

TEMA 2

EL ESTIMADOR MCO



S. Álvarez, A. Beyaert, M. Camacho, M. González, A. Quesada
Departamento de Métodos Cuantitativos para la Economía y la Empresa



Lo que estudiaremos en este tema:

- 1. El modelo de regresión múltiple**
- 2. Funcionamiento e interpretación del estimador MCO**
 - 2.1 Introducción
 - 2.2 Estimación MCO. Modelo de regresión simple
 - 2.3 Estimación MCO. Modelo de regresión múltiple
 - 2.4 Estimación MCO. Interpretación
 - 2.5 Propiedades algebraicas del estimador MCO
 - 2.6 Bondad del ajuste: R-cuadrado
 - 2.7 Bondad del ajuste: R-cuadrado ajustado
- 3. Unidades de medida y forma funcional**
 - 3.1 Unidades de medida
 - 3.2 Formas funcionales

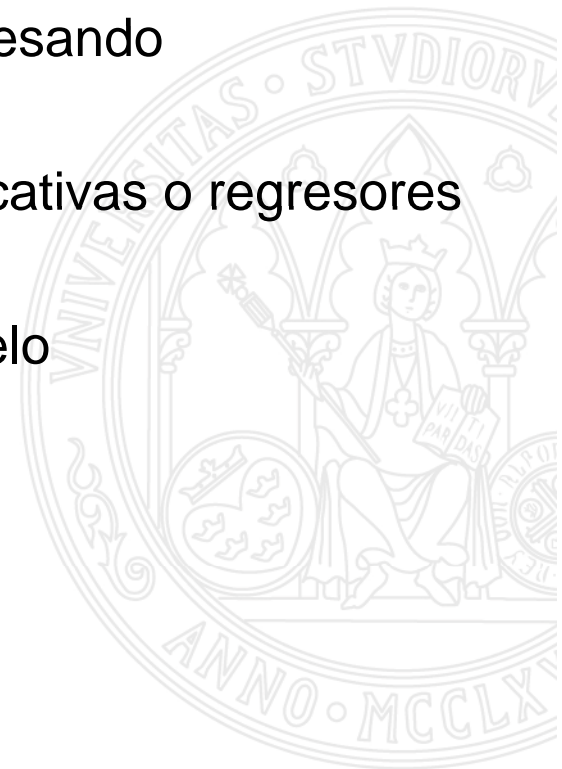


Bibliografía básica: Wooldridge, 2008, cap. 2, 3 y 6

1. El modelo de regresión múltiple

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$$

- y : variable dependiente, variable explicada o regresando
- x_1, \dots, x_k : variables independientes, variables explicativas o regresores
- $\beta_0, \beta_1, \dots, \beta_k$: son los $K=(k+1)$ coeficientes del modelo
- ε : término de error, perturbación o shock



1. El modelo de regresión múltiple

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$$

- Los coeficientes son **efectos ceteris paribus**, si se cumple el supuesto de **media condicionada nula**:

$$E(\varepsilon/x_1, x_2, \dots, x_k) = E(\varepsilon) = 0$$

Dos implicaciones:

- $E(\varepsilon/x_1, x_2, \dots, x_k) = E(\varepsilon)$

Es un supuesto clave. Implica que el valor esperado de ε sea independiente de los valores de x_1, \dots, x_k

- $E(\varepsilon) = 0$

No es restrictivo, cumpliéndose lo anterior, siempre que el modelo incluya término constante

1. El modelo de regresión múltiple

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$$

- Es un **modelo lineal en parámetros**
- La interpretación de β_1 es:

$$\beta_1 = \frac{\Delta y}{\Delta x_1} \quad \text{si } \Delta x_2 = \Delta x_3 = \dots = \Delta x_k = \Delta \varepsilon = 0$$



1. El modelo de regresión múltiple

- Un caso particular: el **modelo de regresión simple**

$$y = \beta_0 + \beta_1 x + \varepsilon$$

- El modelo de regresión múltiple es más útil que el simple porque:
 - permite controlar explícitamente los diversos factores que afectan a la variable dependiente
 - permite generalizar relaciones funcionales entre variables: por ejemplo, una función cuadrática

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \varepsilon$$

2. Funcionamiento e interpretación del estimador MCO

2.1 Introducción

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$$

- Objetivo: estimar $\beta_0, \beta_1, \dots, \beta_k$ de **la función de regresión poblacional**

$$E(y/x_1, \dots, x_k) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$$

- Necesitamos una **muestra** de la población

$$y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki} + \varepsilon_i; \quad i = 1, \dots, N$$

- $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$ son los valores estimados de los coeficientes y definen la **función de regresión muestral**

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_k x_{ki}$$


- La diferencia entre el valor verdadero y el ajustado es el **residuo**

$$e_i = y_i - \hat{y}_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki}$$

2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

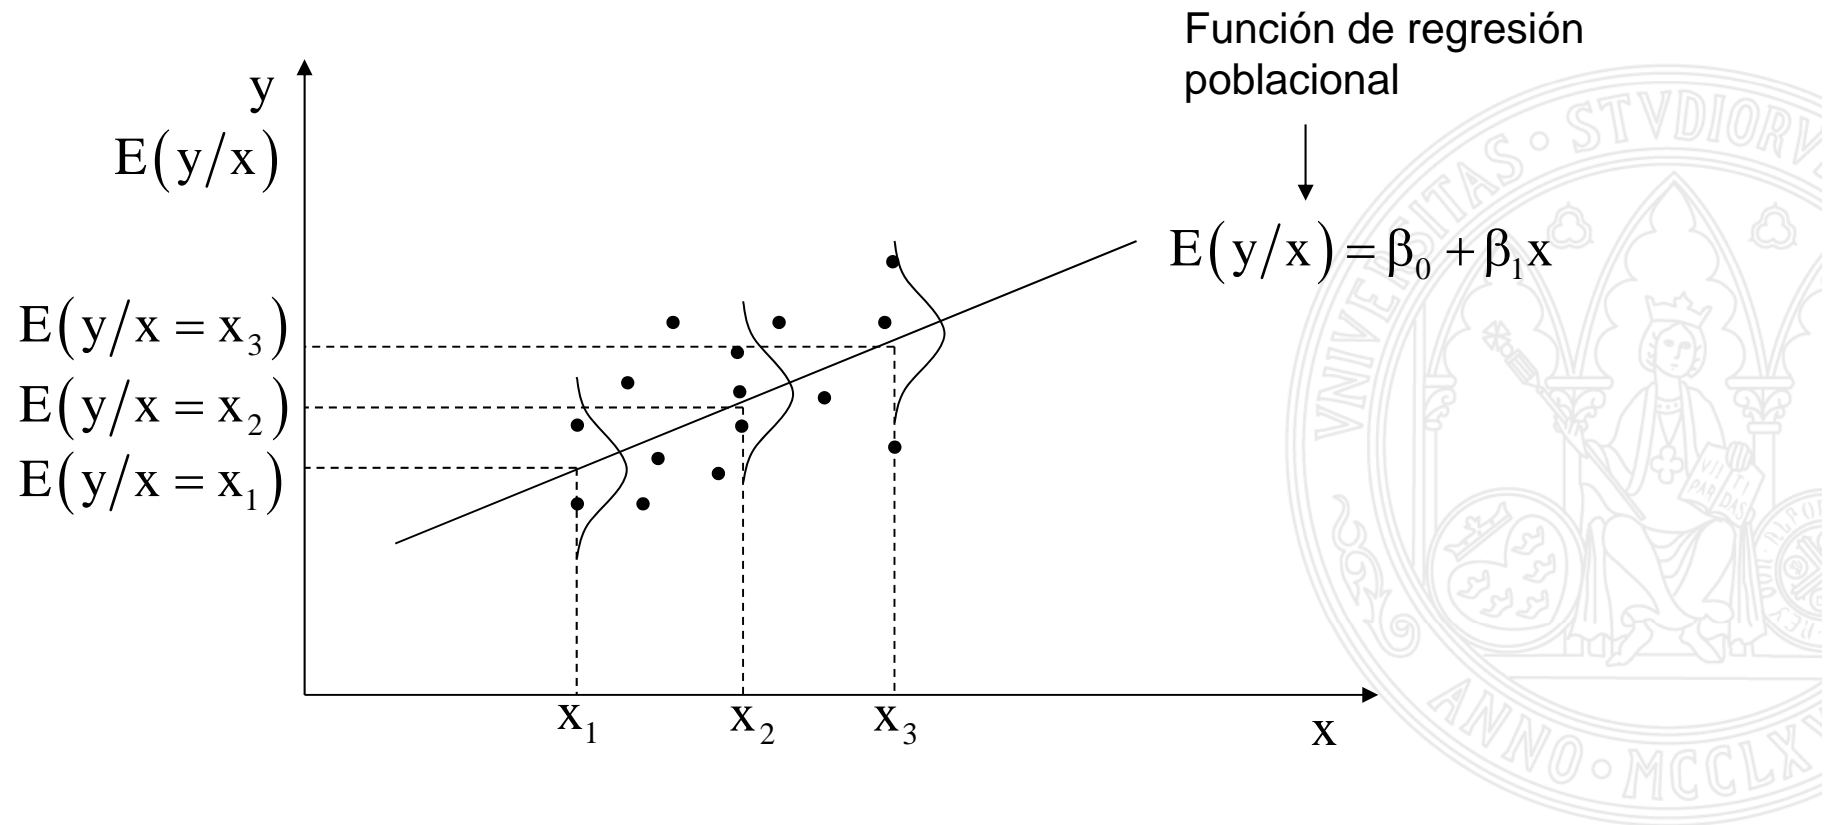
Ilustración gráfica en modelo de regresión simple: $y = \beta_0 + \beta_1 x + \varepsilon$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

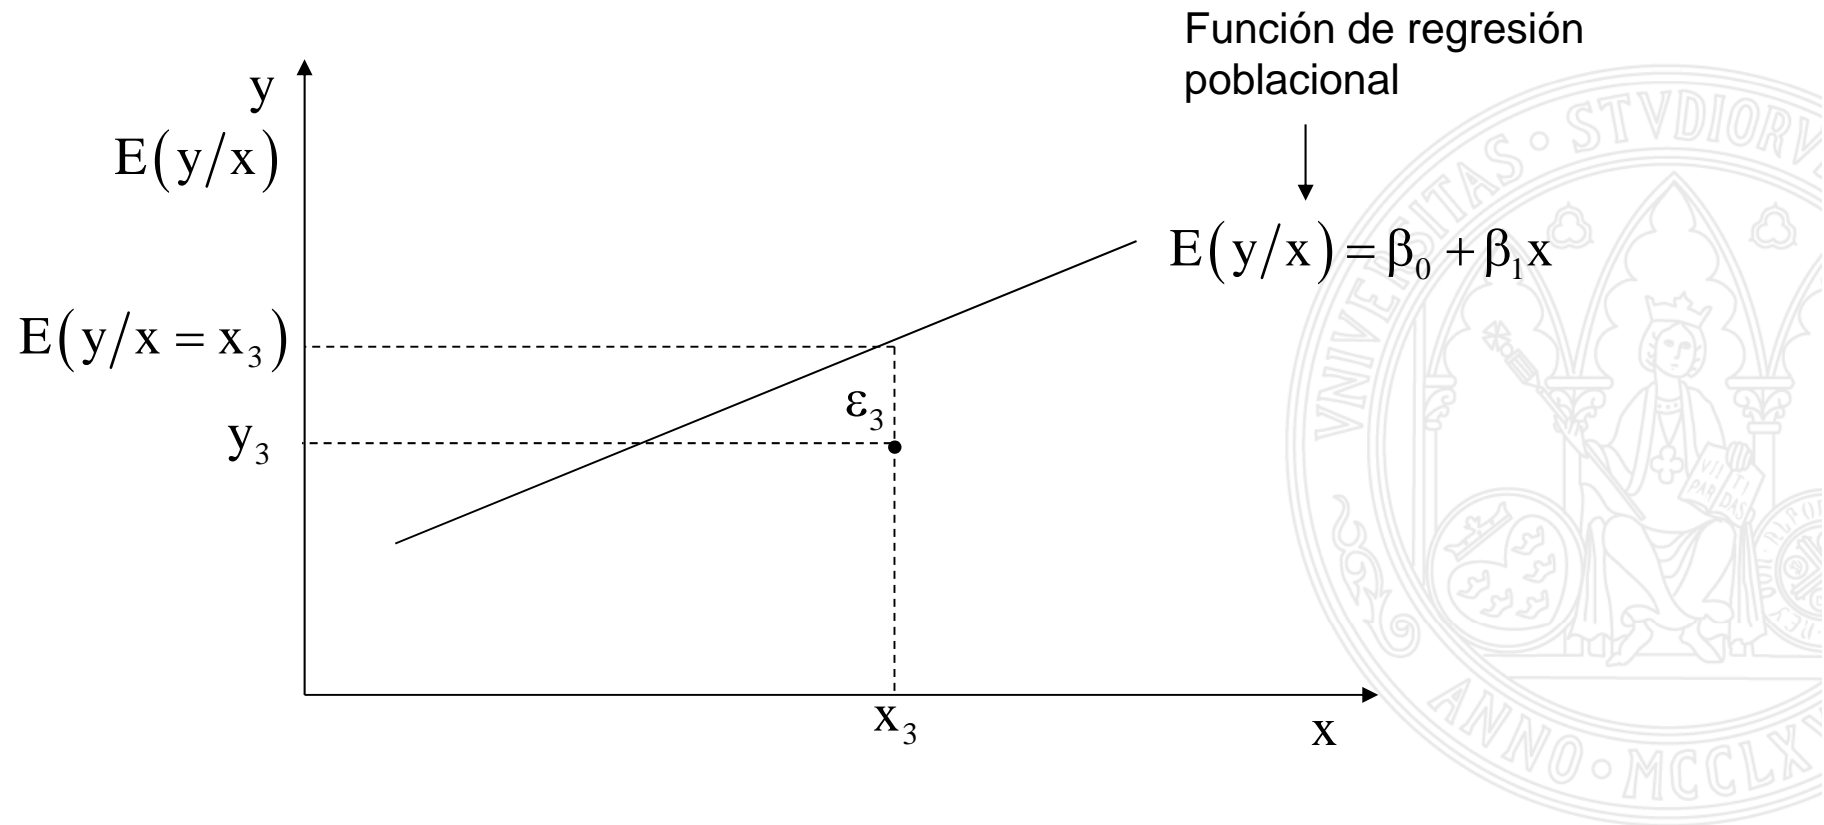
$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

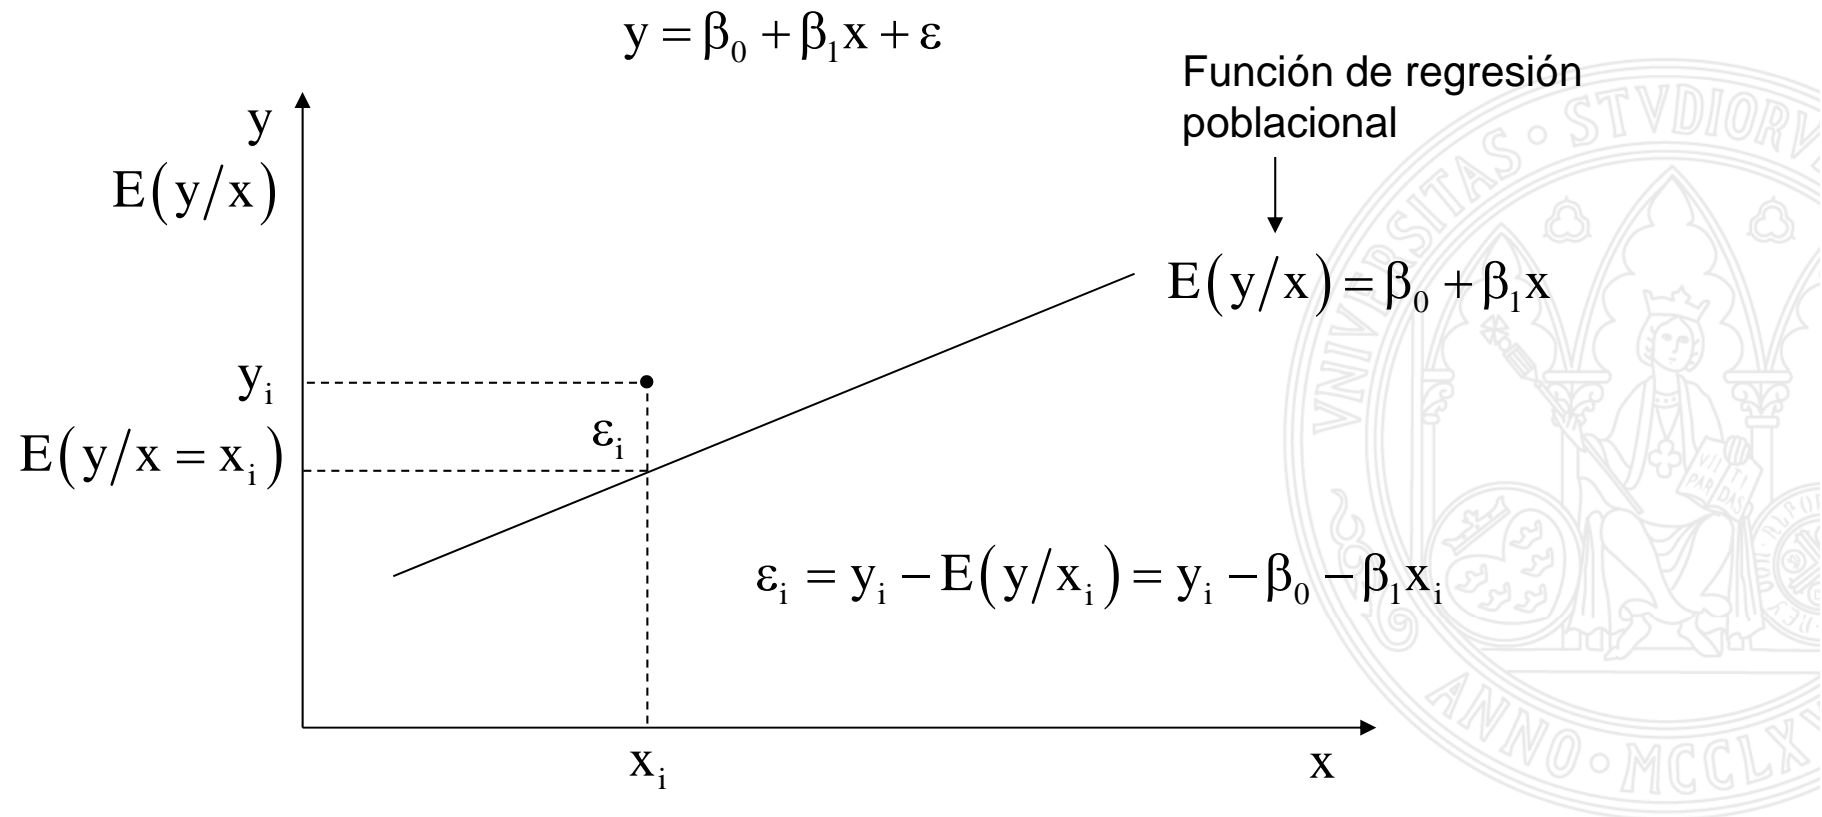
$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple



En general, para la observación “i”



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

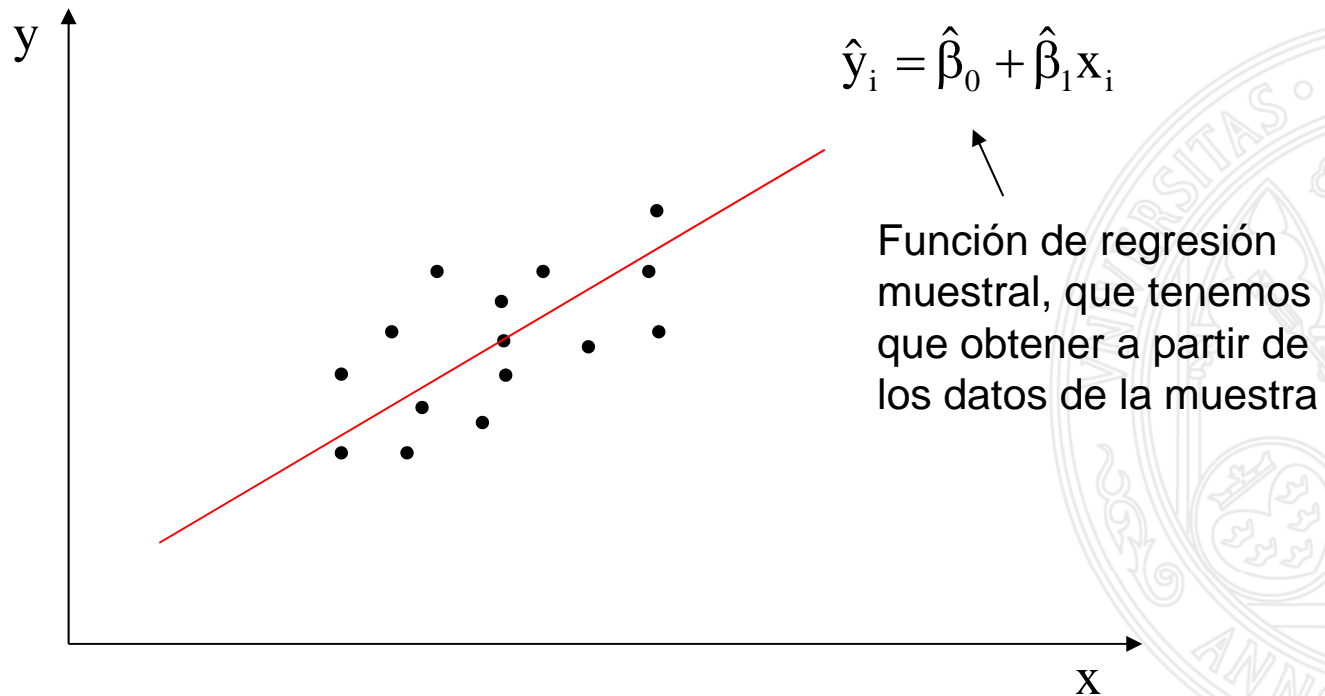
$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

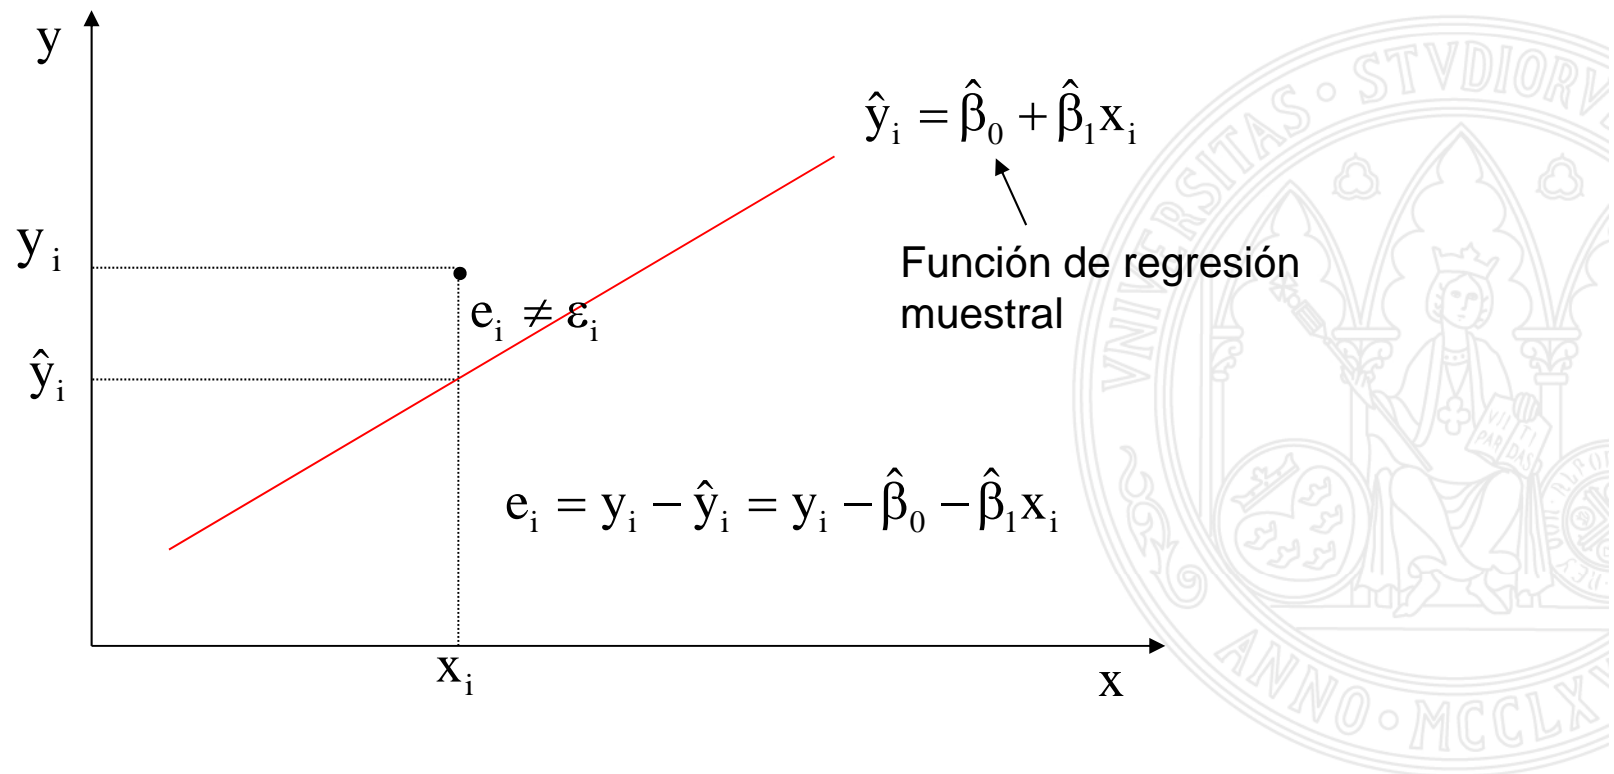
$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple


$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

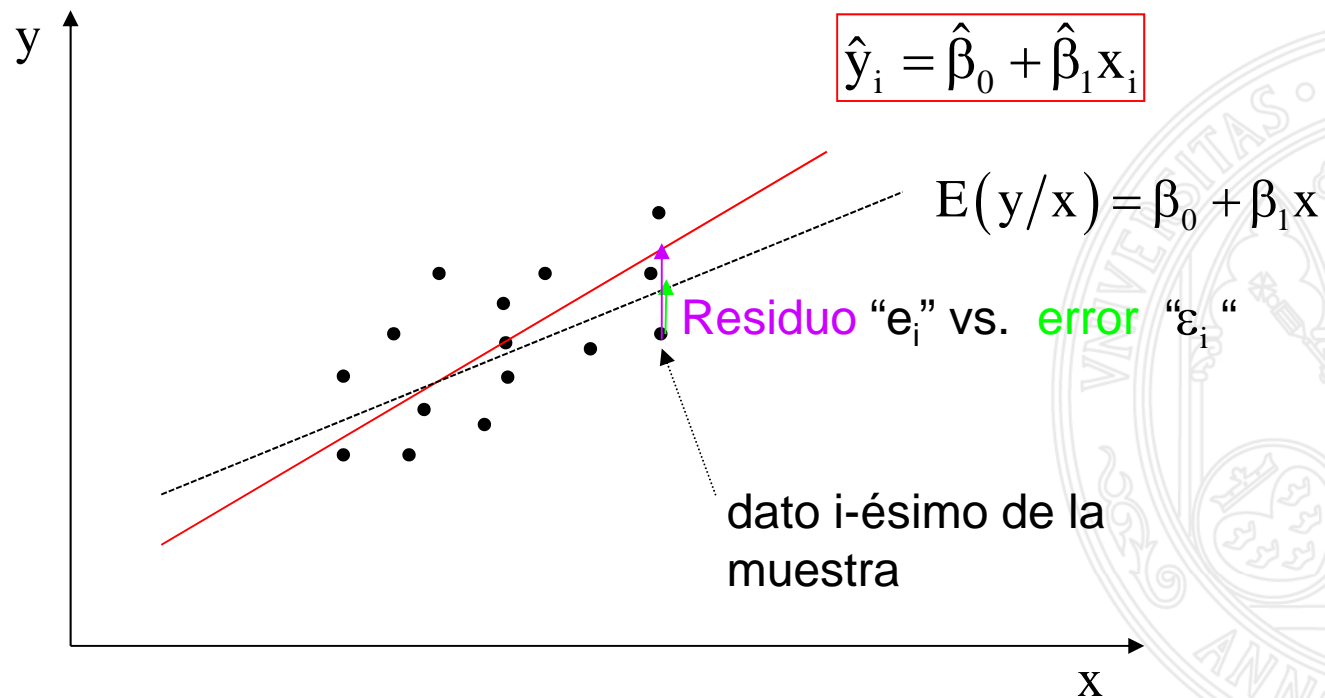
$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

$$y = \beta_0 + \beta_1 x + \varepsilon$$



2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

- *Mínimos Cuadrados Ordinarios (MCO), regresión simple:*

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i; \forall i = 1, \dots, N$$

- Buscamos $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$
- MCO escoge $\hat{\beta}_0$ y $\hat{\beta}_1$ para minimizar la suma de los cuadrados de los residuos:

$$\text{Min}_{b_0, b_1} \sum_{i=1}^N (y_i - b_0 - b_1 x_i)^2 \equiv \text{Min}_{b_0, b_1} Q(b_0, b_1)$$

- Las condiciones de primer orden son:

$$\left. \frac{\partial Q(b_0, b_1)}{\partial b_0} \right|_{b_0 = \hat{\beta}_0, b_1 = \hat{\beta}_1} = 0$$

$$\left. \frac{\partial Q(b_0, b_1)}{\partial b_1} \right|_{b_0 = \hat{\beta}_0, b_1 = \hat{\beta}_1} = 0$$

2. Funcionamiento e interpretación del estimador MCO

2.2 Estimación MCO. Modelo de regresión simple

- De las condiciones de primer orden obtenemos el **sistema de ecuaciones normales**:

$$\sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

$$\sum_{i=1}^N x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

- Resolviendo:

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^N x_i (y_i - \bar{y})}{\sum_{i=1}^N x_i (x_i - \bar{x})} = \frac{\sum_{i=1}^N (x_i - \bar{x}) y_i}{\sum_{i=1}^N x_i (x_i - \bar{x})} = \frac{\sum_{i=1}^N (x_i - \bar{x}) (y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2} = \frac{S_{xy}}{S_x^2}$$

- => una condición necesaria para estimar por MCO es: $\sum_{i=1}^N (x_i - \bar{x})^2 > 0$

2. Funcionamiento e interpretación del estimador MCO

2.3 Estimación MCO. Modelo de regresión múltiple

- **Regresión múltiple:** $y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad \forall i = 1, \dots, N$
- Buscamos: $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_k x_{ki}$
- MCO escoge $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$ para minimizar la suma de los cuadrados de los residuos:

$$\text{Min}_{b_0, b_1, \dots, b_k} \sum_{i=1}^N (y_i - b_0 - b_1 x_{1i} - \dots - b_k x_{ki})^2 \equiv \text{Min}_{b_0, b_1, \dots, b_k} Q(b_0, b_1, \dots, b_k)$$

- Condiciones de primer orden:

$$\left. \frac{\partial Q(b_0, b_1, \dots, b_k)}{\partial b_0} \right|_{b_0 = \hat{\beta}_0, b_1 = \hat{\beta}_1, \dots, b_k = \hat{\beta}_k} = 0$$

$$\vdots$$

$$\left. \frac{\partial Q(b_0, b_1, \dots, b_k)}{\partial b_k} \right|_{b_0 = \hat{\beta}_0, b_1 = \hat{\beta}_1, \dots, b_k = \hat{\beta}_k} = 0$$

2. Funcionamiento e interpretación del estimador MCO

2.3 Estimación MCO. Modelo de regresión múltiple

- El sistema de ecuaciones normales es:

$$\sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki}) = 0$$

$$\sum_{i=1}^N x_{1i} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki}) = 0$$

⋮

$$\sum_{i=1}^N x_{ki} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki}) = 0$$

- Resolviendo obtenemos $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$



2. Funcionamiento e interpretación del estimador MCO

2.3 Estimación MCO. Modelo de regresión múltiple

En modelos sin termino constante: $\hat{y} = \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$

- El sistema de ecuaciones normales es:

$$\begin{aligned} \sum_{i=1}^N x_{li} (y_i - \hat{\beta}_1 x_{li} - \dots - \hat{\beta}_k x_{ki}) &= 0 \\ \vdots & \\ \sum_{i=1}^N x_{ki} (y_i - \hat{\beta}_1 x_{li} - \dots - \hat{\beta}_k x_{ki}) &= 0 \end{aligned}$$

- Resolviendo obtenemos $\hat{\beta}_1, \dots, \hat{\beta}_k$



2. Funcionamiento e interpretación del estimador MCO

2.3 Estimación MCO. Modelo de regresión múltiple

- Expresión algebraica del estimador MCO:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^N r_{1i} y_i}{\sum_{i=1}^N r_{1i}^2}$$

r_1 es el residuo de la regresión de x_1 sobre x_2, \dots, x_k , y una constante. Es la parte de x_1 que no está explicada con x_2, \dots, x_k

$\hat{\beta}_1$ mide la relación muestral entre y y x_1 una vez tomado en cuenta el efecto de x_2, \dots, x_k

⇒ estimación del efecto ceteris paribus

2. Funcionamiento e interpretación del estimador MCO

2.4 Estimación MCO. Interpretación

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_k x_{ki} \quad \forall i=1, \dots, N$$

- $\hat{\beta}_0$: Matemáticamente, es el valor estimado de y cuando todas las variables explicativas valen cero. Pero ojo con la interpretación económica.
- $\hat{\beta}_1, \dots, \hat{\beta}_k$: Efectos parciales o efectos ceteris paribus

$$\hat{\beta}_j = \frac{\hat{\Delta}y}{\Delta x_j} \quad \text{Variación estimada en } y \text{ ante cambios unitarios en } x_j, \text{ cuando el resto de variables explicativas no cambian (j=1,2,\dots,k)}$$

- La regresión ofrece información ceteris paribus aunque los datos no hayan sido recogidos de forma ceteris paribus, si se cumple:

$$E(\varepsilon_i / x_{1i}, x_{2i}, \dots, x_{ki}) = E(\varepsilon_i) = 0 \quad \forall i$$

2. Funcionamiento e interpretación del estimador MCO

2.5 Propiedades algebraicas del estimador MCO

Derivan del sistema de ecuaciones normales

1. En **modelos con término constante**:

- La suma y la media muestral de los residuos MCO es nula:

$$\sum_{i=1}^N e_i = 0 \Rightarrow \bar{e} = 0$$

- Las medias muestrales de y y de \hat{y} son iguales:

$$e_i = y_i - \hat{y}_i \Rightarrow \bar{e} = \bar{y} - \bar{\hat{y}} \Rightarrow \bar{y} = \bar{\hat{y}}$$

- El punto $(\bar{y}, \bar{x}_1, \bar{x}_2, \dots, \bar{x}_k)$ siempre está sobre la función de regresión MCO:


$$\bar{e} = 0 \Rightarrow \bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}_1 + \hat{\beta}_2 \bar{x}_2 + \dots + \hat{\beta}_k \bar{x}_k$$

2. Funcionamiento e interpretación del estimador MCO

2.5 Propiedades algebraicas del estimador MCO

Modelo de regresión simple con término constante: $\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}$

Gráficamente



2. Funcionamiento e interpretación del estimador MCO

2.5 Propiedades algebraicas del estimador MCO

2. Con o sin término constante:

- Los regresores y los residuos MCO son ortogonales:

$$\sum_{i=1}^N x_{ji} e_i = 0; j = 1, \dots, k$$

- Implica que \hat{y} y los residuos MCO son ortogonales:

$$\sum_{i=1}^N \hat{y}_i e_i = 0$$

Demostración:

$$\begin{aligned} \sum_{i=1}^N \hat{y}_i e_i &= \sum_{i=1}^N (\hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_k x_{ki}) e_i = \\ &= \hat{\beta}_0 \sum_{i=1}^N e_i + \hat{\beta}_1 \sum_{i=1}^N x_{1i} e_i + \dots + \hat{\beta}_k \sum_{i=1}^N x_{ki} e_i = 0 \end{aligned}$$

- Si $\bar{e} = 0 \Rightarrow$ las covarianzas muestrales entre cada regresor y el residuo y entre \hat{y} y el residuo son nulas.

2. Funcionamiento e interpretación del estimador MCO

2.6 Bondad del ajuste: R-cuadrado

- El coeficiente de determinación es:

$$R^2 = 1 - \frac{SCE}{STC} \quad R^2 \leq 1$$

donde: $STC = \sum_{i=1}^N (y_i - \bar{y})^2$

$$SCE = \sum_{i=1}^N e_i^2$$

además: $SCR = \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2 = \sum_{i=1}^N (\hat{y}_i - \bar{y})^2$

en modelos con
constante

STC: Suma total de cuadrados

SCE: Suma de cuadrados de los residuos

SCR: Suma de cuadrados de la regresión

2. Funcionamiento e interpretación del estimador MCO

2.6 Bondad del ajuste: R-cuadrado

- En **modelos con término constante** $STC = SCR + SCE$

$$R^2 = 1 - \frac{SCE}{STC} = \frac{SCR}{STC} \quad 0 \leq R^2 \leq 1$$

Interpretación: Es la fracción de la variación muestral de y explicada por la función de regresión muestral

- También se puede demostrar que $R^2 = \left(\frac{S_{y\hat{y}}}{S_y S_{\hat{y}}} \right)^2$
- Si **no existe término constante** $STC \neq SCR + SCE$
- El R^2 puede ser negativo sólo en modelos sin término constante

2. Funcionamiento e interpretación del estimador MCO

2.6 Bondad del ajuste: R-cuadrado

- Un R^2 bajo no implica que la regresión MCO no sea útil
- El R^2 nunca disminuye cuando se añade otro regresor
⇒ no permite comparar modelos con distinto número de regresores

En efecto, sea cual sea la calidad de los regresores, ocurre que



$$\text{Si } K = N \Rightarrow R^2 = 1$$

2. Funcionamiento e interpretación del estimador MCO

2.6 Bondad del ajuste: R-cuadrado

Gráficamente



Modelo de regresión simple: $y = \beta_0 + \beta_1 x + \varepsilon \Rightarrow K = 2$



2. Funcionamiento e interpretación del estimador MCO

2.6 Bondad del ajuste: R-cuadrado


Si $N = 2$



2. Funcionamiento e interpretación del estimador MCO

2.6 Bondad del ajuste: R-cuadrado

Entonces, $K = N$ y $R^2 = 1$



2. Funcionamiento e interpretación del estimador MCO

2.7 Bondad del ajuste: R-cuadrado ajustado

- El **coeficiente de determinación ajustado** es:

$$R_a^2 = 1 - \frac{(N-1) \text{SCE}}{(N-K) \text{STC}} = 1 - (1 - R^2) \frac{N-1}{N-K} \quad R_a^2 \leq 1$$

- Penaliza la inclusión de variables independientes
- Permite comparar algo mejor que el R^2 modelos con distinto número de regresores
- El R_a^2 puede ser negativo incluso en modelos con término constante

3. Unidades de medida y forma funcional

3.1 Unidades de medida

Modelo poblacional: $y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$

Modelo estimado: $y = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k + e$

- Los cambios de origen en las variables sólo afectan a β_0 y a $\hat{\beta}_0$
- Si y se multiplica por una constante c (cambio de escala), entonces **todos** los coeficientes $(\beta_0, \beta_1, \dots, \beta_k)$ y sus estimaciones MCO $(\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k)$ se multiplican por c .
- Si una x_j se multiplica (divide) por una constante c , entonces β_j y $\hat{\beta}_j$ se dividen (multiplican) por c
- Si las variables están en logaritmos los cambios de escala en las unidades de medida sólo afectan a β_0 y a $\hat{\beta}_0$
- El R-cuadrado es invariable a los cambios de unidades en las variables

3. Unidades de medida y forma funcional

3.1 Unidades de medida

Ejemplo: Cambio de origen en y

$$y^* = c + y$$

A. Efectos en el **modelo poblacional**: $y = \beta_0 + \beta_1 x + \varepsilon$

- El nuevo modelo es: $y^* = \beta_0^* + \beta_1^* x + \varepsilon^*$
- Deshaciendo el cambio de origen:

$$y + c = \beta_0^* + \beta_1^* x + \varepsilon^* \Rightarrow y = (\beta_0^* - c) + \beta_1^* x + \varepsilon$$

$$\beta_1^* = \beta_1 \quad \beta_0^* = c + \beta_0$$



3. Unidades de medida y forma funcional

3.1 Unidades de medida

$$y^* = c + y$$

B. Efectos en el **modelo estimado**: $y = \hat{\beta}_0 + \hat{\beta}_1 x + e$

- El nuevo modelo estimado es: $y^* = \hat{\beta}_0^* + \hat{\beta}_1^* x + e^*$

$$\hat{\beta}_0^* = \bar{y}^* - \hat{\beta}_1^* \bar{x} \quad \hat{\beta}_1^* = \frac{S_{xy^*}}{S_x^2}$$

- Deshaciendo el cambio de origen:

$$\hat{\beta}_1^* = \frac{S_{xy}}{S_x^2} = \hat{\beta}_1 \quad \hat{\beta}_0^* = c + \bar{y} - \hat{\beta}_1 \bar{x} = c + \hat{\beta}_0$$

¿Qué pasa con el R-cuadrado?

¿Qué pasaría si el cambio de origen afectara a x ?

3. Unidades de medida y forma funcional

3.1 Unidades de medida

Ejemplo: Cambio de escala en y

$$y^* = c \cdot y$$

A. Efectos en el **modelo poblacional**: $y = \beta_0 + \beta_1 x + \varepsilon$

- El nuevo modelo es: $y^* = \beta_0^* + \beta_1^* x + \varepsilon^*$

- Deshaciendo el cambio de escala:

$$c \cdot y = \beta_0^* + \beta_1^* x + \varepsilon^* \Rightarrow y = \frac{\beta_0^*}{c} + \frac{\beta_1^*}{c} x + \varepsilon$$

$$\beta_1^* = c \cdot \beta_1 \quad \beta_0^* = c \cdot \beta_0$$



3. Unidades de medida y forma funcional

3.1 Unidades de medida

$$y^* = c \cdot y$$

B. Efectos en el **modelo estimado**: $y = \hat{\beta}_0 + \hat{\beta}_1 x + e$

- El nuevo modelo estimado es: $y^* = \hat{\beta}_0^* + \hat{\beta}_1^* x + e^*$

$$\hat{\beta}_0^* = \bar{y}^* - \hat{\beta}_1^* \bar{x} \quad \hat{\beta}_1^* = \frac{S_{xy^*}}{S_x^2}$$

- Deshaciendo el cambio de escala:

$$\hat{\beta}_1^* = \frac{c S_{xy}}{S_x^2} = c \hat{\beta}_1 \quad \hat{\beta}_0^* = c \bar{y} - c \hat{\beta}_1 \bar{x} = c \hat{\beta}_0$$

¿Qué pasa con el R-cuadrado?

¿Qué pasaría si el cambio de escala afectara a x ?

3. Unidades de medida y forma funcional

3.2 Formas funcionales

- Modelo lineal en parámetros y variables: $y = \beta_0 + \beta_1 x + \varepsilon$

Derivando: $\beta_1 = \frac{dy}{dx}$ es el **efecto marginal** de x sobre y

Tomando incrementos: $\Delta y = \beta_1 \Delta x$ si $\Delta \varepsilon = 0$

$$\Rightarrow \beta_1 = \frac{\Delta y}{\Delta x} = \frac{dy}{dx}$$

Por ser el modelo
lineal en parámetros y
variables

- Modelos lineales en parámetros, pero no en variables:
 - modelos que incluyen variables en logaritmos
 - funciones cuadráticas
 - otros

3. Unidades de medida y forma funcional

3.2 Formas funcionales

Modelos que incluyen variables en logaritmos:


- **Modelo log-log:** $\ln y = \beta_0 + \beta_1 \ln x + \varepsilon$

Derivando:
$$\beta_1 = \frac{d \ln y}{d \ln x} = \frac{dy/y}{dx/x}$$

Aproximando a incrementos (válido sólo para Δx pequeños)

$$\beta_1 \approx \frac{\Delta y/y}{\Delta x/x} = \frac{100 \cdot \Delta y/y}{100 \cdot \Delta x/x} = \frac{\% \Delta y}{\% \Delta x} = \text{elasticidad}$$

$\Rightarrow \beta_1$ es una **elasticidad**



3. Unidades de medida y forma funcional

3.2 Formas funcionales

Modelos que incluyen variables en logaritmos:

- **Modelo log-nivel:** $\ln y = \beta_0 + \beta_1 x + \varepsilon$

$$\text{Derivando: } \beta_1 = \frac{d \ln y}{dx} = \frac{dy/y}{dx}$$

Aproximando a incrementos (válido sólo para Δx pequeños)

$$\beta_1 \approx \frac{\Delta y/y}{\Delta x}$$

Multiplicando por 100 para expresar la variación de y en %

$$100 \cdot \beta_1 \approx \frac{100 \cdot \Delta y/y}{\Delta x} \Rightarrow 100 \cdot \beta_1 \approx \frac{\% \Delta y}{\Delta x} = \text{semielasticidad}$$

3. Unidades de medida y forma funcional

3.2 Formas funcionales

Modelos que incluyen variables en logaritmos:

- **Modelo nivel-log:** $y = \beta_0 + \beta_1 \ln x + \varepsilon$

$$\text{Derivando: } \beta_1 = \frac{dy}{d \ln x} = \frac{dy}{dx/x}$$

Aproximando a incrementos (válido sólo para Δx pequeños)

$$\beta_1 \approx \frac{\Delta y}{\Delta x/x}$$

Dividiendo por 100 para expresar la variación de x en %

$$\frac{\beta_1}{100} \approx \frac{\Delta y}{100 \cdot \Delta x/x} \Rightarrow \frac{\beta_1}{100} \approx \frac{\Delta y}{\% \Delta x} = \text{semielasticidad}$$

3. Unidades de medida y forma funcional

3.2 Formas funcionales

Ejemplo numérico:

- $\ln \hat{y} = 2 + 0,05x$

Si $\Delta x = 1 \Rightarrow \Delta \hat{y}\% \approx (0.05 \cdot 100)\% = 5\%$

- $\hat{y} = 2 + 70 \ln x$

Si $\Delta x\% = 1\% \Rightarrow \Delta \hat{y} \approx (70 / 100) = 0.7$ unidades

- $\ln \hat{y} = 2 - 2 \ln x$

Si $\Delta x\% = 1\% \Rightarrow \Delta \hat{y}\% \approx -2\%$



3. Unidades de medida y forma funcional

3.2 Formas funcionales

Funciones cuadráticas:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \varepsilon$$

- Permiten captar efectos marginales crecientes o decrecientes
- El **efecto marginal** de x sobre y es:

$$\frac{dy}{dx} = \beta_1 + 2\beta_2 x$$

Es creciente cuando $\beta_2 > 0$ y decreciente cuando $\beta_2 < 0$

Aproximando a incrementos: $\frac{\Delta y}{\Delta x} \approx \beta_1 + 2\beta_2 x$

Lo que hemos aprendido:

- Definir e interpretar el modelo de regresión múltiple
- El método de los Mínimos Cuadrados Ordinarios para estimar los coeficientes del modelo
- Interpretar las estimaciones
- Propiedades algebraicas de los estimadores MCO
- Utilizar el R-cuadrado y el R-cuadrado ajustado para medir la bondad del ajuste
- Cambio en las estimaciones MCO cuando cambian las unidades de medida de la variable dependiente o de las variables independientes
- Utilizar el modelo de regresión lineal para modelizar relaciones no lineales entre las variables:
 - o el logaritmo neperiano permite trabajar con modelos de elasticidad constante y de semielasticidad constante
 - o las funcionales cuadráticas permiten captar efectos marginales crecientes o decrecientes