

Egzamin z ekonometrii 12.09.2006

I semestr

Pytania teoretyczne

1. Wyjaśnić różnicę między parametrami i oszacowaniami parametrów oraz między odchyleniami losowymi i resztami

Parametry są nielosowe ale nieobserwowalne. Oszacowanie parametrów są funkcjami obserwowalnych y_i , x_i a więc są obserwowalne ale z reguły są losowe. Na przykład, w *KMRL* o wektorze parametrów β zakładamy, że jest nielosowy i nieobserwowalny ale oszacowanie tego parametru

$$\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\varepsilon$$

jest losowe, ponieważ jest funkcją błędów losowych ε .

Błędy losowe w *KMRL* odpowiadają, za losową niewyjaśnioną część zmienności y_i

$$y_i = \mathbf{x}_i\beta + \varepsilon_i$$

Reszty stanowią oszacowanie błędów losowych i liczymy je jako różnice między dopasowanymi y_i i zaobserwowanymi y_i :

$$e_i = y_i - \hat{y}_i = y_i - \mathbf{x}_i\mathbf{b}$$

2. Udowodnić, że w *KMRL* estymator \mathbf{b} jest nieobciążony.

$$E\left[(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}\right] = E\left[(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'(\mathbf{X}\beta + \varepsilon)\right] = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\underbrace{E(\varepsilon)}_0 = \beta$$

3. Dlaczego w modelu nie powinno się umieszczać jednocześnie stałej i wszystkich zmiennych zerojedynkowych związanych z poziomami zmiennej dyskretnej? Odpowiedź uzasadnić.

Jeśli zmienna dyskretna ma s poziomów, to jedna i tylko jedna z s utworzonych na jej podstawie zmiennych zerojedynkowych D_i przyjmuje wartość 1 a pozostałe przyjmują wartość 0. Wynika z tego, że $\sum_i^s D_i = 1$. Istnieje więc taka kombinacja liniowa D_i , która daje kolumnę jedynek. Oznacza to, że zbiór zawierający wszystkie zmienne dyskretne oraz stałą jest współliniowy.

4. Do czego służą testy diagnostyczne?

Testy diagnostyczne służą do testowania prawdziwości założeń modelu. Przykładowo w przypadku *KMRL* testy diagnostyczne mogą być wykorzystane do testowania prawdziwości założeń o homoskedastyczności, braku autokorelacji, czy normalności rozkładu błędu losowego.

ZADANIE 1

1. Jakie wymiary mają macierze $(\mathbf{X}'\mathbf{X})^{-1}$ i $\mathbf{X}'\mathbf{y}$, jeżeli szacowany jest KMRL ze stałą i z dziesięcioma zmiennymi objaśniającymi, a liczba obserwacji wynosi 120?
2. Zapisać pierwszy wiersz macierzy $\mathbf{X}'\mathbf{X}$ dla modelu ze stałą?
3. Na podstawie próby zawierającej s obserwacji wyestymowano model:

$$y = \alpha_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_s x_s + \varepsilon$$

Ile wyniesie współczynnik R^2 dla tego modelu?

Rozwiązanie:

1. Macierze $(\mathbf{X}'\mathbf{X})^{-1}$ i $\mathbf{X}'\mathbf{y}$ będą wymiarów, odpowiednio: 11×11 i 11×1 .
2. Pierwsza kolumna macierzy \mathbf{X} składa się z 1, więc pierwszy wiersz macierzy $\mathbf{X}'\mathbf{X}$ będzie miał elementy równe sumom elementów kolumn macierzy \mathbf{X} .

3. Współczynnik R^2 tego modelu jest równy 1, ponieważ wszystkie punkty/obserwacje leżą na hiperpłaszczyźnie regresji (np. dla jednego regresora liczba obserwacji wynosi 2). Ponadto, ponieważ liczba obserwacji (s) jest równa liczbie nieznanym parametrów modelu, liczba stopni swobody wynosi 0. Powoduje to że nie można oszacować błędów standardowych szukanych parametrów.

ZADANIE 2 Na podstawie danych pochodzących ze strony www.economagic.com zbudowano KMRL wyjaśniający kurs dolara amerykańskiego w stosunku do euro za pomocą podaży pieniądza w USA i indeksu cen dóbr konsumpcyjnych w USA (inflacji): $kurs = \alpha + \beta_1 podaz + \beta_2 cpi + \varepsilon$. Model bazuje na 108 obserwacjach od stycznia 1990 do stycznia 1999. Otrzymano następujące wyniki:

Source	SS	df	MS	Number of obs = 108		
Model	.136566483	2	.068283242	F(2, 105)	=	13.06
Residual	.548871572	105	.005227348	Prob > F	=	0.0000
-----				R-squared	=	0.1992
Total	.685438055	107	.006405963	Adj R-squared	=	0.1840
-----				Root MSE	=	.0723

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
kurs						
podaz	.0000863	.0000958	0.90	0.370	-.0001037	.0002764
cpi	-.0040808	.0010651	-3.83	0.000	-.0061927	-.001969
_cons	1.73358	.1012719	17.12	0.000	1.532776	1.934383

Durbin-Watson d-statistic(3, 108) = .1814083
 Breusch-Pagan chi2(1) = 1.61 Prob > chi2 = 0.2049
 Ramsey RESET F(3, 102) = 15.09 Prob > F = 0.0000
 Jarque-Bera chi2(2) = 6.91 Prob > chi2 = 0.0315

oraz macierz wariancji i kowariancji estymatorów:

	podaz	cpi	_cons
podaz	9.2e-09		
cpi	-8.0e-08	1.1e-06	
_cons	2.4e-06	-.000086	.010256

Na podstawie powyższych wyników odpowiedzieć na następujące pytania. Każdą odpowiedź uzasadnić wielkościami odpowiednich statystyk testowych. Testy przeprowadzić na poziomie istotności $\alpha = 0.05$.

Podpowiedź: wartości d_L i d_U dla testu DW przy 108 obserwacjach, 2 zmiennych i stałej oraz $\alpha = 0.05$ wynoszą $d_L = 1.63$, $d_U = 1.72$

1. Sprawdzić istotność oraz łączną istotność uzyskanych wyników.
2. Zinterpretować parametry modelu.
3. Sprawdzić, czy w modelu występuje heteroskedastyczność.
4. Sprawdzić, czy w modelu występuje autokorelacja.
5. Sprawdzić poprawność formy funkcyjnej modelu.
6. Sprawdzić, czy składnik losowy ma rozkład normalny.
7. Korzystając z wyników poprzednich podpunktów napisać, jakiej procedury estymacyjnej należy użyć, by otrzymać zgodny estymator macierzy wariancji?

Rozwiązanie:

1. Statystyka $F(3, 105) = 13.06$ oraz jej $p\text{-value} \approx 0$ wskazuje na łączną istotność zmiennych w modelu. Pojedynczo istotna jest α , ponieważ statystyka $|t_{\alpha}| = 17.12 > 1,96$ [$0.000 < 0.05$] oraz cpi ponieważ $|t_{CPI}| = 3,83 > 1,96$ [$0.000 < 0.05$], natomiast nieistotna jest $podaz$ ponieważ $p\text{-value}$ statystyki t dla tej zmiennej jest większe od 0.05 [$0.370 > 0,05$].

2. Wzrost podaży pieniądza o jednostkę powoduje wzrost kursu dolara w stosunku do euro o 0.00008. Wzrost wskaźnika cen konsumpcyjnych o jednostkę powoduje spadek kursu o 0.004.
3. Na podstawie testu Breuschy-Pagana nie ma podstaw do odrzucenia hipotezy o homoscedastyczności ponieważ p -value statystyki testowej wynosi 0.20 i jest większe od 0.05.
4. W modelu występuje autokorelacja, ponieważ statystyka Durбина-Watsona jest bliska 0. Dolna wartość krytyczna odczytana z tablic dla 2 zmiennych i 100 obserwacji wynosi 1.63. Wobec tego $DW < d_L$.
5. Na podstawie testu RESET $F(3, 105) = 15,09$, widzimy, że statystyka testowa jest duża, więc odrzucamy hipotezę zerową o poprawności formy funkcyjnej modelu.
6. Na podstawie statystyki Jarque-Berra równej 6,91 odrzucamy hipotezę zerową o normalności składnika losowego [$0.0315 < 0.05$].
7. Ponieważ w modelu występuje autokorelacja pierwszego rzędu i nie ma hetroscedastyczności zastosować estymator odporny Newey'a-Westy. Można też podjąć próbę usunięcia autokorelacji za pomocą Stosowalnej UMNK.

ZADANIE 3 Wyestymowano MNK następujący model dla wysokości płacy:

$$\ln(\text{płaca}_i) = \beta_0 + \beta_1 \text{staż}_i + \beta_2 \text{płeć}_i + \beta_3 \text{płeć}_i \times \text{staż}_i + \varepsilon_i \quad (*)$$

gdzie zmienna płeć koduje płeć respondenta (0 mężczyzna, 1 kobieta), a zmienna staż oznacza staż pracy ogółem. Uzyskano następujące oszacowania parametrów:

	Współczynnik	Błąd Std.	t	Pr ($ t > t^*$)
płeć	-.168465	.0265421	-6.347	0.000
staż	.010842	.0008269	13.111	0.000
płeć × staż	.000430	.0012526	.343	0.731
stała	7.457208	.0180958	412.096	0.000

1. Zinterpretować wielkości oszacowań parametrów w tym modelu (także nieistotnych).
2. Wyjaśnić z jakiego powodu w modelu umieszczono zmienną płeć × staż.
3. Pokazać, że otrzymane w tej regresji oszacowania parametrów $\beta_0, \beta_1, \beta_2, \beta_3$ można również uzyskać przeprowadzając osobno regresję dla kobiet i dla mężczyzn.

Podpowiedź: skorzystaj z tego, że model (*) można równoważnie zapisać jako:

$$\ln(\text{płaca}_i) = \beta_0 (1 - \text{płeć}_i) + \beta_2 (1 - \text{płeć}_i) \times \text{staż}_i + (\beta_0 + \beta_1) \text{płeć}_i + (\beta_2 + \beta_3) \text{płeć}_i \times \text{staż}_i + \varepsilon_i \quad (**)$$

oraz z tego, że dla modelu (**), przy odpowiednim uporządkowaniu obserwacji, macierzy X jest macierzą blokowo diagonalną.

Rozwiązanie:

1. Współczynnik przy płci oznacza, że kobiety zarabiają średnio o 16.8% mniej niż mężczyźni, współczynnik przy stażu oznacza, że mężczyźni zarabiają o 1% więcej z każdym dodatkowym rokiem stażu, współczynnik przy płeć × staż oznacza, że kobiety zyskują o 0.043% punktu procentowego więcej na dodatkowym roku stażu niż mężczyźni
2. Zmienną płeć × staż umieszczono po to, by uwzględnić w modelu różnicę między wzrostem płacy związanej ze wzrostem stażu w przypadku mężczyzn i kobiet.
3. Zmienna płeć jest zmienną zerojedynkową. Oznacza to, że jeśli płeć_i przyjmuje wartość 1, to 1 - płeć_i przyjmuje wartość 0. Jeśli uporządkujemy obserwacje według płci to macierz obserwacji X dla modelu

postaci (**) przyjmie postać:

$$\mathbf{X} = \begin{array}{cccc|c}
 \text{płeć}_i & \text{staż}_i & {}_i1 - \text{płeć} & (1 - \text{płeć}_i) \times \text{staż}_i & \\
 \hline
 1 & \text{staż} & 0 & 0 & \\
 \vdots & \vdots & \vdots & \vdots & \\
 1 & \text{staż} & 0 & 0 & \\
 0 & 0 & 1 & \text{staż} & \\
 \vdots & \vdots & \vdots & \vdots & \\
 0 & 0 & 1 & \text{staż} & \\
 \hline
 \end{array} = \begin{bmatrix} \mathbf{X}_1 & 0 \\ 0 & \mathbf{X}_2 \end{bmatrix}$$

a więc estymator MNK w modelu (*) można zapisać jako:

$$\begin{aligned}
 \mathbf{b} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} = \begin{bmatrix} (\mathbf{X}'_1\mathbf{X}_1)^{-1} & 0 \\ 0 & (\mathbf{X}'_2\mathbf{X}_2)^{-1} \end{bmatrix} \begin{bmatrix} \mathbf{X}'_1\mathbf{y}_1 \\ \mathbf{X}'_2\mathbf{y}_2 \end{bmatrix} \\
 &= \begin{bmatrix} (\mathbf{X}'_1\mathbf{X}_1)^{-1} \mathbf{X}'_1\mathbf{y}_1 \\ (\mathbf{X}'_2\mathbf{X}_2)^{-1} \mathbf{X}'_2\mathbf{y}_2 \end{bmatrix} = \begin{bmatrix} \mathbf{b}_1 \\ \mathbf{b}_2 \end{bmatrix}
 \end{aligned}$$

Estymatory \mathbf{b}_1 i \mathbf{b}_2 uzyskujemy z regresji logarytmu płacy na stałej i stażu osobno na podpróbce dla kobiet i mężczyzn. Oszacowania równe oszacowaniom w oryginalnym modelu można uzyskać wykorzystując relacja między parametrami w modelu (*) i (**)