

Egzamin z ekonometrii 14.06.2011

Pytania teoretyczne

1. Pokazać, że w modelu ze stałą suma reszt jest równa zeru.
2. Wyjaśnić, dlaczego R^2 nie można używać do porównywania modeli.
3. Wymienić założenia Klasycznego Modelu Regresji Liniowej (KMRL).
4. Za pomocą jakich testów testuje się autokorelację? Jakiemu założeniu KMRL odpowiada H_0 w tych testach? Jakie są hipotezy alternatywne w tym testach?

ZADANIE 1 Pokazać, że w modelu $y_i = \beta + \varepsilon_i$ suma kwadratów reszt $e' e = \sum_{i=1}^N (y_i - \bar{y})^2$

Rozwiązanie: W modelu, w którym występuje tylko stała $X = \mathbf{1}$ a $\mathbf{b} = (\mathbf{1}'\mathbf{1})^{-1} \mathbf{1}'\mathbf{y} = \frac{1}{N} \sum_{i=1}^N y_i = \bar{y}$. 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 Na podstawie danych z Diagnozy Społecznej z roku 2009 badacz oszacował model, który wyjaśnia poziom logarytmu dochodu respondenta (*ldochód*) za pomocą logarytmu czasu pracy (*lczas_pracy*), płci (zmienna *plec*; kodowanie: 1 - mężczyzna, 2 - kobieta), wieku (*wiek*), wieku do kwadratu (*wiek2*), lat nauki (*lata_nauki*), interakcją między płcią i latami nauki (*plec_2Xlata* - liczba lat nauki dla kobiet, dla mężczyzn 0) oraz znajomością języka angielskiego (*ang*, kodowanie: 1 - czynna znajomość języka, 2 - bierna, 3 - brak znajomości). Uzyskane przez badacza wyniki regresji wraz z wynikami testów diagnostycznych znajdują się poniżej.

Source	SS	df	MS	Number of obs =	10258
Model	1071.42376	8	133.92797	F(8, 10249) =	479.44
Residual	2863.00835	10249	.279345141	Prob > F =	0.0000
Total	3934.43212	10257	.383585075	R-squared =	0.2723
				Adj R-squared =	0.2718
				Root MSE =	.52853

ldochód	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
lczas_pracy	.0134909	.0005247	25.71	0.000	.0124624 .0145195
wiek	.03176	.003029	10.49	0.000	.0258225 .0376975
wiek2	-.0002728	.0000351	-7.78	0.000	-.0003415 -.000204
_Iplec_2	-.3891494	.0467148	-8.33	0.000	-.4807195 -.2975793
lata_nauki	.0713448	.0027206	26.22	0.000	.0660119 .0766776
_Iplec_2Xlata	.0116455	.0035241	3.30	0.001	.0047376 .0185533
_Iang_2	-.0329431	.0185773	-1.77	0.076	-.0693582 .003472
_Iang_3	-.1750962	.018	-9.73	0.000	-.2103797 -.1398128
_cons	5.3019	.0668522	79.31	0.000	5.170857 5.432943

Variable	VIF	1/VIF
wiek	47.60	0.021011
wiek2	46.55	0.021482
_Iplec_2Xlata	22.02	0.045410
_Iplec_2	19.96	0.050096
_Iang_3	2.63	0.380093
lata_nauki	2.43	0.412268
_Iang_2	1.74	0.576161
lczas_pracy	1.12	0.893374
Mean VIF	18.01	

Breusch-Pagan test $\chi^2(1) = 21.81$ [0.000]
Jarque - Bera test $\chi^2(2) = 2254.93$ [0.000]
RESET $F(3, 115) = 5.27$ [0.0012]

UWAGA: testy przeprowadzamy na poziomie istotności $\alpha = 0.05$. W nawiasach kwadratowych znajdują się wartości p. Odpowiedzi należy uzasadnić wielkościami odpowiednich statystyk testowych.

1. Zinterpretuj wielkość R^2 . Sprawdź, czy zmienne w modelu są łącznie istotne.
2. Wskaż zmienne nieistotne w modelu. Podaj interpretację ekonomiczną nieistotności wskazanych zmiennych.
3. Zinterpretuj wielkość współczynnika przy zmiennej *czas_pracy*. Czy oszacowana wielkość współczynnika wydaje ci się sensowna? Odpowiedź uzasadnij.
4. Policz i zinterpretować semielastyczność cząstkową dla wieku. Średni wiek respondentów w próbie wynosi 42 lata.
5. Zinterpretuj wielkość współczynnika przy zmiennej *plec_2Xlata*.
6. O czym świadczą policzone wielkości statystyk VIF?
7. Zinterpretuj wielkości statystyk diagnostycznych.
8. Jakie są konsekwencje problemów wykrytych przez statystyki diagnostyczne? Wymień metody radzenia sobie z tym problemami.

Rozwiązanie:

1. Wielkość statystyki R^2 świadczy o tym, że 27.23% zmienności zmiennej objaśnianej zostało wyjaśnione za pomocą zmienności zmiennych objaśniających. Na zadanym poziomie istotności odrzucamy hipotezę zerową o łącznej nieistotności wszystkich zmiennych ($F=479$, wartość $p=0.000 < 0.05$)
2. Zmienną nieistotną jest zmienna zerojedynkowa związana z bierną znajomością języka angielskiego ($t=-1.77$, wartość $p = 0.076 > 0.05$). Ponieważ poziomem bazowym jest czynna znajomość języka angielskiego oznacza to, że czynna i bierna znajomość języka angielskiego ma identyczny wpływ na poziom dochodu respondenta.
3. Współczynnik przy zmiennej *czas_p* jest elastycznością cząstkową. Oszacowana wielkość oznacza, że wydłużenie czasu pracy o 1% powoduje wzrost zarobków o 0.01%. Oszacowanie to wydaje się zdecydowanie zbyt niskie, ponieważ sugeruje nierealistycznie niskie wynagrodzenie za dodatkowe godziny pracy (nadgodziny).
4. Semielastyczność cząstkową dla wieku liczymy jako

$$\frac{\partial E(\text{dochód})}{\partial \text{wiek}} = 2 \times \text{wiek} \times \beta_{\text{wiek}^2} + \beta_{\text{wiek}},$$

przy czym za wiek przyjmujemy średnią w próbie dla zmiennej wiek

$$2 \times 42 \times (-.0002728) + .03176 = 0.009$$

co oznacza, że wzrost wieku o 1 rok powoduje wzrost dochodu o 0.9% w przypadku osób w wieku równym średniej w próbie.

5. Wielkość współczynnika przy zmiennej *plec_2Xlata* oznacza, że dochód kobiet rośnie z każdym rokiem nauki o 1.16% więcej niż rośnie dochód mężczyzn.
6. Wielkość statystyk VIF świadczy o tym, że między zmiennymi *wiek*, *wiek2*, *plec_2Xlata* oraz *plec* występuje silna współliniowość.
7. Wielkość statystyki Breuscha-Pagana oznacza, że należy odrzucić hipotezę zerową o braku homoskedastyczności czynnika losowego i przyjąć hipotezę alternatywną o występowaniu heteroskedastyczności (21.81 wartość- $p < 0.000 < 0.05$), wartość statystyki testu JB zmusza nas do odrzucenia hipotezy o normalności czynnika losowego (2254.93 wartość $p < 0.000 < 0.05$). Wynik testu RESET skłania nas do odrzucenia hipotezy o liniowej formie zależności między zmienną objaśnianą a zmiennymi objaśniającymi (5.27 wartość $p < 0.0012 < 0.05$)

8. Występowanie heteroskedastyczności spowoduje, że obciążony i niezgodny będzie estymator macierzy wariancji kowariancji, brak normalności czynnika losowego powoduje, że błędne będą rozkłady statystyk w małych próbach, brak liniowości może zarówno obciążyć estymatory jak i negatywnie wpłynąć na poprawność wnioskowania statystycznego. Aby rozwiązać problem heteroskedastyczności składnika losowego można zastosować odporną macierz wariancji kowariancji lub UMNK, problem nieliniowości formy funkcyjnej i braku normalności składnika losowego da się często rozwiązać modyfikując formę funkcyjną modelu.

ZADANIE 3 Oszacowano MNK następujący model:

$$c_t = \beta_0 + \beta_1 y_t + \beta_2 p_t + \varepsilon_t,$$

w którym: c_i jest logarytmem nominalnych wydatków konsumpcyjnych gospodarstwa domowego, y_i jest logarytmem jego nominalnego dochodu, a p_i logarytmem indeksu cen żywności. Otrzymano następujące wyniki dla 66 obserwacji:

zmienna	współczynnik	błąd standardowy
stała	6.0	4.0
y	5.0	2.0
p	2.0	1.0

$RSS = 256$ i macierz wariancji-kowariancji estymatorów:

$$\begin{bmatrix} 16 & 3 & 5 \\ 3 & 4 & 5 \\ 5 & 5 & 1 \end{bmatrix}.$$

1. Oblicz prognozę dla c_{t+1} jeżeli $y_{t+1} = 2$, a $p_{t+1} = 3$.
2. Oblicz wariancję prognozy.
3. Oblicz wariancję błędu prognozy.

Rozwiązanie:

1. Prognoza wynosi:

$$\hat{c}_{t+1} = b_0 + b_1 y_{t+1} + b_2 p_{t+1} = 22.$$

2. Nieobciążony estymator wariancji błędu losowego jest równy:

$$s^2 = \frac{RSS}{T - k} = 4$$

Wariancja prognozy

$$\text{Var}(\hat{c}_{t+1}) = \mathbf{x}'_{t+1} \text{Var}(\mathbf{b}) \mathbf{x}_{t+1} = 143$$

Wariancja błędu prognozy

$$\text{Var}(c_{t+1} - \hat{c}_{t+1}) = \mathbf{x}'_{t+1} \text{Var}(\mathbf{b}) \mathbf{x}_{t+1} + s^2 = 147$$