

Estimación del Probit Ordinal y del Logit Multinomial

Microeconomía Cuantitativa

R. Mora

Departamento de Economía
Universidad Carlos III de Madrid

Esquema

- 1 Introducción
- 2 Estimación del modelo de respuesta ordinal
- 3 El modelo Logit Multinomial

Introducción

El modelo probit ordinal con tres posibles resultados

$$U = x'\beta + \varepsilon, \varepsilon \sim N(0, 1)$$

$$y = 0 \text{ if } U \leq \alpha_1$$

$$y = 1 \text{ if } \alpha_1 < U \leq \alpha_2$$

$$y = 2 \text{ if } \alpha_2 < U$$

- No observamos U , pero sí la elección de cada individuo entre los tres posibles resultados
- Esta elección se representa por y , que es una variable ordinal (es decir, no tiene sentido cardinal)
- El objetivo es estimar β , α_1 , y α_2

Logit Multinomial con tres alternativas

$$\Pr(y = 0|x) = 1 - \Pr(y = 1|x) - \Pr(y = 2|x)$$

$$\Pr(y = 1|x) = \frac{\exp(x'\beta_1)}{1 + \exp(x'\beta_1) + \exp(x'\beta_2)}$$

$$\Pr(y = 2|x) = \frac{\exp(x'\beta_2)}{1 + \exp(x'\beta_1) + \exp(x'\beta_2)}$$

- La elección se representa mediante la variable y , que es una variable cualitativa (es decir, no tiene ni sentido cardinal ni ordinal)
- El objetivo es obtener estimaciones para β_1 y β_2

Estimación del modelo de respuesta ordinal

Ejemplo: No-trabaja, tiempo-parcial y tiempo-completo

h^* : horas deseadas de trabajo semanal (en decenas)

$$h^* = -0.5 + 0.07 * educ - 1.0 * kids + \varepsilon, \varepsilon \sim N(0, 1)$$

- Si hay solo dos tipos de contratos: a tiempo parcial y a tiempo completo
 - los contratos a tiempo parcial tienen jornadas de como mucho 20 horas a la semana
 - los contratos a tiempo completo tienen jornadas de más de 20 horas a la semana
- En nuestros datos, no observamos h^* sino:
 - $y = 0$ para todos los individuos que no trabajan. ($h^* \leq 0$).
 - $y = 1$ para aquellos que trabajan a tiempo parcial. ($0 < h^* \leq 2$).
 - $y = 2$ para aquellos que trabajan a tiempo completo. ($2 < h^*$).

Normalización

- Sea $y^* = 0.07 * educ - 1.0 * kids + \varepsilon$ de forma que
 $h^* = -0.5 + y^*$
- No trabajar implica que

$$\begin{aligned} -0.5 + y^* \leq 0 &\Rightarrow y^* \leq 0.5 \\ &(\alpha_1 = 0.5) \end{aligned}$$

- Trabajar a tiempo completo implica que

$$-0.5 + y^* > 2 \Rightarrow y^* > 2.5$$

El modelo sin constante

El modelo puede ser normalizado

$$y^* = 0.07 * educ - 1.5 * kids + \varepsilon, \varepsilon \sim N(0,1)$$

$$y = 0 \text{ si } y^* \leq 0.5$$

$$y = 1 \text{ si } 0.5 < y^* \leq 2.5$$

$$y = 2 \text{ si } 2.5 < y^*$$

Probabilidades de los extremos

$$\begin{aligned}\Pr(y = 0|x) &= \Pr(x'\beta + \varepsilon \leq \alpha_1|x) \\ &= \Phi(-(x'\beta - \alpha_1)) \\ &= 1 - \Phi((x'\beta - \alpha_1))\end{aligned}$$

$$\begin{aligned}\Pr(y = 2|x) &= \Pr(\alpha_2 < x'\beta + \varepsilon|x) \\ &= \Pr(\varepsilon > -(x'\beta - \alpha_2)|x) \\ &= \Phi((x'\beta - \alpha_2))\end{aligned}$$

(Téngase en cuenta que $\Phi(a) = 1 - \Phi(-a)$, porque la distribución normal es simétrica)

Probabilidades intermedias

- In el ejemplo con 3 alternativas solo hay una probabilidad intermedia:

$$\begin{aligned}\Pr(y = 1|x) &= \Pr(\alpha_1 < x'\beta + \varepsilon \leq \alpha_2|x) \\ &= \Pr(\varepsilon > -(x'\beta - \alpha_1), \varepsilon \leq -(x'\beta - \alpha_2) |x)\end{aligned}$$

- Puesto que $-(x'\beta - \alpha_1) < -(x'\beta - \alpha_2)$:

$$\begin{aligned}\Pr(\varepsilon \leq -(x'\beta - \alpha_2) |x) &= \Pr(\varepsilon < -(x'\beta - \alpha_1) |x) \\ &= \Phi(-(x'\beta - \alpha_2)) - \Phi(-(x'\beta - \alpha_1))\end{aligned}$$

$$\Pr(y = 1|x) = \Phi(x'\beta - \alpha_1) - \Phi(x'\beta - \alpha_2)$$

La esperanza condicional y MCO

$$\begin{aligned}\Pr(y = 0|x) &= 1 - \Phi((x'\beta - \alpha_1)) \\ +\Pr(y = 1|x) &= \Phi(x'\beta - \alpha_1) - \Phi(x'\beta - \alpha_2) \\ +\Pr(y = 2|x) &= \Phi((x'\beta - \alpha_2))\end{aligned}$$

$$\sum \Pr(y = j|x) = 1 \text{ (Las probabilidades suman uno)}$$

- En general, MCO no funciona porque la esperanza condicional de la variable dependiente no es lineal:

$$\begin{aligned}E(y|x) &= 0 \times \Pr(y = 0|x) + 1 \times \Pr(y = 1|x) + 2 \times \Pr(y = 2|x) \\ &= \Pr(y = 1|x) + 2 \times \Pr(y = 2|x) \\ &= \Phi(x'\beta - \alpha_1) + \Phi(x'\beta - \alpha_2)\end{aligned}$$

Estimación MV

La probabilidad de una observación es

$$\begin{aligned} \Pr(y|x) = & (1 - \Phi(x'\beta - \alpha_1))^{1(y=0)} \times \\ & (\Phi(x'\beta - \alpha_1) - \Phi(x'\beta - \alpha_2))^{1(y=1)} \times \\ & (\Phi(x'\beta - \alpha_2))^{1(y=2)} \end{aligned}$$

Por ello, para N observaciones la verosimilitud es:

$$\begin{aligned} L(b) = \prod_{i=1}^N \left\{ & (1 - \Phi(x'_i b - \alpha_1))^{1(y_i=0)} \times \right. \\ & (\Phi(x'_i b - \alpha_1) - \Phi(x'_i b - \alpha_2))^{1(y_i=1)} \times \\ & \left. (\Phi(x'_i b - \alpha_2))^{1(y_i=2)} \right\} \end{aligned}$$

Efectos marginales

Opciones para presentar los resultados:

- Cuando la ecuación de la variable latente tiene una interpretación sencilla (como en el ejemplo), presentarla es una buena manera de informar sobre el modelo.
- Por otra parte, los efectos marginales de las probabilidades de cada una de las categorías se pueden calcular.
 - Cuando la variable independiente es discreta, efectos marginales se pueden calcular como en el caso binario.
- Por último, se puede estimar el efecto sobre el valor esperado de la variable observada.

Efectos marginales cuando el regresor es continuo

Efectos marginales cuando el regresor es continuo

$$\frac{\partial \Pr(y = 0|x)}{\partial x_j} = -\phi(x'\beta - \alpha_1) \beta_j$$

$$\frac{\partial \Pr(y = 1|x)}{\partial x_j} = (\phi(x'\beta - \alpha_1) - \phi(x'\beta - \alpha_2)) \beta_j$$

$$\frac{\partial \Pr(y = 2|x)}{\partial x_j} = \phi(x'\beta - \alpha_2) \beta_j$$

El modelo Logit multinomial

Modelo de Utilidad Aleatoria

- Suponiendo que hay tres alternativas de transporte: bus, coche, tren:

$$U_b = x'_b \beta_b + \varepsilon_b$$

$$U_c = x'_c \beta_c + \varepsilon_c$$

$$U_t = x'_t \beta_t + \varepsilon_t$$

donde $\{\varepsilon_b, \varepsilon_c, \varepsilon_t\}$ son los efectos en la utilidad inobservados por el econometra

- Sea $y = 0$ si bus, $y = 1$ si coche, and $y = 2$ si tren.
 - y no tiene sentido ni cardinal ni ordinal!

Re-parametrización del modelo

$$\begin{aligned}\varepsilon_{01} &\equiv \varepsilon_b - \varepsilon_c, & \varepsilon_{02} &\equiv \varepsilon_b - \varepsilon_t \\ x' \beta_{01} &\equiv x'_b \beta_b - x'_c \beta_c, & x' \beta_{02} &\equiv x'_b \beta_b - x'_t \beta_t\end{aligned}$$

- Supuesto: $\{\varepsilon_{01}, \varepsilon_{02}\} \sim F$, donde F es simétrica.

$$\begin{aligned}\Pr(y = 0|x) &= F(x' \beta_{01}, x' \beta_{02}) \\ \Pr(y = 1|x) &= F(-x' \beta_{01}, x'(\beta_{02} - \beta_{01})) \\ \Pr(y = 2|x) &= F(-x' \beta_{02}, -x'(\beta_{02} - \beta_{01}))\end{aligned}$$

El Logit Multinomial

Cuando el vector $\{\varepsilon_b, \varepsilon_c, \varepsilon_t\}$ tiene una distribución de valor extremo, entonces tenemos el **Logit Multinomial**:

$$\Pr(y = 0|x) = 1 - \Pr(y = 1|x) - \Pr(y = 2|x)$$

$$\Pr(y = 1|x) = \frac{\exp(x'\beta_1)}{1 + \exp(x'\beta_1) + \exp(x'\beta_2)}$$

$$\Pr(y = 2|x) = \frac{\exp(x'\beta_2)}{1 + \exp(x'\beta_1) + \exp(x'\beta_2)}$$

- OLS no funciona porque la esperanza condicionada no es lineal
- La estimación MV proporciona estimadores consistentes y asintóticamente normales
 - En `gret1`, el comando `logit` estima el Logit multinomial cuando la variable dependiente es discreta y no binaria si se usa la opción `--multinomial`

Ejemplo: Coche, bicicleta, y tren

$$\Pr(car|x) = 1 - \Pr(bicycle|x) - \Pr(train|x)$$

$$\Pr(bicycle|x) = \frac{\exp(x'\beta_1)}{1 + \exp(x'\beta_1) + \exp(x'\beta_2)}$$

$$\Pr(train|x) = \frac{\exp(x'\beta_2)}{1 + \exp(x'\beta_1) + \exp(x'\beta_2)}$$

donde

$$x'\beta_1 = 1 - 0.1 * age - .1 * income - 3 * kids + 5 * center$$

$$x'\beta_2 = 1 - .1 * income + 1.5 * kids + 2 * center$$

Observa que $\beta_1 = \beta_{bicycle} - \beta_{car}$ y que $\beta_2 = \beta_{train} - \beta_{car}$.
¿Cuál es la valoración relativa entre *train* y *bicycle*?

$$x'\beta_1 = 1 - 0.1 * age - .1 * income - 3 * kids + 5 * center$$

$$x'\beta_2 = 1 - .1 * income + 1.5 * kids + 2 * center$$

- $\beta_{1,age} = -.1 < 0$: A medida que las personas envejecen, tiene más valor usar el coche que usar la bicicleta.
- $\beta_{1,income} = \beta_{2,income} = -.1 < 0$: Cuanto mayor sea el ingreso, más probable es el coche en vez del tren o la bicicleta.
- $\beta_{1,kids} = -3, \beta_{2,kids} = 1.5$: entonces
 $\beta_{car,kids} - \beta_{train,kids} = -1.5 < 0$ y
 $\beta_{bicycle,kids} - \beta_{train,kids} = -3 - 1.5 = -4.5 < 0$: Cuantos más niños, más probable es el tren frente al coche y la bicicleta.
- Si el viaje pasa por el centro de la ciudad, el tren y la bicicleta son más probables que el coche (y cómo se valora el tren

```
logit transport const age income kids center --multinomial
```

Model 3: Multinomial Logit, using observations 1–5000

Dependent variable: transport, Standard errors based on Hessian

	Coefficient	Std. Error	z	p-value
transport = 2				
const	0.522376	0.501274	1.0421	0.2974
age	-0.0969857	0.00890363	-10.8928	0.0000
income	-0.0957303	0.00589953	-16.2268	0.0000
kids	-2.78035	0.222090	-12.5190	0.0000
center	5.29508	0.422875	12.5216	0.0000
transport = 3				
const	0.867895	0.197401	4.3966	0.0000
age	0.00590025	0.00495462	1.1909	0.2337
income	-0.100911	0.00351216	-28.7320	0.0000
kids	1.42980	0.0869553	16.4429	0.0000
center	1.89417	0.0899837	21.0502	0.0000
Mean dependent var	2.253800	S.D. dependent var	0.915616	
Log-likelihood	-2687.761	Akaike criterion	5395.521	
Schwarz criterion	5460.693	Hannan-Quinn	5418.363	

Number of cases 'correctly predicted' = 3787 (75.7 percent)

Likelihood ratio test: $\chi^2(8) = 3712.464$ [0.0000]

Resumen

- No podemos estimar por MCO ni el probit ordinal ni el logit multinomial.
- La estimación MV proporciona estimadores que son consistentes y asintóticamente normales.
- Los efectos marginales se pueden calcular como en el caso binario.