

Egzamin z ekonometrii 13.06.2006

I semestr

Pytania teoretyczne

1. Zapisać model liniowy. Podać interpretację poszczególnych elementów tego modelu.

$$y_i = x_i \beta + \varepsilon_i$$

gdzie y_i jest zmienną objaśnianą, x_i wektorem zmiennych objaśniających, β nieznanym wektorem parametrów, ε_i zaburzeniem losowym

2. Dlaczego nie da się uzyskać oszacowań MNK jeśli liczba zmiennych objaśniających w modelu jest większa od liczby obserwacji?

Ponieważ w takim przypadku macierz $X'X$ jest macierzą osobliwą i nie da się znaleźć wielkości $b = (X'X)^{-1} X'y$

3. Wyprowadzić postać macierzy wariancji kowariancji b i podać interpretację jej elementów

Wyprowadzenie:

$$\begin{aligned} \text{Var}(b) &= \text{Var} \left[(X'X)^{-1} X'y \right] = \text{Var} \left[(X'X)^{-1} X' (X'\beta + \varepsilon) \right] = \text{Var} \left[\beta + (X'X)^{-1} X'\varepsilon \right] \\ &= (X'X)^{-1} X' \underbrace{\text{Var}(\varepsilon)}_{\sigma^2 I} X (X'X)^{-1} = \sigma^2 (X'X)^{-1} \end{aligned}$$

Elementy na przekątnej macierzy $\text{Var}(b)$ to wariancje elementów wektora b - $\text{Var}(b_r)$, a elementy poza przekątną to kowariancje między elementami wektora b - $\text{Cov}(b_r, b_s)$.

4. Pokazać, w jaki sposób można, dla znanej macierzy Ω , sprowadzić model z niesferycznymi błędami losowymi do modelu spełniającego założenia $KMRL$.

Model jest liniowy

$$y = X\beta + u,$$

$\text{Var}(u) = \Omega = \sigma^2 V$, V jest znana. Definiujemy L takie, że $LV L' = I$

$$Ly = LX\beta + Lu$$

lub

$$y^* = X^* \beta + u^*$$

Wariancję błędu losowego u^* dla modelu przekształconego:

$$\text{Var}(u^*) = \text{Var}(Lu) = \sigma^2 LV L' = \sigma^2 I$$

ZADANIE 1 Rozwiązać poniższe problemy:

1. Oszacowano model: $y_i = \beta_1 + \beta_2 x_{1i} + \varepsilon_i$. Obliczyć nieznane wartości reszt (e_3, e_4) , jeżeli wiadomo, że $x_1' = [2, 3, 1, 2]$, a $e' = [2, 1, e_3, e_4]$.
2. Oszacowano model $y_i = \beta_0 + \beta_1 x_{1i} + \varepsilon_i$ dla $y' = [2, 3, 5, 3, 2, 4]$ i uzyskano wartości dopasowane $\hat{y}' = [2, 2, 6, 2, 1, \hat{y}_6]$. Znaleźć \hat{y}_6 .
3. Pokazać, że w modelu $y_i = \beta + \varepsilon_i$ suma kwadratów reszt $e' e = \sum_{i=1}^N (y_i - \bar{y})^2$

Rozwiązanie:

1. Korzystamy z tego, że w modelu ze stałą $\sum e_i = 0$ i $X' e = 0 \implies \sum e_i x_{1i} = 0$. Wektor reszt będzie postaci: $e' = [2, -1, -5, 2]$.
2. Do rozwiązania zadania należy wykorzystać następującą właściwość hiperpłaszczyzny regresji - $\sum y_i = \sum \hat{y}_i$. Zatem $\hat{y}_6 = 6$.

3. W modelu, w którym występuje tylko stała $\mathbf{X} = \mathbf{l}$ a $\mathbf{b} = (\mathbf{l}'\mathbf{l})^{-1} \mathbf{l}'\mathbf{y} = \frac{1}{N} \sum_{i=1}^N y_i = \bar{y}$. Z kolei

$$e_i = y_i - x_i \mathbf{b} = y_i - \bar{y}$$

$$e'e = \sum_{i=1}^N (y_i - \bar{y})^2$$

ZADANIE 2 Procentowa różnica między średnią płacą kobiet i mężczyzn jest dana wzorem:

$$G = \frac{\bar{W}^m - \bar{W}^f}{\bar{W}^f}$$

gdzie $\bar{W}^f = \exp \left[\frac{1}{N} \sum_{i=1}^N \ln(W_i^f) \right] = \sqrt[N]{\prod_{i=1}^N W_i^f}$ jest średnią geometryczną płac dla kobiet. Analogicznie definiujemy \bar{W}^m .

Przekształcając wyjściowy wzór na G otrzymujemy:

$$\ln(G + 1) = \ln(\bar{W}^m) - \ln(\bar{W}^f)$$

Założmy, że płace determinowane są w następujący sposób

$$\begin{aligned} \ln(W_i^f) &= \mathbf{x}_i^f \boldsymbol{\beta}^f + \varepsilon_i^f \\ \ln(W_i^m) &= \mathbf{x}_i^m \boldsymbol{\beta}^m + \varepsilon_i^m \end{aligned}$$

gdzie $\mathbf{x}_i^f, \mathbf{x}_i^m$ są wierszowymi wektorami charakterystyk jednostek a ε_i^f i ε_i^m błędami losowymi. Oczekiwana wartość $\ln(1 + G)$ można wyrazić za pomocą wielkości parametrów w obu modelach i wektorów średnich charakterystyk $\bar{\mathbf{x}}^f$ i $\bar{\mathbf{x}}^m$

$$E[\ln(1 + G)] = \bar{\mathbf{x}}^f \boldsymbol{\beta}^f - \bar{\mathbf{x}}^m \boldsymbol{\beta}^m = \bar{\mathbf{x}}^f \boldsymbol{\beta}^f - \bar{\mathbf{x}}^m \boldsymbol{\beta}^f + (\bar{\mathbf{x}}^m \boldsymbol{\beta}^f - \bar{\mathbf{x}}^m \boldsymbol{\beta}^m) = (\bar{\mathbf{x}}^f - \bar{\mathbf{x}}^m) \boldsymbol{\beta}^f + \bar{\mathbf{x}}^m (\boldsymbol{\beta}^f - \boldsymbol{\beta}^m)$$

Ronald Oaxaca (1973) zaproponował, by wielkość $d_x = (\bar{\mathbf{x}}^f - \bar{\mathbf{x}}^m) \boldsymbol{\beta}^f$ interpretować jako różnicę w płacach wynikającą ze z różnic w charakterystykach kobiet i mężczyzn a wielkość $d_\beta = \bar{\mathbf{x}}^m (\boldsymbol{\beta}^f - \boldsymbol{\beta}^m)$ traktować jako miarę dyskryminacji.

Zlogarytmowana płaca została w poniższych modelach uzależniona od wykształcenia w latach i wieku respondentów. Dla kobiet i mężczyzn regresje MNK oszacowano osobno. Zakładamy, że próby dla mężczyzn i kobiet są niezależne.

Regresja dla mężczyzn			Regresja dla kobiet		
ln (płaca)	Współczynnik	Bł. Std	ln (płaca)	Współczynnik	Bł. Std
wykształcenie	0.313	0.008	wykształcenie	0.252	0.007
wiek	0.060	0.002	wiek	0.067	0.002

Średnie charakterystyki dla kobiet i mężczyzn:

pleć	wykształcenie	wiek
mężczyzna	11.191	39.040
kobieta	11.764	39.827

1. Znaleźć oszacowania \hat{d}_x i \hat{d}_β
2. Oszacować współczynnik zróżnicowania płac $E[\ln(G + 1)]$
3. Zinterpretować uzyskane wyniki. **Podpowiedź:** Dla małych x , $\ln(x + 1) = x$

Założmy, że znamy oszacowanie wariancji oszacowań wektorów parametrów uzyskanych z MNK : $\text{Var}(\hat{\mathbf{b}}^f) = \hat{\Sigma}^f$ i $\text{Var}(\hat{\mathbf{b}}^m) = \hat{\Sigma}^m$

4. Policzyc wariancję:

- (a) oszacowania \widehat{d}_x
- (b) oszacowania \widehat{d}_β

5. Policzyc wariancję oszacowania $E[\ln(\widehat{G+1})]$

Rozwiązanie:

1. Z podanego wzoru współczynnik zróżnicowania płac jest równy:

$$\widehat{d}_x = (11.764 - 11.191) 0.252 + (39.827 - 39.040) 0.067 = 0.197$$

$$\widehat{d}_\beta = 11.191 (0.252 - 0.313) + 39.040 (0.067 - 0.060) = -0.409$$

2. $\ln(G+1) = 0.197 - 0.409 = -0.212$

3. Całkowita różnica w płacach wynosi 21.12%. Z powodu dyskryminacji kobiety płaca kobiet jest o 40.9% niższa, ze zróżnicowania charakterystyk wynikałoby, że kobiety powinny zarabiać 19.7% więcej niż mężczyźni.

4. Wariancję oszacowań można \widehat{d}_x liczymy ze wzoru na wariancję prognozy:

$$\text{Var}(\widehat{d}_x) = \text{Var}[(\bar{x}^f - \bar{x}^m) \mathbf{b}^f] = (\bar{x}^f - \bar{x}^m) \text{Var}(\mathbf{b}^f) (\bar{x}^f - \bar{x}^m)'$$

oszacowaniem tej wielkości będzie $(\bar{x}^f - \bar{x}^m) \widehat{\Sigma}^f (\bar{x}^f - \bar{x}^m)'$

5. Wariancja oszacowania \widehat{d}_β znajdujemy z ogólnych własności wariancji

$$\text{Var}(\widehat{d}_\beta) = \text{Var}[\bar{x}^m (\mathbf{b}^f - \mathbf{b}^m)] = \bar{x}^m \text{Var}(\mathbf{b}^f - \mathbf{b}^m) \bar{x}^{m'}$$

Z kolei

$$\text{Var}(\mathbf{b}^f - \mathbf{b}^m) = \text{Var}(\mathbf{b}^f) + \text{Var}(\mathbf{b}^m) - \underbrace{2\text{Cov}(\mathbf{b}^f, \mathbf{b}^m)}_0 = \text{Var}(\mathbf{b}^f) + \text{Var}(\mathbf{b}^m)$$

$\text{Cov}(\mathbf{b}^f, \mathbf{b}^m) = 0$, ponieważ błędy oszacowań uzyskanych z dwóch niezależnych prób są też niezależne

W rezultacie oszacowaniem wariancji jest $\bar{x}^m (\widehat{\Sigma}^f + \widehat{\Sigma}^m) \bar{x}^{m'}$

6. Wariancja oszacowania jest równa:

$$\begin{aligned} \text{Var}(E[\ln(\widehat{G+1})]) &= \text{Var}(\bar{x}^f \mathbf{b}^f - \bar{x}^m \mathbf{b}^m) \\ &= \bar{x}^f \text{Var}(\mathbf{b}^f) \bar{x}^{f'} + \bar{x}^m \text{Var}(\mathbf{b}^m) \bar{x}^{m'} - \underbrace{\bar{x}^f \text{Cov}(\mathbf{b}^f, \mathbf{b}^m) \bar{x}^{m'}}_0 \\ &= \bar{x}^f \text{Var}(\mathbf{b}^f) \bar{x}^{f'} + \bar{x}^m \text{Var}(\mathbf{b}^m) \bar{x}^{m'} \end{aligned}$$

Oszacowaniem wariancji estymatora $E[\ln(\widehat{G+1})]$ będzie więc $\bar{x}^f \widehat{\Sigma}^f \bar{x}^{f'} + \bar{x}^m \widehat{\Sigma}^m \bar{x}^{m'}$

ZADANIE 3 Oszacowano regresję logarytmu zagregowanej konsumpcji w wyrażeniu *nominalnym* (zmienna y) na logarytmie PKB w wyrażeniu *nominalnym* (zmienna x_1) i logarytmie deflatora (zmienna x_2). Regresję przeprowadzono dla danych kwartalnych dla Polski z okresu 1995-2002. Wprowadzono także do modelu zmienne sezonowe przyjmujące wartość 1 dla odpowiedniego kwartału a 0 dla pozostałych. Wyniki regresji znajdują się w tabeli poniżej.

y	Coef.	Std.Err.	t	P> t
x1	.80	.081	9.72	0.000
x2	-.59	.117	-5.00	0.000
seasonal2	-.05	.011	-4.38	0.000
seasonal3	-.07	.011	-6.25	0.000
seasonal4	-.17	.012	-14.36	0.000
cons	1.87	.926	2.02	0.054

Number of obs = 32, F(5, 26) = 229.88 [0.0000]
R-squared = 0.9779, s = .02027

Durbin-Watson test statistic: d(6, 32) =2.261303
Breusch-Godfrey LM statistic: Chi-sq(2) =4.894179 [.0867]
Breusch-Pagan test statistic: Chi-sq(2) =10.41 [.0054]
White's general test statistic: Chi-sq(14) =35.15268 [.0013]
Jarque-Berra test statistic: Chi-sq(2) =8.34 [.0154]
Ramsey RESET test statistic: F(3, 23) =1.66 [.2030]
Chow test statistic (t=1999.1): F(3, 23) =0.28 [.8359]

Przy założonym poziomie istotności $\alpha = 0.01$ przeprowadzić analizę wyników. Każdą z odpowiedzi należy uzasadnić za pomocą odpowiedniego testu.

Podpowiedź: wartości d_L i d_U dla testu DW przy 32 obserwacjach, 5 zmiennych i stałej oraz $\alpha = 0.01$ wynoszą $d_L = 0.917$, $d_U = 1.597$.

1. Określić, czy model jest dobrze dopasowany, czy zbiór zmiennych niezależnych istotnie objaśnia zmienną zależną.
2. Podać, które zmienne w modelu są istotne.
3. Zbadać, czy w modelu występuje autokorelacja.
4. Zbadać, czy w modelu występuje heteroskedastyczność.
5. Sprawdzić, czy forma funkcyjna modelu jest prawidłowa.
6. Przetestować, czy błąd losowy w modelu ma rozkład normalny.
7. Sprawdzić, czy parametry modelu są stabilne.
8. Zinterpretować współczynnik przy zmiennej x_2 .
9. W jaki sposób należałoby weryfikować hipotezę o neutralności pieniądza w gospodarce (tzn., że ważne są jedynie wartości realne a nie nominalne)?
10. W jaki sposób należałoby weryfikować hipotezę mówiącą o tym, że zmienne sezonowe są nieistotne w modelu?
11. Jeśli model nie spełnia założeń KMRL określić:
 - (a) które założenie nie jest spełnione?
 - (b) jakie ma to konsekwencje dla wnioskowania statystycznego?
 - (c) jakie są metody radzenia sobie z tym problemem?

Rozwiązanie:

1. Oszacowany model objaśnia prawie 98% zmienności zmiennej zależnej (współczynnik $R^2 = 0.9779$). Zbiór zmiennych objaśniających (bez stałej) jest łącznie istotny ($F_{5,26} = 229.88$) [$0.0000 < 0.01$].
2. Wszystkie zmienne objaśniające poza stałą są istotne na zadanym poziomie istotności (p -value dla statystyk t są mniejsze od 0.01).

-
3. W modelu nie występuje autokorelacja I rzędu ponieważ statystyka $DW \approx 2.26 \in (1.597, 2.403)$ przyjmuje wartość, która nie pozwala odrzucić hipotezy zerowej. Odpowiednie wartości krytyczne dla tego testu wynoszą ($d_L = 0.917, d_U = 1.597$). Także p -value dla testu Breuscha-Godfrey'a świadczy o tym, że w modelu nie ma autokorelacji [$.0867 > 0.01$].
 4. Odrzucamy hipotezę o homoskedastyczności składnika losowego w związku z wartością p -value dla testu White'a [$.0013 < 0.01$].
 5. Forma specyfikacji modelu jest prawidłowa, o czym świadczy p -value dla testu RESET [$.2030 > 0.01$].
 6. Błąd losowy ma rozkład normalny, o czym świadczy p -value dla testu Jarque'a-Berra [$.1886 > 0.01$].
 7. Parametry modelu są stabilne, o czym świadczy p -value dla testu Chowa [$.8359 > 0.01$].
 8. Współczynnik przy zmiennej x_2 jest elastycznością zagregowanej konsumpcji względem deflatora, zatem wzrost deflatora o 1% spowoduje spadek zagregowanej konsumpcji o -0.59% .
 9. Model można zapisać jako

$$\log(\text{cons}) = \alpha_1 + \alpha_2 \log(\text{pkb}) + \alpha_3 \log(\text{defl}) + \varepsilon$$

Konsumpcja i PKB w wyrażeniu realnym są równe odpowiednio $\text{cons}^* = \frac{\text{cons}}{\text{defl}}$, $\text{pkb}^* = \frac{\text{pkb}}{\text{defl}}$. Odejmując od obu stron $\log(\text{defl})$ uzyskujemy

$$\log(\text{cons}^*) = \alpha_1 + \alpha_2 \log(\text{pkb}^*) + (\alpha_2 + \alpha_3 - 1) \log(\text{defl}) + \varepsilon$$

a więc na konsumpcję w wyrażeniu realnym wpływa jedynie dochód w wyrażeniu realnym jeśli prawdziwe jest $H_0 : \alpha_2 + \alpha_3 = 1$.

10. Hipotezę o łącznej nieistotności zmiennych sezonowych należy testować za pomocą testu F , nakładając łączne ograniczenie na parametry przy zmiennych $\text{seasonal}_2, \text{seasonal}_3, \text{seasonal}_4$, - przyrównując je jednocześnie do zera.
11. (a) Model nie spełnia założenia braku heteroskedastyczności składnika losowego
 (b) Macierz wariancji-kowariancji jest niewłaściwa, co powoduje, że niewłaściwe są błędy standardowe parametrów i tym samym niewłaściwe są statystyki t .
 (c) Jeśli nie chcemy usunąć heteroskedastyczności, należy posłużyć się tzw. odporną macierzą wariancji-kowariancji White'a. Można też podjąć próbę usunięcia heteroskedastyczności za pomocą Stosowanej UMNK.