

# Zawansowane modele wyborów dyskretnych

Jerzy Mycielski

Uniwersytet Warszawski

grudzien 2013

- Zmienna ukryta

$$y_i^* = \mathbf{x}_{it} \boldsymbol{\beta} + c_i + u_{it}$$

- Zmienna obserwowalna

$$y_i = \begin{cases} 1 & \text{dla } y_i^* \geq 0 \\ 0 & \text{dla } y_i^* < 0 \end{cases}$$

- Kluczowe założenie:

- $c_i$  zależne od  $\mathbf{x}_{it} \implies$  model efektów stałych
- $c_i$  niezależne od  $\mathbf{x}_{it} \implies$  model efektów losowych

# Estymator efektów stałych - problem parametrów pobocznych

- Warunkowa funkcja prawdopodobieństwa:

$$\Pr(y_i = 1 | c_i) = \Pr(\mathbf{x}_{it} \boldsymbol{\beta} + c_i + u_{it} \geq 0) = F(\mathbf{x}_{it} \boldsymbol{\beta} + c_i)$$

- Czy można w tym przypadku zastosować estymator analogiczny do estymatora *LSDV* i oszacować model z dodatkowymi zmiennymi zerojedynkowymi dla każdej jednostki?
- Niestety estymator taki będzie zgodny tylko dla  $T \rightarrow \infty$  i  $N \rightarrow \infty$ , dla  $T$  ustalonego nie będzie zgodny

# Estymator efektów stałych - problem parametrów pobocznych c.d.

- Estymator *LSDV* w liniowym modelu efektów nieobserwowalnych jest o tyle wyjątkowy, że można dla niego pokazać

$$\hat{\beta}_{FE} \xrightarrow{P} \beta \text{ dla } N \rightarrow \infty \text{ i } T \text{ ustalonego}$$

mimo, że  $\hat{\mathbf{c}}$  nie jest zgodny ( $\hat{\mathbf{c}} \not\xrightarrow{P} \mathbf{c}$  dla  $N \rightarrow \infty$  i  $T$  ustalonego) co wynika z asymptotycznej niezależności obu estymatorów

- Wynik ten generalnie nie jest prawdziwy w przypadku modeli nieliniowych
  - problem parametrów pobocznych (incidental parameters problem)

# Model logitowy z efektami stałymi

- Okazuje się, że w przypadku modelu logitowego prawdopodobieństwa warunkowego względem ilości sukcesów  $n_i$  dla jednostki  $i$ , nie zależy od  $c_i$
- Na przykład dla  $T = 2$

$$\begin{aligned}\Pr(y_{i2} = 1 | \mathbf{x}_i, c_i, n_i = 1) &= \frac{\Pr(y_{i2} = 1, n_i = 1 | \mathbf{x}_i, c_i)}{\Pr(n_i = 1 | \mathbf{x}_i, c_i)} \\ &= \frac{\Pr(y_{i2} = 1 | \mathbf{x}_i, c_i) \Pr(y_{i1} = 0 | \mathbf{x}_i, c_i)}{\Pr(y_{i1} = 0, y_{i2} = 1 | \mathbf{x}_i, c_i) + \Pr(y_{i1} = 1, y_{i2} = 0 | \mathbf{x}_i, c_i)} \\ &= \frac{\Lambda(\mathbf{x}_{i2}\boldsymbol{\beta} + c_i) [1 - \Lambda(\mathbf{x}_{i1}\boldsymbol{\beta} + c_i)]}{[1 - \Lambda(\mathbf{x}_{i1}\boldsymbol{\beta} + c_i)] \Lambda(\mathbf{x}_{i2}\boldsymbol{\beta} + c_i) + \Lambda(\mathbf{x}_{i1}\boldsymbol{\beta} + c_i) [1 - \Lambda(\mathbf{x}_{i2}\boldsymbol{\beta} + c_i)]} \\ &= \Lambda[(\mathbf{x}_{i2} - \mathbf{x}_{i1})\boldsymbol{\beta}]\end{aligned}$$

- Ogólnie

$$\Pr(\mathbf{y}_i | \mathbf{x}_i, c_i, n_i = n) = \frac{\exp\left(\sum_{i=1}^T y_{it} \mathbf{x}_{it} \boldsymbol{\beta}\right)}{\exp\left(\sum_{\mathbf{a} \in R_i} a_t y_{it} \mathbf{x}_{it} \boldsymbol{\beta}\right)}$$

where  $R_i \in R^T$  oraz  $R_i = \left\{ \mathbf{a} : a_t \in \{0, 1\}, \sum_{i=1}^T a_i = n_i \right\}$

- Funkcję wiarygodności budujemy przy użyciu tej prawdopodobieństwa

- Obserwacje dla poszczególnych jednostek nie są niezależne
- Obserwacje dla różnych jednostek są od siebie niezależne
  - zgodnym ale nieefektywnym estymatorem jest w takim przypadku estymator *pseudo* – *ML* (identyczny w sensie obliczeniowym do estymatora *ML*).
  - macierz wariancji dla oszacowań powinniśmy w tym przypadku uzyskać za pomocą estymatora warstwowego (cluster )

# Model probitowy z efektami losowymi

Estymator ML

- Warunkowa funkcja prawdopodobieństwa dla obserwacji dla jednostki  $i$ :

$$\Pr(\mathbf{y}_i | c_i) = \prod_{t=1}^T [\Phi(\mathbf{x}_{it} \boldsymbol{\beta} + c_i)]^{y_{it}} [1 - \Phi(\mathbf{x}_{it} \boldsymbol{\beta} + c_i)]^{1-y_{it}}$$

- Załóżmy, że efekty losowe są pochodzą z wielowymiarowego rozkładu normalnego i są niezależne:

$$\mathbf{c} \sim N(\mathbf{0}, \sigma_u^2 \mathbf{I})$$



# Model probitowy z efektami losowymi

Estymator ML c.d.

- Bezwarunkowa funkcja prawdopodobieństwa ma więc następującą postać:

$$\Pr(\mathbf{y}_i) = \int_{-\infty}^{\infty} \prod_{t=1}^T [\Phi(\mathbf{x}_{it} \boldsymbol{\beta} + c_i)]^{y_{it}} [1 - \Phi(\mathbf{x}_{it} \boldsymbol{\beta} + c_i)]^{1-y_{it}} \times \\ \times \frac{1}{\sigma_c} \phi\left(\frac{c_i}{\sigma_c}\right) dc_i$$

- Tego rodzaju całki nie da się policzyć analitycznie - zamiast tego stosujemy metody numeryczne (kwadratury)
- W modelu probitowym z efektami losowymi obserwacje są niezależne pomiędzy jednostkami, więc funkcja wiarygodności ma standardową postać:

$$\ell(\boldsymbol{\beta}) = \sum_{i=1}^N \ln \Pr(\mathbf{y}_i)$$

- Kwadratura polega na zastąpieniu całki sumą policzoną dla pewnego zbioru punktów. W najprostszym przypadku:

$$\int_a^b f(x) dx \approx \sum_{s=0}^{S-1} f(x_i^*) d^*$$

gdzie  $d^* = \frac{a-b}{S}$ ,  $x_i^* = a + (i + 0.5) d^*$

- charakterystyka danych
  - mamy  $K$  alternatyw
  - dysponujemy uszeregowaniem alternatyw pod względem ich atrakcyjności

$$y_{k_1} > y_{k_2} > \dots > y_{k_K}$$

- uszeregowanie nie musi być kompletne
- Metoda szacowania: oparta na estymatorze dla modelu proporcjonalnego hazardu Cox-a

# Model probitowy z endogenicznymi zmiennymi objaśniającymi c.d.

- Model

$$y_{i1}^* = \mathbf{y}_{2i}\boldsymbol{\beta} + \mathbf{x}_{1i}\boldsymbol{\gamma} + u_{1i} = \mathbf{z}_i\boldsymbol{\delta} + u_{1i}$$

$$y_{2i} = \mathbf{x}_{1i}\boldsymbol{\alpha}_1 + \mathbf{x}_{2i}\boldsymbol{\alpha}_2 + u_{2i} = \mathbf{x}_i\boldsymbol{\alpha} + u_{2i}$$

- Zmienna  $\mathbf{y}_{2i}$  jest bezpośrednio obserwowalna i endogeniczna w równaniu dla zmiennej ukrytej  $y_{i1}^*$ , ponieważ  $Cov(u_{1i}, u_{2i}) \neq 0$ .
- Zakładamy, że wektor błędów losowych  $\mathbf{u}_i \sim N(0, \boldsymbol{\Sigma})$  przy czym przyjmujemy założenie identyfikujące parametry, że  $\Sigma_{11} = 1$
- Powyższy model ma strukturę rekursywną  $y_{2i}$  pojawia się w równaniu dla  $y_{i1}^*$  ale  $y_{i1}^*$  nie pojawia się w równaniu dla  $y_{2i}$ .
- Równanie dla  $y_{2i}$  może być traktowane jako forma zredukowana

- Zmienna obserwowalna

$$y_{1i} = \begin{cases} 1 & \text{dla } y_i^* \geq 0 \\ 0 & \text{dla } y_i^* < 0 \end{cases}$$

- Funkcja prawdopodobieństwa dla zdarzenia  $i$

$$\begin{aligned} f(y_{1i}, y_{2i} | \mathbf{x}_{1i}, \mathbf{x}_{2i}) &= \Pr(y_{1i} | y_{2i}, \mathbf{x}_{1i}, \mathbf{x}_{2i}) f(y_{2i} | \mathbf{x}_{1i}, \mathbf{x}_{2i}) \\ &= [\Phi(m_i)]^{y_{1i}} [1 - \Phi(m_i)]^{1-y_{1i}} \frac{1}{\sigma} \phi\left(\frac{y_{2i} - \mathbf{x}_{1i}\boldsymbol{\alpha}}{\sigma}\right) \end{aligned}$$

gdzie

$$m_i = \frac{\mathbf{z}_i \boldsymbol{\delta} + \rho (y_{2i} - \mathbf{x}_{1i}\boldsymbol{\alpha})}{(1 - \rho^2)^{\frac{1}{2}}}$$

a  $\rho$  jest współczynnikiem korelacji między  $u_{1i}$  i  $u_{2i}$

- Z użyciem tej funkcji prawdopodobieństwa możemy stworzyć funkcję wiarygodności

# Założenie o symetrii rozkładu

## Asymetryczny logit (skewed logit)

- Założenie o symetrii rozkładu w mówi, że

$$F(z) = 1 - F(-z)$$

- Założenie to implikuje, że efekt cząstkowy jest najwyższy dla  $F(\mathbf{x}_i\boldsymbol{\beta}) = \frac{1}{2}$
- Istotnie efekt cząstkowy

$$\frac{\partial E(y_i | \mathbf{x}_i)}{\partial \mathbf{x}_i} = f(\mathbf{x}_i\boldsymbol{\beta}) \boldsymbol{\beta}_k$$

a dla rozkładu symetrycznego wartość modalna jest zawsze równa medianie

- Jeśli chcemy to założenie uchylić powinniśmy użyć modelu o niesymetrycznym rozkładzie błędu losowego dla zmiennej ukrytej

# Założenie o symetrii rozkładu

## Asymetryczny logit (skewed logit)

- Model: prawdopodobieństwo sukcesu

$$\Pr(y_i = 1) = F(\mathbf{x}_i\boldsymbol{\beta})$$

dla

$$F(z) = 1 - \frac{1}{[1 + \exp(x)]^\alpha}, \quad \alpha > 0$$

- Dla  $\alpha = 1$  otrzymujemy logita
- W innych przypadkach rozkład zmiennej losowej jest niesymetryczny

- Model: prawdopodobieństwo sukcesu

$$\Pr(y_i = 1) = F(\mathbf{x}_i\boldsymbol{\beta})$$

dla

$$F(z) = 1 - \exp[-\exp(z)]$$

- W tym przypadku dystrybuanta jest także niesymetryczna
- Model ten używamy gdy liczba sukcesów (bądź porażek jest mała)