



Johan Koskinen, Statistiska institutionen, Stockholms universitet

Finansiell statistik, vt-05

F15 regressionsanalys

Regressionsmodellen

Modellen kan skrivas:

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

där $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ är oberoende likafördelade $N(0, \sigma^2)$

För alla $i = 1, 2, \dots, n$.

$$\begin{aligned} E(Y_i) &= E(\beta_0 + \beta_1 x_i + \varepsilon_i) \\ &= \beta_0 + \beta_1 x_i + E(\varepsilon_i) \\ &= \beta_0 + \beta_1 x_i \end{aligned}$$

$\varepsilon_i \in N(0, \sigma^2)$

konstanter



Johan Koskinen, Department of Statistics

2005-05-02

2

Regressionsmodellen

För alla $i = 1, 2, \dots, n$.

$$\begin{aligned} \text{Var}(Y_i) &= \text{Var}(\beta_0 + \beta_1 x_i + \varepsilon_i) \\ &= 0 + 0 + \text{Var}(\varepsilon_i) \\ &= \sigma^2 \end{aligned}$$

$\varepsilon_i \in N(0, \sigma^2)$

konstanter

För alla $i \neq j$

$$\begin{aligned} \text{Cov}(Y_i, Y_j) &= E((\beta_0 + \beta_1 x_i + \varepsilon_i)(\beta_0 + \beta_1 x_j + \varepsilon_j)) \\ &\quad - E(\beta_0 + \beta_1 x_i + \varepsilon_i)E(\beta_0 + \beta_1 x_j + \varepsilon_j) \end{aligned}$$



Johan Koskinen, Department of Statistics

2005-05-02

3

Regressionsmodellen

$$\begin{aligned} E((\beta_0 + \beta_1 x_i + \varepsilon_i)(\beta_0 + \beta_1 x_j + \varepsilon_j)) &= E((\beta_0 + \beta_1 x_i)(\beta_0 + \beta_1 x_j)) + (\beta_0 + \beta_1 x_i)E(\varepsilon_j) + (\beta_0 + \beta_1 x_j)E(\varepsilon_i) + E(\varepsilon_i \varepsilon_j) \\ &= (\beta_0 + \beta_1 x_i)(\beta_0 + \beta_1 x_j) \\ &\quad + (\beta_0 + \beta_1 x_i)E(\varepsilon_j) + (\beta_0 + \beta_1 x_j)E(\varepsilon_i) \\ &\quad + E(\varepsilon_i \varepsilon_j) \end{aligned}$$

$\varepsilon_i, \varepsilon_j \in N(0, \sigma^2)$

konstanter

förför normalfordelade variabler
oberoende medför kovarians 0

$$\begin{aligned} E(\beta_0 + \beta_1 x_i + \varepsilon_i)E(\beta_0 + \beta_1 x_j + \varepsilon_j) &= (\beta_0 + \beta_1 x_i + E(\varepsilon_i))(\beta_0 + \beta_1 x_j + E(\varepsilon_j)) \\ &= (\beta_0 + \beta_1 x_i)(\beta_0 + \beta_1 x_j) \end{aligned}$$



Johan Koskinen, Department of Statistics

2005-05-02

4

Regressionsmodellen

M.a.o., för alla $i \neq j$

$$\begin{aligned}\text{Cov}(Y_i, Y_j) &= E((\beta_0 + \beta_1 x_i + \varepsilon_i)(\beta_0 + \beta_1 x_j + \varepsilon_j)) \\ &\quad - E(\beta_0 + \beta_1 x_i + \varepsilon_i)E(\beta_0 + \beta_1 x_j + \varepsilon_j) \\ &= (\beta_0 + \beta_1 x_i)(\beta_0 + \beta_1 x_j) - (\beta_0 + \beta_1 x_i)(\beta_0 + \beta_1 x_j) = 0\end{aligned}$$

Om vi sammanfattar (Lee)

- den oberoende variabelns x_i värden är fixa (A)
- variablen ε_i är normalfördelad (B)
- variablen ε_i har väntevärde 0 (C)
- ε_i och ε_j är statistiskt oberoende för alla $i \neq j$ (D)
- variablene ε_i har konstant varians σ^2 (E)



02

5

Regressionsanalys

Vi gör parvisa observationer. För fixa x_1, x_2, \dots, x_n
gör vi observationer Y_1, Y_2, \dots, Y_n , där vi antar

$$Y_i \in N(\beta_0 + \beta_1 x_i, \sigma^2)$$

Vi skall hitta estimatorer av

β_0, β_1 och σ^2

Som helst är

- väntevärdesriktiga
- konsistenta
- effektiva

2005-05-02

7

Regressionsanalys

Vi har en modell för Y givet värdet på
 β_0, β_1 och x är

$$Y \in N(\beta_0 + \beta_1 x, \sigma^2)$$


där alltså väntevärdet för Y
beskrivs av en rät linje

Vi utgår från att x ej varierar
utan fix

Okänt i modell

LTH
 β_0, β_1 och σ^2

Hur skatta dessa parametrar?



2005-05-02


6

Regressionsanalys - räta linjens ekv.

Vi har två observationspar


$$b = (\text{förändringen i } y) / (\text{förändringen i } x)$$

Finn a och b så att




8


Regr. analys - minsta kvadrat skattningen



Minstakvadrat-skattningen - residual



Minstakvadrat-skattningen - residual



Minstakvadrat-skattningen (MKS)

Minstakvadratskattningen ges av att minimera kvadratsumman
med a och b

$$\begin{aligned}\frac{\partial}{\partial a} \sum_{i=1}^n (y_i - g_i)^2 &= \frac{\partial}{\partial a} \sum_{i=1}^n (y_i - (a + bx_i))^2 \\&= 2 \sum_{i=1}^n (y_i - a - bx_i)(-1) \\&= -2 \sum_{i=1}^n y_i + 2 \sum_{i=1}^n a + 2b \sum_{i=1}^n x_i\end{aligned}$$

$$a = \frac{1}{n} \sum_{i=1}^n y_i - \frac{1}{n} b \sum_{i=1}^n x_i$$

Minstakvadrat-skattningen (MKS)

$$\begin{aligned}
 \frac{\partial}{\partial b} \sum_{i=1}^n (y_i - \hat{y}_i)^2 &= \frac{\partial}{\partial b} \sum_{i=1}^n (y_i - a - bx_i)^2 \\
 &= 2 \sum_{i=1}^n (y_i - a - bx_i)(-x_i) \\
 &= -2 \sum_{i=1}^n y_i x_i + 2 \sum_{i=1}^n a x_i + 2b \sum_{i=1}^n x_i^2 \\
 &= -2 \sum_{i=1}^n y_i x_i + 2 \left\{ \frac{\sum y_i - b \sum x_i}{n} \right\} \sum_{i=1}^n x_i + 2b \sum_{i=1}^n x_i^2
 \end{aligned}$$

$$a = \frac{1}{n} \sum_{i=1}^n y_i - \frac{1}{n} b \sum_{i=1}^n x_i$$




Johan

$$b = \frac{\sum_{i=1}^n y_i x_i - \frac{1}{n} (\sum_{i=1}^n y_i) (\sum_{i=1}^n x_i)}{\sum_{i=1}^n x_i^2 - \frac{1}{n} (\sum_{i=1}^n x_i)^2}$$

2005-05-02

13

Minstakvadrat-skattningen (MKS)



$$b = \frac{\sum yx - \frac{1}{n} \sum y \sum x}{\sum x^2 - \frac{1}{n} (\sum x)^2} = \frac{8990.5 - \frac{1}{10} (63.2)(3320)}{374.24 - \frac{1}{10} (63.2)^2} = -25.2559$$

$$a = \bar{y} - b \bar{x} = 332 - (-25.2559)(6.32) = 491.62$$



Johan Koskinen, Department of Statistics

2005-05-02

14

Kvadratsummor

Definiera kvadratsumman

$$SS_x = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2$$

och

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n y_i \right)^2$$

så att

$$s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} = \frac{SS_x}{n-1} \quad s_y^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1} = \frac{SST}{n-1}$$




Johan Koskinen, Department of Statistics

2005-05-02

15

Kvadratsummor



Johan Koskinen, Department of Statistics

2005-05-02

16

Korsprodukter

Definiera korsproduktsumman


$$SS_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n y_i x_i - \frac{1}{n} \left(\sum_{i=1}^n y_i \right) \left(\sum_{i=1}^n x_i \right)$$

så att stickprovskovariansen

$$s_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1} = \frac{SS_{xy}}{n-1}$$



Korsprodukter



Väntevärdesriktiga skattningar

Antag modellen med antagandena A-E uppfyllda

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

För fixa x_1, x_2, \dots, x_n gör vi observationer Y_1, Y_2, \dots, Y_n

Låt estimatorerna av β_0, β_1 vara

$$\hat{\beta}_0 = a = \frac{1}{n} \sum_{i=1}^n y_i - \frac{1}{n} b \sum_{i=1}^n x_i$$

$$\hat{\beta}_1 = b = \frac{\sum_{i=1}^n y_i x_i - \frac{1}{n} \left(\sum_{i=1}^n y_i \right) \left(\sum_{i=1}^n x_i \right)}{\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2} = \frac{SS_{xy}}{SS_x}$$



Väntevärdesriktiga skattningar

Är estimatorn av β_1 vvr?

$$\begin{aligned} E(\hat{\beta}_1) &= \frac{1}{SS_x} E \left(\sum_{i=1}^n Y_i x_i - \frac{1}{n} \left(\sum_{i=1}^n Y_i \right) \left(\sum_{i=1}^n x_i \right) \right) \\ &= \frac{1}{SS_x} E \left(\sum_{i=1}^n Y_i x_i \right) - \frac{1}{n} \frac{1}{SS_x} E \left(\sum_{i=1}^n Y_i \right) \left(\sum_{i=1}^n x_i \right) \\ &= \frac{1}{SS_x} \sum_{i=1}^n E(Y_i x_i) - \underbrace{\frac{1}{n} \frac{\left(\sum_{i=1}^n x_i \right)}{SS_x} \sum_{i=1}^n E(Y_i)}_{\text{constant}} \\ &= \frac{1}{SS_x} \sum_{i=1}^n x_i (\beta_0 + \beta_1 x_i) - \frac{\sum_{i=1}^n x_i}{n SS_x} \sum_{i=1}^n (\beta_0 + \beta_1 x_i) \end{aligned}$$



Väntevärdesriktiga skattningar

$$\begin{aligned}
 &= \frac{1}{SS_x} \sum_{i=1}^n x_i (\beta_0 + \beta_1 x_i) - \frac{\sum_{i=1}^n x_i}{nSS_x} \sum_{i=1}^n (\beta_0 + \beta_1 x_i) \\
 &= \frac{n}{nSS_x} \sum_{i=1}^n x_i (\beta_0 + \beta_1 x_i) - \frac{\sum_{i=1}^n \sum_{j=1}^n x_i (\beta_0 + \beta_1 x_j)}{nSS_x} \\
 &= \frac{n\beta_0 \sum_{i=1}^n x_i + n\beta_1 \sum_{i=1}^n x_i^2}{nSS_x} - \frac{\beta_0 n \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n \sum_{j=1}^n x_i x_j}{nSS_x} \\
 &= \frac{\beta_1 n \sum_{i=1}^n x_i^2 - \beta_1 \sum_{i=1}^n \sum_{j=1}^n x_i x_j}{nSS_x} = \frac{\beta_1 n \sum_{i=1}^n x_i^2 - \beta_1 (\sum_{i=1}^n x_i)^2}{nSS_x} = \boxed{\frac{\beta_1 n SS_x}{nSS_x}}
 \end{aligned}$$




Johan Koskinen, Department of Statistics

2005-05-02

21

Variansuppdelning



22

Variansuppdelning

Eftersom

$$y_i - \bar{y} = (y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})$$

kan vi visa

$$\begin{aligned}
 \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \\
 SST &= SSE + SSR
 \end{aligned}$$

Till att börja med

$$\begin{aligned}
 \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\
 &\quad - 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2
 \end{aligned}$$



Johan Koskinen

2005-05-02

23

Variansuppdelning

$$\begin{aligned}
 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) &= \sum_{i=1}^n (y_i - \hat{y}_i)(x_i - \bar{x}) \\
 &= b \sum_{i=1}^n (y_i - \hat{y}_i)(x_i - \bar{x}) \\
 &= b \sum_{i=1}^n (y_i - \hat{y}_i)x_i - b\bar{x} \sum_{i=1}^n (y_i - \hat{y}_i) \\
 \sum_{i=1}^n (y_i - \hat{y}_i) &= \sum_{i=1}^n (y_i - a - bx_i) \\
 &= \sum_{i=1}^n y_i - \sum_{i=1}^n a - \sum_{i=1}^n bx_i \\
 &= \sum_{i=1}^n y_i - \sum_{i=1}^n (\bar{y} - b\bar{y}) - \sum_{i=1}^n bx_i \\
 &= \sum_{i=1}^n y_i - \sum_{i=1}^n y_i + \sum_{i=1}^n bx_i - \sum_{i=1}^n bx_i = 0
 \end{aligned}$$




Johan Koskinen, De

Variansuppdelning

$$\begin{aligned}
 \sum_{i=1}^n (y_i - \bar{y}_i)x_i &= \sum_{i=1}^n (y_i - a - bx_i)x_i \\
 &= \sum_{i=1}^n y_i x_i - \sum_{i=1}^n ax_i - \sum_{i=1}^n bx_i^2 \\
 &= \sum_{i=1}^n y_i x_i - \sum_{i=1}^n \left(\frac{1}{n} \sum_{j=1}^n y_j - \frac{1}{n} b \sum_{j=1}^n x_j \right) x_i - \sum_{i=1}^n bx_i^2 \\
 &= \sum_{i=1}^n y_i x_i - \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n y_j x_i + \frac{1}{n} b \sum_{i=1}^n \sum_{j=1}^n x_j x_i - \sum_{i=1}^n bx_i^2 \\
 &= SS_x b - SS_x b = 0
 \end{aligned}$$



Hur starkt är sambandet - korrelationskoefficienten



Residualvarians

För fixa x_1, x_2, \dots, x_n gör vi observationer Y_1, Y_2, \dots, Y_n , där vi antar

$$Y_i \in N(\beta_0 + \beta_1 x_i, \sigma^2)$$

och eftersom vi vvr estimatorer av regressionskoefficienterna kan man visa att

$$s_e^2 = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n-2} = \frac{\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2}{n-2} = \frac{SSE}{n-2}$$

är en vvr estimator av σ^2 . Alltså



$$E(s_e^2) = E\left(\frac{\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2}{n-2}\right) = E\left(\frac{SSE}{n-2}\right) = \sigma^2$$

..... 02

Korrelationskoefficienten

De parvisa avvikelserna har olika tecken - negativ korrelation

De parvisa avvikelserna har samma tecken - positiv korrelation



Stark positiv korrelation

Korrelationskoefficienten

Eftersom

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (x_i - \bar{x})^2}} = \frac{SS_{xy}}{\sqrt{SST \times SS_x}}$$

och

$$b = \frac{SS_{xy}}{SS_x}$$

kan vi skriva

$$b = r \frac{\sqrt{SST}}{\sqrt{SS_x}}$$



Determinationskoefficienten

Determinationskoefficienten R^2 anger andelen variation i Y som förklaras av regressionslinjen

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}$$

och kan också skrivas

$$R^2 = r^2$$

