

Información cualitativa y modelos no lineales

Gabriel V. Montes-Rojas

Variable binaria o dummy

Un factor cualitativo (vs. uno cuantitativo) es un factor cuya información tiene que ser codificada en forma numérica.

Definición: Una variable que toma valores 0 y 1 se define como VARIABLE DUMMY. La categoría que tiene valor 0 se llama CATEGORIA BASE.

- Ej. *Sexo. female* es una variable binaria que tiene 1 si sexo femenino, 0 si sexo masculino. No importa cual es 1 o 0, lo importante es que distinga.
- Ej. *Estado civil*. Para categorizar estado civil se puede necesitar más de dos valores. 0 soltera/o, 1 casada/o, 2 divorciada/o, 3 viuda/o.
- Ej. *Nacionalidad*. Para categorizar la nacionalidad se necesita una variable que tome más de dos valores. 0 Argentina, 1 Uruguay, 2 Brasil, 3 Paraguay, 4 Chile, 5 otros.

En los dos últimos casos más de una dummy. Como regla, si hay Q categorías necesitamos $Q - 1$ dummies. (ver más abajo)

Variable binaria o dummy

Consideremos el modelo:

$$wage = \beta_0 + \delta_0 female + \beta_1 educ + u$$

En este caso *female* no es una variable continua, pero δ_0 tiene la misma interpretación que otros coeficientes. En particular, cuál es el cambio en *wage* cuando la variable *female* se incrementa *ceteris paribus* una unidad. En el caso particular de las dummies se obtiene:


$$\delta_0 = E(wage | female = 1, educ) - E(wage | female = 0, educ)$$

Notar que este efecto es independiente del nivel de *educ*, es decir, se mantiene para todo nivel de educación.

Discriminación por género

$$\text{wage} = \beta_0 + \delta_0 \text{female} + \beta_1 \text{educ} + u, \quad \delta_0 < 0$$

wage



Variable binaria o dummy

Ejercicio: Probar que el modelo

$$wage = \beta_0 + \delta_0 female + \beta_1 educ + u$$

y

$$wage = \beta'_0 + \alpha_0 male + \beta'_1 educ + e$$

donde $male = 1 - female$, cumplen las relaciones $\beta'_0 + \alpha_0 = \beta_0$, $\beta_0 + \delta_0 = \beta'_0$, $\beta_1 = \beta'_1$.

Esto significa que la selección de la categoría base no tiene ningún efecto sobre los resultados. Sólo para el intercepto.

Pregunta: ¿Cuál es el problema con este modelo?

$$wage = \beta_0 + \delta_0 female + \alpha_0 male + \beta_1 educ + u$$

Efectos individuales y compuestos: interacciones

Las variables dummy pueden ser combinadas para efectos compuestos.

- Supongamos que d_1 and d_2 son dos variables dummy que reflejan dos categorías binarias diferentes (ejemplo género y casado). Definamos la interacción como $d_1 \times d_2$. Consideremos el modelo

$$y = \alpha + \gamma d_1 + \delta d_2 + \phi(d_1 \times d_2) + u$$

- ¿Cómo se interpretan $\alpha, \gamma, \delta, \phi$? Notar que $E[y|d_1 = 0, d_2 = 0] = \alpha$,
 $E[y|d_1 = 1, d_2 = 0] = \alpha + \gamma$, $E[y|d_1 = 0, d_2 = 1] = \alpha + \delta$,
 $E[y|d_1 = 1, d_2 = 1] = \alpha + \gamma + \delta + \phi$.
- Notar que ϕ se puede interpretar como estimador de diferencias en diferencias (d-en-d):

$$\phi = \{E[y|d_1 = 1, d_2 = 1] - E[y|d_1 = 0, d_2 = 1]\} - \{E[y|d_1 = 1, d_2 = 0] - E[y|d_1 = 0, d_2 = 0]\}.$$

Estimador de diferencia en diferencias (d-en-d)

Esta metodología es muy común para establecer relaciones causales. El ejemplo típico es evaluar un cambio de política.

Tratamiento: Lo que queremos evaluar.

Grupo de control: Grupo de individuos que no tienen el tratamiento.

Grupo de tratamiento: Grupo de individuos que se ve afectado por el tratamiento.

$$y_{it} = \beta_0 + \beta_1 TREAT_i + \delta_0 AFTER_t + \delta_1 TREAT_i \times AFTER_t + u_{it}$$

- Consideremos una muestra de $i = 1, \dots, N$ individuos donde cada individuo se lo ve en periodos $t = 1, \dots, T$.
- $TREAT_i$ es una dummy que indica si el individuo i está en el grupo de tratamiento (o no). Tratamiento vs. control.
- $AFTER_t$ es una dummy que indica si el periodo t ya tiene el tratamiento aplicado (o no). Antes vs. después.

	Antes	Después	Después-Antes
Control	β_0	$\beta_0 + \delta_0$	δ_0
Tratamiento	$\beta_0 + \beta_1$	$\beta_0 + \delta_0 + \beta_1 + \delta_1$	$\delta_0 + \delta_1$
Tratamiento-Control	β_1	$\beta_1 + \delta_1$	δ_1

δ_1 es el estimador **d-en-d**.

Efecto de la ubicación de un incinerador de basura en los precios de las casas

- Ejemplo tomado de Kiel y McClain (1995) sobre el efecto de un incinerador de basura en los precios de las casas en North Andover, Massachusetts, para los años 1978 y 1981.
- La base de datos se puede acceder en:
use <http://fmwww.bc.edu/ec-p/data/wooldridge/KIELMC>, clear
- Las variables son
rprice: precio de las casas en términos reales.
nearinc: variable dummy para cercanía al incinerador.
- Los rumores de que el incinerador se iba a construir empezaron **después** de 1978, su construcción empezó en 1981, y empezó a operar en 1985.
- Un estimador simple usaría sólo datos de 1981:

$$\begin{aligned}
 rprice &= \gamma_0 + \gamma_1 \text{nearinc} + u \\
 \widehat{rprice} &= 101308 - 30688 \text{nearinc} \\
 &\quad (3093) \quad (5828)
 \end{aligned}$$

- ¿Es correcto afirmar que vivir cerca del incinerador causa que los precios disminuyan 30 mil dólares?

Efecto de la ubicación de un incinerador de basura en los precios de las casas

- El estimador previo no implica que el incinerador **cause** una disminución del precio de las casas. De hecho la misma regresión para 1978 da:

$$\widehat{rprice} = \begin{matrix} 82517 & -18824 \text{ nearinc} \\ (2654) & (4744) \end{matrix}$$

- ¿Por qué? Porque el incinerador se construyó donde el precio de las casas ya era bajo.
- Estimador d-en-d:**

$$\hat{\delta}_1 = (\widehat{rprice}_{81,nr} - \widehat{rprice}_{81,fr}) - (\widehat{rprice}_{78,nr} - \widehat{rprice}_{78,fr})$$

donde *nr* significa cerca del incinerador y *fr* sin (free) incinerador.

- Usando el modelo general:

$$\begin{aligned} \widehat{rprice} &= \beta_0 + \beta_1 \text{ nearinc} + \delta_0 \text{ y81} + \delta_1 \text{ nearinc*y81} + u \\ \widehat{rprice} &= \begin{matrix} 82517 & - & 18824 \text{ nearinc} & + & 18790 \text{ y81} & - & 11864 \\ (2727) & & (4875) & & (4050) & & (7466) \end{matrix} \end{aligned}$$

Card y Krueger (1994)

Estudio de cambios en el salario mínimo sobre empleo

David Card y Alan B. Krueger (1994), "Minimum Wages and Employment: A Case Study of the Fast-Food Industry in New Jersey," American Economic Review 84(4), 772-793.

Ver una discusión avanzada en

<http://econ.lse.ac.uk/staff/spischke/ec524/evaluation3.pdf>

Card y Krueger (1994)

- Datos de EEUU. Hay salario mínimo a nivel federal y a nivel de cada estado. Aplica el mayor.
- En noviembre de 1989 se aprobó una ley para incrementar el salario mínimo a nivel federal de \$3.35 por hora a \$3.80 (en abril 1990), \$4.25 por hora (en abril 1991), y al principio de 1990 se decidió incrementarlo a \$5.05 por hora (en abril de 1992).
- Sin embargo había diferencias a nivel estadual en cuanto al salario mínimo vigente (Pennsylvania y New Jersey)
- ¿Qué tipo de firmas iban a ser más afectadas? Aquellas que usaban trabajo no calificado (*unskilled labor*).
- Entonces estudiaron: Burger King, KFC, Wendy's, Roy Rogers
 - ① son los empleadores líderes para trabajadores de bajo salario
 - ② cumplen con la regulación de salarios mínimos
 - ③ los trabajos son relativamente homogéneos
 - ④ es relativamente fácil construir una muestra de franquicias de esas cadenas

Card y Krueger (1994)

- **Tratamiento:** incremento del salario mínimo efectivo
- **Grupo de control:** restaurantes en Pennsylvania
- **Grupo de tratamiento:** restaurantes en New Jersey
- Mapa of New Jersey
- **Antes:** Wave 1, February 15 - March 4, 1992
- **Después:** Wave 2, November 5 - December 31, 1992
- Efecto sobre el empleo: Los autores no encuentran ningún efecto significativo sobre el empleo.
- Impacto sobre otros beneficios no salariales: Podría ser que no hay efecto sobre el empleo porque los restaurantes reducen otros beneficios, o reducen training y las promociones. No hay evidencia.
- Impacto sobre precios: En un modelo competitivo incrementar el salario implica incrementar los precios. Tampoco hay evidencia de esto.

Efectos individuales y compuestos: interacciones

- Supongamos que queremos contrastar si una variable continua, X , tiene distintas pendientes en distintos grupos, dados por la variable dummy D .


$$y = \alpha + \gamma d + \beta x + \delta(d \times x) + u$$

- $(d \times x)$ es la interacción.
- Este modelo permite dos pendientes de acuerdo a la clasificación de d , β y $\beta + \delta$.
- Notar que $E[y|d = 0] = \alpha + \beta E[x|d = 0]$ y que $E[y|d = 1] = \alpha + \gamma + (\beta + \delta)E[x|d = 1]$. También, $E[y|d = 0, x] = \alpha + \beta x$ y $E[y|d = 1, x] = \alpha + \gamma + (\beta + \delta)x$. ¿Cuál es la diferencia entre estos términos?

Discriminación por género $wage =$

$$\beta_0 + \delta_0 female + \beta_1 educ + \delta_1 female \times educ + u, \quad \delta_0 < 0, \delta_1 > 0$$

$wage$



STATA: dummies

Una variable dummy se implementa como cualquier otra variable independiente. Supongamos que queremos ver el efecto de la variable z , que tiene categorías múltiples. $Z \in 0, 1, 2, \dots, J$

- Para ver la distribución de z en la muestra:
`tab z`
- Para ver los valores de y para distintos z en la muestra:
`tab z, summ(y)`
- Para ver un histograma de z :
`hist z`
- En forma general, si tenemos más de dos categorías, ej. Q , necesitamos $Q - 1$. Esto se implementa automáticamente en STATA
`xi: reg y i.z x1 x2 x3`
Nota: Por default, STATA omite el valor de z del primer grupo. Pero esto se puede cambiar (por ej. $z=2$)
`char z[omit] 2`
- Más detalles:
<http://www.stata.com/help.cgi?xi>

Modelos cuadráticos

Consideremos el siguiente modelo:

$$wage = \beta_0 + \beta_1 exper + \beta_2 exper^2 + u$$

En este caso,

$$\frac{\partial E(wage|exper)}{\partial exper} = \beta_1 + 2\beta_2 exper$$

En palabras, el efecto de *exper* sobre *wage* no es lineal, y el efecto lineal (pendiente) depende de los valores de *exper*.

Logaritmos

Consideremos el siguiente modelo log-lineal:

$$\log wage = \beta_0 + \beta_1 educ + u$$

Resultado: $\frac{d \log wage}{d educ} = \frac{\frac{d wage}{wage}}{\frac{d educ}{educ}}$

En general funciona la siguiente aproximación: $\frac{d wage}{wage} \approx \frac{\Delta wage}{wage} \approx \% \text{ cambio en } wage$

β_1 : Es el cambio porcentual en *wage* ante un cambio de una unidad en *educ*.

$$\begin{array}{rcc}
 l wage = & .584^{***} + & .083^{***} educ \\
 & (.097) & (.0076) \\
 & < 0.000 > & < 0.000 > \\
 & [6.0] & [10.9]
 \end{array}$$

(error estándar); $< p - valor >$; $[t - valor]$; * significancia 10%; ** significancia 5%;
*** significancia 1%

Logaritmos

Sin embargo, la aproximación sólo funciona para pequeños cambios en la variable independiente. El cálculo exacto es

$$\% \hat{\Delta} y = 100[\exp(\hat{\beta}_1 \Delta x) - 1]$$

$$\exp(.083) - 1 = .087 \neq .083$$

Logaritmos

Ahora consideremos el modelo log-log:

$$\log wage = \beta_0 + \beta_1 \log educ + u$$

Pregunta: ¿Qué significa β_1 en este modelo?

Ejemplos

<http://fmwww.bc.edu/gstat/examples/wooldridge/wooldridge7.html>

STATA: modelos de variables no lineales

- Para implementar modelos cuadráticos se debe crear el cuadrado de la variable.

Por ejemplo,

```
gen exper2=exper*exper  
reg wage educ exper exper2
```

- Para implementar logaritmos se debe transformar la variable en log.

Por ejemplo,

```
gen lwage=ln(wage)  
reg lwage educ  
gen leduc=ln(educ)  
reg wage leduc  
reg lwage leduc
```

Cambio en las unidades de medida

Es muy importante saber cuales son la unidades de medida en X e Y para interpretar correctamente los parámetros estimados.

Ej.: Supongamos que educ se mide en meses, en vez de años como teníamos antes.
Definamos $educ_m = 12 * educ$

$$wage = \beta_0 + \beta_1 educ + u$$

$$wage = \gamma_0 + \gamma_1 educ_m + u$$

- ¿Cómo se comparan β y γ ?
- $\beta_1 = \frac{\Delta wage}{\Delta educ} = \frac{\Delta wage}{\Delta educ * \frac{12}{12}}$.
- $\beta_1 / 12 = \frac{\Delta wage}{\Delta educ * 12} = \frac{\Delta wage}{\Delta educ_m} = \gamma_1$.
- ¿Qué pasa con las constantes?

Cambio en las unidades de medida

Ej.: supongamos que *wage* se mide en centavos. Definamos $wagec = wage * 100$

$$wage = \beta_0 + \beta_1 educ + u$$

$$wagec = \gamma_0 + \gamma_1 educ + u$$

- ¿Cómo se comparan β y γ ?
- $wage * 100 = \beta_0 * 100 + \beta_1 educ * 100 = wagec = \gamma_0 + \gamma_1 * educ$ entonces $\beta_1 = \gamma_1 / 100$