



Bài giảng 11

BIẾN PHỤ THUỘC ĐỊNH TÍNH

NỘI DUNG

- Các tình huống ứng dụng
- Dạng hàm:
 - Mô hình hàm xác suất tuyến tính (Linear Probability Model – LPM)
 - Mô hình hàm phân phối tích lũy (Cumulative Distribution Function – CDF)
 - Hàm Logit
 - Hàm Probit
- Ứng dụng trên Eviews

Các tình huống


- Cải thiện / không cải thiện năng lực
- Sở hữu nhà / không sở hữu nhà
- Nghèo / không nghèo
- Thành công / không thành công của một chính sách mới
- Tham gia đầu tư / không tham gia đầu tư
- ...

Mô hình LPM

- . $Y_i = 1 \rightarrow$ có mua nhà
- . $Y_i = 0 \rightarrow$ không có mua nhà
- . X_i : Thu nhập của gia đình

Y_i	X_i
1	20000
0	5000
0	4000
1	18000
-	-
-	-

Mô hình LPM



Mô hình LPM

- Dùng phương pháp OLS ta có:

$$Y_i = \beta_1 + \beta_2 X_i + \varepsilon_i \qquad \varepsilon_i = Y_i - \beta_1 - \beta_2 X_i$$


- $\Pr (Y_i = 1 \mid X_i) = P_i \%$
- $\Pr (Y_i = 0 \mid X_i) = (1 - P_i) \%$
- $E[Y_i] = P_i = b_1 + b_2 X_i = \text{Xác suất để có nhà}$

Các vấn đề của mô hình LPM




- Không thỏa mãn điều kiện $0 \leq P_i \leq 1$
- R^2 không còn đo lường tốt độ thích hợp của dữ liệu
- Tác động biên của mô hình thay đổi đều
- $\text{Var}(e_i)$ thay đổi
- e_i không tuân theo phân phối chuẩn

Mô hình hàm phân phối tích lũy CDF



Mô hình hàm Logit



Mô hình hàm Logit

$$P_i = F(Z_i) = F(\beta_1 + \beta_2 X_i) = \frac{1}{1 + e^{-Z_i}} = \frac{1}{1 + e^{-(\beta_1 + \beta_2 X_i)}}$$

$$\left. \begin{aligned} P_i &= \frac{e^{Z_i}}{1 + e^{Z_i}} \\ 1 - P_i &= \frac{1}{1 + e^{Z_i}} \end{aligned} \right\} \frac{P_i}{1 - P_i} = e^{Z_i}$$

Mô hình hàm Logit

$$\ln \frac{P_i}{1-P_i} = \overbrace{\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki}}^{Z_i}$$

Tác động biên

$$\frac{\Delta \hat{P}_i}{\Delta X_i} = \hat{P}_i (1 - \hat{P}_i) \beta_i$$

Dấu của tác động biên phụ thuộc vào dấu của β_i

$$P_i(1 - P_i) > 0$$

Mô hình hàm Logit

Độ lớn của tác động biên:

Ở giá trị X_i ta có $P_i = P_0$.

Khi X_i tăng lên X_{i+1} thì $P_i = P_1 = ?$

$$O_0 = \frac{P_0}{1-P_0} = e^{(\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki})}$$

$$O_1 = \frac{P_1}{1-P_1} = e^{[\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k (X_{ki} + 1)]}$$

$$O_1 = \frac{P_1}{1-P_1} = O_0 e^{\beta_k} \qquad P_1 = \frac{O_0 e^{\beta_k}}{1 + O_0 e^{\beta_k}}$$

Mô hình hàm Logit

Ý nghĩa của β_i :

Trong điều kiện các yếu tố khác không đổi, khi biến X_i tăng lên 1 đơn vị thì về mặt trung bình, tỷ lệ giữa xác suất thành công và xác suất không thành công là $(p_i/1-p_i)$ sẽ tăng lên (nếu $\beta_i > 0$) hay giảm xuống (nếu $\beta_i < 0$) e^{β_i} (lần)

Mô hình hàm Logit


β_k	$P_0 = 10\%$	$P_0 = 20\%$		$P_0 = 90\%$
	P_1	P_1		P_1
β_2	15%			
β_3	5%	Khi X_2 tăng 1 đơn vị thì P_i tăng $(15\% - 10\%) = 5\%$		
β_k	10%			

Mô hình hàm Logit

Đánh giá ý nghĩa thống kê của mô hình

	OLS	Maximum Likelihood
$H_0: \beta_k = 0$ $H_1: \beta_k \text{ khác } 0$	$T_{\text{statistic}}$ P- value	$Z_{\text{statistic}}$ P- value
Đo độ thích hợp mô hình	R^2_{adjusted}	R^2_{Fadden}
$H_0: \beta_2 = \beta_3 = \dots = \beta_k = 0$ $H_1: \text{ít nhất } 1 \beta \text{ khác } 0$	$F_{\text{statistic}}$ P- value	$\begin{cases} X^2 = 2(LLF_{UR} - LLF_R) \\ P_{\text{value}} \end{cases}$

Mô hình hàm Probit



$$Z_i = F^{-1}(P_i) = \beta_1 + \beta_2 X_i$$

$$P_i = \frac{1}{\sqrt{2\Pi}} \int_{-\infty}^{Z_i = \beta_1 + \beta_2 X_i} e^{-Z^2/2} dZ$$

$$\frac{\Delta \hat{P}_i}{\Delta X_i} = \phi \beta_i$$

Dấu của tác động biên phụ thuộc vào dấu của β_i vì $\phi > 0$

Độ dốc hàm Logit < hàm Probit

$$\beta_k^{\text{Logit}} = \beta_k^{\text{Probit}} \times 1.81$$

Ứng dụng EViews



- **EIEWS**

Quick \ Estimate Equation \ Binary \ **Logit**

Quick \ Estimate Equation \ Binary \ **Probit**