

# Egzamin z ekonometrii 30.01.2009

## 1 semestr

### Pytania teoretyczne

1. Pokazać, że w modelu ze stałą sumą reszt jest równa zero.
2. Wyprowadzić postać macierzy wariancji kowariancji  $\mathbf{b}$  i podać interpretację jej elementów.
3. Jaką postać ma statystyka służąca do testowania hipotezy o tym, że  $\beta_k = \beta_k^*$ ?
4. W jakim szczególnym przypadku można uzyskać prawidłowe oszacowania parametrów mimo, że w modelu pominięto istotne zmienne?

**ZADANIE 1** Przyjmijmy, że  $y$  to logarytm dochodu respondenta, a  $x$  to zmienna opisująca płeć respondenta, przyjmująca wartość 2 dla mężczyzny oraz 1 dla kobiety. Czyli badamy wpływ płci na dochód, ale badacz zapomniał rozkodować zmienną dyskretną na zmienne zerojedynkowe. Badacz szacuje model:

$$y_i = \alpha_0 + \alpha_1 x_i + \varepsilon_i \quad (*)$$

podczas gdy chce oszacować model:

$$y_i = \beta_0 + \beta_1 \text{plec}_m + \varepsilon_i \quad (**)$$

gdzie  $\text{plec}_m$  przyjmuje wartość 1 dla mężczyzny a 0 dla kobiety.

1. Zakładając, że są spełnione założenia KMRL, pokaż, że szacując MNK model (\*) uzyskamy nieobciążony estymator  $\hat{\alpha}_1$  dla parametru  $\beta_1$ , ale obciążony estymator  $\hat{\alpha}_0$  parametru dla stałej  $\beta_0$ .
2. Porównaj  $RSS$  i  $R^2$  w regresjach (\*) i (\*\*) – odpowiedź dokładnie uzasadnij.

*Rozwiązanie:*

1. Zauważmy, że  $x_i = \text{plec}_m + 1$ . Model (\*\*) można przekształcić w sposób następujący:

$$\begin{aligned} y_i &= \beta_0 + \beta_1 \text{plec}_m + \varepsilon_i \\ &= (\beta_0 - \beta_1) + \beta_1 (\text{plec}_m + 1) + \varepsilon_i \\ &= (\beta_0 - \beta_1) + \beta_1 x_i + \varepsilon_i \\ &= \alpha_0 + \alpha_1 x_i + \varepsilon_i \end{aligned}$$

gdzie  $\alpha_0 = \beta_0 - \beta_1$ ,  $\beta_1 = \alpha_1$ . Przy spełnionych założeniach KMRL estymator  $\hat{\alpha}_1$  jest nieobciążonym estymatorem parametru  $\beta_1$  a estymator  $\hat{\alpha}_0$  nieobciążonym estymatorem parametru  $\alpha_0 = \beta_0 - \beta_1$  ale obciążonym estymatorem parametru  $\beta_0$ . Obciążenie estymatora  $\hat{\alpha}_0$  jako estymatora parametru  $\beta_0$  wynosi  $\beta_0 - E(\hat{\alpha}_0) = \beta_1$ .

2.  $TSS$  w modelu (\*) i (\*\*) będzie takie samo, bo zmienna zależna w obu modelach jest identyczna. Zauważmy, z zależności  $\text{plec}_m = x_i - 1$  wynika, że  $\mathbf{X}^* = \mathbf{X}\mathbf{A}$ , gdzie  $\mathbf{X}$  zmienne w modelu (\*) a  $\mathbf{X}^*$  zmienne w modelu (\*\*). a  $\mathbf{A}$  ma postać  $\begin{bmatrix} 1 & -1 \\ 0 & 1 \end{bmatrix}$  i jest nieosobliwa (przyjmujemy, że pierwszą kolumną macierzy  $\mathbf{X}$  jest stała).  $RSS$  w modelu (\*) jest równa

$$RSS = \mathbf{e}'\mathbf{e} = \mathbf{y}'\mathbf{M}_X\mathbf{y},$$

a w modelu (\*\*)

$$\begin{aligned} RSS^* &= \mathbf{e}^{*'}\mathbf{e}^* = \mathbf{y}\mathbf{M}_{X^*}\mathbf{y} = \mathbf{y}'\left(\mathbf{I} - \mathbf{X}^*(\mathbf{X}^{*'}\mathbf{X}^*)^{-1}\mathbf{X}^{*'}\right)\mathbf{y} \\ &= \mathbf{y}'\left(\mathbf{I} - \mathbf{X}^*\mathbf{A}(\mathbf{A}'\mathbf{X}^{*'}\mathbf{X}^*\mathbf{A})^{-1}\mathbf{A}'\mathbf{X}^{*'}\right)\mathbf{y} \\ &= \mathbf{y}'\left(\mathbf{I} - \mathbf{X}^*\mathbf{A}\mathbf{A}^{-1}(\mathbf{X}^{*'}\mathbf{X}^*)^{-1}\mathbf{A}'\mathbf{X}^{*'}\right)\mathbf{y} \\ &= \mathbf{y}'\left(\mathbf{I} - \mathbf{X}^*(\mathbf{X}^{*'}\mathbf{X}^*)^{-1}\mathbf{X}^{*'}\right)\mathbf{y} \\ &= RSS \end{aligned}$$

tak więc sumy kwadratów reszt w obu modelach są równe, ponieważ równe są też  $TSS$  więc takie same będą również  $R^2 = \frac{ESS}{TSS} = \frac{TSS - RSS}{TSS}$

**ZADANIE 2** Zakładamy, że prawdziwy jest następujący model bez stałej i z dwoma zmiennymi objaśniającymi:

$$y_i = \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i,$$

gdzie  $E(\varepsilon_i) = 0$ ,  $\text{Var}(\varepsilon_i) = \sigma^2$ ,  $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$  dla  $i \neq j$ .

Jako oszacowanie nieznanego parametru  $\beta_1$  zaproponowano estymator postaci  $b_1 = \frac{\sum_{i=1}^n y_i}{x_{n:n}}$ , gdzie  $x_{n:n} = \max(x_{11}, \dots, x_{1n})$ . Wyznaczyć obciążenie dla podanego estymatora przy założeniu, że zmienne objaśniające są nielosowe.

*Rozwiązanie:*

$$E(y_i) = E(\beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i) = \beta_1 x_{1i} + \beta_2 x_{2i}$$

$$\begin{aligned} E(b_1) &= E\left(\frac{\sum_{i=1}^n y_i}{x_{n:n}}\right) = \frac{1}{x_{n:n}} E\left(\sum_{i=1}^n y_i\right) = \frac{1}{x_{n:n}} \sum_{i=1}^n E(y_i) = \frac{1}{x_{n:n}} \sum_{i=1}^n (\beta_1 x_{1i} + \beta_2 x_{2i}) \\ &= \frac{1}{x_{n:n}} \left(\beta_1 \sum_{i=1}^n x_{1i} + \beta_2 \sum_{i=1}^n x_{2i}\right) \end{aligned}$$

Zatem obciążenie estymatora wynosi:

$$\beta_1 - E(b_1) = \beta_1 - \frac{1}{x_{n:n}} \sum_{i=1}^n (\beta_1 x_{1i} + \beta_2 x_{2i})$$

**ZADANIE 3** Październikowe Badania Wynagrodzeń jest przekrojowym badaniem płacy w przedsiębiorstwach zatrudniających powyżej 10 pracowników. Na podstawie uzyskanych informacji oszacowano parametry równania płacy w sektorze przedsiębiorstw dla Polski, uzyskując następujące wyniki: Zmienna *lzarobki* oznacza logarytm płacy, *wiek* jest wiekiem pracownika w latach, *wiek2* to kwadrat zmiennej *wiek*, *plec* przyjmuje wartość 2 dla kobiety, *dosw* to doświadczenie zawodowe pracownika w latach, *dosw2* to kwadrat doświadczenia, *prywatna* oznacza, że firma jest własnością prywatną, *wielkosc 1* oznacza firmę do 20 pracowników, *wielkosc 2* oznacza firmę zatrudniającą od 20 do 100 pracowników, a *wielkosc 3* firmę zatrudniającą powyżej 100 pracowników.

Source	SS	df	MS	Number of obs =	48692
Model	1544.52571	8	193.065714	F( 8, 48683) =	788.67
Residual	11917.5166	48683	.244798319	Prob > F =	0.0000
				R-squared =	0.1147
				Adj R-squared =	0.1146
Total	13462.0423	48691	.276479068	Root MSE =	.49477

lzarobki	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
wiek	.0322697	.0026325	12.26	0.000	.0271099 .0374295
wiek2	-.0003021	.0000315	-9.60	0.000	-.0003638 -.0002404
_Iplec_2	-.1579855	.0046649	-33.87	0.000	-.1671287 -.1488423
dosw	-.003419	.0012305	-2.78	0.005	-.0058308 -.0010073
dosw2	.0001455	.0000294	4.94	0.000	.0000878 .0002032
prywatna	.1710564	.0047111	36.31	0.000	.1618226 .1802901
_Iwielkosc_2	.1138605	.0089159	12.77	0.000	.0963853 .1313358
_Iwielkosc_3	.2243529	.008288	27.07	0.000	.2081083 .2405975
_cons	6.645797	.0461863	143.89	0.000	6.555271 6.736322

Breusch-Pagan  $\chi^2(1) = 2.90$  Prob >  $\chi^2 = 0.0886$   
 Ramsey RESET test  $F(9, 48675) = 2.14$  Prob > F = 0.0534

Przyjmując poziom istotności  $\alpha = 0,05$  odpowiedz na poniższe pytania:

1. Oceń dopasowanie modelu do danych empirycznych.
2. Określ które zmienne można uznać za statystycznie istotne?

3. Dokonaj interpretacji wartości parametrów modelu.
4. Czy forma funkcyjna oszacowanego powyżej modelu jest liniowa?
5. Czy składnik losowy oszacowanego modelu jest homoscedastyczny
6. Zaproponuj sposób weryfikacji hipotezy o braku wpływu doświadczenia zawodowego na wysokość uzyskiwanych zarobków.
7. Z jakiego powodu nie przeprowadzono testu autokorelacji składnika losowego?
8. Jeżeli model nie spełnia założeń KMRL opisz jakie to ma konsekwencje dla poprawności wnioskowania statystycznego, oraz jakie są metody radzenia sobie z tym problemem.

Każdą odpowiedź uzasadnij wynikiem odpowiednich testów diagnostycznych zapisując po wartości statystyki testowej lub jej *p-value*, oraz interpretację wyniku.

*Rozwiązanie:*

1. Zmienne objaśniające wyjaśniają wariację zarobków w 11 %, o czym świadczy wielkość statystyki  $R^2$ . Parametry modelu są łącznie istotne, gdyż *p-value* statystyki F wynosi 0.000
2. Statystycznie istotne są wszystkie zmienne objaśniające, poza zmienną płeć, gdyż statystyki *t* są większe od 2, a ich *p-value* wynosi 0.
3. Zmienna zależna jest zlogarytmowana więc współczynniki należy interpretować jako semielastyczności. Kobiety zarabiają przeciętnie 15 % mniej niż mężczyźni, pracownicy firm prywatnych zarabiają przeciętnie 17 % więcej niż pracownicy firm państwowych w sektorze przedsiębiorstw, pracownicy form średniej wielkości zarabiają przeciętnie o 11% więcej od pracowników małych firm, pracownicy dużych firm zarabiają przeciętnie o 22 % więcej od pracowników małych firm. Wiek oraz doświadczenie zawodowe wpływa na uzyskiwane zarobki w sposób nieliniowy.

$$\frac{\partial \text{zarobki}}{\partial \text{wiek}} = \beta_{\text{wiek}} + 2\beta_{\text{wiek}^2} \bar{\text{wiek}}$$

$$\frac{\partial \text{zarobki}}{\partial \text{dosw}} = \beta_{\text{dosw}} + 2\beta_{\text{dosw}^2} \bar{\text{dosw}}$$

Bez informacji o średnim wieku i doświadczeniu zawodowym w próbie nie można dokonać ilościowej interpretacji.

4. Założenie o poprawności formy funkcyjnej można weryfikować testem RESET. Wartość statystyki testowej wynosi 2.14, a jej *p-value*  $\text{Prob} > F = 0.0534 > \alpha = 0.05$  wobec tego brak jest podstaw do odrzucenia hipotezy o poprawności formy funkcyjnej.
5. Na podstawie wyniku testu Breuscha-Pagana można stwierdzić, że brak jest podstaw do odrzucenia hipotezy o homoscedastyczności składnika losowego, gdyż *p-value* statystyki testowej wynosi  $0.0886 > \alpha = 0.05$
6. Aby przetestować hipotezę o braku wpływu doświadczenia na wysokość zarobków należy sprawdzić czy współczynniki przy zmiennych *dosw* oraz *dosw*<sup>2</sup> wynosi zero. Mając oszacowania modelu bez ograniczeń można oszacować model z narzuconymi ograniczeniami, a następnie na podstawie sumy kwadratów reszt obu modeli zbudować statystykę  $F = \frac{(RSS_R - RSS_U) / (N - k)}{RSS_U}$  i porównać z wartością krytyczną z rozkładu F.
7. Nie testowano występowania autokorelacji, ponieważ zjawisko autokorelacji jest związane z czasowym wymiarem danych, a parametry modelu zostały uzyskane na podstawie próby przekrojowej.
8. Na podstawie przeprowadzonych testów można uznać, że model spełnia założenia KMRL, zatem uzyskane oszacowania, w myśl tw. Gaussa-Markowa, są najlepszymi, liniowymi i nieobciążonymi estymatorami.