

Aufgabe zur einfachen linearen Regression mit E-Views

Zusammenhang zwischen Arbeitsmarktregulierung und Arbeitsplatzsicherheit

1) Daten

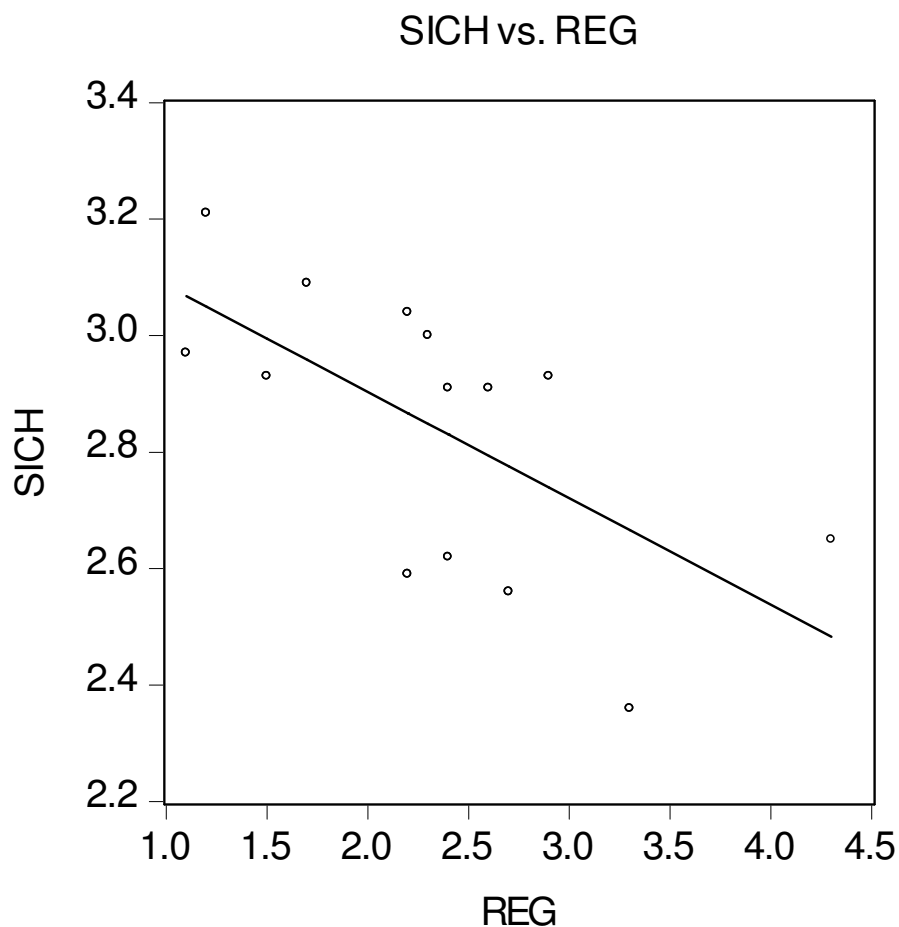
a) als Bild aus iwd-48/2006



b) als E-Views "group" (Gruppe von Variablen, hier zwei Variablen REG und SICH)

obs	REG	SICH
1	1.100000	2.970000
2	1.200000	3.210000
3	1.500000	2.930000
4	1.700000	3.090000
5	2.200000	3.040000
6	2.200000	2.590000
7	2.300000	3.000000
8	2.400000	2.910000
9	2.400000	2.620000
10	2.600000	2.910000
11	2.700000	2.560000
12	2.900000	2.930000
13	3.300000	2.360000
14	4.300000	2.650000

2) Streuungsdiagramm (E-Views output) (weitere graphische Optionen möglich)



3) Ergebnisse der Regressionsanalyse (der Befehl heißt: "make equation")
in Word übertragen und formatiert [z.B. mit farblicher Hervorhebung]

Dependent Variable: SICH				
Method: Least Squares				
Date: 11/08/07 Time: 16:58				
Sample: 1 14				
Included observations: 14				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
REG	- 0.182486	0.063930	- 2.854484	0.0145
C	3.268253	0.158559	20.61225	0.0000
R-squared	0.404410	Mean dependent var		2.840714
Adjusted R-squared	0.354777	S.D. dependent var		0.242375
S.E. of regression	0.194690	Akaike info criterion		-0.303258
Sum squared resid	0.454848	Schwarz criterion		-0.211964
Log likelihood	4.122804	F-statistic		8.148076
Durbin-Watson stat	3.264928	Prob(F-statistic)		0.014502

4) Weitere Auswertungen

Die **Regressionsgerade** $\hat{y}_t = \hat{\alpha} + \hat{\beta}x_t$ (oder $\hat{y} = a + bx$) lautet demnach

$$\text{SICH} = 3,268253 - 0,182486 (\text{REG})$$

Der **Korrelationskoeffizient** beträgt $-0,63593 (= -\sqrt{0,404410})$ aus $\hat{\beta} < 0$ und dem Streudiagramm [scatter plot] ist ersichtlich, dass die Korrelation negativ ist.

Aus $t_{\hat{\beta}} = \hat{\beta} / \hat{\sigma}_{\hat{\beta}}$ folgt $-2,854484 = -0,182486 / 0,063930^1$ (entsprechender Zusammenhang für $t_{\hat{\alpha}}$). Die Werte der Spalte **t-Statistic** lassen sich also aus den anderen beiden Spalten errechnen.²

Aus entsprechenden Tabellen erhält man die folgenden Werte für t bei der **t-Verteilung** mit $T - K - 1 = T - 2 = 14 - 2 = 12$ Freiheitsgraden ($K = \text{Anzahl der Regressoren}$)

einseitig		zweiseitig	
0,975	2,18	0,95	1,78
0,995	3,05	0,99	2,68

Weil die angegebenen t-Werte alle (bei α und β) erheblich größer sind als diese Tabellenwerte, sind die Schätzwerte $\hat{\alpha}$ und $\hat{\beta}$ **hochsignifikant** (H_0 jeweils $\alpha = 0$ und $\beta = 0$).³ Damit lässt sich auch ein zweiseitiges **Konfidenzintervall** berechnen für β (entsprechend für α und entsprechend auch bei einseitigen Konfidenzintervallen).

Grenzen des Konfidenzintervalls bei 95%

$$\text{unten} - 0,182486 - 1,78 \cdot 0,063930 = -0,294361$$

$$\text{oben} - 0,182486 + 1,78 \cdot 0,063930 = -0,0706085.$$

Die Grenzen des Konfidenzintervalls bei 99% sind entsprechend zu berechnen mit 2,68 statt 1,78. Ergebnis: unten $-0,3538184$ oben $-0,1111536$. Da der Wert 0 *nicht* enthalten ist, ist $-\beta$ wie schon beim Vergleich von $t_{\hat{\beta}}$ mit dem Tabellenwert der t-Verteilung ersichtlich $-\beta$ signifikant verschieden von Null ($H_0: \beta = 0$).

5) Konfidenzintervall für die Varianz σ^2 (der Störgröße)⁴

Der **S.E.** (standard error) of Regression, d.h. die Größe 0,194690 und die **Sum (of squared resid.** ($= \sum \hat{u}_t^2 = S_{\hat{u}\hat{u}}$) = 0,454848 hängen bei $T = 14$ wie folgt zusammen

$$\hat{\sigma}_u = \sqrt{\frac{1}{T-2} \sum \hat{u}_t^2} = \sqrt{\frac{0,454848}{12}} = 0,194690 \text{ (dies ist der erwartungstreue Schätzer für } \sigma^2 \text{)}.$$

Man kann diesen Wert benutzen um ein Konfidenzintervall für σ^2 , die Varianz der Störgröße zu berechnen (jetzt mit der χ^2 Verteilung mit $T-2$ Freiheitsgraden arbeiten⁵). Ergebnis: **Untergrenze** $S_{\hat{u}\hat{u}}/G_o = 0,4548/23,3 = 0,01952$ und

$$\text{Obergrenze } S_{\hat{u}\hat{u}}/G_u = 0,4548/4,4 = 0,10337,$$

¹ (Rundungsfehler!) mit dem oben angegebenen Bruch $-0,182486/0,063930$ erhält man $-2,854466$ statt $-2,854484$ (aber die Werte $0,182486$ und $0,063930$ sind ja ihrerseits auch wieder gerundet !!).

² Wenn H_0 lautet $\beta = 0$. Die H_0 kann aber auch lauten $\beta = -0,2$ (nur als ein Beispiel).

³ Erklärung der Spalte "prob." (= prob. value) in der Vorlesung.

⁴ Zur Intervallschätzung von σ^2 vgl. Teil C des downloads Nr. 2 (Übersicht über Schätz- und Testtheorie ...)

⁵ zu den Größen G_u und G_o siehe nächste Seite.

G_u und G_o sind der in der χ^2 Tabelle mit $T-K-1 = T-2 = 12$ Freiheitsgraden angegebenen untere und obere Wert (Signifikanzschranke) für das 95% Konfidenzintervall, also $G_u = \chi_{0,025}^2 = 4,40$ und $G_o = \chi_{0,975}^2 = 23,30$.

6) ANOVA (Analysis of Variance [F Test]) und weitere Zusammenhänge zwischen den von E-Views ausgegebenen Rechenergebnissen

Aus **S.D.** (standard deviation) of dependent variable $\sqrt{\frac{1}{T-1}S_{yy}} = 0,242375$ folgt $S_{yy} = 0,76369$. Man hat damit alle Bestandteile der **ANOVA-Tabelle** (Varianzzerlegung), die wie folgt aussieht

Variation (sum of squares)	d.f. (degrees of freedom)	Varianz (mean squares)
explained $S_{\hat{y}\hat{y}} = 0,308842^*$	$K = 1$	$S_{\hat{y}\hat{y}}/K = 0,308842$
residual $S_{\hat{u}\hat{u}} = 0,454848$	$T - K - 1 = T - 2 = 12$	$S_{\hat{u}\hat{u}}/(T - K - 1) = 0,454848/12 = 0,037904$
total $S_{yy} = 0,76369$	$T - 1 = K + (T-K-1)$	$0,76369/13 = 0,05874 = (0,24237)^2 = (S.D.depend.var.)^2$ (nicht die Summe von 0,3088 und 0,0379)

* als Differenz bestimmt: $0,76369 - 0,454848$

Die F-Statistik $F = \frac{\text{explained mean square}}{\text{residual mean square}} = \frac{S_{\hat{y}\hat{y}}/K}{S_{\hat{u}\hat{u}}/(T-K-1)}$

ist F verteilt mit $K=1$ und $T-K-1 = 12$ Freiheitsgraden (Symbol $F_{K,T-K-1} = F_{1,12}$). Sie beträgt in diesem Fall $F = 0,308842/0,037904 = 8,1480055$ (E-Views [siehe oben unter Nr. 3] gibt an 8,148076). Die entsprechenden F-Werte der Tabelle sind bei 5% Signifikanzniveau $4,75 < 8,14$ und bei 1% $9,33 > 8,14$ (prob.value ist 1,45%).

Man beachte, dass bei einfacher Regression gilt $\sqrt{F} = t_{\hat{\beta}}$ (im Beispiel $\sqrt{8,148076} = 2,854$) und dass die F-Verteilung mit *einem* Freiheitsgrad im Zähler, also $F_{1,v}$ identisch ist mit der t-Verteilung t_v (t-Verteilung mit v Freiheitsgraden). Der Test der Hypothese $H_0: \beta = 0$ und der Hypothese $H_0: \rho^2 = 0$ (Unkorreliertheit) sind also identisch.⁶

Zwischen R^2 und dem korrigierten (adjusted) R^2 (mit \bar{R}^2 bezeichnet) besteht folgender Zusammenhang

$$R^2 = r^2 = \frac{S_{\hat{y}\hat{y}}}{S_{yy}} = 1 - \frac{S_{\hat{u}\hat{u}}}{S_{yy}} = 0,3088/0,76369 = 0,4044075 \text{ (vgl. E-Views Angabe oben 0,404410)}$$

$$\bar{R}^2 = R^2 - \frac{(1-R^2)K}{T-K-1} = 1 - \frac{S_{\hat{u}\hat{u}}/(T-K-1)}{S_{yy}/(T-1)} \text{ (man verifiziere das für das Zahlenbeispiel).}$$

7) Weitere Bemerkung

Der Durbin-Watson Koeffizient (oder DW statistic) in Höhe von $d = 3.264928$ weist auf eine negative Autokorrelation der Residuen (Störgrößen u_t, u_{t-1}, \dots) von etwa $r = 1 - d/2 = -0,6325$ hin (mehr dazu später beim Thema Autokorrelation).

⁶ in der Stichprobe spricht man von r und r^2 . In der Grundgesamtheit werden griechische Symbole verwendet also ρ (Rho) bzw. ρ^2 .