

Anatomia de MCO

Walter Sosa-Escudero

Universidad de San Andrés, UNLP y CONICET

- $\hat{\beta} = (X'X)^{-1}X'Y$
- Mejor: Gauss/Markov
- Bueno: sesgo varianza

Que hace a MCO: a) sesgado b) impreciso?

Fuente de sesgos

$$Y = X_1\beta_1 + X_2\beta_2 + u$$

- X_1, X_2 , dos variables o dos grupos de variables.
- Interes en β_1 . Regresar Y en X_1 y X_2 .
- Supongamos que regresamos Y en solo X_1 omitiendo X_2 :

$$\hat{\beta}_1^* = (X_1'X_1)^{-1}X_1'Y$$

Omision de variables relevantes

Resultado (Sesgo por variable omitida):

$$E(\hat{\beta}_1^*|X) = \beta_1 + \underbrace{\delta_{21} \beta_2}_{\text{sesgo}}$$

$$\delta_{21} = (X_1' X_1)^{-1} X_1' X_2$$

- δ_{21} ?
- Sesgo: δ_{21} y $\beta_2 \neq 0$
- **Sesgo por omision de variables:** omitir variables relevantes ($\beta_2 \neq 0$) y correlacionadas con las incluidas ($\delta_{21} \neq 0$) sesga al estimador de MCO.

Tatuense esto un brazo.

Prueba:

$$\begin{aligned}\hat{\beta}_1^* &= (X_1' X_1)^{-1} X_1' Y \\ &= (X_1' X_1)^{-1} X_1' (X_1 \beta_1 + X_2 \beta_2 + u) \\ E(\hat{\beta}_1^*) &= \beta_1 + (X_1' X_1)^{-1} X_1' X_2 \beta_2\end{aligned}$$

Idea clave: lo que dejemos fuera del modelo pertenece al termino de error.

Fuentes de imprecision

Imprecision: varianza alta. Resultado: si $V(\hat{\beta}) = \sigma^2(X'X)^{-1}$,

$$V(\hat{\beta}_j) = \frac{\sigma^2}{n (1 - R_j^2) V(X_j)},$$

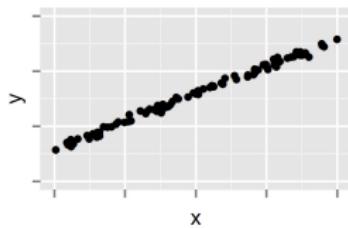
Para un modelo dado, cuatro factores contribuyen a la varianza:

- ① σ^2 : ignorancia.
- ② $V(X_j)$: variabilidad de X_j .
- ③ n : tamaño de muestra
- ④ R_j^2 : multicolinealidad.

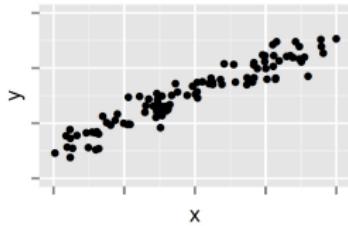
Tatuense esto en un brazo. Dejen lugar para una mas... Dejaremos la demostracion para un curso de posgrado.

Fuentes de impresion: Dos variables

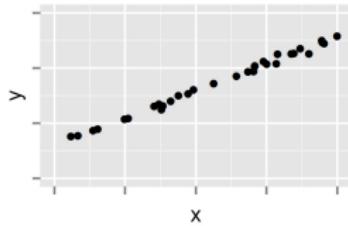
Original



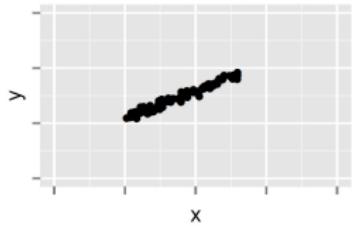
Mayor $V(u)$



Menor n



Menor $V(X)$



Multicolinealidad

$$V(\hat{\beta}_j) = \frac{\sigma^2}{n (1 - R_j^2) V(X_j)}$$

Con K variables, fuente adicional de imprecision: **multicolinealidad**.

- R_j^2 : R^2 de regresar la j -ésima variable en todas las otras variables explicativas.
- Multicolinealidad **exacta**: $R_j^2 = 1$. Viola los supuestos clasicos ($\rho(X) \neq K$). $\hat{\beta}$ no existe.
- Multicolinealidad **alta**: R_j^2 'alto'.
- Cuestion de grado: mayor multicolinealidad, mayor varianza

$$V(\hat{\beta}_j) = \frac{\sigma^2}{n (1 - R_j^2)V(X_j)}$$

- Multicolinealidad alta: modelo poco claro. Muchas variables
- Mayor n compensa multicolinealidad, pero no la resuelve.
- Sacar variables? Peligroso, como veremos a continuacion.

Inclusion de variables irrelevantes

$$Y = X_1\beta_1 + X_2\beta_2 + u$$

Interes en β_1 . Que pasa si sabemos que $\beta_2 = 0$ y asi y todo incluimos X_2 ?: **inclusion de variables irrelevantes.**

- $\hat{\beta}$, MCO de regresar Y en X_1 y X_2 (incluye variables irrelevantes).
- $\hat{\beta}$ es **insesgado**. Bajo supuestos clasicos, $E(\hat{\beta}) = \beta$) para todo β , no importa que uno de sus componentes valga cero.
- $\hat{\beta}$ es **ineficiente**. Por el Teorema de Gauss Markov, el insesgado y eficiente es el que regresa Y en X_1 solamente (basado en el verdadero modelo, ahora con $\beta_2 = 0$)

- **Cuidado:** la inclusion de variables irrelevantes no aparece en nuestra formula de factores que afectan a la varianza. Porque esta refiere a un modelo *dado*.
- La ineficiencia de incluir variables irrelevantes se sigue del Teorema de Gauss/Markov para el modelo correcto.

Omitir variables relevantes:

- Sesga al estimador de MCO, si las variables omitidas son relevantes y correlacionadas con las incluidas.

Incluir variables irrelevantes:

- MCO que incluye X_1 y X_2 , pero es ineficiente (mayor varianza)

Modelos grandes vs chicos

$Y = X_1\beta_1 + X_2\beta_2 + u$, Interes en β_1 . Que hacer con X_2 ?

- $\beta_2 = 0$. Omitir. Por que?
- $\beta_2 \neq 0$
 - $\delta_{21} = 0$, se puede omitir X_2 .
 - $\delta_{21} \neq 0$, incluir X_2 para evitar sesgo.

En la practica, incluir X_2 o no?

Trade-off sesgo/varianza: incluir variables reduce el sesgo pero aumenta la varianza, y viceversa. Modelos chicos, tienden a ser eficientes pero sesgados.

Sesgo por variables omitidas: un ejemplo

Datos ficticios, compatibles con Appleton, French and Vanderpump ("Ignoring a Covariate: an Example of Simpson's Paradox", The American Statistician, 50, 4, 1996)

- Y = riesgo de muerte.
- $SMOKE$ = consumo de cigarrillos.

```
. reg y smoke
```

Source	SS	df	MS	Number of obs	=	100
Model	7613.25147	1	7613.25147	F(1, 98)	=	194.34
Residual	3839.18734	98	39.1753811	Prob > F	=	0.0000
Total	11452.4388	99	115.6812	R-squared	=	0.6648
				Adj R-squared	=	0.6614
				Root MSE	=	6.259

y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
smoke	-1.819348	.1305081	-13.94	0.000	-2.078337 -1.560359
_cons	158.5975	4.774249	33.22	0.000	149.1231 168.0718

```
. reg y smoke age
```

Source	SS	df	MS	Number of obs = 100		
Model	11350.9524	2	5675.47622	F(2, 97)	=	5424.58
Residual	101.486373	97	1.04625126	Prob > F	=	0.0000
				R-squared	=	0.9911
				Adj R-squared	=	0.9910
Total	11452.4388	99	115.6812	Root MSE	=	1.0229

y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
smoke	.9431267	.050902	18.53	0.000	.8421004 1.044153
age	.9804631	.0164039	59.77	0.000	.9479059 1.01302
_cons	12.84084	2.560392	5.02	0.000	7.759169 17.92251

```
. cor y smoke age  
(obs=100)
```

	y	smoke	age
y	1.0000		
smoke	-0.8153	1.0000	
age	0.9797	-0.9080	1.0000

- ① MCO: $\hat{\beta} = (X'X)^{-1}X'Y$
- ② Varianza: $V(\hat{\beta}_j) = \frac{\sigma^2}{n(1-R_j^2)V(X_j)}$
- ③ Sesgo: $E(\hat{\beta}_1^*) = \beta_1 + \delta_{21} \beta_2$