

# Modelo lineal general (K variables)

## Interpretación y usos

Mariana Marchionni  
*marchionni.mariana@gmail.com*

Econometría I - FCE - UNLP  
*www.econometria1unlp.com*

# Temario de la clase

- 1 El modelo lineal general
- 2 Variables binarias
- 3 Variables no lineales e interacciones
- 4 Ejemplo empírico

# Vimos el modelo lineal simple bajo los supuestos clásicos

$$Y_i = \alpha + \beta X_i + \mu_i, \quad i = 1, \dots, n$$

- 1  $E[\mu_i] = 0, \quad i = 1, \dots, n.$
- 2  $V[\mu_i] = \sigma^2, \quad i = 1, \dots, n.$
- 3  $Cov[\mu_i, \mu_j] = 0, \quad i \neq j.$
- 4 Las  $X_i$  no son aleatorias y no son todas iguales

## El modelo lineal general (K variables)

Simplemente agregamos variables explicativas:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_K X_{Ki} + \mu_i, \quad i = 1, \dots, n$$

- Ahora los regresores son  $X_2, \dots, X_K$
- Desde ahora, por comodidad de notación, a la ordenada al origen del modelo la llamaremos  $\beta_1$ . Es como si hubiera una variable explicativa  $X_{1i} = 1$  para todas las observaciones.
- Mantendremos todos los supuestos clásicos salvo una pequeña modificación en la segunda parte del supuesto 4

## No multicolinealidad perfecta en el modelo lineal general

- **Requiere que no haya dependencia lineal entre las variables explicativas.**
- En otras palabras, que ninguna de las variables explicativas pueda expresarse como una combinación lineal de las demás.
  - No puede darse que existan constantes  $a_j$ , no todas iguales a cero, tales que  $X_k = \sum_{j \neq k} a_j X_j$   $k = 1, \dots, K$
- **No multicolinealidad perfecta  $\neq$  no correlación entre las variables explicativas**
  - puede haber correlación siempre que no sea perfecta
  - no alcanza con que la correlación no sea perfecta de a pares de variables
  - ninguna de las variables  $X_2, \dots, X_K$  puede ser una constante.  
¿Por qué?

## Interpretación de los parámetros del modelo lineal general

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_K X_{Ki} + \mu_i, \quad i = 1, \dots, n$$

- Con  $E(\mu_i) = 0$  y regresores no aleatorios tenemos que:

$$E(Y_i) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_K X_{Ki}$$

- El efecto marginal de  $X_k$  viene dado por:

$$\frac{\partial E(Y_i)}{\partial X_{ki}} = \beta_k \quad \forall i$$

# Interpretación de los parámetros del modelo lineal general

$$\frac{\partial E(Y_i)}{\partial X_{ki}} = \beta_k \quad \forall i$$

- $\beta_k$  mide el efecto sobre  $E(Y_i)$  de un cambio marginal de la  $k$ -ésima variable explicativa, **manteniendo constantes todas las demás** (derivada parcial)
- El significado de “*cambio marginal*” está atado a las unidades de medida de la variable explicativa (1 centavo, 1\$, 1 mil \$, 1 millón \$, etc.)

# Interpretación de los parámetros del modelo lineal general

- ¿Y si el cambio no es **marginal** sino **discreto**?
- ¿Cuál es el efecto sobre  $E(Y_i)$  cuando  $X_s$  cambia en  $\Delta X_s$ ?

$$\Delta E(Y_i) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_s (X_{si} + \Delta X_{si}) + \dots + \beta_K X_{Ki}$$

$$- [\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_s X_{si} + \dots + \beta_K X_{Ki}]$$

$$\Delta E(Y_i) = \beta_s \Delta X_{si}$$

- Vale la regla de 3. Notar que dejamos constantes todas las demás variables explicativas (*ceteris paribus*)



# Interpretación de los parámetros del modelo lineal general

- Podemos evaluar cambios discretos en variables de naturaleza continua
  - un aumento en el ingreso de los hogares de 50.000\$ a 80.000\$.
  - un cambio en el nivel educativo de primario completo a secundario completo que implica 6 (o 5) años más de educación.
- También hay variables que son discretas por naturaleza:
  - Variables de conteo (*count variables*):  
número de hijos por familia, número de veces que un estudiante repitió un año, número de visitas al médico, etc.
  - **Variables binarias o *dummy***

# Variables explicativas binarias

- ¿Cómo incorporamos al modelo **variables explicativas que son cualitativas**?
  - género
  - raza
  - sector productivo
  - región geográfica
- Primero nos concentramos en los **fenómenos binarios**: se tiene o no cierta característica
- En un fenómeno binario hay **sólo dos posibilidades y son excluyentes**.
  - una persona trabaja o no trabaja
  - un banco quebró o no quebró durante la crisis
  - un país firmó o no firmó cierto acuerdo internacional
  - una trabajadora doméstica “está en blanco” o no

- ¿Cómo incorporamos un fenómeno binario en el modelo?
- Vamos a crear una **variable artificial** que toma un valor cuando la característica de interés está presente y otro valor distinto cuando no lo está.
- Los valores son arbitrarios, pero es práctico elegir **1 y 0**
- Llamamos **variable binaria o *dummy*** a esa variable artificial
- **Ejemplo:** queremos incorporar una variable que indique el género del individuo. Definamos la variable dummy  $d_i = 1$  si el individuo  $i$  es hombre,  $d_i = 0$  si el individuo  $i$  es mujer.

obs.	sexo	d
1	mujer	0
2	hombre	1
...	...	...
n	hombre	1

Podríamos capturar la misma información definiendo la variable  $d$  al revés: que valga 1 para las mujeres y 0 para los hombres

obs.	sexo	d (opción 1)	d (opción 2)
1	mujer	0	1
2	hombre	1	0
...	...	...	...
n	hombre	1	0

- Esta arbitrariedad no modifica los resultados, sólo condiciona la manera de interpretarlos
- **Resulta útil que el nombre de la variable dummy sugiera cuál es la característica asociada con el valor 1.** En la primera opción la variable en vez de llamar  $d$  a la variable dummy, podríamos llamarla *hombre* ( $hombre_i = 1$  para los hombres y  $hombre_i = 0$  para las mujeres)
- **La característica asociada al valor 0 se conoce como categoría base.** En la opción 1, las mujeres son la categoría base (importante para la interpretación, ya veremos)

## Ejemplo: modelo de los determinantes del salario

$$W_i = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \mu_i$$

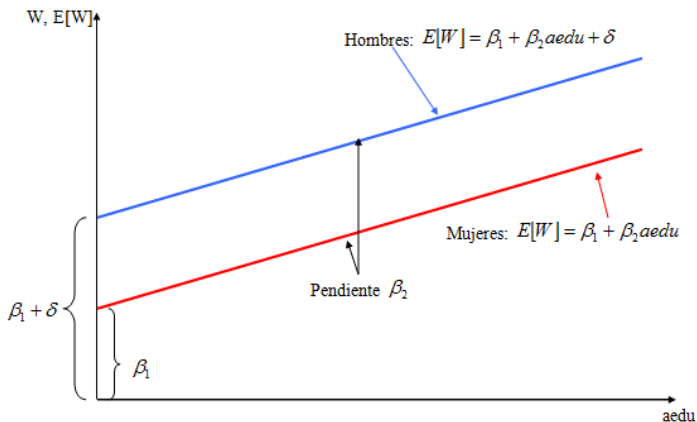
- Si  $E(\mu_i) = 0 \Rightarrow E(W_i) = \beta_1 + \beta_2 aedu_i + \delta hombre_i$
- Notar que hay dos regresiones:
  - Para los hombres:  $E[W_i | hombre_i = 1] = \beta_1 + \beta_2 aedu_i + \delta$
  - Para las mujeres:  $E[W_i | hombre_i = 0] = \beta_1 + \beta_2 aedu_i$

- Restando miembro a miembro:

$$\begin{aligned} E[W_i | hombre_i = 1] - E[W_i | hombre_i = 0] &= \\ \beta_1 + \beta_2 aedu_i + \delta \times 1 - (\beta_1 + \beta_2 aedu_i + \delta \times 0) &= \delta \end{aligned}$$

- Entonces  $\delta$  es la diferencia entre el salario esperado de un hombre y de una mujer que tienen la misma educación

$$E(W_i) = \beta_1 + \beta_2 aedu_i + \delta hombre_i \text{ con } \delta > 0$$



- La recta de regresión de los hombres es paralela a la de las mujeres (misma pendiente) pero tiene una ordenada al origen mayor.

- El fenómeno binario tiene 2 categorías (hombre o mujer), pero **alcanza con una sola variable dummy** para diferenciar entre ambas.
- Dada la información de la variable dummy *hombre*, la variable *mujer* no agrega nada, es **redundante**.

obs.	sexo	d (opción 1): <i>hombre</i>	d (opción 2): <i>mujer</i>
1	mujer	0	1
2	hombre	1	0
...	...	...	...
n	hombre	1	0

- Regla:** si hay 2 categorías incluimos sólo una *dummy*.
- ¿Qué pasa si incluimos las dos variables *dummy* en el modelo?  
**Trampa de la variable binaria**

- ¿Cuál de las 2 variables dummy incluir?
  - Opción 1:  $W_i = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \mu_i$
  - Opción 2:  $W_i = \beta_1 + \beta_2 aedu_i + \eta mujer_i + \mu_i$
- Puede mostrarse que **las 2 opciones son equivalentes** con  $\delta = -\eta$ , pero **la interpretación cambia** con la opción (¿cuál es la categoría base en cada caso?)
- Supongamos  $\delta = 5 (\Rightarrow \eta = -5)$ 
  - Interpretación basada en la Opción 1: el salario esperado de un hombre es **5\$ más alto que el de una mujer** (categoría base) con la misma educación
  - Interpretación basada en la Opción 2: el salario esperado de una mujer es **5\$ más bajo que el de un hombre** (categoría base) con la misma educación



## Variables dummy para categorías múltiples

- Supongamos que los salarios no solo dependen de la educación y del género, sino también de la región; supongamos que hay 3 regiones
- Generalizamos la regla: si hay **S** categorías incluimos **S-1** variables *dummy*
- Hay 3 regiones  $\Rightarrow$  necesitamos 2 dummies:
  - $región1_i \begin{cases} = 1 & \text{si el individuo pertenece a la región 1} \\ = 0 & \text{en caso contrario} \end{cases}$
  - $región2_i \begin{cases} = 1 & \text{si el individuo pertenece a la región 2} \\ = 0 & \text{en caso contrario} \end{cases}$
- La **categoría base u omitida** se da cuando  $región1_i = 0$  y  $región2_i = 0$ , y corresponde a la región 3

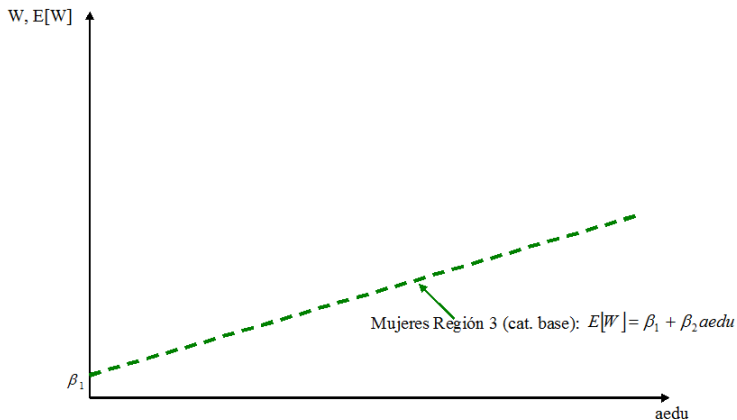
El modelo viene dado por:

$$W_i = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \lambda_1 región1_i + \lambda_2 región2_i + \mu_i$$

- Supongamos que los hombres ganan más que las mujeres (manteniendo las demás variables constantes)  $\Rightarrow \delta > 0$
- Además, supongamos que los trabajadores de la región 1 ganan más que los de la región 2, que a su vez ganan más que los de la región 3 ( $\lambda_1 > \lambda_2 > 0$ ) (dado todo lo demás...¿qué es todo lo demás?)

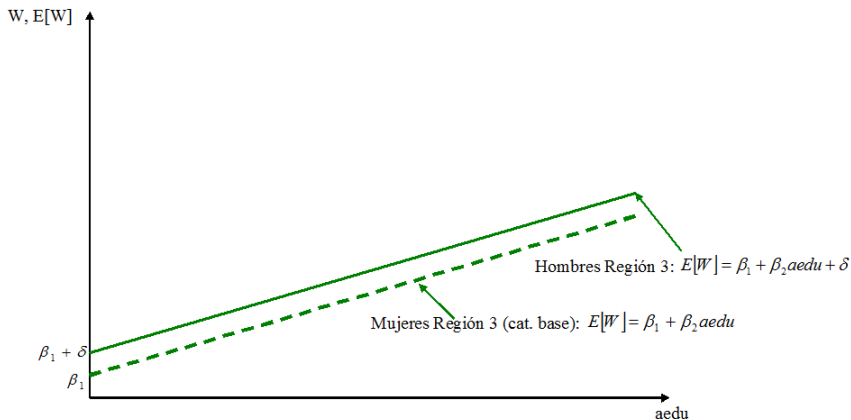
$$E[W_i] = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \lambda_1 región1_i + \lambda_2 región2_i$$

con  $\beta_1 > 0$ ,  $\beta_2 > 0$ ,  $\delta > 0$  y  $\lambda_1 > \lambda_2 > 0$



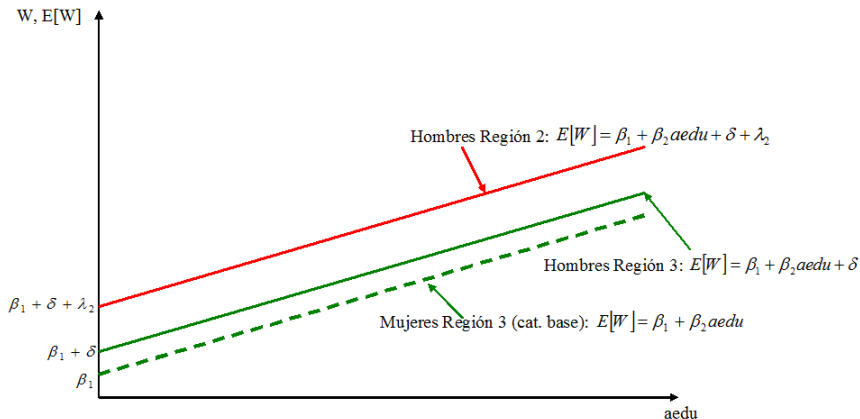
$$E[W_i] = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \lambda_1 región1_i + \lambda_2 región2_i$$

$$\text{con } \beta_1 > 0, \beta_2 > 0, \delta > 0 \text{ y } \lambda_1 > \lambda_2 > 0$$



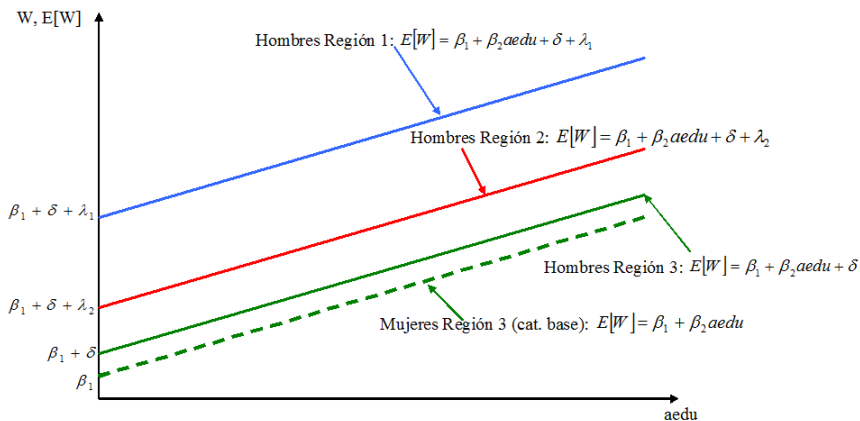
$$E[W_i] = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \lambda_1 región1_i + \lambda_2 región2_i$$

$$\text{con } \beta_1 > 0, \beta_2 > 0, \delta > 0 \text{ y } \lambda_1 > \lambda_2 > 0$$



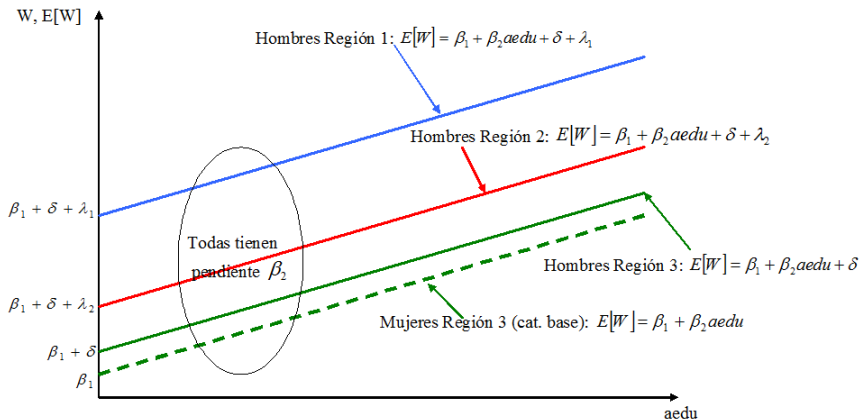
$$E[W_i] = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \lambda_1 región1_i + \lambda_2 región2_i$$

$$\text{con } \beta_1 > 0, \beta_2 > 0, \delta > 0 \text{ y } \lambda_1 > \lambda_2 > 0$$



$$E[W_i] = \beta_1 + \beta_2 aedu_i + \delta hombre_i + \lambda_1 región1_i + \lambda_2 región2_i$$

con  $\beta_1 > 0$ ,  $\beta_2 > 0$ ,  $\delta > 0$  y  $\lambda_1 > \lambda_2 > 0$



## Estimación e inferencia con variables explicativas binarias

- Todo igual que antes
- Lo único que cambia es la manera de interpretar los coeficientes



## El modelo lineal no es tan lineal

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_K X_{Ki} + \mu_i$$

Notemos que este modelo es **lineal** en las variables y en los parámetros:

- $Y$  es una función lineal de las variables  $X_2, X_3, \dots, X_K$   
⇒ Modelo lineal en las variables
- $Y$  es una función lineal de  $\beta_1, \beta_2, \dots, \beta_K$   
⇒ Modelo lineal en los parámetros

MCO sólo requiere linealidad en los parámetros

## Ya vimos algunos ejemplos de no linealidades en las variables

### Variables en logaritmos

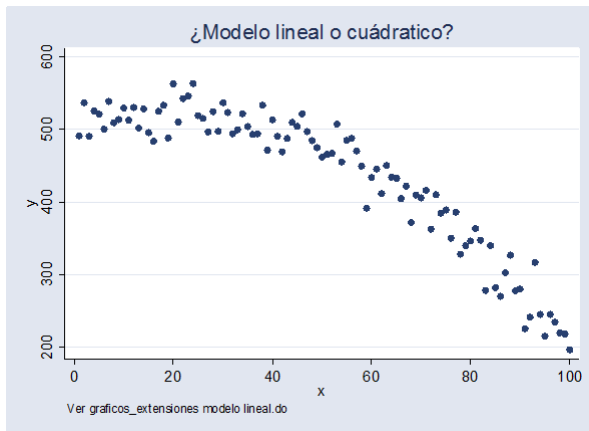
- Modelo logarítmico (log-log):  $\ln Y_i = \beta_1 + \beta_2 \ln X_i + \mu_i$   
→  $\beta_2$  es una elasticidad
- Modelo semilogarítmico (log-lin):  $\ln Y_i = \beta_1 + \beta_2 X_i + \mu_i$   
→  $\beta_2$  es una semielasticidad

## Interpretación

- Importante: siempre tenemos que pensar en **qué modelo** estamos y cuáles son las **unidades de medida** de las variables
- Supongamos que  $Y$  y  $X$  están medidas en pesos, y que  $\beta_2 = 0,5$

Modelo	Ecuación	Efecto marginal
Lineal	$Y = \beta_1 + \beta_2 X_i + u_i$	Si $X$ aumenta en \$1, $Y$ aumenta en \$0,50
Log-log	$\ln Y_i = \beta_1 + \beta_2 \ln X_i + u_i$	Si $X$ aumenta un 1 %, $Y$ aumenta en 0,50 %
Log-lin	$\ln Y_i = \beta_1 + \beta_2 X_i + u_i$	Si $X$ aumenta en \$1, $Y$ aumenta en 50 % ( $0,50 \times 100$ %)
Lin-log	$Y_i = \beta_1 + \beta_2 \ln X_i + u_i$	Si $X$ aumenta en 1 %, $Y$ aumenta en 0,005\$ ( $\frac{0,50}{100}$ )

## ¿Qué sugieren estos datos?



## Variables cuadráticas

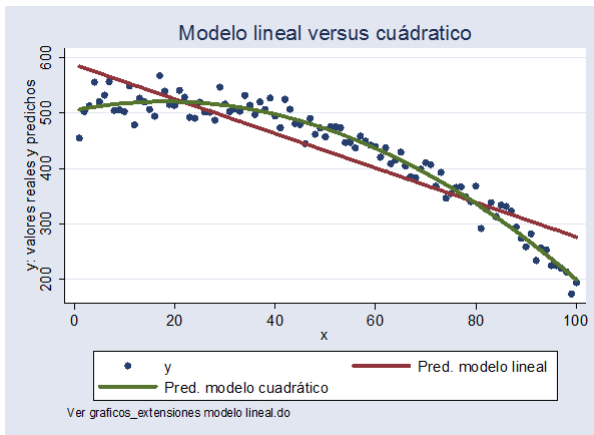
Modelo cuadrático en  $X$ :

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \mu_i$$

- El efecto marginal de  $X$  ahora viene dado por:

$$\frac{\partial E[Y_i]}{\partial X_i} = \beta_2 + 2\beta_3 X_i$$

- **El efecto marginal ya no es constante:** depende de  $\beta_2$ , de  $\beta_3$  y del valor que asignemos a  $X_i$ .
- No sólo la magnitud del efecto depende de  $X$ . Cuando  $\beta_2$  y  $\beta_3$  tienen distinto signo, el signo del efecto marginal también depende del valor que asignemos a  $X_i$ .



- **Por construcción**, el modelo lineal predice un efecto marginal constante de  $X$  sobre  $Y$
- Notar que el efecto marginal del modelo cuadrático cambia con el valor de las  $X$  (aquí el efecto marginal es cada vez más negativo)

## Otra forma de no linealidad: interacción entre variables

- Un año más de educación ¿tiene el mismo efecto sobre la productividad/salarios para cualquiera?
- Es factible que el “talento” potencie el efecto de la educación sobre la productividad/salarios, de manera que un año más de educación “rinda” más para individuos con más talento.
- La interacción entre variables se usa para capturar situaciones donde el efecto de una variable  $X$  se potencia o atenúa con el de otra variable  $Z$

## Otra forma de no linealidad: interacción entre variables

- Incluimos en el modelo un **término multiplicativo** entre las variables para capturar su interacción:

$$Y_i = \beta_1 + \beta_2 X_i + \gamma(X_i \times Z_i) + u_i$$

- Ahora el efecto marginal de  $X$  viene dado por

$$\frac{\partial E[Y_i]}{\partial X_i} = \beta_2 + \gamma Z_i$$

- Si  $\beta_2 > 0$  y  $\gamma > 0$ , aumentos de  $Z$  potencian el efecto positivo de  $X$  sobre  $E[Y]$
- Si  $\beta_2 > 0$  y  $\gamma < 0$ , aumentos de  $Z$  atenúan (e incluso podrían contrarrestar) el efecto positivo de  $X$  sobre  $E[Y]$
- Notar que cuando el signo de los coeficientes coincide, una variable potencia el efecto de la otra; de lo contrario, el efecto se atenúa.



## Ejemplo: efecto de la educación sobre los salarios

- Supongamos que el salario ( $Y$ ) depende de los años de educación ( $X$ ) y de los años de experiencia laboral ( $Z$ ).
- También creemos que la educación tiene un efecto positivo sobre los salarios que se potencia con la experiencia laboral.
- Entonces propondríamos un modelo con interacción entre  $X$  y  $Z$  y esperaríamos que  $\beta_2 > 0$  y  $\gamma > 0$
- ¿Y si  $Z$  fuera una variable dummy?

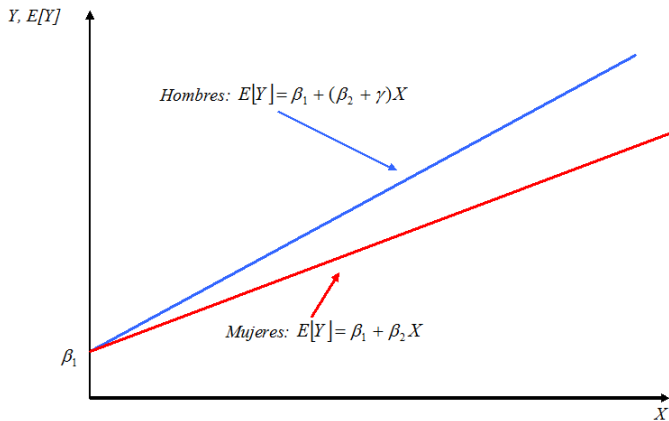
## Interacción con una dummy

Volvamos al modelo con interacción, pero reemplacemos  $Z$  por la variable dummy *hombre* (=1 si es hombre, =0 si es mujer)


$$Y_i = \beta_1 + \beta_2 X_i + \gamma(X_i \times \text{hombre}_i) + \mu_i$$

- Tenemos dos modelos en realidad:
  - Para las mujeres:  $Y_i = \beta_1 + \beta_2 X_i + \mu_i$
  - Para los hombres:  $Y_i = \beta_1 + \beta_2 X_i + \gamma X_i + \mu_i$
- El efecto marginal de  $X$  también difiere:
  - Para las mujeres:  $\frac{\partial E[Y_i]}{\partial X_i} = \beta_2$
  - Para los hombres:  $\frac{\partial E[Y_i]}{\partial X_i} = \beta_2 + \gamma$

$$E[Y_i] = \beta_1 + \beta_2 X_i + \gamma(X_i \times \text{hombre}_i) \text{ con } \beta_2 > 0 \text{ y } \gamma > 0$$



$$E[Y_i] = \beta_1 + \beta_2 X_i + \gamma(X_i \times \text{hombre}_i) \text{ con } \beta_2 > 0 \text{ y } \gamma < 0$$



## Dummies aditivas y multiplicativas


Consideremos el siguiente modelo:

$$Y_i = \beta_1 + \beta_2 X_i + \delta \text{hombre}_i + \gamma(X_i \times \text{hombre}_i) + \mu_i$$

- La dummy aditiva en el término  $\delta \text{hombre}_i$  permite que las ordenadas al origen difieran
- La dummy multiplicativa en el término  $\gamma(X_i \times \text{hombre}_i)$  permite que las pendientes de las regresiones difieran por género

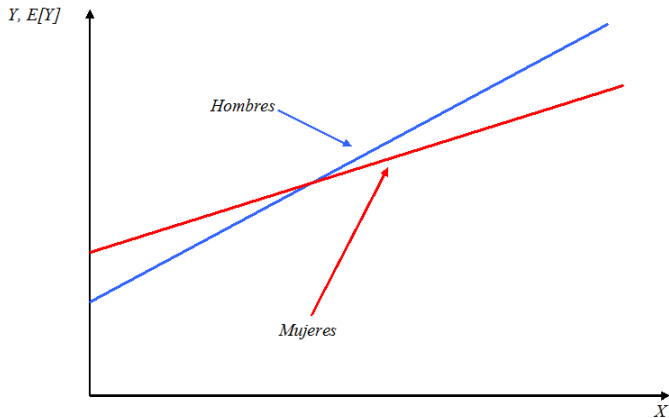
$$E[Y_i] = \beta_1 + \beta_2 X_i + \delta \text{hombre}_i + \gamma(X_i \times \text{hombre}_i)$$

supongamos todos los parámetros positivos



$$E[Y_i] = \beta_1 + \beta_2 X_i + \delta \text{hombre}_i + \gamma (X_i \times \text{hombre}_i)$$

¿Qué signo tienen los parámetros?



## Ejemplo empírico: estimación de un modelo de los determinantes de los salarios en la Argentina

- **Modelo log-lin (semilogarítmico) con variables lineales, cuadráticas y dummies:**

$$\ln(W_i) = \beta_1 + \beta_2 aedu_i + \beta_3 edad_i + \beta_4 edad_i^2 + \delta hombre_i + \mu_i$$

- $W$  es el salario por hora trabajada
  - $aedu$  son años de educación formal
  - $edad$  en años
  - $edad^2$  es la edad al cuadrado
  - $hombre$  es una variable dummy =1 si hombre, =0 si mujer
- 
- Datos de la Encuesta Permanente de Hogares para todo el país (EPH)



```
regress logW aedu edad edad2 hombre
```

Source	SS	df	MS			
Model	3825.0433	4	956.260826	Number of obs =	24138	
Residual	11323.5513	24133	.469214406	F( 4, 24133) =	2038.00	
Total	15148.5946	24137	.627608839	Prob > F =	0.0000	
				R-squared =	0.2525	
				Adj R-squared =	0.2524	
				Root MSE =	.68499	

logW	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
aedu	.0907561	.0011789	76.99	0.000	.0884454	.0930667
edad	.0622396	.0019396	32.09	0.000	.0584379	.0660413
edad2	-.0005638	.0000232	-24.31	0.000	-.0006093	-.0005184
hombre	.0712211	.0089857	7.93	0.000	.0536087	.0888336
_cons	-1.645838	.0401596	-40.98	0.000	-1.724553	-1.567122

Source	SS	df	MS			
Model	3825.0433	4	956.260826	Number of obs =	24138	
Residual	11323.5513	24133	.469214406	F( 4, 24133) =	2038.00	
				Prob > F =	0.0000	
				R-squared =	0.2525	
				Adj R-squared =	0.2524	
				Root MSE =	.68499	
-----						
logW	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
aedu	.0907561	.0011789	76.99	0.000	.0884454	.0930667
edad	.0622396	.0019396	32.09	0.000	.0584379	.0660413
edad2	-.0005638	.0000232	-24.31	0.000	-.0006093	-.0005184
hombre	.0712211	.0089857	7.93	0.000	.0536087	.0888336
_cons	-1.645838	.0401596	-40.98	0.000	-1.724553	-1.567122

- Recordar: especificación semilogarítmica.
- Un año más de educación (*aedu*) tendría el efecto de aumentar en un 9.07% el salario por hora esperado, manteniendo constantes las demás variables (**retorno a la educación**)

Source	SS	df	MS			
Model	3825.0433	4	956.260826	Number of obs = 24138		
Residual	11323.5513	24133	.469214406	F( 4, 24133) = 2038.00		
				Prob > F = 0.0000		
				R-squared = 0.2525		
				Adj R-squared = 0.2524		
				Root MSE = .68499		
logW	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
aedu	.0907561	.0011789	76.99	0.000	.0884454	.0930667
edad	.0622396	.0019396	32.09	0.000	.0584379	.0660413
edad2	-.0005638	.0000232	-24.31	0.000	-.0006093	-.0005184
hombre	.0712211	.0089857	7.93	0.000	.0536087	.0888336
_cons	-1.645838	.0401596	-40.98	0.000	-1.724553	-1.567122

- Como *edad2* es estadísticamente significativa, decimos que la edad tiene un *efecto no lineal significativo* sobre el log. de los salarios horarios.
- Si la *edad* aumenta 1 año, *ceteris paribus*, esperamos que el salario por hora aumente en  $[0.06 - 2 \times 0.0005 \times \text{edad}] \times 100\%$ .
- Para *edad*=20 años, el efecto estimado es de un 4%.

Source	SS	df	MS			
Model	3825.0433	4	956.260826	Number of obs = 24138		
Residual	11323.5513	24133	.469214406	F( 4, 24133) = 2038.00		
				Prob > F = 0.0000		
				R-squared = 0.2525		
				Adj R-squared = 0.2524		
				Root MSE = .68499		
-----						
logW	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
aedu	.0907561	.0011789	76.99	0.000	.0884454	.0930667
edad	.0622396	.0019396	32.09	0.000	.0584379	.0660413
edad2	-.0005638	.0000232	-24.31	0.000	-.0006093	-.0005184
<b>hombre</b>	<b>.0712211</b>	.0089857	7.93	0.000	.0536087	.0888336
_cons	-1.645838	.0401596	-40.98	0.000	-1.724553	-1.567122

- El salario de un hombre es, en promedio, aproximadamente un 7% ( $0.0712 \times 100\%$ ) mayor que el de una mujer de la misma edad y con la misma educación.
- Vamos a ver que **esta interpretación no siempre es correcta para los coeficientes de las dummies.**

## ¿Cómo se interpreta el coeficiente de la variable binaria *hombre* en un modelo semilogarítmico?

- Para hombres tenemos:

$$\ln \hat{W}_H = \hat{\beta}_1 + \hat{\beta}_2 aedu + \hat{\beta}_3 edad + \hat{\beta}_4 edad^2 + \hat{\delta}$$

- Para mujeres tenemos:  $\ln \hat{W}_M = \hat{\beta}_1 + \hat{\beta}_2 aedu + \hat{\beta}_3 edad + \hat{\beta}_4 edad^2$

- Restando miembro a miembro:

$$\ln \hat{W}_H - \ln \hat{W}_M = \ln \left[ \frac{\hat{W}_H}{\hat{W}_M} \right] = \hat{\delta} \implies \left[ \frac{\hat{W}_H}{\hat{W}_M} \right] - 1 = \left[ \frac{\hat{W}_H - \hat{W}_M}{\hat{W}_M} \right] = \exp(\hat{\delta}) - 1$$

Entonces, la interpretación correcta es que el salario horario estimado para un hombre es  $\left[ \exp(\hat{\delta}) - 1 \right] \times 100\%$  mayor que el de una mujer con la misma edad y educación.

Source	SS	df	MS			
Model	3825.0433	4	956.260826	Number of obs = 24138		
Residual	11323.5513	24133	.469214406	F( 4, 24133) = 2038.00		
				Prob > F = 0.0000		
				R-squared = 0.2525		
				Adj R-squared = 0.2524		
				Root MSE = .68499		
Total	15148.5946	24137	.627608839			

logW	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
aedu	.0907561	.0011789	76.99	0.000	.0884454	.0930667
edad	.0622396	.0019396	32.09	0.000	.0584379	.0660413
edad2	-.0005638	.0000232	-24.31	0.000	-.0006093	-.0005184
<b>hombre</b>	<b>.0712211</b>	.0089857	7.93	0.000	.0536087	.0888336
_cons	-1.645838	.0401596	-40.98	0.000	-1.724553	-1.567122


- Entonces, deberíamos esperar que un hombre gane por hora  $[\exp(0.07) - 1] \times 100\% = 7.25\%$  más que una mujer con la misma edad y educación.
- Resultado muy similar al que obteníamos antes mirando directamente el coeficiente estimado  $\hat{\delta}$ , porque para  $\hat{\delta}$  pequeño (digamos,  $\hat{\delta} < 0.20$ ),  $\exp(\hat{\delta}) - 1 \cong \hat{\delta}$ .
- Si  $\hat{\delta}$  es grande, también lo es diferencia entre  $\hat{\delta}$  y  $\exp(\hat{\delta}) - 1$ .

## Agregamos una interacción entre educación y género

$$\ln(W_i) = \beta_1 + \beta_2 aedu_i + \beta_3 edad_i + \beta_4 edad_i^2 + \delta hombre_i \\ + \gamma (hombre \times aedu)_i + \mu_i$$

- ¿Cuál es el retorno a la educación bajo esta especificación?
  - para mujeres  $\beta_2 \times 100\%$
  - para hombres  $(\beta_2 + \gamma) \times 100\%$
- ¿Cómo evaluarían la hipótesis de que el retorno a la educación no difiere entre hombres y mujeres?

## Brechas salariales de género en América Latina



Fuente: Marchionni, Gasparini & Edo (2019), estimaciones basadas en encuestas de hogares de 2015.

<https://scioteca.caf.com/handle/123456789/1401>



## Bibliografía para esta clase

- Notas de clase, capítulo 3 secciones 3.2, 3.3 y Apéndice del capítulo 3
- Wooldridge, capítulo 3 sección 3.1, capítulo 6 sección 6.2, capítulo 7 secciones 7.1 a 7.4.
- Marchionni. M., L. Gasparini y M. Edo (2019). Brechas de género en América Latina, un estado de situación. Caracas: CAF. Disponible en <http://scioteca.caf.com/handle/123456789/1401>.