

ANEXO. Demostración de que la varianza residual es mayor en el modelo IIa que en el la

La alta correlación lineal entre x_1 y x_2 significa que puede establecerse un modelo lineal que las relaciona:

$$x_{2i} = (r_{12}\sigma_1 / \sigma_2) x_{1i} + w_i = (\sum x_1 x_2 / \sum x_2^2) x_{1i} + w_i \quad (III)$$

donde σ_1 y σ_2 son las desviaciones típicas de x_1 y x_2 , respectivamente, y el error w_i tiene distribución normal con media 0 y varianza σ_w^2 .

Sustituyendo III en la se obtiene:

$$\begin{aligned} y_i &= \beta_1 x_{1i} + \beta_2 [(\sum x_1 x_2 / \sum x_2^2) x_{1i} + w_i] + u_i = \\ &= [\beta_1 + \beta_2 (\sum x_1 x_2 / \sum x_2^2)] x_{1i} + \beta_2 w_i + u_i = \\ &= \beta_1^* x_{1i} + v_i \quad (IIa) \end{aligned}$$

donde $\beta_1^* = \beta_1 + \beta_2 (\sum x_1 x_2 / \sum x_2^2)$, por lo tanto el sesgo introducido por β_1^* es $\beta_2 (\sum x_1 x_2 / \sum x_2^2)$ como señalan Sáez y Barceló; y $v_i = \beta_2 w_i + u_i$ es normal de media 0 y varianza $\sigma_v^2 = \beta_2^2 \sigma_w^2 + \sigma_u^2 \geq \sigma_u^2$. La igualdad se produce sólo en el caso $\sigma_w^2 = 0$, es decir, cuando x_2 está completamente determinada por x_1 ($r_{12} = 1$)

Respuesta

Correspondencia: Marc Sáez. Departament d'Economia. Universitat de Girona. Campus de Montivili. 17071 Girona.

Recibido: 21 de abril de 1999

Aceptado: 21 de abril de 1999

Hemos leído con sumo interés los comentarios de Llorca¹ a nuestra carta, en la que propusimos un criterio para omitir variables superfluas en modelos de regresión². Como toda réplica que se valga, estamos en parte de acuerdo y en parte en desacuerdo con los contenidos en estos comentarios.

Como bien menciona Llorca, nuestro propósito fue el de proponer un criterio *sencillo*, en el sentido de no considerar incumplimientos o violaciones de las hipótesis básicas del modelo, lo que sin duda complicaría en exceso cualquier discusión. Es bien sabido que la elevada multicolinealidad *no* representa un incumplimiento de *ninguna* de las hipótesis básicas del modelo. En este sentido a veces se ha dicho que la multicolinealidad no es un problema sino una molestia que, por desgracia, siempre se debe soportar. Llorca, plantea modelos en los que se incumple al menos una de las principales hipótesis básicas. Nos referimos en concreto a la existencia de regresores estocásticos.

Así, en su modelo la:

$$y_i = \beta_1 x_{1i} + \beta_2 x_{2i} + u_i \quad (Ia)$$

la variable x_2 es estocástica, por cuanto tal y como la fórmula contiene un error aleatorio:

$$x_{2i} = (\sum x_1 x_2 / \sum x_2^2) x_{1i} + w_i \quad (III)$$

donde el error w_i tiene una distribución normal con media 0 y varianza σ_w^2 .

Pero es que además, los errores u_i y w_i podrían correlacionados. Como consecuencia, el estimador de β_1 no sólo estaría sesgado en (IIa), resultado de la omisión de una variable relevante, *sino también* en (Ia), a causa del incumplimiento de la citada hipótesis básica. Así, Llorca compararía estimadores sesgados por lo que, creemos, no puede deducir ninguna consecuencia relevante.

Por otra parte, y de nuevo parafraseando a Llorca, sus comentarios *contienen un error*. En la última frase del anexo señala que 'la igualdad se produce sólo en el caso $\sigma_w^2=0$, es decir, cuando x_2 está completamente determinada por x_1 ($r_{12}=1$)'. Volviendo a (III) es evidente que aún siendo $\sigma_w^2=0$, el coeficiente de correlación entre ambos regresores puede ser diferente de la unidad. De hecho cuando $\sigma_w^2=0$ (y por tanto $\sigma_v^2=\sigma_u^2$) la variable explicativa x_2 será determinista, el caso que, precisamente, comentamos nosotros.

M. Sáez y M.A. Barceló

Departament d'Economia, Universitat de Girona

Bibliografía

1. Llorca J. Omisión de variables en modelos de regresión con alta multicolinealidad. *Gac Sanit* 1999;13(3):243-4.

2. Sáez M y Barceló MA. Un criterio para omitir variables superfluas en modelos de regresión. *Gac Sanit* 1998;12:281-3.