


# EXTENSIÓN DEL MODELO DE REGRESIÓN LINEAL DE DOS VARIABLES

## REGRESIÓN A TRAVÉS DEL ORIGEN



**“A MENOS QUE EXISTA UNA EXPECTATIVA A PRIORI MUY FUERTE ES ACONSEJABLE APEGARSE AL MODELO CONVENCIONAL CON PRESENCIA DE INTERSECCIÓN”**

## ¿QUÉ OCURRE CON LOS MODELOS SIN INTERCEPTO?

- Si el modelo que se va a estimar teóricamente debe llevar intersección y ésta no se incluye, se puede cometer un error de especificación y con ello violar un supuesto del MCRL, dando origen a estimadores **NO MELI**.
- La  $\sum \hat{\varepsilon}_i$  que siempre es cero en modelos con intercepto puede no serlo cuando está ausente  $\hat{\beta}_1$ . Es decir que los residuos ya no tienen media muestral igual a cero  $E(\varepsilon_i|X_i) \neq 0$ .
- El coeficiente de determinación ( $R^2$ ) que siempre es no negativo podría llegar a ser negativo, por tanto el coeficiente de determinación convencional no resulta adecuado para evaluar la bondad de ajuste del modelo. Para ello se utiliza el  $R^2$  simple, que se interpreta de la manera ya conocida pero no se puede comparar con el  $R^2$  tradicional.

$$R^2 \text{ simple} = \frac{(\sum X_i Y_i)^2}{\sum X_i^2 \sum Y_i^2}$$

- Si en el modelo poblacional el intercepto es diferente de cero, y se usa un modelo muestral con  $\hat{\beta}_1 = 0$ , los estimadores MCO de la pendiente estarán sesgados.
- El costo de estimar  $\hat{\beta}_1$  cuando realmente  $\beta_1 = 0$ , es que las varianzas de los estimadores MCO son mayores (no mínimas).

En resumen:

MODELO CON INTERCEPTO	MODELO SIN INTERCEPTO
$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{u}_i$	$Y_i = \hat{\beta}_2 X_i + \hat{u}_i$
$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2}$	$\hat{\beta}_2 = \frac{\sum X_i Y_i}{\sum X_i^2}$
$Var(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2}$	$Var(\hat{\beta}_2) = \frac{\sigma^2}{\sum X_i^2}$
$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n - 2}$	$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n - 1}$

“Si la intercepción efectivamente está ausente, el coeficiente de la pendiente puede ser estimado con mucha más precisión que cuando el término de la intersección está incluido” H. Theil (1978)

**Ejemplo 1<sup>1</sup>:** Considere el modelo de asignación de precios de activos de capital (CAMP) de la teoría moderna de portafolios, expresada

$$(ER_i - r_f) = \beta_i(ER_m - r_f) \quad (2)$$

El modelo puede expresarse como:

$$R_i - r_f = \beta_i(R_m - r_f) + u_i$$

$$R_i - r_f = \alpha_i + \beta_i(R_m - r_f) + u_i \quad \text{MODELO DEL MERCADO}$$

Si se cumple el CAMP, entonces  $\alpha_i = 0$

La siguiente regresión muestra los datos referentes a los rendimientos excedentes ( $Y_t$ ) en %, de índice de 104 acciones del sector de bienes de consumo cíclico y los rendimientos excedentes ( $X_t$ ) en % del índice de todo el mercado de valores del Reino Unido para 1980:01-1999:12

<sup>1</sup> Revisar Haim Levy y Marsahall Sarnta, (1984). *Portfolio and Investment Selection: Theory and Practice*. Cap. 14

<sup>2</sup>  $ER_i$ : tasa esperada de rendimiento del título  $i$ .  $ER_m$ : tasa esperada del rendimientos del portafolios del mercado como se representa.  $r_f$ : tasa de rendimiento libre de riesgo.  $B_i$ : coeficiente BETA (medida de riesgo sistemático, es decir, riesgo que no se ha eliminado con la diversificación)

## Coefficients:

## Estimate Std. Error t value Pr(>|t|)

## Xt 1.1555 0.0744 15.53 <2e-16 \*\*\*

## ---

## Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

##

## Residual standard error: 5.549 on 239 degrees of freedom

## Multiple R-squared: 0.5023, Adjusted R-squared: 0.5003

## F-statistic: 241.2 on 1 and 239 DF, p-value: < 2.2e-16

## Coefficients:

## Estimate Std. Error t value Pr(>|t|)

## (Intercept) -0.44748 0.36294 -1.233 0.219

## Xt 1.17113 0.07539 15.535 <2e-16 \*\*\*

## ---

## Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

##

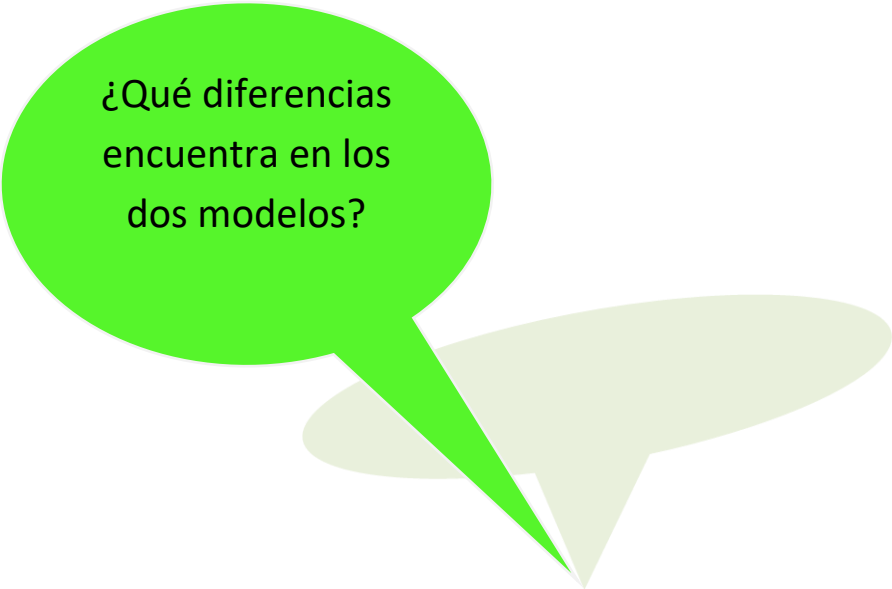
## Residual standard error: 5.543 on 238 degrees of freedom

## Multiple R-squared: 0.5035, Adjusted R-squared: 0.5014

## F-statistic: 241.3 on 1 and 238 DF, p-value: < 2.2e-16

Prof. Laura Castillo

Econometría I



¿Qué diferencias encuentra en los dos modelos?

Capítulo 6. Tema III


**Ejemplo 2:** PIB en millones e inversión doméstica privada bruta millones (GPDIM), EEUU 1988-1997.

Dependent Variable: PIB  
Sample: 1988 1997

Variable	Coefficient	Std. Error	t-Statistic	Prob.
GPDIM	0.007259	0.001385	5.240237	0.0005
R-squared	-54.203821	Mean dependent var		6.440900
Adjusted R-squared	-54.203821	S.D. dependent var		0.455016
S.E. of regression	3.380733	Akaike info criterion		5.368702
Sum squared resid	102.8642	Schwarz criterion		5.398960
Log likelihood	-25.84351	Hannan-Quinn criter.		5.335508
Durbin-Watson stat	0.550763			

Dependent Variable: PIB  
Sample: 1988 1997

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7.018338	0.245104	28.63408	0.0000
GPDIM	-0.000840	0.000318	-2.645248	0.0295
R-squared	0.466572	Mean dependent var		6.440900
Adjusted R-squared	0.399894	S.D. dependent var		0.455016
S.E. of regression	0.352485	Akaike info criterion		0.929238
Sum squared resid	0.993965	Schwarz criterion		0.989755
Log likelihood	-2.646191	Hannan-Quinn criter.		0.862851
F-statistic	6.997338	Durbin-Watson stat		0.724787
Prob(F-statistic)	0.029472			



## ESCALAS Y UNIDADES DE MEDICIÓN

Los cambios en las escalas y en las unidades de medida se realizan con la finalidad expresar números en menores cantidades que permitan ser manejados fácilmente.

$$\text{Sea } Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{\varepsilon}_i \quad (1)$$

$$\begin{aligned} \text{Defina: } Y_i^* &= w_1 Y_i \\ X_i^* &= w_2 X_i \\ \hat{\varepsilon}_i^* &= w_1 \hat{\varepsilon}_i \end{aligned}$$

$w_1$  y  $w_2$  Se denominan **FACTORES DE ESCALA** ( $w_1 = \text{ó} \neq w_2$ )

$$Y_i^* = \hat{\beta}_1^* + \hat{\beta}_2^* X_i^* + \hat{\varepsilon}_i^* \quad (2)$$

Aplicando en método de MCO a (2) se obtiene:

$$\hat{\beta}_1^* = \bar{Y}^* - \hat{\beta}_2^* \bar{X}^*$$

$$\hat{\beta}_2^* = \frac{\sum x_i^* y_i^*}{\sum x_i^{*2}}$$

$$\text{Var}(\hat{\beta}_1^*) = \frac{\sum X_i^{*2}}{n \sum x_i^{*2}} \sigma^{*2}$$

$$\text{Var}(\hat{\beta}_2^*) = \frac{\sigma^{*2}}{\sum x_i^{*2}}$$

$$\sigma^{*2} = \frac{\sum \hat{\varepsilon}_i^{*2}}{n - k}$$

Se pueden establecer las relaciones entre los dos conjuntos de parámetros estimados:

$$\hat{\beta}_2^* = \left(\frac{w_1}{w_2}\right) \hat{\beta}_2$$

$$\hat{\beta}_1^* = w_1 \hat{\beta}_1$$

$$\sigma^{*2} = w_1^2 \hat{\sigma}^2$$

$$\text{Var}(\hat{\beta}_1^*) = w_1^2 \text{Var}(\hat{\beta}_1)$$

$$\text{Var}(\hat{\beta}_2^*) = \left(\frac{w_1}{w_2}\right)^2 \text{Var}(\hat{\beta}_2)$$

$$R^2_{xy} = R^2_{x^*y^*}$$



*Cambios en el origen:*

$$Y_i^* = a + Y_i$$

$$X_i^* = b + X_i$$

Si ( $a = 0$  ó  $b \neq 0$ )

$$\hat{\beta}_2^* = \hat{\beta}_2$$

$$\rho_{xy} = \rho_{x^*y^*}$$

**“LA TRANSFORMACION DE LA ESCALA  
(Y, X) A LA ESCALA (Y\*, X\*) NO AFECTA  
LAS PROPIEDADES DE LOS  
ESTIMADORES MCO”**

**Ejemplo 2:** Inversión doméstica privada bruta (GPDIBL) en función del PIB (GDPB), ambos en miles de millones de dólares del 2000, EEUU 1990-2005.

```
## Call:
## lm(formula = GPDIBL ~ GDPB)
##
## Residuals:
##   Min     1Q   Median     3Q      Max
## -7.346 -3.746  0.500  3.441  7.346
##
## Coefficients:
##           Estimate Std. Error t value Pr(>|t|)
## (Intercept) 11.1250   2.4580   4.526  0.000475 ***
## GDPB       -0.3088   0.2542  -1.215  0.244499
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.687 on 14 degrees of freedom
## Multiple R-squared:  0.09537, Adjusted R-squared:  0.03076
## F-statistic: 1.476 on 1 and 14 DF, p-value: 0.2445
```

Inversión doméstica privada bruta (GPDIM) en función del PIB (GDPPM) ambos en millones de dólares, EEUU 1990-2005.

## Call:

## lm(formula = GPDIM ~ GDPPM)

##

## Residuals:

## Min 1Q Median 3Q Max

## -7.346 -3.746 0.500 3.441 7.346

##

## Coefficients:

## Estimate Std. Error t value Pr(>|t|)

##(Intercept) 11.1250 2.4580 4.526 0.000475 \*\*\*

## GDPPM -0.3088 0.2542 -1.215 0.244499

## ---

## Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

##

## Residual standard error: 4.687 on 14 degrees of freedom

## Multiple R-squared: 0.09537, Adjusted R-squared: 0.03076

## F-statistic: 1.476 on 1 and 14 DF, p-value: 0.2445

## REGRESIÓN SOBRE LAS VARIABLES ESTANDARIZADAS

La influencia que tiene sobre la interpretación de los efectos de las variables las unidades de medida en que éstas sean expresadas, puede evitarse si se expresan ambas variables como *variables estandarizadas*.

Una variable estandarizada se expresa como:

$$Y_i^* = \frac{Y_i - \bar{Y}}{ee_y}$$

$$X_i^* = \frac{X_i - \bar{X}}{ee_x}$$


La propiedad más resaltante de las variables estandarizadas es que el valor de su media siempre es cero y su desviación estándar es siempre 1.

$$Y_i^* \sim (0,1)$$

$$X_i^* \sim (0,1)$$

La regresión con variables estandarizadas queda:

$$Y_i^* = \beta_2^* X_i^* + \varepsilon_i^*$$



¿POR QUÉ?, ¿QUÉ  
PASA CON EL  
COEFICIENTE DEL  
INTERCEPTO?

## PARA TENER EN CUENTA:

- Los coeficientes de regresión de las variables estandarizadas se conocen como coeficientes beta<sup>3</sup>.
- Después de estandarizadas las variables ya no importa las unidades de medida.
- Los coeficientes beta se interpretan en términos de desviaciones estándar, es decir, se mide el efecto en las unidades de la desviación estándar.
- Los coeficientes dentro de la misma ecuación son comparables entre sí. Se pueden utilizar como una medida de fuerza relativa de las distintas regresoras.

---

<sup>3</sup> No se deben confundir estos coeficientes beta con los coeficientes beta de la teoría del portafolio.

#### Ejemplo 4: Regresión de inversión sobre PIB

VARIABLES ORIGINALES					VARIABLES ESTANDARIZADAS				
<b>Matriz de correlación</b>					<b>Matriz de correlación</b>				
	PIB	INV				INV	PIB		
PIB	1.000000	0.164923			INV	1.000000	0.164923		
INV	0.164923	1.000000			PIB	0.164923	1.000000		
Dependent Variable: INV Method: Least Squares					Dependent Variable: INV Method: Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	900.2423	58.96998	15.26611	0.0000	C	-1.33E-10	0.330817	-4.02E-10	1.0000
PIB	0.001281	0.002708	0.472948	0.6489	PIB	0.164923	0.348712	0.472948	0.6489
R-squared	<b>0.027200</b>	Mean dependent var		916.1100	R-squared	<b>0.027200</b>	Mean dependent var		-1.00E-10
Adjusted R-squared	-0.094401	S.D. dependent var		146.5929	Adjusted R-squared	-0.094401	S.D. dependent var		1.000000
S.E. of regression	153.3561	Akaike info criterion		13.08026	S.E. of regression	1.046136	Akaike info criterion		3.104940
Sum squared resid	188144.8	Schwarz criterion		13.14078	Sum squared resid	8.755204	Schwarz criterion		3.165457
Log likelihood	-63.40130	F-statistic		0.223680	Log likelihood	-13.52470	F-statistic		0.223680
Durbin-Watson stat	0.269266	Prob(F-statistic)		0.648885	Durbin-Watson stat	0.269266	Prob(F-statistic)		0.648885

**¿Cómo interpretaría los parámetros estimados de cada regresión?**

## Lecturas obligatorias:

- ✓ Gujarati, D. y Porter, D. (2010). *Econometría*. 5ta. Edición McGraw Hill. Capítulo 6.
- ✓ Wooldridge, J. (2010). *Introducción a la econometría un enfoque moderno*. Capítulos 6.