

Egzamin z ekonometrii 2.02.2010

Pytania teoretyczne

1. Pokaż, że w modelu ze stałą średnia wartość zmiennej zależnej równa jest średniej z wartości dopasowanych.
2. Podaj definicję elastyczności cząstkowej.
3. Wyprowadź postać macierzy wariancji kowariancji estymatora MNK.
4. Kiedy mówimy, że w modelu występuje problem równoczesności? Jakie są jej dwie najczęstsze przyczyny i jakie ma ona konsekwencje dla własności MNK?

ZADANIE 1 Załóżmy, że spełnione są założenia KMRL

1. Pokaż, że wartość oczekiwana $E(e) = 0$, gdzie e jest wektorem reszt z modelu oszacowanego MNK.
2. Oblicz estymator MNK b_e z regresji y na e .

Rozwiązanie:

1. Jedno rozwiązanie

$$E(e) = E(M_x \varepsilon) = M_x \underbrace{E(\varepsilon)}_0 = 0$$

Inne rozwiązanie

$$E(e) = E(y - \hat{y}) = E(x\beta + \varepsilon - Xb) = X\beta + \underbrace{E(\varepsilon)}_0 - x \underbrace{E(b)}_\beta = 0$$

2. Jeden możliwy dowód: ponieważ $e'y = e'(Xb + e) = \underbrace{e'Xb}_0 + e'e = e'e$ a więc $b_e = (e'e)^{-1} e'e = 1$.

Inny dowód:

$$b_e = (e'e)^{-1} e'y = \frac{y'M_x y}{y'M_x y} = 1$$

przy czym skorzystaliśmy z tego, że macierz M_x jest idempotentna. Nieco trudniejszy jest dowód jeśli przyjmiemy, że w modelu jest także stała. Wtedy

$$\begin{aligned} b_e &= (e'e)^{-1} e'y = \begin{bmatrix} \mathbf{1}'\mathbf{1} & e'\mathbf{1} \\ \mathbf{1}'e & e'e \end{bmatrix}^{-1} \begin{bmatrix} e'y \\ e'y \end{bmatrix} \\ &= \begin{bmatrix} \frac{e'y}{N} \\ (e'e)^{-1} e'y \end{bmatrix} = \begin{bmatrix} \frac{e'e}{N} \\ 1 \end{bmatrix} \end{aligned}$$

ZADANIE 2 Badacz oszacował model, który wyjaśnia stopę wzrostu wyrażoną w procentach (growth), stosunkiem zagranicznych inwestycji bezpośrednich do PKB (FDI_GDP) wyrażonym w procentach, procentem populacji która jest piśmienna ($literacy$), stosunkiem inwestycji zagranicznych do PKB (inv_GDP) wyrażonym w procentach oraz zmienną zerojedynkową związaną z członkowstwem w Unii Europejskiej ($eu = 0$ nie jest członkiem, $eu = 1$ jest członkiem). Uzyskane przez badacza wyniki regresji wraz z wynikami testów diagnostycznych znajdują się poniżej

growth	b	se	t	p
FDI_GDP	-0.001	0.013	-0.055	0.956
literacy	0.050	0.020		
inv_GDP	0.124	0.049	2.520	0.013
eu	-1.176176	1.040	-1.130	0.261
stała	-2.336	1.847	-1.265	0.208
N	123			
F(4, 118)	3.840			0.006
R^2	.115			

Breusch-Pagan test $\chi^2(1) = 31.68$ [0.0000]
 Jarque - Bera test $\chi^2(2) = 2.71$ [0.2585]
 RESET F(3, 115) = 1.13 [0.3392]

UWAGA: testy przeprowadzamy na poziomie istotności $\alpha = 0.05$. Odpowiedzi należy uzasadnić wielkościami odpowiednich statystyk testowych.

1. Zinterpretuj wielkość R^2 . Sprawdź, czy zmienne w modelu są łącznie istotne.
2. Policz wielkość statystyki t dla zmiennej *literacy*. Zweryfikuj hipotezę o istotności tej zmiennej oraz o istotności zmiennej *FDI_GDP*.

Podpowiedź: $t_{0.975}(118) = 1.96$.

3. Zinterpretuj wielkości współczynników przy zmiennych *inv_GDP* oraz *eu*.
4. Badacz postanowił sprawdzić, poprawność obserwacji użytych w modelu. Policzył w tym celu dźwignię, standaryzowane reszty oraz odległość Cooka i uporządkował obserwacje według odległości Cooka. Czy w uzyskanej tabeli zawierającej obserwacje dla 3 największych odległości Cooka jest coś niepokojącego? W jaki sposób tego rodzaju problem należy rozwiązać?

	FDI_gdp	growth	inv_gdp	eu	literacy	cook	dźwignia	reszta stand.
Gwinea Równikowa	19.331	-7.758	41.654	0	87.0	.187	.058	-3.872
Azerbejdżan	-2.941	33.032	31.560	0	99.3	.246	.026	6.789
Luksemburg	304.948	5.016	17.797	1	99.0	23.109	.962	2.130

5. Zinterpretuj wielkość statystyk diagnostycznych.
6. Jakie są konsekwencje problemu wykrytego przez statystyki diagnostyczne? Wymień przynajmniej dwie metody radzenia sobie z tym problemem.

Rozwiązanie:

1. 11.5% zmienności zmiennej zależnej została wyjaśniona w modelu za pomocą zmiennych niezależnych. Hipoteza o nieistotności wszystkich zmiennych należy odrzucić wartość $p = 0.006 < 0.05$.
2. Statystyka t dla zmiennej *literacy* jest równa $\frac{0.050}{0.020} = 2.5 > 1.96$, hipotezę o nieistotności tej zmiennej należy odrzucić. Dla zmiennej *FDI_GDP*, wartość p jest równa $0.956 > 0.05$, w tym przypadku hipotezy o nieistotności nie da się odrzucić.
3. Wzrost sotosunku inwestycji do PKB o jeden punkt % powoduje podniesienie stopy wzrostu gospodarczego o 0.124 punktu procentowego, kraje przynależące do EU mają wzrost *ceteris paribus* niższy od krajów nie należących do tego ugrupowania o 1.176 punktu procentowego.
4. Bardzo niepokojąca jest wielkość statyki Cooka dla Luksemburga. Jest ona znacznie większa zarówno od 0.5 jak i od 1. Obserwacja ta jest więc bardzo wpływowa. Wydaje się jednak równośnie obserwacją błędną ponieważ trudno sobie wyobrazić by w roku 2006 bezpośrednio inwestycje w Luksemburgu były trzykrotnie większe od jego dochodu narodowego. Obserwację tę należy jeszcze raz sprawdzić w razie ustalenia, że jest błędna usunąć z próby.
5. Wielkość statystyki Breusch-Pagana zmusza na do odrzucenia H_0 o homoskedastyczności i przyjęcia H_1 o heteroskedastyczności (wartość $p = 0.000 < 0.05$), wartość statystyki dla testu Jarque-Bera nie pozwala na odrzucenie H_0 o normalności rozkładu czynnika losowego ($0.2585 > 0.05$), wartość statystyki hipotezy RESET nie pozwala na odrzucenie hipotezy o poprawności formy funkcyjnej ($0.3392 > 0.05$)
6. Testy diagnostyczne wykryły heteroskedastyczność w modelu. Konsekwencją heteroskedastyczności są błędne (obciążone i niezgodne) oszacowania macierzy wariancji kowariancji MNK. Z problem tym można sobie poradzić przy użyciu SUMNK lub odpornej macierzy wariancji kowariancji.

ZADANIE 3 Badacz postanowił oszacować wpływ zmian w systemie zasiłków rodzinnych na zachowania prokreacyjne. Badacz oznaczył zmienną otrzymywanie zasiłku przez z przyjmującą wartość 1 jeśli gospodarstwo miało prawo do zasiłku i 0 jeśli nie miało prawa do zasiłku. Pod koniec 2005 dochód na członka gospodarstwa, poniżej

którego wypłacano zasiłek rodzinny został obniżony z 548 zł do 504 zł. W konsekwencji rodziny o dochodzie między 504 i 548 utraciły prawo do zasiłku. Badacz dysponuje obserwacjami z roku 2005 i z roku 2006 dotyczącymi liczby narodzin y i sytuacji społeczno ekonomicznej rodzin o dochodzie niższym niż 548 zł. Dla tych obserwacji badacz zdefiniował zmienną zerojedynkową g , przyjmującą wartość 1 jeśli dana rodzina miała dochód w przedziale 504 do 548 i 0 dla rodzin o niższym dochodzie, oraz zmienną t , która przyjmuje wartość 0 dla obserwacji z roku 2005 i 1 dla obserwacji z roku 2006. Badacz poczynił następujące założenia upraszczające:

- a. Oczekiwana liczba narodzin we wszystkich rodzinach o dochodzie niższym niż 504 w roku 2005 byłaby równa β_0 , gdyby rodziny te nie otrzymywały zasiłku:

$$E(y|t = 0, g = 0, z = 0) = \beta_0$$

- b. Oczekiwana liczba narodzin między rokiem 2005 i 2006 zmieniłaby się o tyle samo dla rodzin o dochodzie poniżej 504 i o dochodzie między 504 i 548, gdyby nie wprowadzono zmian w systemie zasiłków rodzinnych:

$$E(y|t = 1, g = 0, z = 0) - E(y|t = 0, g = 0, z = 0) = \beta_1$$

$$E(y|t = 1, g = 1, z = 0) - E(y|t = 0, g = 1, z = 0) = \beta_1$$

- c. Oczekiwana liczba narodzin w rodzinach o dochodzie niższym od 504 i dochodzie między 504 i 548 różni się o β_2 . Różnica ta nie zmieniłaby się między rokiem 2005 i 2006, gdyby nie wprowadzono zmian w systemie zasiłków rodzinnych:

$$E(y|t = 0, g = 1, z = 0) - E(y|t = 0, g = 0, z = 0) = \beta_2$$

$$E(y|t = 1, g = 1, z = 0) - E(y|t = 1, g = 0, z = 0) = \beta_2$$

- d. Wpływ wprowadzonego zasiłku sumuje się z wpływem różnic dochodowych i wpływem czasu.

$$E(y|t, g, z) = E(y|t, g) + \beta_3 z$$

Pytania:

- Na podstawie podanych powyżej założeń znajdź rozwiązania dla $E(y|t = 0, g = 0, z = 0)$, $E(y|t = 1, g = 0, z = 0)$, $E(y|t = 0, g = 1, z = 0)$, $E(y|t = 1, g = 1, z = 0)$ w kategoriach β_0 , β_1 i β_2 .
- Na podstawie wyników uzyskanych w punkcie (1) i założenia (d) sformułuj model liniowy dla $E(y|t, g)$.
Podpowiedź: skorzystaj z tego, że t i g są zmiennymi zerojedynkowymi.
- Na podstawie wyników z punktu (2) oraz założenia (d) sformułuj model dla $E(y|t, g, z)$.
- Zastanów się, które gospodarstwa domowe nie otrzymują zasiłku. Korzystając z tego spróbuj zapisać z jako funkcję t i g i sformułuj model równoważny modelowi z punktu (3), ale wykorzystujący jako zmienne objaśniające jedynie t i g .

Rozwiązanie:

- Wychodząc założenia (d) dochodzimy oraz z założeń (b) i (c) dochodzimy do wniosku, że:

$$E(y|t = 0, g = 0, z = 0) = \beta_0$$

$$E(y|t = 1, g = 0, z = 0) - E(y|t = 0, g = 0, z = 0) = \beta_1$$

$$E(y|t = 1, g = 1, z = 0) - E(y|t = 0, g = 1, z = 0) = \beta_1$$

$$E(y|t = 0, g = 1, z = 0) - E(y|t = 0, g = 0, z = 0) = \beta_2$$

$$E(y|t = 1, g = 1, z = 0) - E(y|t = 1, g = 0, z = 0) = \beta_2$$

Daje to nam układ 5 równań z 4 niewiadomymi. Jedno równanie można odrzucić ponieważ jest liniowo zależne od pozostałych. Rozwiązaniem jest:

$$E(y|t = 0, g = 0, z = 0) = \beta_0$$

$$E(y|t = 1, g = 0, z = 0) = \beta_0 + \beta_1$$

$$E(y|t = 0, g = 1, z = 0) = \beta_0 + \beta_2$$

$$E(y|t = 1, g = 1, z = 0) = \beta_0 + \beta_1 + \beta_2$$

2. Dla zmiennych zerojedynkowych t i g równania z poprzedniego punktu można zapisać w sposób następujący:

$$E(y|t, g, z = 0) = \beta_0 + \beta_1 t + \beta_2 g$$

Korzystając znowu z założenia (d) dochodzimy do wniosku, że

$$E(y|t, g, z = 0) = E(y|t, g) = \beta_0 + \beta_1 t + \beta_2 g$$

3. Korzystając jeszcze raz z założenia (d) wnioskujemy, że

$$E(y|t, g, z) = E(y|t, g) + \beta_3 z = \beta_0 + \beta_1 t + \beta_2 g + \beta_3 z$$

4. W grupie analizowanych gospodarstw zasiłku nie otrzymywały jedynie gospodarstwa o dochodzie między 504 i 548 w roku 2006. Wynika z tego, że w naszej bazie danych zmienna $z = 1 - gt$. Ostatecznie model będzie miał postać:

$$E(y|t, g) = \beta_0 + \beta_1 t + \beta_2 g + \beta_3 (1 - gt)$$

lub

$$y = \beta_0 + \beta_1 t + \beta_2 g + \beta_3 (1 - gt) + \varepsilon$$

dla ε spełniającego $E(\varepsilon|t, g_i) = 0$.