 + \delta_1 + \beta_2 X_i + u_i$$

$$Y_i | \text{centro} = \beta_1 + \delta_2 + \beta_2 X_i + u_i$$

- Categoria base: oeste.
- Efectos diferenciales: $\delta_1 = \text{este/oeste}$, $\delta_2 = \text{centro/oeste}$.
- centro/este?

$$D_{3i} = 1[\text{oeste}]$$

$$Y_i = \beta_1 + \beta_2 X_i + \delta_1 D_{1i} + \delta_2 D_{2i} + \delta_3 D_{3i} + u_i$$

Problema?

En general

- **Trampa de variables binarias:** si hay un intercepto, para J categorías, incluir $J - 1$ variables binarias.
- Intercepto y $J - 1$ variables binarias da los mismos efectos diferenciales que sin intercepto y J variables binarias

$$Y_i = \beta_2 X_i + \delta_1 D_{1i} + \delta_2 D_{2i} + \delta_3 D_{3i} + u_i$$

Verificar, como ejercicio.

- Idea: misma pendiente, distintos interceptos para cada categoría. Generalización: diferentes pendientes.

Por que paneles?

Ejemplo (Cronwell y Trumbull): Determinantes del crimen

- $y = g(I)$, $y =$ crimen, $I =$ justicia criminal.
- Corte transversal: (y_i, I_i) para regiones $i = 1, \dots, n$
- I es 'importante'
- Critica: I captura el efecto de otros factores regionales. Sesgo por variable omitida. Control

Paneles: solucion al problema de sesgo, sin agregar otras variables.

Modelo simple para paneles

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

$$u_{it} = \mu_i + \delta_t + \epsilon_{it}$$

$i = 1, \dots, N$, $t = 1, \dots, T$. x_{it} , a vector de K variables explicativas.

- Panel: doble variabilidad
- u_{it}
- μ_i efectos no observables que varían solo por individuo.
- SPG, $\delta_t = 0$

Efectos fijos

$$y_{it} = x'_{it}\beta + \mu_i + \epsilon_{it}$$

Efecto fijo: Estima β y μ_i como parametros $K + (N - 1)$

Modelo lineal con un intercepto para cada individuo:

$$y_{it} = \underbrace{\mu_i + \beta_1}_{\text{intercepto}} + \beta_2 x_{2,it} + \dots + \beta_K x_{K,it} + \epsilon_{it}$$

Agregar $N - 1$ variables binarias por individuo, o sin intercepto y N binarias.

En terminos matriciales

$$Y = X\beta + D\mu + u$$

$Y_{NT \times 1}$, $X_{NT \times K}$ sin intercepto. D , matriz de N binarias por individuo.

$$1_N \equiv \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}, \quad D = \begin{bmatrix} 1_N & 0 & \cdots & 0 \\ 0 & 1_N & 0 & \vdots \\ \vdots & & \ddots & \vdots \\ 0 & 0 & \cdots & 1_N \end{bmatrix}_{NT \times N}$$

Escribamos el modelo como:

$$Y = X\beta + D\mu + u = \dot{X}\delta + u$$

con $\dot{X} \equiv [X \ D]$ y $\delta \equiv [\beta' \ \mu']'$.

El *estimador de efectos fijos* es:

$$\hat{\delta}_{EF} = \begin{pmatrix} \hat{\beta}_{EF} \\ \hat{\mu}_{EF} \end{pmatrix} = (\dot{X}'\dot{X})^{-1}\dot{X}'Y.$$

MCO mas N dummies ('LSDV').

Efectos fijos y la transformacion 'within'

Por el TFWL

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

con $X^* \equiv M_D X$ y $Y^* \equiv M_D Y$. $M_D = I - D(D'D)^{-1}D'$ es la matriz que genera errores de regresar las X y las Y en D .

Es facil mostrar (hacerlo!) que

$$X_{it}^* = X_{it} - \bar{X}_i$$

Transformacion within: controlar por efectos fijos es identico a restar las medias individuales.

El TFWL sugiere dos forma idénticas de obtener el estimador de efectos fijos


- Regresar Y on X and D .
- Primero restar las medias individuales y luego regresar.

Conceptualmente relevante (nexo con VI, ya veremos)

Efectos fijos y heterogeneidad no observable

- $\hat{\beta}_{FE}$ insesgado, independientemente de si X correlacionada con D (FE **controla** for D).
- Si la variable omitida en nuestro ejemplo varia solo por individuo, es como si hubiesemos controlado por ella **aun sin observarla**.
- Intuicion: la transformacion within elimina cualquier variable que varia a nivel individual, observada o no.


Panel como control: representacion grafica




Verbalizacion

- Y = crimen.
- X = ineficiencia del sistema judicial.
- Dos regiones
- Determinante del crimen no observado, que varia por region y positivamente correlacionado con la ineficiencia judicial (densidad?).

MCO



Efectos fijos



Tres estimadores

$$y_{it} = x_{it}\beta + \mu_i + \epsilon_{it}$$

Within: $y_{it}^* = x_{it}^*\beta + \epsilon_{it}^*$

- Controla por μ_i . Varacion N, T . Insesgado siempre

Between: $\bar{y}_i = \bar{x}_i + \mu_i + \bar{\epsilon}_i$

- Omite μ_i . Varacion N . Insesgado solo si $\mu \perp \epsilon$

MCO de y_{it} en x_{it} ?

TABLE 3.—RESULTS FROM ESTIMATION
(standard errors in parentheses)

	Between	Within	2SLS (fixed effects)	2SLS (no fixed effects)
CONSTANT	-2.097 (2.822)			-3.719 (8.189)
P_A	-0.648 (0.088)	-0.355 (0.032)	-0.455 (0.618)	-0.507 (0.251)
P_C	-0.528 (0.067)	-0.282 (0.021)	-0.336 (0.371)	-0.530 (0.110)
P_P	0.297 (0.231)	-0.173 (0.032)	-0.196 (0.200)	0.200 (0.343)
S	-0.236 (0.174)	-0.00245 (0.02612)	-0.0298 (0.0300)	-0.218 (0.185)
<i>POLICE</i>	0.364 (0.060)	0.413 (0.027)	0.504 (0.617)	0.419 (0.218)
<i>DENSITY</i>	0.168	0.414	0.291	0.226

Probs de arresto, condena, prision

Diferencias-en-diferencias

Efecto de salarios mínimos en empleo (Card, Krueger (1994)).

- Salario mínimo (MW) reduce el empleo?
- Empleo en McDonalds antes y después de cambios en MW?
Confunde MW con otros cambios temporales.
- Empleo en McDonalds, mismo periodo, estados diferentes con diferentes políticas de MW ? Confunde MW con determinantes regionales del empleo.

Contexto hiper-simple

- Unidad de analisis: restaurant i en el estado s en el periodo t .
- Variable de interes Y_{its} : empleo en el restaurant its .
- Dos periodos: $t = 1, 2$
- Dos estados: A, B .
- N restaurants por estado.
- MW, politica a nivel *estado*.
- Estado A no cambia la politica de MW. Solo B lo hace, en el periodo 2.
- $D_{ist} = 1$ si el estado s cambia MW en t , 0 si no.
- Notar que $D_{ist} = 1$ iff $s = B$ y $t = 2$.

Modelo aditivo:

$$Y_{its} = \gamma_s + \lambda_t + \beta D_{ist} + \epsilon_{ist}$$

β es el parametro de interes: efecto de MW controlando por factores regionales (γ_s) y temporales (λ_t).

Diferencias-en-diferencias

$$Y_{its} = \gamma_s + \lambda_t + \beta D_{ist} + \epsilon_{ist}$$

Notar

$$E(Y|B, 2) - E(Y|B, 1) = \lambda_2 - \lambda_1 + \beta$$

$$E(Y|A, 2) - E(Y|A, 1) = \lambda_2 - \lambda_1$$

Restando

$$\begin{array}{rcccl} \left[E(Y|B, 2) - E(Y|B, 1) \right] & - & \left[E(Y|A, 2) - E(Y|A, 1) \right] & = & \beta \\ \text{Cambio en B} & - & \text{Cambio en A} & = & \beta \end{array}$$

$$\hat{\beta} = \text{Average change in B} - \text{Average change in A}$$

Dif-in-dif via paneles

$$Y_{its} = \gamma_s + \lambda_t + \beta D_{ist} + \epsilon_{ist}$$

- $DB_{ist} = 1$ sii i esta en el estado B
- $D2_{ist} = 0$ sii $t = 2$.
- Por contruccion $D_{ist} = DB_{ist} \times D2_{ist}$ (el cambio ocurre solo en el estado B y el periodo 2).

Reemplazando:

$$Y_{its} = \gamma_s + \lambda_t + \beta(DB_{ist} \times D2_{ist}) + \epsilon_{ist}$$

$$Y_{its} = \gamma_s + \lambda_t + \beta(DB_{ist} \times D2_{ist}) + \epsilon_{ist}$$

- Es un *panel* de N restaurants en 2 regions y 2 periods, con efectos fijos regionales y por periodos.
- Regresar Y_{its} en 1) dummy for region B, 2) dummy por periodo 2) 'interacciones' entre ambas.
- Parametro de interes: β .

Comments

- Panel? errores estandar y tests de hipotesis.
- 'Tendencia comun': crucial. Ambos estados comparten λ_t : la evolucion del empleo es identica en ambos estados.
'Tratamiento' (cambio en MW) solo implica salirse de la tendencia comun. Testeable
- No correlacion serial: supuesto clave para inferencia. Clustered standard errors, Bertrand, Duflo, y Mullainathan (2004).

Random effects estimator

Same model

$$Y = X\beta + D\mu + \epsilon$$

If seen as a random variable $D\mu$ is orthogonal to X , and if $E(\mu_i|X) = 0$, then the OLS estimator that regresses Y on X is unbiased.

That is, if $D\mu$ is orthogonal to X , omitting the dummy variables does not bias OLS.

Fixed or random?

Careful. It is a matter of treatment/estimation.

$$Y = X\beta + D\mu + \epsilon$$

Fixed effects (controls for $D\mu$)

$$Y = X\beta + D\mu + \epsilon$$

Random effects (treats $D\mu$ as an omitted variable)

$$Y = X\beta + D\mu + \epsilon$$

$$Y = X\beta + D\mu + \epsilon$$

$$Y = X\beta + u, \quad u \equiv D\mu + \epsilon$$

Problem: u does not satisfy the classical assumptions, even when $D\mu$ and ϵ do.

Simple proof: assume classical assumptions separately (zero expected value, no serial correlation/heteroskedasticity). Also $D\mu$ and ϵ uncorrelated. Then

$$\begin{aligned} V(u) &= V(D\mu + \epsilon) \\ &= DV(\mu)D' + V(\epsilon) \\ &= \sigma_{\mu}^2 DD' + \sigma_{\epsilon}^2 I_{NT}, \end{aligned}$$

certainly non-spherical.

Intuition: $u_{it} = \mu_i + \epsilon_{it}$

- Trivially, u_{it} is correlated with $u_{i,t-1}$ since both 'share' μ_i : the persistent presence of μ_i implies that random effects induce serial correlation.
- Though not biased, OLS is inefficient (in the sense discussed in class).
- Efficient? GLS.

Generalized Least Squares

Supongamos que valen todos los supuestos clásicos, pero que

$$V(u) = \sigma^2 \Omega,$$

con Ω cualquier matriz positiva (permitimos heterocedasticidad y/o correlación serial). Perdemos Gauss/Markov

Resultado (Aitken): bajo todos los supuestos clásicos y cuando $V(u) = \sigma^2 \Omega$

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

es un estimador de varianza mínima en la clase de estimadores lineales e insesgados.

Prueba: Caso X no aleatoria. En primer lugar, si Ω es positiva, existe $C_{n \times n}$ invertible tal que $C' C = \Omega^{-1}$. Partiendo de $Y = X\beta + u$, premultipliquemos ambos lados por C , para obtener

$$Y^* = X^* \beta + u^* \quad (1)$$

con $Z^* = CZ$, $Z = Y, X, u$. El modelo transformado (1) tiene los mismos coeficientes desconocidos que el modelo original, y es fácil mostrar que satisface todos los supuestos clásicos (chequear). En particular

$$V(u^*) = E(u^* u^{*'}) = C \sigma^2 \Omega C' = \sigma^2 C [(C' C)^{-1}] C' = \sigma^2 I_n$$

Entonces, por el Teorema de Gauss/Markov aplicado al modelo transformado, el estimador de mínima varianza en la clase de los lineales e insesgados es

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

GLS 'factible'

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

en donde $\hat{\Omega}$ es cualquier estimador consistente de Ω .

GLS random effects

Recall

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

In our case

$$V(u) = \sigma_{\mu}^2 DD' + \sigma_{\epsilon}^2 I_{NT} \equiv \Omega(\theta)$$

with $\theta' = (\sigma_{\mu}^2, \sigma_{\epsilon}^2)'$

- FGLS requires to estimate θ first (variance components).
- Random effects estimator: GLS for random effects.

Test de Hausman

$$Y = X\beta + D\mu + \epsilon$$

- $X \perp D\mu$: MCO, EF, BE, RE todos insesgados para β . RE (por que).
- $X \not\perp D\mu$: solo EF insesgado β .

Test de Hausman

$$H_0 : X \perp D\mu, \quad H_A : X \not\perp D\mu$$

Test de Hausman: under H_0

$$H = (\hat{\beta}_{BE} - \hat{\beta}_{EF})'(\Omega_{EF} - \Omega_{BE})^{-1}(\hat{\beta}_{BE} - \hat{\beta}_{EF}) \sim \chi^2(K)$$

Rechazar si H es significativamente alto.

Hausman/Taylor (1981): es lo mismo reemplazar BE con RE.

Intuición: bajo H_0 , $\hat{\beta}_{BE}$ y $\hat{\beta}_{EF}$ consistentes, H chico. Bajo H_A , solo $\hat{\beta}_{EF}$ consistente, H grande.