

Stockholm University
Department of Statistics
Per Gösta Andersson

Econometrics I

WRITTEN EXAMINATION

Tuesday December 4, 2018, 10 am - 3 pm

Allowed tools: Pocket calculator

Passing rate: 50% of overall total, which is 100 points. For detailed grading criteria, see the course description.

For the maximum number of points on each problem detailed and clear solutions are required.

If not indicated otherwise, the disturbance terms u_i in the models are supposed to fulfill the usual requirements of normality, homoscedasticity and independence.

1. (21p) Följande datamaterial har blivit klassiskt: genomsnittspriset Y i dollar för begagnade bilar 1957 i USA, där X = ålder (år).

Ålder (X) Genomsnittspris (Y)

1	2651
2	1943
3	1494
4	1087
5	765
6	538
7	484
8	290
9	226
10	204

Följande summor är givna: $\sum_{i=1}^{10} X_i = 55$, $\sum_{i=1}^{10} X_i^2 = 385$, $\sum_{i=1}^{10} Y_i = 9682$, $\sum_{i=1}^{10} Y_i^2 = 15\ 502\ 372$, $\sum_{i=1}^{10} X_i Y_i = 32\ 202$

- (a) Skatta β -parameterna för modellen

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

Är du nöjd med anpassningen av skattade modellen till data?

Vad är förklaringsgraden R^2 ?

Vad skulle residualernas värden kunna tyda på?

- (b) Ett alternativ till modellen i (a) är att (naturliga) logaritmen för Y modelleras enligt den linjära modellen

$$\ln Y_i = \beta'_1 + \beta'_2 X_i + u'_i$$

Skatta β'_1 och β'_2 .

Lite räknehjälp: $\sum_{i=1}^{10} \ln Y_i = 65.2734$, $\sum_{i=1}^{10} (\ln Y_i)^2 = 433.428$, $\sum_{i=1}^{10} X_i \ln Y_i = 334.445$

Vad är förklaringsgraden R^2 ? Är det lämpligt att direkt jämföra den med förklaringsgraden för modellen i(a)?

Hur ser uttrycket ut för $Y_i|X_i$?

Skatta $E(Y_i|X_i)$ för de givna X -värdena och jämför med motsvarande skattningar för modellen i (a). Resultat? Åskådliggör skillnaderna i lämplig plott.

2. (18p) Antag att vi har brukat mäta värdet på någon kvantitet X med hjälp av en viss metod A som ger värdet Y . Nu har en ny mätmetod B introducerats. I följande tabell har vi nio mätningar med mätmetod A och en med B.

	X	Y
A	4.0	3.7
A	8.0	7.8
A	12.5	12.1
A	16.0	15.6
A	20.0	19.8
A	25.0	24.5
B	31.0	31.1
A	36.0	35.5
A	40.0	39.4
A	40.0	39.5

- (a) Om vi skattar en enkel linjär regressionsmodell utifrån dessa data, går det då att hävda att mätningen med metod B verkar avvika från de övriga? (Genomför alltså först regressionsanalysen och skatta β -parameterna.)
- (b) Oavsett resultatet i (a) ange (utan beräkning) hur man skulle formellt kunna testa huruvida mätmetod B avviker från de övriga.

3. (15p)

- (a) Visa analytiskt (räknemässigt) att

$$\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = \sum_{i=1}^n (X_i - \bar{X})Y_i$$

- (b) Antag att $(X_1, Y_1), \dots, (X_n, Y_n)$ används för att OLS-skatta β -parameterna i en enkel linjär regressionsmodell. Hur förändras skattningsarna (om de allts förändras) om vi i stället använder oss av $(X_1, Y_1 - c), \dots, (X_n, Y_n - c)$ (för någon känd konstant c)? Motivera både analytiskt och grafiskt.

4. (15p) Vi vill studera hur inkomst (X) påverkar konsumtion (Y) och även studera om vi har säsongseffekter (kvartalsvis). Följande skattade modell erhölls för åren 2012-2017:

$$\hat{Y}_i = 1.20 + 2.31X_i - 0.71D_{2i} - 0.77D_{3i} - 0.03D_{4i},$$

där D_{2i} , D_{3i} och D_{4i} är indikatorvariabler för kvartal 2, 3 och 4.

Antag $X = 10$.

- (a) Vad är skattade väntevärdet för Y i kvartal 1?
(b) Hur tolkas skattade koeficienten -0.71 för kvartal 2?
(c) Om vi i stället skulle ha haft en modell med indikatorvariabler för alla fyra kvartalen, hur skulle vi då generellt tolka koeficienten framför D_{2i} ?

5. (16p) Sant eller falskt? Motivering krävs.

- (a) Autokorrelation kan uppkomma om en viktig regressor inte är inkluderad i en linjär regressionsmodell.
(b) Om förutsättningarna är giltiga (tillräckliga) för Runs-testet att användas är de också giltiga för användning av Durbin-Watsons test.
(c) Orsaken till förkastande av nollhypotesen i White-testet kan enbart bero på heteroskedasticitet.
(d) Antag att vi har två starkt korrelerade X-variabler i en linjär regressionsmodell. Ett F-test kan då genomföras, men t-test kan bli missvisande.

6. (15p) Fyll i de saknade värdena i följande tabell:

Predictor	Coef	SE Coef	T	P
Constant	(a)	0.3501	0.59	0.563
X1	1.8515	(b)	2.31	0.040
X2	2.7241	0.7124	(c)	0.002
S = (d)	R-Sq = 83.4%		R-Sq(adj) = 80.6%	
Analysis of Variance				
Source	DF	SS	MS	F
Regression	(e)	(f)	(g)	(h)
Residual Error	12	17.28	1.44	0.000
Total	(i)	104.09		

Formula sheet, Econometrics I, Fall 2018

Under the simple linear model $Y_i = \beta_1 + \beta_2 X_i + u_i$, where $u_i \sim N(0, \sigma^2)$ and given independent pairs of observations $(Y_1, X_1), \dots, (Y_n, X_n)$, the OLS estimators are:

$$\begin{aligned}\hat{\beta}_1 &= \bar{Y} - \hat{\beta}_2 \bar{X} \\ \hat{\beta}_2 &= \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \\ \hat{\sigma}^2 &= \frac{RSS}{n-2} = \frac{\sum (Y_i - \hat{Y}_i)^2}{n-2}\end{aligned}$$

where $\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i$ and where $E(\hat{\beta}_1) = \beta_1$, $E(\hat{\beta}_2) = \beta_2$ and $E(\hat{\sigma}^2) = \sigma^2$ and further

$$\begin{aligned}V(\hat{\beta}_1) &= \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} \sigma^2 \\ V(\hat{\beta}_2) &= \frac{\sigma^2}{\sum (X_i - \bar{X})^2} \\ V(\hat{Y}_0) &= \sigma^2 \left(\frac{1}{n} + \frac{(X_0 - \bar{X})^2}{\sum (X_i - \bar{X})^2} \right) \\ V(Y_0 - \hat{Y}_0) &= \sigma^2 \left(1 + \frac{1}{n} + \frac{(X_0 - \bar{X})^2}{\sum (X_i - \bar{X})^2} \right)\end{aligned}$$

Distributional results:

$$\begin{aligned}\frac{\hat{\beta}_i - \beta_i}{se(\hat{\beta}_i)} &\sim t(n-2), \quad i = 1, 2 \\ \frac{\hat{\sigma}^2 (n-2)}{\sigma^2} &\sim \chi^2(n-2)\end{aligned}$$

Coefficient of determination:

$$r^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$

Coefficient of correlation:

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

where $r = \pm\sqrt{r^2}$

If we let $Y_i^* = w_1 Y_i$ and $X_i^* = w_2 X_2$, then

$$\hat{\beta}_1^* = w_1 \hat{\beta}_1, \quad \hat{\beta}_2^* = \left(\frac{w_1}{w_2}\right) \hat{\beta}_2, \quad \hat{\sigma}^{*2} = w_1^2 \hat{\sigma}^2$$

Under the multiple linear regression model $Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$, where $u_i \sim N(0, \sigma^2)$ and given independent vectors of observations $(Y_1, X_{21}, \dots, X_{k1}), \dots, (Y_n, X_{2n}, \dots, X_{kn})$, the following holds for the OLS estimators:

$$\hat{\sigma}^2 = \frac{RSS}{n - k} = \frac{\sum (Y_i - \hat{Y}_i)^2}{n - k}$$

$$\begin{aligned} \frac{\hat{\beta}_i - \beta_i}{se(\hat{\beta}_i)} &\sim t(n - k), \quad i = 1, \dots, k \\ \frac{\hat{\sigma}^2 (n - k)}{\sigma^2} &\sim \chi^2(n - k) \end{aligned}$$

The multiple coefficient of determination:

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$

Adjusted:

$$\bar{R}^2 = 1 - \frac{RSS/(n - k)}{TSS/(n - 1)}$$

Testing $H_0 : \beta_2 = \dots = \beta_k = 0$:

$$F = \frac{ESS/(k - 1)}{RSS/(n - k)} = \frac{\sum (\hat{Y}_i - \bar{Y})^2 / (k - 1)}{\sum (Y_i - \hat{Y}_i)^2 / (n - k)}$$

Comparing an "old" model with a "new" (larger):

$$\begin{aligned} F &= \frac{(ESS_{new} - ESS_{old})/\text{number of new regressors}}{RSS_{new}/(n - \text{number of parameters in the new model})} \\ &= \frac{(R^2_{new} - R^2_{old})/\text{number of new regressors}}{(1 - R^2_{new})/(n - \text{number of parameters in the new model})} \end{aligned}$$

Comparing an "unrestricted" model with a "restricted":

$$F = \frac{(RSS_R - RSS_{UR})/m}{RSS_{UR}/(n-k)} = \frac{(R_{UR}^2 - R_R^2)/m}{(1 - R_{UR}^2)/(n-k)}$$

where m is the number of linear constraints and k is the number of parameters in the unrestricted model.

Variance inflation factor:

$$VIF_j = \frac{1}{1 - R_j^2}$$

Auxiliary regression:

$$F_j = \frac{R_j^2/(k-2)}{(1 - R_j^2)/(n-k+1)}$$

where $R_j^2 = R^2$ in the regression of x_j on the remaining $(k-2)$ regressors.

Tests of heteroscedasticity: (all test statistics are evaluated under the null hypothesis of no heteroscedasticity)

White's test: Regress \hat{u}_i^2 against the $k-1$ regressors and the squares of these.
Test statistic: $n R^2 \xrightarrow{\text{appr}} \chi^2(2(k-1))$

Glejser test: Regress $|\hat{u}_i|$ against the regressor X_j , (one regressor at a time)
Test statistic: t -test of the slope

Park test: Regress $\ln \hat{u}_i^2$ against the regressor $\ln X_j$, (one regressor at a time)
Test statistic: t -test of the slope

Goldefeld Quandt test of equal variances in two separate regressions:
Test statistic: $\frac{S_1^2}{S_2^2} \sim F(n_1 - k_1, n_2 - k_2)$

Tests of autocorrelation:

The Runs test: For R = number of runs, where $N = N_1 + N_2$ total number of observations:

$$\begin{aligned} E(R) &= \frac{2N_1 N_2}{N} + 1 \\ V(R) &= \frac{2N_1 N_2 (2N_1 N_2 - N)}{N^2 (N-1)} \end{aligned}$$

The Durbin Watson d statistic:

$$d = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2}$$

Breusch Godfrey test: Null hypothesis: $H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0$

Test statistic: nR^2 from the regression of \hat{u}_t on the regressors which have produced \hat{u}_t plus lagged \hat{u}_t up to lag K .

n = the number of observations used in this regression.

The test statistic is approximately $\chi^2(K)$

Akaike's information criterion:

$$AIC = \frac{e^{2k/n} RSS}{n}$$

Schwartz's information criterion:

$$SIC = \frac{n^{k/n} RSS}{n}$$

Mallow's C_p criterion:

$$C_p = \frac{RSS_p}{\hat{\sigma}^2} - (n - 2p)$$

Logistic regression (logit model):

$$P(Y = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}, \quad \ln\left(\frac{P(Y = 1)}{1 - P(Y = 1)}\right) = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k$$



Correction sheet

Date: 04/12/2018

Room: Brunnsvikssalen

Course: Econometrics (eng)

Exam: Econometrics I (eng)

Anonymous code:

6002-VTE

I authorise the anonymous posting of my exam, in whole or in part, on the department homepage as a sample student answer.

NOTE! ALSO WRITE ON THE BACK OF THE ANSWER SHEET

Mark answered questions

1	2	3	4	5	6	7	8	9	Total number of pages
X	X	X	X	X	X				3 8c
Teacher's notes 21	13	14	15	16	15				

Points	Grade	Teacher's sign.
94	A	PGo

SU, DEPARTMENT OF STATISTICS

Room: Brunnsvikssalen

Anonymous code: 0002-KTE

Sheet number:

1

$$Y_i = \beta_0 + \beta_1 X_i + u_i, \quad n=10$$

1. a) OLS:

$$\hat{\beta}_2 = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} = \frac{32202 - 10 \cdot \frac{55}{10} \cdot \frac{9682}{10}}{385 - 10 \cdot \left(\frac{55}{10}\right)^2} \approx -255,4$$

$$\hat{\beta}_1 = \bar{y} - \hat{\beta}_2 \bar{x} = \frac{9682}{10} - (-255,4 \cdot \frac{55}{10}) \approx 2371,47$$

$$\text{dvs. } \hat{Y}_i = 2371,47 - 255,4 X_i$$

För enkel linjär regression

$$R^2 = r^2 = (-0,9361)^2 \approx 0,8763$$

$$r = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sqrt{(\sum x_i^2 - n \bar{x}^2)(\sum y_i^2 - n \bar{y}^2)}} = \frac{32202 - 10 \cdot \frac{55}{10} \cdot \frac{9682}{10}}{\sqrt{(385 - 10 \cdot \left(\frac{55}{10}\right)^2)(15502572 - 10 \cdot \left(\frac{9682}{10}\right)^2)} \approx -0,9361}$$

$$\approx -0,9361$$

$$0,8763 = R^2 = 1 - \frac{RSS}{TSS}$$

$$TSS = \sum (Y_i - \bar{y})^2 = \sum y_i^2 - n \bar{y}^2 =$$

$$= 15502572 - 10 \left(\frac{9682}{10}\right)^2 =$$

$$= 6128259,6$$

$$\sum \hat{u}_i^2 = RSS = 0,1237 \cdot 6128259,6 = \\ = 758065,7125$$

Svar:

Residualernas värden →

tiM higer indikerar

tänkbart autokorrelation

i modellen. Detta 'bröte'

kanna testas med ett

Rwns test, där få rums

(i värst fall) indikerar positiv

autokorrelation. Paga detta

är jag inte nöjd med

den sista halva modellen HII

data. Plus att residualerna

är relativt stora värden.

X	\hat{u}_i	+/-	Rwns
1	534,67	+	1
2	81,81	+	2
3	-112,05	-	3
4	-263,9	-	4
5	-350,77	-	5
6	-302,63	-	6
7	-101,49	-	7
8	-40,35	-	8
9	150,79	+	9
10	363,93	+	10

Residualerna kan också indikera att modellen är fel specificerad, det är att vi inte harit med en fit

b) OLS: $\ln Y_i = \beta_0 + \beta_1 X_i + u_i$

$$\hat{\beta}_1 = \frac{\sum (\ln(Y_i))(X_i) - n \cdot \bar{\ln Y} \cdot \bar{X}}{\sum X_i^2 - n \bar{X}^2} = \frac{334,445 - 10 \cdot \left(\frac{65,2734}{10}\right) \left(\frac{55}{10}\right)}{385 - 10 \left(\frac{55}{10}\right)^2}$$

$$\approx -0,2977$$

$$\hat{\beta}_0 = \bar{\ln Y} - \hat{\beta}_1 \bar{X} = \frac{65,2734}{10} - (-0,2977) \frac{55}{10} \approx 8,1646$$

$$\boxed{\ln(\bar{Y}) = 8,1646 - 0,2977 X_i}$$

Det är inte lämpligt att direkt jämföra R^2

för dessa två modeller ty de är i olika form (modell 1: Y_i och modell 2: $\ln Y_i$). Därför
är man inte jämföra dessa värden.

$$R^2 = f^2 = (0,9962)^2 \approx 0,9926 \quad \text{← förklaringsgrad modell 2}$$


$$f = \frac{\sum (\ln(Y_i))(X_i) - n \cdot \bar{\ln Y} \cdot \bar{X}}{\sqrt{(\sum X_i^2 - n \bar{X}^2)(\sum (\ln Y)^2 - n \cdot \bar{\ln Y}^2)}} = \frac{334,445 - 10 \left(\frac{65,2734}{10}\right) \left(\frac{55}{10}\right)}{\sqrt{(385 - 10 \left(\frac{55}{10}\right)^2)(433,429 - 10 \left(\frac{65,2734}{10}\right)^2)}}$$

$$\approx -0,9963$$

$$e^{\ln Y_i} = Y_i = e^{\beta_0 + \beta_1 X_i + u_i}$$

Svar: Om vi jämför värdena i tabellen
till höger ser vi att Modell 2
ligger närmare det observerade
 Y -värdet.

	K	Modell 1: \hat{Y}_i	Modell 2: \hat{Y}_i
1	2116,53	2609,46	
2	1861,19	1937,59	
3	1606,05	1438,71	
4	1350,91	1068,27	
5	1095,77	793,22	
6	840,63	588,98	
7	585,49	437,54	
8	330,35	329,73	
9	75,21	241,12	
10	-179,93	179,03	



Modell 1: + Modell 2: *

Obs. värden: •

Se tabell till vänster

Som vi ser i tabellen följer + och • varandra bättre än - och •.

SU, DEPARTMENT OF STATISTICS

Room: Brunnsvikssolen

Anonymous code: 0002-KTE Sheet number: 2

$$Y_i = \beta_0 + \beta_1 X_i$$

2. a) OLS

$$\hat{\beta}_1 = \frac{\sum x_i y_i - \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} = \frac{884,65 - 10 \cdot \frac{232,5}{10} \cdot \frac{229}{10}}{6974,25 - 10 \cdot (\frac{232,5}{10})^2} \approx 0,9948$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} = \frac{229}{10} - 0,9948 \cdot \frac{232,5}{10} \approx -0,2281$$

$$\hat{Y}_i = -0,2281 + 0,9948 x_i$$

Ja, man kan hävda det, ty resultaten av den skattade modellen visar att värdet på \hat{Y}_i inte kan vara större än x_i -värdet, vilket gäller för alla observerade värden på Y_i med metod A. Däremot för måtmetod B har vi observerat ett Y -värdet större än x_i -värdet vilket inte är förenligt med modellen. Man bör dock tänka på att vi endast har få observationer och där endast en observation med måtmetod B, men utifrån resultaten ansar jag att man kan hävda att mätningen med metod B avviker från de övriga.

b) Man skulle kunna beräkna ett prediktionsintervall $Y|X_i=31$ för en enskild Y -observation på önskad signifikansnivå (t.ex. $\alpha=0,05$). Täcker det obeskrivna prediktionsintervallet för $Y|X_i=31$ det observerade värdet med måtmetod B kan vi inte förhålla oss till att måtmetod arviver från de övriga, med 95% konfiden. Däremot om det uträknade prediktionsintervallet för $Y|X_i=31$ ej täcker det observerade va det $(31,1)$ kan vi förhålla oss med 95% konfiden och säga att måtmetod B skiller sig från de övriga.

$$\frac{n-1}{k-2}$$


$$t_{0,025}(n-k) = t_{0,025}(8)$$

$$15\% P \text{ för } Y|X_i=31 \text{ är vänds } 90 \pm t_{0,025}(8) \cdot \sqrt{V(Y-90)} \text{ sm eftersom } /13$$

$$\begin{aligned}
 3. \quad a) \quad & \Sigma(x_i - \bar{x})(y_i - \bar{y}) = \Sigma(\bar{x} - \bar{x})y_i - \Sigma(x_i - \bar{x})\bar{y} = \\
 & = \Sigma(\bar{x} - \bar{x})y_i - \bar{y}(\Sigma(\bar{x} - \bar{x})) = \Sigma(\bar{x} - \bar{x})y_i - \bar{y}(\Sigma\bar{x} - n\bar{x}) = \\
 & = \Sigma(\bar{x} - \bar{x})y_i - \bar{y} \cdot 0 = \Sigma(\bar{x} - \bar{x})y_i \quad \text{V.S.V.}
 \end{aligned}$$

$$\begin{aligned}
 b) \quad \hat{\beta}_2' &= \frac{\Sigma(\bar{x} - \bar{x})(y_i - c) - (\bar{y} - c)}{\Sigma(\bar{x} - \bar{x})^2} = \frac{\Sigma(\bar{x} - \bar{x})(y_i - c - \bar{y} + c)}{\Sigma(\bar{x} - \bar{x})^2} = \\
 &= \frac{\Sigma(\bar{x} - \bar{x})(y_i - \bar{y})}{\Sigma(\bar{x} - \bar{x})^2} \quad \text{dvs } \hat{\beta}_2' \text{ förändras inte} \\
 &\quad \text{utan } \hat{\beta}_2' = \hat{\beta}_2 \\
 \hat{\beta}_1' &= \bar{y} - c - \hat{\beta}_2' \bar{x} = (\bar{y} - \hat{\beta}_2' \bar{x}) - c \quad \text{urspr. sättning} \quad \text{konst}
 \end{aligned}$$

dvs $\hat{\beta}_1'$ kommer att förändras i form av att interceptet flyttas med $-c$



$$4. \quad a) \quad E(Y_i | X=10, D_2=0, D_3=0, D_4=0) = 1,20 + 2,31 \cdot 10 = 24,3$$

dvs skattade väntevärde för kvarthal 1 är 24,3 under antagandet att $X=10$.

b) Den skattade koeficienten $-0,77$ för kvarthal 2 tolkas som den förändrade stignaden i konsumtion jämfört med kvarthal 1. Då denna är negativ indikerar det att vi förväntar oss lägre konsumtion i kv 2 än i kv 1 i genomsnitt, allt annat lika.

c) Det skulle si istället vilken koeficient som intercept till kvarthal 2 dvs genomsnittlig (förändrad) konsumtion, givet ingen inkomst ($X_i=0$), i kvarthal 2. //5

5.


a) Sant, ta exemplet att en bra modell har formen:

$\text{P} \quad Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$, men vi avvänder modell.

$\text{Y}'_i = \beta'_0 + \beta'_1 X_{1i} + \beta'_2 X_{2i} + v_i$. Då kommer för inskrivna tabelln i att modell i ha formen $v_i = \beta_3 X_{3i} + u_i$ och resulterar i att $\text{Cov}(v_i, v_j) \neq 0$. D.v.s vi har nu autokorrelation, vilket gör påståendet sant.

b) Falskt. Runs test är ett icke-parametriskt test som inte förutsätter exempelvis normalfördelning, medan Durbin-Watsons test bygger på t ex. antagande om normalfördelade störningsvariabler. Därmed är påståendet falskt.

c) Falskt. Om vi förkastar nollhypotesen i White-testet kan orsaken också vara att vår modell är fel-specificerad. Ett exempel ges nedan:



d) Sant. Om vi genomför t-test för parametrarna i en multikollinär modell (som exemplet antyder) kommer resultatet av de ssa kunna bli missriktande och inte gå i linje med resultatet från ett övergripande F-test. F-testet därför kan förtakande användas då den endast säger oss om minst en av de förklarande variablerna bör tas med i modellen. Dvs F-testet är förtakande och att använda, men inte t-test. Påståendet är felaktigt. //6

$$b. \quad a = 0,206559 \quad \frac{a}{0,3501} = 0,5a \Rightarrow a = 0,501 \cdot 0,5a = 0,206559$$

$$b = 0,8015 \quad \frac{1,8515}{b} = 2,31 \Rightarrow b = \frac{1,8515}{2,31} \approx 0,8015$$

$$c = 3,82 \quad \frac{27241}{0,77124} = c = 3,82$$

$$d = 1,2 \quad s = \sqrt{\hat{\sigma}^2} = \sqrt{\frac{RSS}{n-k}} = \sqrt{\frac{17,28}{12}} = 1,2$$

$$e = 2 \quad e = k - i = 3 - 1 = 2$$

$$f = 86,81 \quad f = ESS = TSS - RSS = 104,09 - 17,28 = 86,81$$

$$g = 43,405 \quad g = \frac{f}{e} = \frac{86,81}{2} = 43,405$$

$$h = 30,14 \quad F = \frac{ESS/(k-1)}{RSS/(n-k)} = \frac{86,81/2}{17,28/12} \approx 30,14$$

$$i = 14 \quad k = 3 \quad n - k = 12 \Rightarrow n = 12 + k = 15$$

$$j = n - 1 = 15 - 1 = 14$$

15