

Regresión en la Práctica y Sesgo de Variable Omitida

Clase 10 — 14.310x: Data Analysis for Social Scientists

B.Sc. Cristian Lazo Quispe

BREIT (Brescia Institute of Technology) · Aporta — Grupo Breca

Programa SDS (Statistics and Data Science, MITx) · BREIT (Brescia Institute of Technology), iniciativa de Aporta —Grupo Breca—
en alianza con MIT IDSS.

Basado en MIT 14.310x (CC BY-NC-SA 4.0).

✉ clazoq@uni.pe · [in linkedin.com/in/cristian-lazo-quispe](https://www.linkedin.com/in/cristian-lazo-quispe) · github.com/CristianLazoQuispe

¡Arrancamos con un Kahoot! (repaso Clases 8, 9 y 10)

Únete ahora

Entra a **kahoot.it** con el **PIN** en pantalla. Son **30 preguntas** rápidas de repaso: causalidad y experimentos (Clase 8), modelo lineal y OLS (Clase 9), y regresión en la práctica y OVB (Clase 10).

Reglas del juego

- Responde rápido: la velocidad da más puntos.
- Cuidado con las **trampas** (el error clásico).
- Cada pregunta trae su imagen y, al revelar, la explicamos paso a paso.



¿Qué veremos hoy?

- ① Variables de control (covariables)
- ② Formas funcionales: logaritmos
- ③ Polinomios e interacciones
- ④ Sesgo de variable omitida (OVB)
- ⑤ Efectos fijos (fixed effects)
- ⑥ Errores estándar en la práctica
- ⑦ Regresión discontinua (RDD)
- ⑧ Regresión en la práctica en R
- ⑨ Manos a la obra

Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVB)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra

¿Qué es “controlar” una variable? (y qué es *ceteris paribus*)

“Controlar” = comparar peras con peras

Agregar una variable de **control** W al modelo sirve para comparar personas que son **iguales en W** , y así no mezclar el efecto de W con el de la variable que de verdad nos importa, X .

Ejemplo: efecto de la educación sobre el salario

Los más educados suelen tener también más **experiencia**. Si comparamos sin cuidado, confundimos “lo que aporta estudiar” con “lo que aporta la experiencia”. Al *controlar* por experiencia comparamos personas con la **misma experiencia**: así aparece el efecto *limpio* de la educación.

“Ceteris paribus” en cristiano = “todo lo demás igual”

Es una frase en latín que significa “**manteniendo lo demás constante**”. Que $\hat{\beta}_1$ sea el efecto de X *ceteris paribus* quiere decir: *cuánto cambia Y si subo X en 1 y **dejo fijas** las demás variables*. En $Y = \beta_0 + \beta_1 X + \gamma W + \varepsilon$, la W es justamente esa variable de control (la que “dejamos fija”).

Demo: un buen control *cambia la conclusión* (mira el antes/después)


La pregunta

¿El **programa social** sube el **gasto en salud**? Si comparamos *crudo* (izquierda), los del programa gastan *menos*. ¿El programa hace daño?

El truco: controlar por ingreso

Los del programa son **más pobres** de entrada, y los más pobres gastan menos en salud: el **ingreso** es el confusor. Al comparar *a igual ingreso* (derecha), dentro de cada grupo el programa gasta **más**. ¡El signo se dio vuelta!

Ojo: controlar por “tiene seguro” (que el programa otorga) sería un *bad control* —es una *consecuencia* del



Izquierda (crudo): el programa “parece” gastar menos. Derecha (a igual ingreso): gasta más en cada grupo.

Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVB)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra

¿Qué es un logaritmo aquí? Convierte “soles” en “por ciento”

La idea, sin fórmulas

A veces no nos importan los *soles* sino el *porcentaje*. Subir de 1000 a 1100 y de 5000 a 5500 son saltos **distintos en soles** (+100 vs +500), pero el **mismo +10 por ciento**.

El truco del logaritmo

Si medimos el salario **en logaritmo**, ese +10 por ciento es **el mismo salto** en los dos casos (mira la derecha). Por eso, cuando una variable entra en log, su cambio se lee en **por ciento**, no en unidades.

Regla útil: un cambio en $\ln Y \approx$ el cambio *porcentual* de Y .

Ideal para salarios, precios, población... (positivos y muy asimétricos).

+10% = +100



1000

+10% = +500



5000

en SOLES: el salto CRECE

+0.095



+0.095



el MISMO salto

en LOG: el salto es IGUAL (= %)

En soles el salto crece; en logaritmo, el mismo porcentaje es siempre el mismo salto.

Semi-elasticidad: cuando Y está en logaritmo

Qué es, en una frase

Si el modelo es $\ln Y = \beta_0 + \beta_1 X$ (solo Y en log), el coeficiente β_1 es una **semi-elasticidad (semi-elasticity)**: dice en qué por ciento cambia Y cuando X sube en 1.

Paso a paso, con números

Regresión $\widehat{\ln(\text{salario})} = 6.2 + 0.09 \cdot \text{educación}$.

- ps El coeficiente es 0.09, y Y está en log $\Rightarrow$ se lee en por ciento.
- ps Multiplica por 100: $100 \times 0.09 = 9$.
- ps **Lectura:** cada año más de educación se asocia con $\approx +9$ por ciento de salario (no “+0.09 soles”).

Para recordar

“log-lin” (Y en log, X en nivel) $\Rightarrow$ el coeficiente, $\times 100$, es el **por ciento** que cambia Y por cada unidad más de X .

Elasticidad: cuando X e Y están en logaritmo (log-log)

Qué es, en una frase


Si *ambos* están en log ($\ln Y = \beta_0 + \beta_1 \ln X$), β_1 es la **elasticidad (elasticity)**: en qué por ciento cambia Y por cada 1 por ciento que cambia X .
Un número sin unidades, muy usado en economía.

Paso a paso

Demanda: $\ln(\widehat{\text{cantidad}}) = 8 - 1.3 \ln(\text{precio})$.

- OS La elasticidad es -1.3 .
- OS El precio sube 10 por ciento.
- OS Multiplica: $-1.3 \times 10 = -13$.
- OS **Lectura:** la cantidad cae ≈ 13 por ciento.

Como $|-1.3| > 1$, la demanda es *elástica* (reacciona fuerte al precio).



La elasticidad traduce "1 por ciento de X " en " β_1 por ciento de Y ".

Resumen: las tres combinaciones con logaritmos

Ya con la intuición, la tabla de referencia

Cómo entra	Modelo	Lectura del coeficiente β_1
log-lin (Y en log)	$\ln Y = \beta_0 + \beta_1 X$	+1 en $X \Rightarrow \approx 100\beta_1$ por ciento en Y (semi-elasticidad)
lin-log (X en log)	$Y = \beta_0 + \beta_1 \ln X$	+1 por ciento en $X \Rightarrow \approx \beta_1/100$ en Y (unidades)
log-log (ambos)	$\ln Y = \beta_0 + \beta_1 \ln X$	+1 por ciento en $X \Rightarrow \approx \beta_1$ por ciento en Y (elasticidad)

Cómo recordarlo (truco de un vistazo)

Cuenta cuántos lados están en **log**: cada lado en log se lee en **por ciento**. Y en log $\Rightarrow Y$ en por ciento; X en log $\Rightarrow X$ en por ciento; los dos $\Rightarrow$ elasticidad pura.

Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones**
- 4 Sesgo de variable omitida (OVB)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra

¿Por qué agregar X^2 ? El efecto deja de ser constante

La idea, en palabras

En una recta, “una unidad más de X ” siempre suma lo mismo. Pero muchas cosas **cambian de ritmo**: la experiencia sube el salario mucho al inicio y poco después. Para captarlo, agregamos X al cuadrado: $Y = \beta_0 + \beta_1 X + \beta_2 X^2$ (¡sigue siendo OLS!).

Qué significa cada pieza

- El efecto de una unidad más de X ya no es fijo: es $\beta_1 + 2\beta_2 X$ (depende de cuánto X ya tienes).
- Si $\beta_2 < 0$, la curva **sube y luego baja** (una loma).
- El punto más alto, donde deja de crecer, es el **punto de retorno** $X^* = -\beta_1/(2\beta_2)$.

Cómo leer el signo de β_2

$\beta_2 < 0 \Rightarrow$ loma (sube y baja); $\beta_2 > 0 \Rightarrow$ valle (baja y sube). Lo verás con números en el demo siguiente.

Interacción: el efecto de X *depende* de otra variable


La idea, en palabras

A veces el efecto de X no es el mismo para todos. Ejemplo: el retorno de la **educación** podría ser distinto para hombres y mujeres. Eso se modela con una **interacción (interaction)**: el producto $X \cdot W$.

Qué significa

En $Y = \beta_0 + \beta_1 X + \beta_2 W + \beta_3 (X \cdot W)$, el efecto de X es $\beta_1 + \beta_3 W$: *cambia según W* . Si W es una dummy (0/1), hay **dos pendientes**: β_1 (grupo $W = 0$) y $\beta_1 + \beta_3$ (grupo $W = 1$).

(El DiD de la Clase 9 era justo una interacción tratado $\times$ post.)



Distinta pendiente por grupo: eso es una interacción.

Demo: perfil de experiencia con punto de retorno


Problema

$\ln(\widehat{\text{salario}}) = \dots + 0.04 \text{ exper} - 0.0008 \text{ exper}^2$. Se pide: ¿a cuántos años de experiencia el salario deja de crecer?

Solución

$$X^* = -\frac{\beta_1}{2\beta_2} = -\frac{0.04}{2(-0.0008)} = \frac{0.04}{0.0016} = 25 \text{ años.}$$

Como $\beta_2 < 0$, sube hasta ~ 25 años de experiencia y luego se aplana/baja (rendimientos decrecientes). Una recta no podría capturar esta forma.



Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVB)**
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra

¿Qué es el sesgo de variable omitida (OVb)?

La idea, en una frase

Si dejas fuera del modelo una variable que *importa*, el coeficiente que sí estimas sale **contaminado**: se lleva parte del efecto de la que faltó. Eso es el **sesgo de variable omitida (omitted variable bias)**.

De dónde sale la fórmula (paso a paso)

Modelo verdadero: $Y = \beta_0 + \beta_1 X + \beta_2 W + \varepsilon$. Si corres la “corta” (sin W):

$$\mathbb{E}[\tilde{\beta}_1] = \underbrace{\beta_1}_{\text{lo verdadero}} + \underbrace{\beta_2 \cdot \delta}_{\text{el sesgo}}.$$

- β_2 = cuánto afecta la *omitida* W al resultado Y .
- δ = cuánto se *relacionan* W y X (la pendiente de W sobre X).
- El sesgo es su **producto**: $\beta_2 \cdot \delta$.

Hacen falta las DOS cosas

No hay sesgo si $\beta_2 = 0$ (la omitida no afecta a Y) o si $\delta = 0$ (no se relaciona con X). Por eso un sorteo (RCT) salva a OLS: hace $\delta = 0$ para *toda* omitida.

Demo: la “habilidad” omitida sobrestima el retorno de la educación


Problema

Salario vs educación. Corta (solo educación): coef = 302.
Larga (+ habilidad, normalmente no observada): coef = 181. Con $\text{Corr}(\text{educ}, \text{habil}) = 0.83$, $\delta = 0.366$, $\beta_2 = 331$. **Se pide:** verificar el sesgo con la fórmula.

Solución

$$\beta_2 \delta = 331 \times 0.366 = 121 = 302 - 181.$$

$\beta_2 > 0$ y $\delta > 0 \Rightarrow$ sesgo **hacia arriba**: sin controlar la habilidad *sobrestimamos* el retorno de la educación en 121 soles/año. Al controlarla, el efecto “limpio” baja a 181.



La tabla de signos del sesgo

¿Hacia arriba (sobrestima) o hacia abajo (subestima)?

	$\text{Corr}(X, W) > 0 \ (\delta > 0)$	$\text{Corr}(X, W) < 0 \ (\delta < 0)$
$\beta_2 > 0$ (omitida sube Y)	hacia arriba (+)	hacia abajo (-)
$\beta_2 < 0$ (omitida baja Y)	hacia abajo (-)	hacia arriba (+)

Ejemplo peligroso: policías y crimen

X = policías, Y = crimen; omitimos W = tamaño de la ciudad ($\beta_2 > 0$: ciudades grandes tienen más crimen; $\delta > 0$: y más policías). Sesgo hacia arriba $\Rightarrow$ ¡el coeficiente puede salir **positivo**! Parecería que “más policías causan más crimen”: puro OVB.

OVB = violación de la exogeneidad

Es el supuesto de la Clase 9 que falla: la omitida en el error hace $\text{Cov}(X, \varepsilon) \neq 0$ y $\hat{\beta}_1$ mide *asociación*, no *causa*.

Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVb)
- 5 Efectos fijos (fixed effects)**
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra

Efectos fijos: una “caja” por grupo que absorbe lo suyo

La idea, en palabras

Cuando los datos vienen **agrupados** (alumnos por escuela, personas seguidas en el tiempo, distritos), cada grupo tiene su propia “personalidad” que no medimos: la gestión de la escuela, la cultura del distrito. . . Los **efectos fijos** (**fixed effects**) le dan a cada grupo su propio intercepto —*una caja aparte*— para absorber todo eso. En R: + `factor(grupo)`.

Por qué esto combate el sesgo

Con su caja, comparamos **dentro** del mismo grupo (*within*): a la escuela consigo misma, no una escuela contra otra. Así, cualquier confusor que sea *constante dentro del grupo* (aunque no lo midamos) queda absorbido y deja de sesgar. Es OVb resuelto sin medir la omitida.

Su límite (para no exagerar)

Solo controla lo que **no cambia** dentro del grupo. Algo que varíe dentro (y sea confusor) sigue sesgando.


Demo: la paradoja de Simpson (pooled vs within)

Problema

6 distritos; X = gasto por alumno, Y = rendimiento.
Pooled: pendiente -0.38 . Con `+ factor(distrito)`:
 $+1.35$. **Se pide**: ¿a cuál creer y por qué difieren?

Solución

La de **efectos fijos** ($+1.35$): usa la variación *within*. Los distritos con mayor rendimiento de base gastan *menos* por alumno (un confusor de entidad), y eso arrastra la *pooled* a pendiente *negativa* (Simpson). El distrito era la variable omitida; los efectos fijos la controlan.



Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVb)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica**
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra

Errores estándar: ¿qué son y qué los rompe?

¿Qué es un error estándar?

Mide **cuán preciso** es un coeficiente: cuánto bailarían si repitiéramos el muestreo. Con él salen las pruebas t , los p -valores y los intervalos de confianza (Clase 9). Si el error estándar está mal, esas conclusiones también.


Qué lo rompe: heterocedasticidad

Heterocedasticidad (heteroskedasticity) = la varianza del error *no* es constante (la nube "abre como un embudo"). *No* sesga los coeficientes $\hat{\beta}$, pero *sí* arruina la fórmula clásica del error estándar.

La solución

Usar **errores estándar robustos** (tipo White, HC): no asumen varianza constante. Con datos en grupos, **agrupados (clustered)**. En R: `sandwich::vcovHC / vcovCL`.

heterocedasticidad ("embudo")



La dispersión crece con X : los SE clásicos mienten; usa SE robustos.

Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVb)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)**
- 8 Regresión en la práctica en R
- 9 Manos a la obra

RDD: cuando una “línea de corte” nos regala un experimento

La idea, en palabras (glosando cada término)

A veces un beneficio se da según un **número que decide** —la *running variable* a —: beca si sacas al menos 60; jubilación a los 65; ganar una elección con más del 50 por ciento. La línea de corte es el **umbral** a_0 . La **regresión discontinua (RDD)** compara a los que quedaron *justo encima* con los de *justo debajo*.

El truco y la fórmula

Alguien con 59.9 y alguien con 60.1 son **casi gemelos**, salvo por la beca. Si el resultado *salta* justo en el corte, ese salto solo puede ser la beca. Se estima con una recta a cada lado:

$Y_i = \beta_0 + \tau D_i + \gamma(a_i - a_0) + \varepsilon_i$ (con $D = 1$ si cruzaste el umbral). El **salto** τ es el efecto causal.

El supuesto clave (y el matiz)

Sin el programa, el resultado habría seguido *sin saltos* al cruzar el umbral (continuidad). Y ojo: el efecto vale **cerca del corte**, no para todos.

Demo: el salto de una beca por puntaje


Problema

Beca si el puntaje ≥ 60 . En una ventana del corte se estima $\hat{Y} = 41 + 9D + 0.5(a - 60)$. **Se pide:** predecir Y justo debajo y justo encima del corte, y dar el efecto.

Solución

En $a = 60$: sin beca $\hat{Y} = 41$; con beca $\hat{Y} = 41 + 9 = 50$.

El **salto** $\hat{\tau} = 9$ es el efecto causal *local*: vale para quienes están *cerca* de 60 (no para uno con 30 o 90 puntos).



Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVb)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R**
- 9 Manos a la obra

Del concepto al código: lm con log, cuadrático y factor

En R (todo con la misma lm de la Clase 9)

```
# log-lin: coef de educacion = semi-elasticidad (~ por ciento)
m_log <- lm(log(salario) ~ educacion + experiencia, data = d)

# cuadratico: I(exper^2) protege el "^" dentro de la formula
m_quad <- lm(log(salario) ~ educacion + experiencia + I(experiencia^2), data = d)

# interaccion: el retorno de educacion depende del sexo
m_int <- lm(log(salario) ~ educacion * factor(sexo), data = d)

# efectos fijos: una dummy por distrito
m_fe <- lm(rendimiento ~ gasto + factor(distrito), data = panel)
```

Lectura

I() para potencias, * para interacción (incluye efectos principales), factor() para dummies/efectos fijos (omite una base automáticamente). Para SE robustos: `lmtest::coeftest(m, vcov = sandwich::vcovHC(m, "HC1"))`.


Práctica 1 en R: sesgo de variable omitida (OVB)

Problema — resuélvelo *desde cero* en R

Archivo `ovb.csv`: columnas `salario`, `educacion`, `habilidad` (casi nunca se observa; aquí sí, para ver el sesgo).

- 1 Regresión *corta*: `salario ~ educacion`. Anota el coef.
- 2 Regresión *larga*: agrega `habilidad`. Anota el coef de educación.
- 3 Calcula δ = pendiente de `habilidad ~ educacion`.
- 4 Comprueba que $(\text{coef corto} - \text{coef largo}) = \beta_2 \delta$. ¿Arriba o abajo?

Desde cero. Si te trabas: `practica_R/p1_ovb.R` (con vacíos). Solución al final: `p1_ovb_sol.R`.



Los datos: `salario` vs `educación` (color = `habilidad`).


Práctica 2 en R: forma funcional (log y cuadrático)

Problema — resuélvelo *desde cero* en R

Archivo `mincer.csv`: columnas `salario`, `educacion`, `experiencia`.

- 1 Ajusta $\ln(\text{salario})$ sobre `educacion`, `experiencia` y $I(\text{experiencia}^2)$.
- 2 Interpreta el coef de `educacion` como semi-elasticidad (en por ciento).
- 3 Calcula el punto de retorno de la experiencia, $-\beta_1/(2\beta_2)$.
- 4 ¿Qué le pasa al salario *después* de ese punto?

Desde cero. Si te trabas: `practica_R/p2_formas_funcionales.R`. Solución al final: `p2_formas_funcionales_sol.R`.



Los datos: `salario` vs `experiencia`.


Práctica 3 en R: efectos fijos (pooled vs within)

Problema — resuélvelo desde cero en R

Archivo `panel.csv`: columnas `distrito`, `gasto`, `rendimiento` (6 distritos).

- 1 Regresión *pooled*: $\text{rendimiento} \sim \text{gasto}$. Anota la pendiente.
- 2 Agrega `factor(distrito)` (efectos fijos). Anota la nueva pendiente.
- 3 ¿Cambia el *signo*? Explica por qué (¿qué variable omitida hay?).

Desde cero. Si te trabas: `practica_R/p3_efectos_fijos.R`. Solución al final: `p3_efectos_fijos_sol.R`.



Los datos por distrito (cada color) + recta global.


Práctica 4 en R: regresión discontinua (RDD)

Problema — resuélvelo *desde cero* en R

Archivo `rdd.csv`: columnas `puntaje`, `beca`, `resultado` (beca si $\text{puntaje} \geq 60$).

- 1 Ventana $|\text{puntaje} - 60| \leq 15$ y centra: $x = \text{puntaje} - 60$.
- 2 Ajusta $\text{resultado} \sim \text{beca} + x + \text{beca}:x$.
- 3 El coef de beca es el *salto*. Interpretalo (¿para quiénes vale?).

Desde cero. Si te trabas: `practica_R/p4_rdd.R`. Solución al final: `p4_rdd_sol.R`.



Los datos: resultado vs puntaje (corte en 60).

Checklist: ¿puedo creerle a este coeficiente?

Pregunta	Riesgo si la ignoras	Remedio
¿Falta un confusor?	OVb: sesgo $\beta_2\delta$ (asociación $\neq$ causa)	controlarlo, efectos fijos, o diseño (RCT/RDD)
¿Controlé algo posterior a X?	<i>bad control</i> : borra el efecto o lo sesga	controla solo lo predeterminado
¿La relación es curva?	forma funcional mal elegida	log, cuadrático, interacción, tramos
¿Varianza no constante?	SE clásicos mal $\Rightarrow p$ e IC falsos	SE robustos / clustered

La pregunta que resume la clase

Ante cualquier coeficiente de datos observacionales: “¿qué me falta controlar, y hacia dónde me sesgaría?” El signo del OVb ($\beta_2 \cdot \delta$) te deja responder aunque no tengas la variable omitida.

Contenido

- 1 Variables de control (covariables)
- 2 Formas funcionales: logaritmos
- 3 Polinomios e interacciones
- 4 Sesgo de variable omitida (OVb)
- 5 Efectos fijos (fixed effects)
- 6 Errores estándar en la práctica
- 7 Regresión discontinua (RDD)
- 8 Regresión en la práctica en R
- 9 Manos a la obra**

¿Y ahora?

- **Controles:** limpian el coeficiente de interés (*ceteris paribus*). Controla lo *predeterminado*; evita los *bad controls*.
- **Formas funcionales:** sigue siendo OLS. Log $\Rightarrow$ por ciento (semi-elasticidad / elasticidad); cuadrático $\Rightarrow$ efecto no constante, punto de retorno $X^* = -\beta_1/(2\beta_2)$; interacción $\Rightarrow$ efecto que depende de otra variable.
- **OVb (lo central):** omitir una relevante sesga: $\mathbb{E}[\tilde{\beta}_1] = \beta_1 + \beta_2\delta$. Hace falta que la omitida afecte a Y y correlacione con X ; el signo del sesgo = signo de $\beta_2 \cdot \delta$.
- **Efectos fijos:** `factor()` absorbe confusores invariantes de la entidad (variación *within*). Cuidado con la paradoja de Simpson.
- **Errores estándar:** la heterocedasticidad no sesga $\hat{\beta}$ pero sí sus SE $\Rightarrow$ robustos / clustered.
- **RDD:** el salto τ en el umbral identifica un efecto causal *local* (bajo continuidad). La Clase 11 seguirá con *variables instrumentales*.

¡A practicar!