

Regresja przełącznikowa

Jerzy Mycielski

Październik 2013

Regresja przełącznikowa - forma modelu

Próby przekrojowe

- Równania regresji

$$y_i = \mathbf{x}_{1i}\boldsymbol{\beta}_1 + u_{1i} \quad \text{dla } s_i = 1 \quad (\text{Rezim 1})$$

$$y_i = \mathbf{x}_{2i}\boldsymbol{\beta}_2 + u_{2i} \quad \text{dla } s_i = 0 \quad (\text{Rezim 2})$$

- Równanie selekcji - model dla zmiennej binarnej

$$s_i = 1 \quad \text{dla } \mathbf{z}_i\boldsymbol{\gamma} \geq u_i$$

$$s_i = 0 \quad \text{dla } \mathbf{z}_i\boldsymbol{\gamma} < u_i$$

- Identyfikacja: wśród zmiennych zawartych w równaniu selekcji powinny się znaleźć zmienne, których nie ma w równaniach regresji

- Zakładamy, że poszczególne błędy losowe są *IID* - nie występuje więc autokorelacja i rozkłady są stałe w czasie
- Macierz wariancji i kowariancji błędu losowego

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \sigma_{1u} \\ & \sigma_{22} & \sigma_{2u} \\ & & 1 \end{bmatrix}$$

- Zazwyczaj konieczne jest założenie o normalności łącznego rozkładu błędu losowego

- Zakładamy normalność błędów losowych
- Podstawowy problem

$$E(u_{i1} | \mathbf{z}_i \gamma \geq u_i) = -\sigma_{1u} \frac{\phi(\mathbf{z}_i \gamma)}{\Phi(\mathbf{z}_i \gamma)}$$

$$E(u_{i2} | \mathbf{z}_i \gamma < u_i) = \sigma_{2u} \frac{\phi(\mathbf{z}_i \gamma)}{\Phi(\mathbf{z}_i \gamma)}$$

- Wniosek: jeśli \mathbf{z}_i zawiera część zmiennych zawartych w \mathbf{x}_{1i} i \mathbf{x}_{2i} to nie jest spełniony warunek, że $E(u_{1i} | \mathbf{x}_{1i}) = 0$ lub $E(u_{2i} | \mathbf{x}_{2i}) = 0$.

- Postać funkcji wiarygodności:

$$\begin{aligned} & L(\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \sigma_{11}, \sigma_{22}, \sigma_{12}, \sigma_{1u}, \sigma_{2u}) \\ &= \prod_{i=1}^N \left[\int_{-\infty}^{\mathbf{z}_i \boldsymbol{\beta}} f(y_i - \mathbf{x}_{1i} \boldsymbol{\beta}_1 | u_i) du_i \right]^{s_i} \\ & \quad \times \left[\int_{\mathbf{z}_i \boldsymbol{\beta}}^{\infty} f(y_i - \mathbf{x}_{2i} \boldsymbol{\beta}_1 | u_i) du_i \right]^{s_i - 1} \end{aligned}$$

- Tobit
- Model Heckmana
- Estymacja za pomocą *MNW* może się okazać kłopotliwa
- W niektórych szczególnych przypadkach możliwa jest estymacja dwustopniowa

Definicja łańcucha Markowa

- Wartości zmiennych losowych X_n należą do skończonego zbioru $\{s_1, s_2, \dots, s_r\}$
- Skończony łańcuch Markowa

$$\Pr(X_n = j | X_0 = i_0, X_1 = i_1, \dots, X_{n-1} = i_{n-1}) = P(X_n = j | X_{n-1} = i)$$

- Proces ma więc krótką pamięć: prawdopodobieństwo przejścia do innego stanu zależy jedynie od stanu w poprzednim okresie
- Skończony jednorodny łańcuch Markowa jest to skończony łańcuch Markowa o następującej własności:

$$P(X_n = j | X_{n-1} = i) = P(X_{n+s} = j | X_{n+s-1} = i) = p_{ij}$$

- Dla jednorodnego łańcucha Markowa prawdopodobieństwa przejścia między stanami nie zmieniają się w czasie

- Macierzą prawdopodobieństw ma następującą postać:

$$\mathbf{P} = \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1r} \\ p_{21} & p_{22} & \cdots & p_{2r} \\ \vdots & \vdots & & \vdots \\ p_{r1} & p_{r2} & \cdots & p_{rr} \end{bmatrix}$$

- p_{ij} muszą spełniać następujące warunki

$$\sum_{j=1}^r p_{ij} = 1$$

$$p_{ij} \geq 0$$

- Równanie regresji

$$y_t = \mathbf{x}_t \boldsymbol{\beta}_1 + \sigma_1 \varepsilon_t \quad \text{dla } s_t = 1 \quad (\text{Rezim 1})$$

$$y_t = \mathbf{x}_t \boldsymbol{\beta}_2 + \sigma_2 \varepsilon_t \quad \text{dla } s_t = 0 \quad (\text{Rezim 2})$$

- Równanie selekcji - łańcuch Markowa ze zmiennymi prawdopodobieństwami przejść (niejednorodny)

$$P(s_t = i | s_{t-1} = j, \mathbf{z}_t) = p_{ij}(\mathbf{z}_t)$$

- Zakładamy, że

$$s_t = 1 \quad \text{dla} \quad \mathbf{z}_i \gamma_{s_{t-1}} \geq u_t$$

$$s_t = 0 \quad \text{dla} \quad \mathbf{z}_i \gamma_{s_{t-1}} < u_t$$

a więc

$$p_{1s_{t-1}}(\mathbf{z}_t) = 1 - \Phi(\mathbf{z}_i \gamma_{s_{t-1}})$$

$$p_{0s_{t-1}}(\mathbf{z}_t) = \Phi(\mathbf{z}_i \gamma_{s_{t-1}})$$

- Ponadto zakładamy, że rozkład bezwarunkowy łańcucha Markowa jest stacjonarny:

$$P(s_t = i | \bar{z}) = P(s = i | \bar{z}) \text{ dla każdego } t$$

$$\begin{bmatrix} \varepsilon_t \\ u_t \end{bmatrix} \sim N\left(0, \begin{bmatrix} 1 & \rho \\ \rho & 1 \end{bmatrix}\right)$$

- Zakłada się, że stan procesu i jest *nieobserwowalny*

- Estymacji dokonujemy *MNW*
- W ogólnym przypadku postać funkcji wiarygodności jest dosyć skomplikowana
- Szczególne przypadki
 - przełączenia egzogeniczne: $\rho = 0$
 - czysty proces Markowa $\gamma_1 = \gamma_2 = \mathbf{0}$

- Łączna funkcja gęstości dla całej próby

$$L(\theta) = \prod_{t=1}^T f(y_t | \Omega_t, \zeta_{t-1}; \theta)$$

gdzie $\zeta_t = (y_t, y_{t-1}, \dots, y_1)$,

$\Omega_t = (\mathbf{x}_t, \mathbf{x}_{t-1}, \dots, \mathbf{x}_1, \mathbf{z}_t, \mathbf{z}_{t-1}, \dots, \mathbf{z}_1)$, $\theta = (\beta_1, \sigma_1, \beta_2, \sigma_2)$.

- Funkcja gęstości dla pojedynczego zdarzenia

$$\begin{aligned} & f(y_t | \Omega_t, \zeta_{t-1}; \theta) \\ = & \sum_i \sum_j f(y_t | s_t = i, s_{t-1} = j, \Omega_t, \zeta_{t-1}; \theta) \times \\ & \Pr(s_t = i, s_{t-1} = j | \Omega_t, \zeta_{t-1}; \theta) \end{aligned}$$

- Prawdopodobieństwo przejścia dla danej obserwacji liczymy rekursywnie przy wykorzystaniu twierdzenia Bayesa oraz tego, że

$$P(s_0 = i | \bar{z}) = P(s = i | \bar{z})$$

- Tak więc:

$$\Pr(s_t = i, s_{t-1} = j | \Omega_t, \zeta_{t-1}; \theta) = p_{ij}(z_t) \Pr(s_{t-1} = j | \Omega_t, \zeta_{t-1}; \theta)$$

- Bezwarunkowe prawdopodobieństwo przejścia liczymy z twierdzenia Bayesa:

$$\begin{aligned}
 & \Pr(s_t = i | \Omega_{t+1}, \zeta_t; \theta) \\
 & \Pr(s_t = i | \Omega_t, \zeta_t; \theta) \\
 = & \frac{f(y_t | s_t = i, \Omega_t, \zeta_{t-1}; \theta)}{f(y_t | \Omega_t, \zeta_{t-1}; \theta)} \\
 = & \frac{1}{f(y_t | \Omega_t, \zeta_{t-1}; \theta)} \times \\
 & \sum_j f(y_t | s_t = i, s_{t-1} = j, \Omega_t, \zeta_{t-1}; \theta) \times \\
 & \Pr(s_t = i, s_{t-1} = j | \Omega_t, \zeta_{t-1}; \theta)
 \end{aligned}$$

- w przypadku, gdy $\rho = 0$

$$f(y_t | s_t = i, s_{t-1} = j, \Omega_t, \zeta_{t-1}; \theta) = \frac{1}{\sigma} \phi\left(\frac{y_t - \mathbf{x}_t \boldsymbol{\beta}}{\sigma}\right)$$