

Egzamin z Ekonometrii IiE18.06.2015

Pytania teoretyczne

1. Wyjaśnić, na czym polega założenie o niezależności od pozostałych alternatyw i podać przykład, dla którego założenie to nie jest spełnione.
2. Opisać dwustopniową procedurę estymacji modelu Heckmana.
3. Co modelowane jest w przypadku, kiedy zmienna zależna jest zmienną binarną (zerojedynkową)? Wyjaśnić, jaka jest relacja między zmienną obserwowalną a ukrytą w przypadku modeli dla zmiennych binarnych i jak tę relację można uzasadnić w oparciu o teorię ekonomii.
4. Wyjaśnić, dlaczego za pomocą estymatora efektów stałych nie można oszacować parametrów przy zmiennych nie zmieniających się w czasie.

ZADANIE 1 Mamy następujący model podaży i popytu na pracę

$$l_t = \alpha_0 + \alpha_1 w_t + \alpha_2 p_t + \varepsilon_{1t}$$

$$l_t = \beta_1 w_t + \beta_2 q_t + \varepsilon_{2t}$$

gdzie l_t oznacza logarytm zatrudnienia, w_t to logarytm płacy realnej, p_t logarytm wielkości siły roboczej, a q_t logarytm produkcji. Zmiennymi endogenicznymi są l_t i w_t a p_t i q_t są traktowane jako egzogeniczne.

1. Które z tych równań jest według Ciebie równaniem popytu, a które podaży? Odpowiedź uzasadnij.
2. Sprawdź identyfikację poszczególnych równań.
3. Wyjaśnij jak wyglądać będzie forma zredukowana tego modelu
4. Wyjaśnij dlaczego równania popytu nie można poprawnie wyestymować za pomocą *MNK*.
5. Jeśli zastosowalibyśmy do estymacji tego równania *MZI*, to jakie zmienne mogłyby być użyte jako instrumenty?

Rozwiązanie:

1. Podaż pracy zależy od wielkości siły roboczej oraz wysokości płacy. Popyt na pracę zależy od wysokości płacy i wielkości produkcji. Wynika z tego, że równanie pierwsze jest równanie podaży a równanie drugie równaniem popytu.
2. Podział na zmienne endo i egzogeniczne

$$\begin{array}{ll} \text{zmienne egzogeniczne (wliczamy stałą)} & 1, p_t, q_t \\ \text{zmienne endogeniczne} & l_t, w_t \end{array}$$

G_s liczba zmiennych endogenicznych w s -tym równaniu, K_s liczba zmiennych egzogenicznych w s -tym równaniu:

$$\begin{array}{lll} K = 3 & G_1 = 2 & K_1 = 2 \\ & G_2 = 2 & K_2 = 1 \end{array}$$

Identyfikacja:

$$\begin{array}{l} 3 = 2 + 2 - 1 \quad (+) \\ 3 > 2 + 1 - 1 \quad (+) \end{array}$$

Równanie popytu i podaży na pracę są zidentyfikowane.

3. Równania formy zredukowanej dla pracy i płacy:

$$\begin{array}{l} l_t = \pi_{10} + \pi_{11} p_t + \pi_{12} q_t + \varepsilon_{1t} \\ w_t = \pi_{20} + \pi_{21} p_t + \pi_{22} q_t + \varepsilon_{2t} \end{array}$$

IMIĘ NAZWISKO.....

- Równania popytu na pracę nie da się wyestymować standardowym MNK, ponieważ zmienna objaśniająca w_t (płaca) jest skorelowana z błędem losowym ε_{1t} z powodu występowania sprzężenia zwrotnego między popytem na pracę i wysokością płacy (wysokość płacy wpływa na popyt na pracę a równocześnie wielkość popytu na pracę wpływa na płacę). Taka korelacja oznacza występowanie problemu równoczesności, który powoduje, że estymator MNK nie jest zgodny.
- Instrumentami w przypadku estymacji równania popytu na pracę powinny być wszystkie zmienne egzogeniczne występujące w modelu a więc $1, p_t, q_t$.

ZADANIE 2 Badane są czynniki skłaniające respondentów do emigracji. W badaniu wykorzystywane są dane z badania "Diagnoza społeczna" z lat 2000, 2003, 2005, 2007. Poniżej znajdują się oszacowania parametrów i efektów cząstkowych policzonych dla średnich w próbie dla modelu probitowego oszacowanego dla tego problemu, w którym zmienną zależną jest odpowiedź na pytanie, czy dany członek gospodarstwa w momencie badania pracuje zagranicą (1 pracuje, 0 nie pracuje). Zmiennymi objaśniającymi w modelu są: logarytm dochodu na głowę w gospodarstwie, liczba lat nauki, zmienna zerojedynkowa związana z płcią respondenta (1 kobieta, 0 mężczyzna) oraz zmienne zerojedynkowe związane z rokiem przeprowadzenia badania.

	parametr	efekt cząstkowy	z	p
ln(dochodu)	-0.292	-0.004	-8.387	0.000
lata nauki	0.064	0.001	8.332	0.000
kobieta	-0.334	-0.005	-7.417	0.000
2003	-0.118	-0.002	-1.240	0.215
2005	0.388	0.008	4.885	0.000
2007	0.598	0.012	7.958	0.000
Constant	-1.550		-7.544	0.000
N	38916	38916		
$R^2_{McKelvey'a i Zavoiny}$	0.134			
$R^2_{liczebnościowe}$	0.992			
$\bar{R}^2_{liczebnościowe}$	0.000			

Testy przeprowadzamy na poziomie istotności $\alpha = 0.05$.

- Wypisz założenia modelu probitowego.
- Które założenie $KMRL$ będzie najprawdopodobniej fałszywe dla modelu liniowego opisującego zależność p-stwa emigracji od charakterystyk respondenta?
- Na jakie problemy natknemy się, jeśli model ten oszacujemy za pomocą MNK ?
- Jakie wnioski można wyciągnąć na podstawie oszacowań parametrów w tym modelu?
- Podaj interpretację $R^2_{McKelvey'a i Zavoiny}$ i $R^2_{liczebnościowe}$. Wyjaśnij dlaczego występuje tak duża rozbieżność między $R^2_{liczebnościowe}$ i miarą skorygowaną $\bar{R}^2_{liczebnościowe}$.
Podpowiedź: W badanej próbie znajduje się jedynie 317 obserwacji, dla których respondenci w momencie badania pracowali zagranicą.
- Podaj interpretację efektu cząstkowego dla płci (kodowanie 0 - mężczyzna, 1 kobieta).
- Zinterpretuj efekt cząstkowy dla logarytmu dochodu na głowę w gospodarstwie.
- Jaki model można by zastosować, by zbadać hipotezę, że wykształcenie wpływa w różny sposób na skłonność do emigracji kobiet i mężczyzn?
- Przetestowano hipotezę, że rok badania nie ma wpływu na skłonność do emigracji respondentów uzyskano i statystykę $LR = 154.95$. Zweryfikuj powyższą hipotezę.
Podpowiedź: $\chi^2_{0.95}(1) = 3.84$, $\chi^2_{0.95}(2) = 5.99$, $\chi^2_{0.95}(3) = 7.81$.

Rozwiązanie:

IMIĘ NAZWISKO.....

1. Zmienna ukryta

$$y^* = \mathbf{x}\beta + \varepsilon$$

$$\varepsilon \sim N(0, 1)$$

i poszczególne obserwacje są niezależne. Obserwujemy

$$y = 0 \quad \text{dla} \quad y^* \leq 0$$

$$y = 1 \quad \text{dla} \quad y^* > 0$$

Alternatywna odpowiedź: prawdopodobieństwa zajścia pojedynczego zdarzenia:

$$\Pr(y_i) = \begin{cases} 1 - \Phi(\mathbf{x}\beta) & \text{dla } y = 0 \\ \Phi(\mathbf{x}\beta) & \text{dla } y = 1 \end{cases}$$

i poszczególne obserwacje są niezależne.

2. W przypadku modelu liniowego (Liniowego Modelu Prawdopodobieństwa - LPM) fałszywe jest założenie o homoskedastyczności, ponieważ $\text{Var}(y) = \text{Var}(\varepsilon) = p(\mathbf{x})[1 - p(\mathbf{x})] = \mathbf{x}\beta(1 - \mathbf{x}\beta)$ i jest zależne od \mathbf{x} .
3. Szacując model LPM natknijemy się na dwa problemy: po pierwsze na wspomnianą wyżej heteroskedastyczność a po drugie możemy uzyskać nieinterpretowalne dopasowane wartości prawdopodobieństw (spoza przedziału $[0, 1]$)
4. Na podstawie oszacowań uzyskanych z modelu możemy zbadać istotność oraz kierunek wpływu poszczególnych zmiennych. Istotne są zmienne: lata nauki, kobieta, 2005, 2007, oraz stała. Dodatni wpływ na p-stwo posiadania emigracji ma zmienna lata nauki, 2005, 2007. Zmienna kobieta ma ujemny wpływ na p-stwo emigracji. Zmienna 2003 ma nieistotny wpływ na p-stwo emigracji co oznacza, że nie było istotnej różnicy między rokiem 2000 i 2003 jeśli chodzi o p-stwo emigracji osób o identycznych charakterystykach.
5. Interpretacja $R^2_{\text{McKelvey'a i Zavoiny}}$: 13,4% zmienności nieobserwowalnej zmiennej ukrytej została wyjaśniona przez zmienne niezależne. Interpretacja $R^2_{\text{liczebnościowe}}$: w przypadku 99,2% obserwacji model prawidłowo przewidział sukces bądź porażkę. $\bar{R}^2_{\text{liczebnościowe}}$ jest skorygowane o liczebność najbardziej liczebnej kategorii. W analizowanym przypadku najliczniejsza kategoria (porażka), to $\frac{38916-317}{38916} = 99.2\%$ obserwacji. Model, który zawsze wskazywałby na tą kategorię przewidywałby prawidłowo 99.2% obserwacji. Po zastosowaniu korekty okazuje się, że zmienne mają bardzo mały wpływ na liczbę prawidłowo przewidzianych zdarzeń.
6. Wielkość efektu cząstkowego dla zmiennej kobieta oznacza, że kobiety o charakterystykach na poziomie średnich w próbie mają o 0.5 punkta procentowego mniejsze prawdopodobieństwo emigracji w stosunku do mężczyzn o charakterystykach na poziomie średnich w próbie.
7. Wielkość efektu cząstkowego dla zmiennej $\ln(\text{dochód})$ oznacza, że wzrost dochodu na głowę w gospodarstwie o 1% związany jest ze spadkiem p-stwa emigracji o 0.4 punktu procentowego.
8. Należy do modelu wstawić interakcję między płcią a latami nauki (kobieta \times lata nauki) oszacować tak rozbudowany model i przetestować istotność współczynnika przy dodanej zmiennej
9. Testując hipotezę łączną o nieistotności roku badania badamy hipotezę łączną o nieistotności parametrów przy trzech zmiennych: 2003, 2005, 2007. Statystyka testu LR ma więc rozkład $\chi^2(3)$. Ponieważ $LR = 154.95 > 7.81$ więc H_0 o nieistotności roku badania odrzucamy.

ZADANIE 3 Zmienna losowa y_i pochodzi z rozkładu Poissona z parametrem $\lambda_i = \exp(\mathbf{x}_i\beta)$ oraz zakładamy, że y_i i y_j są niezależne dla $i \neq j$.

1. Pokazać, że estymator $MNWH$ w tym modelu znajdujemy rozwiązując względem β następujący (nieliniowy) układ równań:

$$\sum_{i=0}^N e_i \mathbf{x}_i = \mathbf{0} \quad (*)$$

gdzie $e_i = y_i - \lambda_i$.

Podpowiedź: $\Pr(y_i = k) = \frac{e^{-\lambda_i} \lambda_i^k}{k!}$

IMIĘ NAZWISKO.....

2. Pokazać, że estymator *UMM* w tym modelu możemy znaleźć rozwiązując układ równań identyczny do układu (*).

Podpowiedź: W rozpatrywanym modelu $E(y_i | \mathbf{x}_i) = \lambda_i$.

3. Pokazać, że w przypadku występowania stałej w modelu, średnia dla wartości dopasowanych zmiennej zależnej $\hat{y}_i = \exp(\mathbf{x}_i \tilde{\boldsymbol{\beta}})$ uzyskana z oszacowanego modelu Poissona jest równa średniej z wielkości zaobserwowanych dla zmiennej zależnej y_i .

4. W przypadku modelu Poissona podnosi się często, że istotnym jego ograniczeniem jest założenie, że $E(y_i | \mathbf{x}_i) = \text{Var}(y_i | \mathbf{x}_i)$. Na podstawie wyników z poprzednich punktów wykazać, że estymator *MNW* parametru $\boldsymbol{\beta}$ uzyskany z modelu Poissona jest zgodny nawet wtedy, gdy założenie o równości wartości oczekiwanej i wariancji nie jest spełnione.

Rozwiązanie:

1. Zauważmy, że

$$\ln \Pr(y = k) = \ln \left(\frac{e^{-\lambda} \lambda^k}{k!} \right) = -\lambda + k \ln \lambda - \ln(k!)$$

$$\frac{\partial \ln \Pr(y = k)}{\partial \lambda} = \frac{k}{\lambda} - 1$$

Logarytm funkcji wiarygodności jest więc równy

$$\frac{\partial \ell(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = \frac{\partial \sum_{i=1}^N \ln \Pr(y_i)}{\partial \boldsymbol{\beta}} = \sum_{i=1}^N \frac{\partial \ln \Pr(y_i)}{\partial \lambda_i} \frac{\partial \lambda_i}{\partial \boldsymbol{\beta}}$$

$$= \sum_{i=1}^N \left(\frac{y_i}{\lambda_i} - 1 \right) \lambda_i \mathbf{x}_i = \sum_{i=1}^N (y_i - \lambda_i) \mathbf{x}_i = \sum_{i=1}^N e_i \mathbf{x}_i$$

a warunek pierwszego rzędu na maksymalizację logarytmu funkcji wiarygodności ma rzeczywiście postać układu równań:

$$\sum_{i=1}^N e_i \mathbf{x}_i = \mathbf{0}$$

2. Moment warunkowy

$$E(y_i | \mathbf{x}_i) = \lambda_i$$

wynika z tego, że

$$E(y_i - \lambda_i | \mathbf{x}_i) = E(\varepsilon_i | \mathbf{x}_i) = 0$$

gdzie $\varepsilon_i = y_i - \lambda_i$.

Moment bezwarunkowy

$$E(\varepsilon_i \mathbf{x}_i) = 0$$

Odpowiednik próbkowy

$$\frac{1}{N} \sum_{i=1}^N e_i \mathbf{x}_i = 0$$

3. W przypadku, gdy w modelu jest stała, jednym z elementów wektora \mathbf{x}_i będzie 1 a jednym z równań (*) będzie równanie $\sum_{i=0}^N e_i = 0$. To z kolei i definicja e_i implikują, że $\sum_{i=1}^N y_i = \sum_{i=1}^N \hat{\lambda}_i = \sum_{i=1}^N \exp(\mathbf{x}_i \tilde{\boldsymbol{\beta}}) = \sum_{i=1}^N \hat{y}_i$. Dzieląc obie strony przez N uzyskujemy $\bar{y} = \bar{\hat{y}}$.

4. Postać estymatora *MNW* w modelu Poissona jest taka sama jak estymatora *UMM*, jednak estymator *UMM* nie wykorzystuje założenia, że $\text{Var}(y_i | \mathbf{x}_i) = \lambda_i$. Estymator *UMM* jest więc zgodny nawet, gdy założenie to nie jest spełnione a zatem to samo dotyczy estymatora *MNW*.