

# INTRODUCCIÓN A LA ECONOMETRÍA

*3er curso LE y LADE*

*Tema 2a*

Dpto. de Econometría y Estadística (EA3)

UPV—EHU

## 2 El Modelo de Regresión Lineal (I). Especificación y Estimación.

## 2.1 Especificación del Modelo de Regresión Lineal General (MRLG).

### Especificación del MRLG (1)

- **Objetivo:** Cuantificar la relación entre:
  - ◆ una variable  $Y$  y
  - ◆ un conjunto de  $K$  variables explicativas  $X_1, X_2, \dots, X_K$ ,
  - ◆ a través de un modelo lineal.
- **Punto de partida:**
  - ◆ un **modelo lineal** :  
 $Y = \beta_0 + \beta_1 X_1 + \dots + \beta_K X_K + u$ ,
  - ◆ una **muestra** de datos de **tamaño**  $T$ :  
 $Y_t, X_{1t}, X_{2t}, \dots, X_{Kt}, t = 1 \dots T$ ,  
donde

$Y_t = t$ -ésima obs de  $Y$ ,

$X_{kt} = t$ -ésima obs de  $X_k, k = 1, 2 \dots K$ .

### Especificación del MRLG (2)

- **MRLG:**

$$Y_t = \beta_0 + \beta_1 X_{1t} + \dots + \beta_K X_{Kt} + u_t, t = 1, 2 \dots T,$$
 cuyos **elementos** son (recuérdese):
  - ◆  $Y$ : variable dependiente ,
  - ◆  $X_k, k = 1 \dots K$ : variables explicativas ,
  - ◆  $\beta_0$ : intercepto,
  - ◆  $\beta_k, k = 1 \dots K$ : coeficientes ( parámetros a estimar),
  - ◆  $u$ : error o perturbación (aleatoria no observable),  
que permite capturar:
    - variables no incluidas en el modelo,
    - comportamiento aleatorio de los agentes económicos,
    - errores de medición, etc.

El modelo

$$Y_t = \beta_0 + \beta_1 X_{1t} + \dots + \beta_K X_{Kt} + u_t, \quad t = 1, 2, \dots, T,$$

supone para cada observación:

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{21} + \dots + \beta_K X_{K1} + u_1$$

$$Y_2 = \beta_0 + \beta_1 X_{12} + \beta_2 X_{22} + \dots + \beta_K X_{K2} + u_2$$

.....

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_K X_{Kt} + u_t$$

.....

$$Y_T = \beta_0 + \beta_1 X_{1T} + \beta_2 X_{2T} + \dots + \beta_K X_{KT} + u_T$$

o de otra manera en forma matricial:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_t \\ \dots \\ Y_T \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 X_{11} + \beta_2 X_{21} + \dots + \beta_K X_{K1} \\ \beta_0 + \beta_1 X_{12} + \beta_2 X_{22} + \dots + \beta_K X_{K2} \\ \dots \\ \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_K X_{Kt} \\ \dots \\ \beta_0 + \beta_1 X_{1T} + \beta_2 X_{2T} + \dots + \beta_K X_{KT} \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_t \\ \dots \\ u_T \end{bmatrix}$$

■ es decir:

$$\begin{matrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_t \\ \dots \\ Y_T \end{bmatrix} \\ Y \\ (T \times 1) \end{matrix} = \begin{matrix} \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{K1} \\ 1 & X_{12} & X_{22} & \dots & X_{K2} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_{1t} & X_{2t} & \dots & X_{Kt} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_{1T} & X_{2T} & \dots & X_{KT} \end{bmatrix} \\ X \\ (T \times (K+1)) \end{matrix} \begin{matrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{pmatrix} \\ \beta \\ (K+1 \times 1) \end{matrix} + \begin{matrix} \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_t \\ \dots \\ u_T \end{bmatrix} \\ u \\ (T \times 1) \end{matrix}$$

■

$$Y = X\beta + u.$$

¶

## 2.2 Supuestos Básicos (Clásicos) . Interpretación.

## Supuestos Básicos del MRLG (1)

### 1. Supuestos sobre la relación:

- El modelo está **correctamente especificado**:  
 $X_k$  explica  $Y \Leftrightarrow X_k \in \text{modelo}$ .

### 2. Supuestos sobre los parámetros:

- son **constantes** a lo largo de la muestra,
- aparecen **de forma lineal** (es decir una constante más coeficientes)
  - $Y_t = \beta_0 + \beta_1 X_t + u_t$
- Nota: pero las vars  $Y, X_1, X_2, \dots$  pueden ser transformaciones:
  - $Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_t^2 + \beta_3 \frac{1}{X_t} + u_t$
  - $Y_t = A X_{1t}^{\beta_1} X_{2t}^{\beta_2} e^{u_t}$  (¿Por qué?)
  - ¿y éste?  $Y_t = \beta_0 + \beta_1 \frac{1}{X_t - \beta_2} + u_t$
  - ¿y estos otros?  $\ln Y_t = \beta_0 X_t^{\beta_1} u_t; \quad Y_t = \beta_0 X_t^{\beta_1} + u_t$   
 $Y_t = \beta_1 X_{1t} + \beta_2 X_{1t} X_{2t} + u_t; \quad Y_t = \beta_0 + \beta_1 X_{1t}^{X_{2t}} + u_t$

## Supuestos Básicos del MRLG (2)

### 3. Supuestos sobre las variables explicativas:

- $X_1, \dots, X_K$ , son **cuantitativas y fijas** (es decir no aleatorias).
  - $X_1, \dots, X_K$ , son **linealmente independientes**:
    - $\nexists X_k | X_k = \text{comb. lin. de otros}$  (¿por qué?)
- <2>Ejemplos de casos **no** válidos:
    - $Y_t = \beta_0 + \beta_1 X_t + \beta_2 (2X_t + 3) + u_t$
    - $Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 (X_{1t} + X_{2t}) + u_t$
  - <2>Ejemplos de casos **válidos**:
    - $Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_t^2 + u_t$
    - $Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{1t} X_{2t} + u_t$

## Supuestos Básicos del MRLG (3)

### 4. Supuestos sobre el término de perturbación:

- Media cero**:  
 $E(u_t) = 0 \quad \forall t$  (¿no es obvio?).
  - Homocedástico**:  
 $\text{Var}(u_t) = E(u_t^2) = \sigma_u^2 (= \sigma^2) \quad \text{const} (\forall t)$ .
  - Serialmente incorrelacionado**:  
 $\text{Cov}(u_t, u_s) = E(u_t u_s) = 0 \quad \forall t \neq s$ .
  - Distribución normal<sup>(\*)</sup>**:  
 $u_t \sim \mathcal{N} \quad \forall t$ . (\* añadido)
- Supuestos 4a–4d conjuntamente:

$$u_t \sim \text{iid } \mathcal{N}(0, \sigma_u^2)$$

## Supuestos Básicos en forma matricial (1)

- de 4a: **Vector de medias**:

$$E(u) = \begin{matrix} (T \times 1) \\ \begin{bmatrix} E(u_1) \\ E(u_2) \\ \vdots \\ E(u_T) \end{bmatrix} \end{matrix} = \begin{matrix} \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \end{matrix} = 0_T$$

- de 4b y 4c: **Matriz de Covarianzas**:

$$E(uu') = \begin{matrix} (T \times T) \\ \begin{bmatrix} E(u_1^2) & E(u_1 u_2) & \dots & E(u_1 u_T) \\ E(u_2 u_1) & E(u_2^2) & \dots & E(u_2 u_T) \\ \dots & \dots & \dots & \dots \\ E(u_T u_1) & E(u_T u_2) & \dots & E(u_T^2) \end{bmatrix} \end{matrix}$$

$$= \begin{matrix} \begin{bmatrix} \sigma_u^2 & 0 & \dots & 0 \\ 0 & \sigma_u^2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \sigma_u^2 \end{bmatrix} \end{matrix} = \sigma_u^2 I_T$$

## Supuestos Básicos en forma matricial (2)

- de manera más compacta:

$$u \sim \begin{pmatrix} 0 \\ \sigma_u^2 I_T \end{pmatrix}$$

$(T \times 1)$                    $(T \times 1)$      $(T \times T)$

- plus 4d:

$$u \sim \mathcal{N} \left( \begin{matrix} 0 \\ \sigma_u^2 I_T \end{matrix} \right)$$

$(T \times 1)$                    $(T \times 1)$      $(T \times T)$

## 2.3a Mínimos Cuadrados Ordinarios (MCO) en el Modelo de Regresión Lineal Simple (MRLS).

## MRLS: la FRP

- Con  $K = 1 \rightsquigarrow Y_t = \beta_0 + \beta_1 X_{1t} + u_t$ ,

$$\text{(MRLS): } Y_t = \alpha + \beta X_t + u_t. \quad (1)$$

- Función de Regresión Poblacional (FRP):  
 $E(u_t) = 0 \rightsquigarrow$  *parte sistemática* o FRP:

$$E(Y_t) = \alpha + \beta X_t$$

- Interpretación de los parámetros:

- $\alpha = E(Y_t | X_t = 0)$ : Valor esperado de  $Y_t$  cuando la variable explicativa es cero.

- $\beta = \frac{\partial E(Y_t)}{\partial X_t} \simeq \frac{\Delta E(Y_t)}{\Delta X_t}$ : Incremento en el valor (esperado) de  $Y_t$  cuando  $X \uparrow$  una unidad (c.p.).

- Objetivo: obtener estimaciones  $\hat{\alpha}, \hat{\beta}$  de los parámetros desconocidos  $\alpha, \beta$  en (1).

## Función de Regresión Muestral (FRM)

- $\hat{\alpha}, \hat{\beta} \rightsquigarrow$  modelo estimado o FRM:

$$\hat{Y}_t = \hat{\alpha} + \hat{\beta} X_t$$

- Interpretación de las estimaciones:

- $\hat{\alpha} = (\hat{Y}_t | X_t = 0)$ : Valor estimado de  $Y_t$  cuando la variable explicativa es cero.

- $\hat{\beta} = \frac{\partial \hat{Y}_t}{\partial X_t} \simeq \frac{\Delta \hat{Y}_t}{\Delta X_t}$ : Incremento estimado en  $Y_t$  cuando  $X \uparrow$  una unidad (c.p.).

- Nótese la diferencia: un estimador (una fórmula) frente a una estimación (un número).

## Perturbaciones frente a Residuos

- **Perturbaciones** en FRP:

$$u_t = Y_t - E(Y_t) = Y_t - \alpha - \beta X_t$$

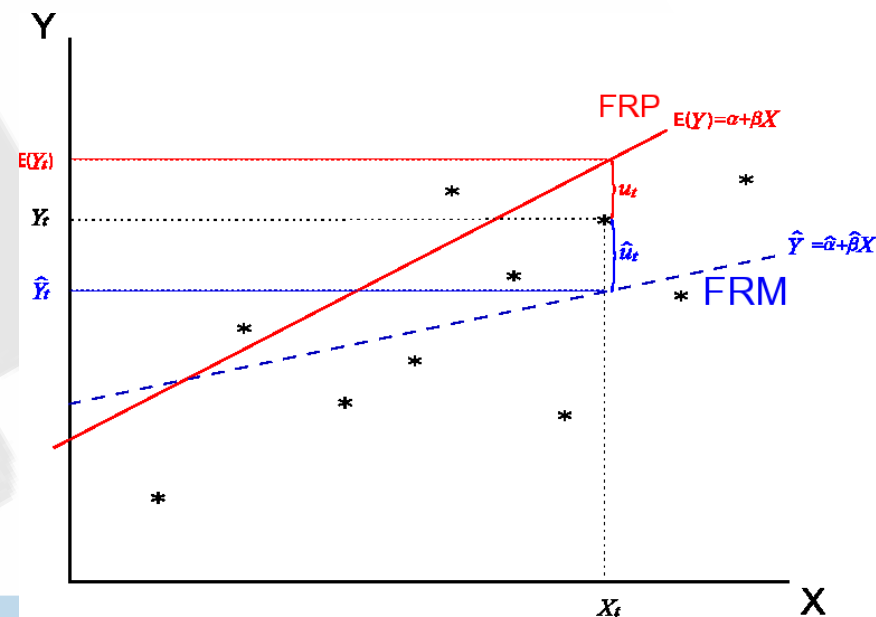
- **Residuos** en FRM:

$$\hat{u}_t = Y_t - \hat{Y}_t = Y_t - \hat{\alpha} - \hat{\beta} X_t$$

- Los **Residuos** son a la **FRM**

lo que las **perturbaciones** son a la **FRP**.

## MRLS: FRP y FRM




## Estimación: Propiedades Deseadas (1)

Sea  $\hat{\beta}$  un estimador de  $\beta$ ...

**Insesgadez:**

$$E(\hat{\beta}) = \beta \Leftrightarrow \hat{\beta} \text{ insesgado}$$




## Estimación: Propiedades Deseadas (2)

Sean  $\hat{\beta}$  y  $\tilde{\beta}$  dos estimadores insesgados de  $\beta$ ...

**Eficiencia relativa:**

$$\text{Var}(\hat{\beta}) \leq \text{Var}(\tilde{\beta}) \Leftrightarrow \hat{\beta} \text{ relativamente eficiente}$$



## Estimación: criterio MCO

- $\langle 1 \rangle$  MRLS:  $Y_t = \alpha + \beta X_t + u_t$ ,
- aplicar ajuste **Mínimo-Cuadrático**:

$$\min_{\alpha, \beta} \sum_{t=1}^T u_t^2 \quad \text{donde} \quad u_t = Y_t - \alpha - \beta X_t :$$

- **Primeras derivadas:**

$$\diamond \quad \frac{\partial \sum u_t^2}{\partial \alpha} = 2 \sum u_t \frac{\partial u_t}{\partial \alpha} = 2 \sum u_t (-1)$$

$$\diamond \quad \frac{\partial \sum u_t^2}{\partial \beta} = 2 \sum u_t \frac{\partial u_t}{\partial \beta} = 2 \sum u_t (-X_t)$$

- **c.1<sup>er</sup>o. (mínimo)**  $\Rightarrow$  primeras derivadas son cero:

$$\diamond \quad \sum \hat{u}_t = \sum (Y_t - \hat{\alpha} - \hat{\beta} X_t) = 0$$

$$\diamond \quad \sum \hat{u}_t X_t = \sum (Y_t X_t - \hat{\alpha} X_t - \hat{\beta} X_t^2) = 0$$

Estimación: Ecuaciones normales y EMC de  $\alpha$ 

- De las c.1<sup>er</sup>o. anteriores:

$$\begin{aligned} \sum (Y_t - \hat{\alpha} - \hat{\beta} X_t) &= 0 \\ \sum (Y_t X_t - \hat{\alpha} X_t - \hat{\beta} X_t^2) &= 0 \end{aligned}$$

- obtenemos las **Ecuaciones Normales**:

$$\left. \begin{aligned} \sum Y_t &= T\hat{\alpha} + \hat{\beta} \sum X_t \\ \sum Y_t X_t &= \hat{\alpha} \sum X_t + \hat{\beta} \sum X_t^2 \end{aligned} \right\} \begin{array}{l} \text{¡sistema de } 2 \\ \text{ecuaciones con } 2 \\ \text{incógnitas!!} \end{array}$$

- $\langle 1 \rangle$  Dividiendo la 1<sup>a</sup> ec. normal por  $T$ :

$$\frac{1}{T} \sum Y_t = \frac{1}{T} T\hat{\alpha} + \hat{\beta} \frac{1}{T} \sum X_t$$

- Es decir:

$$\hat{\alpha}_{MCO} = \bar{Y} - \hat{\beta} \bar{X}$$

Estimación: Ecuaciones normales y EMC de  $\beta$ 

- Sustituyendo  $\hat{\alpha}$  en la 2<sup>a</sup> ec. normal:

$$\sum Y_t X_t = (\bar{Y} - \hat{\beta} \bar{X}) \sum X_t + \hat{\beta} \sum X_t^2$$

- ... dividiendo por  $T$  y agrupando términos:

$$\frac{1}{T} \sum Y_t X_t = (\bar{Y} - \hat{\beta} \bar{X}) \frac{1}{T} \sum X_t + \hat{\beta} \frac{1}{T} \sum X_t^2$$

$$\frac{1}{T} \sum Y_t X_t - \bar{Y} \bar{X} = \hat{\beta} \left( \frac{1}{T} \sum X_t^2 - \bar{X}^2 \right)$$

- ... y despejando la incógnita:

$$\hat{\beta} = \frac{\frac{1}{T} \sum Y_t X_t - \bar{Y} \bar{X}}{\frac{1}{T} \sum X_t^2 - \bar{X}^2} = \frac{\frac{1}{T} \sum y_t x_t}{\frac{1}{T} \sum x_t^2} \quad \left[ \begin{array}{l} \text{¿Por qué?} \\ \text{¿Por qué?} \end{array} \right] \rightarrow$$

- Es decir:

$$\hat{\beta}_{MCO} = \frac{\sum y_t x_t}{\sum x_t^2} = \frac{\text{Cov}(Y, X)}{\text{Var}(X)}$$

## Recuérdese: ¿varianzas y covarianzas?

- ¿varianza de los datos originales (no centrados)?

$$\begin{aligned} \text{Var}(X) &= \frac{1}{T} \sum x_t^2 = \frac{1}{T} \sum (X_t - \bar{X})^2 \\ &= \frac{1}{T} \sum X_t^2 + \frac{1}{T} \sum \bar{X}^2 - \frac{2}{T} \bar{X} \sum X_t \end{aligned}$$

$$\frac{1}{T} \sum x_t^2 = \frac{1}{T} \sum X_t^2 - \bar{X}^2$$

- ¿covarianza de los datos originales (no centrados)?

$$\begin{aligned} \text{Cov}(Y, X) &= \frac{1}{T} \sum x_t y_t = \frac{1}{T} \sum (X_t - \bar{X})(Y_t - \bar{Y}) \\ &= \frac{1}{T} \sum X_t Y_t + \frac{1}{T} \sum \bar{X} \bar{Y} - \frac{1}{T} \bar{Y} \sum X_t - \frac{1}{T} \bar{X} \sum Y_t \end{aligned}$$

$$\frac{1}{T} \sum x_t y_t = \frac{1}{T} \sum X_t Y_t - \bar{X} \bar{Y}$$

## Ejemplo numérico : datos de prod de fresas


- Datos...
- Datos centrados o "en desviaciones" (desviaciones de las medias respectivas)...
- Cuadrados y productos...

	Y	X	y	x	y <sup>2</sup>	x <sup>2</sup>	yx
	40	10	-30	-40	900	1600	1200
	60	25	-10	-25	100	625	250
	50	40	-20	-10	400	100	200
	70	45	0	-5	0	25	0
	90	60	20	10	400	100	200
	80	80	10	30	100	900	300
	100	90	30	40	900	1600	1200
Suma					2800	4950	3350
Media	70	50	0	0	400	707.14	478.57

$$\hat{\alpha} = 36,162 (= \bar{Y} - \hat{\beta}\bar{X}) \qquad \hat{\beta} = 0,677 \left( = \frac{\text{Cov}(Y, X)}{\text{Var}(X)} \right)$$

Se puede utilizar formulas basados en los datos originales... (Ejercicio: ¡Inténtalo!!)

## Ejemplo numérico: gráfico regresión fresas



## 2.4a Propiedades de la Función de Regresión Muestral.

## Propiedades de los residuos y la FRM (1)

$$\hat{\beta}_{\text{MCO}} \rightsquigarrow \hat{\alpha}_{\text{MCO}} \rightsquigarrow \hat{Y}_t = \hat{\alpha} + \hat{\beta}X_t \rightsquigarrow \hat{u}_t = Y_t - \hat{Y}_t$$

- residuos suman cero:  $\sum \hat{u}_t = 0$   
**Demo:** directamente de las c.1<sup>er</sup>o. □
- $\bar{\hat{Y}} = \bar{Y}$   
**Demo:** por def.:  $\hat{u}_t = Y_t - \hat{Y}_t \rightsquigarrow \bar{\hat{Y}} = \bar{Y} - \bar{\hat{u}}$ ,  
pero  $\bar{\hat{u}} = \frac{1}{T} \sum \hat{u}_t = 0$  (de prop 1)  $\rightsquigarrow \bar{\hat{Y}} = \bar{Y}$ . □
- la FRM pasa por el par de medias  $(\bar{X}, \bar{Y})$ :  
 $\bar{Y} = \hat{\alpha} + \hat{\beta}\bar{X}$   
**Demo:** de  $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$  (1<sup>a</sup> ec. normal) □



## Propiedades de los residuos y la FRM (2)

4. residuos ortogonales a v. expl.  $X$ :  $\sum X_t \hat{u}_t = 0$

*Demo:* directamente de las c.1<sup>er</sup> o.

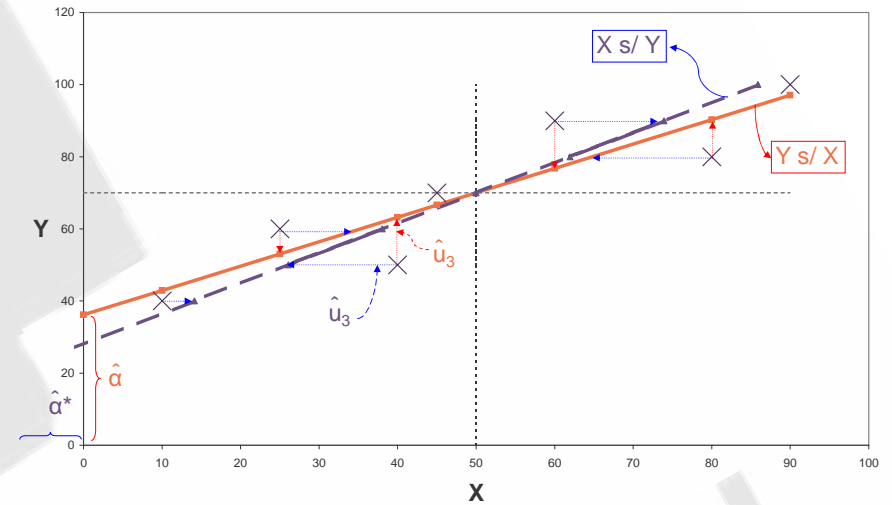
5. residuos ortogonales a la parte explicada de  $Y$ :  $\sum \hat{Y}_t \hat{u}_t = 0$

*Demo:*  $\sum (\hat{\alpha} + \hat{\beta} X_t) \hat{u}_t =$

$$\hat{\alpha} \underbrace{\sum \hat{u}_t}_{=0 \text{ (de prop 1)}} + \hat{\beta} \underbrace{\sum X_t \hat{u}_t}_{=0 \text{ (de prop 4)}} = 0$$



## Causalidad: Y sobre X frente a X sobre Y



## Propiedades de los residuos y FRM (5)

8.  $\hat{\alpha}_{MCO}$  y  $\hat{\beta}_{MCO}$  insesgados  $\rightsquigarrow$  ¡valor esperado = valor verdadero!

9.  $\langle 2 \rangle$  *Demo:*

$$\hat{\beta} = \frac{\sum y_t x_t}{\sum x_t^2}$$

$$E(\hat{\beta}) = \frac{1}{\sum x_t^2} \sum \underbrace{E(y_t)}_{\beta x_t} x_t = \frac{1}{\sum x_t^2} \beta \sum x_t^2$$

$$E(\hat{\beta}) = \beta$$

$$\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$

$$E(\hat{\alpha}) = \frac{1}{T} \sum E(Y_t) - E(\hat{\beta}) \bar{X}$$

$$= \frac{1}{T} \sum (\alpha + \beta X_t) - \beta \bar{X} = \alpha + \beta \bar{X} - \beta \bar{X}$$

$$E(\hat{\alpha}) = \alpha$$



## 2.5a Bondad de Ajuste: Coeficiente de Determinación ( $R^2$ ).

## Bondad de Ajuste: Coeficiente de determinación

- Descomposición de la Suma de Cuadrados:

$$\begin{aligned} \sum Y_t^2 &= \sum (\hat{Y}_t^2 + \hat{u}_t^2 + 2\hat{Y}_t\hat{u}_t) \\ &= \sum \hat{Y}_t^2 + \sum \hat{u}_t^2 \quad (\text{de prop 5}) \end{aligned}$$

- $\sum Y_t^2 - T\bar{Y}^2 = \sum \hat{Y}_t^2 - T\bar{\hat{Y}}^2 + \sum \hat{u}_t^2$  (de prop 2)

$$\sum y_t^2 = \underbrace{\sum \hat{y}_t^2}_{(SCE)} + \underbrace{\sum \hat{u}_t^2}_{(SCR)}$$

- Definición de  $R^2$ :

$$R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT}$$

$0 \leq R^2 \leq 1$  (¿Interpretación en términos de la varianza total??)

## No intercepto $\rightsquigarrow$ inválido $R^2$

- $<1>[]$  MRLS:  $Y_t = \beta X_t + u_t$ ,
- aplicar el ajuste **Mínimo-Cuadrático**:

$$\min_{\beta} \sum_{t=1}^T u_t^2 \quad \text{donde} \quad u_t = Y_t - \beta X_t :$$

- Primeras derivadas:

$$\frac{\partial \sum u_t^2}{\partial \beta} = 2 \sum u_t \frac{\partial u_t}{\partial \beta} = 2 \sum u_t (-X_t)$$

- c.1<sup>er</sup>o. (mínimo)  $\Rightarrow$  primera derivada = cero:

$$\sum \hat{u}_t X_t = \sum (Y_t X_t - \hat{\beta} X_t^2) = 0$$

- 

!  $\neq$  1<sup>a</sup> ecuación!!  $\rightsquigarrow$   $\begin{cases} \sum \hat{u}_t \neq 0, \\ \bar{\hat{Y}} \neq \bar{Y}, \end{cases} \rightsquigarrow R^2 \text{ inválido (¿Por qué?)}$

## Relación de $R^2$ con el coef de correlación

$$\begin{aligned} R^2 &= \frac{\frac{1}{T} \sum \hat{y}_t^2}{\frac{1}{T} \sum y_t^2} = \frac{\frac{1}{T} \sum (\hat{\beta} x_t)^2}{\frac{1}{T} \sum y_t^2} = \frac{\hat{\beta}^2 \frac{1}{T} \sum x_t^2}{\frac{1}{T} \sum y_t^2} \\ &= \hat{\beta}^2 \frac{\text{Var}(X)}{\text{Var}(Y)} = \frac{\text{Cov}(Y, X)^2}{\text{Var}(X)^2 \text{Var}(Y)} \\ &= \frac{\text{Cov}(Y, X)^2}{\text{Var}(X) \text{Var}(Y)} \end{aligned}$$

$$R^2 = r_{X,Y}^2$$

## Ejemplo numérico: datos de prod fresas (cont)

- recuérdese datos y cálculos previos...
- hacer lo mismo para valores ajustados...
- ahora calcular  $R^2$ ...

	$y^2$	$\hat{Y}$	$\hat{y}$	$\hat{y}^2$	$\hat{u}$	$\hat{u}^2$
	900	42.92	-27.07	732.82	-2.92	8.58
	100	53.08	-16.91	286.25	6.91	47.87
	400	63.23	-6.76	45.80	-13.23	175.09
	0	66.61	-3.38	11.45	3.38	11.45
	400	76.76	6.76	45.80	13.23	175.09
	100	90.30	20.30	412.21	-10.30	106.15
	900	97.07	27.07	732.82	2.92	8.58
Media	400	70	0	323.88		
Suma	2800			2267.17		532.82
	SCT			SCE		SCR

$$R^2 = 0,8097 (= \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT})$$

(Ejercicio: ¿Cómo compara esto con  $\text{Corr}(X, Y)$ ? ... ¡Inténtalo!!)