

F16, Enkel linjär regression forts..

Christian Tallberg

Statistiska institutionen

Stockholms universitet

Korrelationskoefficienten

Vi har två stokastiska variabler X och Y . Kovariansen, som är ett mått på hur starkt det linjära sambandet är mellan X och Y , ges av

$$\text{Cov}(X, Y) = E(X - \mu_x)(Y - \mu_y)$$

Kovariansen är ett icke-normerat mått på det linjära sambandet vilket gör den svår att tolka. Ett normerat mått på hur starkt det linjära sambandet är mellan X och Y ges av korrelationskoefficienten

$$\rho = \frac{\text{Cov}(X, Y)}{\text{sqrt}(V(X) V(Y))},$$

som alltid ligger i intervallet

$$-1 \leq \rho \leq 1.$$

I en inferenssituation då vi har data skattas ρ med

$$\begin{aligned} r &= \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\text{sqrt}\left(\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2\right)} \\ &= \frac{\sum xy - \frac{\sum x \sum y}{n}}{\text{sqrt}\left(\left[\sum x^2 - \frac{(\sum x)^2}{n}\right] \left[\sum y^2 - \frac{(\sum y)^2}{n}\right]\right)} \\ &= b \frac{\text{sqrt}\left(\sum x^2 - \frac{(\sum x)^2}{n}\right)}{\text{sqrt}\left(\sum y^2 - \frac{(\sum y)^2}{n}\right)}, \end{aligned}$$

som också alltid ligger i intervallet

$$-1 \leq r \leq 1.$$

Tecknet på r säger om sambandet är positivt eller negativt (jfr med tecknet på b).

I oljeförbrukningsexemplet blir den skattade korrelationen

$$\begin{aligned} r &= \frac{\sum xy - \frac{\sum x \sum y}{n}}{\text{sqrt}\left(\left[\sum x^2 - \frac{(\sum x)^2}{n}\right] \left[\sum y^2 - \frac{(\sum y)^2}{n}\right]\right)} \\ &= \frac{8990.5 - \frac{63.2 \cdot 3320}{10}}{\text{sqrt}\left(\left[874.24 - \frac{63.2^2}{10}\right] \left[1412000 - \frac{3320^2}{10}\right]\right)} \\ &= -0.989 \approx -0.99 \end{aligned}$$

OBS! Tecknet på r anger om lutningen är positiv eller negativ men inte hur kraftig lutningen är (detta anger värdet på regressionskoefficienten b).

Det gäller också att

$$\begin{aligned} r &= \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \\ &= \frac{\sqrt{\sum (x_i - \bar{x})(y_i - \bar{y})} \sqrt{\sum (x_i - \bar{x})(y_i - \bar{y})}}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}} \\ &= \frac{\sqrt{b} \sqrt{\sum (x_i - \bar{x})(y_i - \bar{y})}}{\sqrt{\sum (y_i - \bar{y})^2}} \\ &= \sqrt{\frac{SSR}{SST}} = \sqrt{R^2} \end{aligned}$$

I oljeförbrukningsexemplet är

$$\begin{aligned} r &= \sqrt{R^2} = \sqrt{\frac{SSR}{SST}} = \sqrt{\frac{302866}{309760}} \\ &= \pm 0.99 = -0.99 \end{aligned}$$

Den linjära regressionsmodellen

Enkel linjär regression

Vi har *en* förklarande variabel och *den skattade linjen i stickprovet* (observerat medelvärde betingat på x_i) skrivs som

$$\hat{y}_i = a + bx_i.$$

Den skattade modellen (en enskild observation betingat på x_i) ges av

$$\begin{aligned} y_i &= a + bx_i + e_i \\ &= \hat{y}_i + e_i \end{aligned}$$

där

$$e_i = y_i - \hat{y}_i$$

är det observerade värdets avvikelse till linjen (*residual*) för ett givet x_i -värde.

Ekvationen för *regressionslinjen i populationen* (väntevärde betingat på x_i) skrivs som

$$\mu_{y|x} = \alpha + \beta x_i,$$

där α och β nu är parametrar. Regressionsmodellen (en enskild observation betingat på x_i) skrivs som

$$\begin{aligned} Y_i &= \alpha + \beta x_i + \varepsilon_i \\ &= \mu_{y|x} + \varepsilon_i, \end{aligned}$$

där

$$\varepsilon_i = Y_i - \mu_{y|x}$$

är avvikelsen mellan Y_i och det betingade väntevärdet (*felterm*).

Både Y_i och ε_i är stokastiska variabler med väntevärden

$$\begin{aligned} E(Y_i) &= \mu_{y|x} \\ E(\varepsilon_i) &= E(Y_i - \mu_{y|x}) = E(Y_i) - \mu_{y|x} \\ &= \mu_{y|x} - \mu_{y|x} = 0 \end{aligned}$$

och varians

$$\begin{aligned} V(\varepsilon_i) &= \sigma_\varepsilon^2 \\ V(Y_i) &= V(\mu_{y|x} + \varepsilon_i) = V(\varepsilon_i) = \sigma_\varepsilon^2. \end{aligned}$$

σ_ε^2 skattas väntevärdesriktigt med s_e^2 i stickprovet.

Skattning av α och β

Notera att väntevärdet i regressionen skrivs som

$$\mu_{y|x} = \alpha + \beta x_i.$$

När vi vill skatta $\mu_{y|x}$ med $\hat{y}$, skattar vi α och β med a och b , respektive. Man kan visa att

$$\begin{aligned} E(a) &= \alpha \\ E(b) &= \beta \\ V(a) &= \sigma_a^2 = \sigma_\varepsilon^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right] \\ V(b) &= \sigma_b^2 = \frac{\sigma_\varepsilon^2}{\sum (x_i - \bar{x})^2} \end{aligned}$$

Då σ_ε^2 (nästan) alltid är okänd används skattningen s_e^2 från stickprovet. Den skattade variansen för a och b ges då av

$$\begin{aligned} s_a^2 &= s_e^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right] \\ s_b^2 &= \frac{s_e^2}{\sum (x_i - \bar{x})^2} \end{aligned}$$

	Jämförelse	
Storhet	Utan förkl var	Regression
StokVariab	X	$Y(\varepsilon)$
observerat	x	$y(e)$
Väntevär.	$E(X) = \mu$	$E(Y) = \mu_{y x} \ (E(\varepsilon) = 0)$
Varians	$V(X) = \sigma^2$	$V(Y) = \sigma_\varepsilon^2$
Skattad var	$\hat{V}(X) = s^2$	$\hat{V}(Y) = s_e^2$
Punktskatt	$\bar{X}$	$\hat{y} = a + bx$
Väntevär.	$E(\bar{X}) = \mu$	$E(\hat{y}) = \mu_{y x}$
Varians	$V(\bar{X}) = \frac{\sigma^2}{n}$	$V(\hat{y})$ inklud. $V(a), V(b)$
Skattad var	$\hat{V}(\bar{X}) = \frac{s^2}{n}$	$\hat{V}(\hat{y})$ inklud. s_a^2, s_b^2 (se nec

Hur pass bra är punktskattningarna $y, \hat{y}, a$ och b . För att få en uppfattning om precisionen i skattningarna vill vi göra k.i eller hypotestest. För detta krävs modellantaganden.

- Värdena på variabeln X antas vara fixa. All slumpmässighet finns i Y .
- För varje fixed värde på X antas feltermerna ϵ_i (observationerna Y_i) vara normalfördelade med väntevärde 0 ($\mu_{y|x}$) och varians σ_ε^2 .
- Feltermerna ϵ_i (observationerna Y_i) är oberoende sinsemellan.
- Homoscedastisitet. Variansen för feltermerna ϵ_i (observationerna Y_i) , σ_ε^2 , är lika för alla X .

Konfidensintervall

Om feltermerna ϵ_i (observationerna Y_i) är normalfördelade följer (av satsen om linjära kombinationer) att även skattningarna av regressionskoefficienterna a och b måste vara normalfördelade. Alltså $a \sim N(\alpha; \sigma_a^2)$ och $b \sim N(\beta; \sigma_b^2)$. Ett $(1 - \alpha) 100$ % k.i. för α ges då av

$$\begin{aligned} & a \pm t_{\alpha/2}(n-2) s_a \\ = & a \pm t_{\alpha/2}(n-2) \sqrt{s_e^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right]} \end{aligned}$$

och för β av

$$\begin{aligned} & b \pm t_{\alpha/2}(n-2) s_b \\ = & b \pm t_{\alpha/2}(n-2) \sqrt{\frac{s_e^2}{\sum (x_i - \bar{x})^2}}. \end{aligned}$$

I oljeförbrukningsexemplet är

$$\begin{aligned} s_a &= \sqrt{862 \left[\frac{1}{10} + \frac{6.32^2}{474.82} \right]} = 12.60 \\ s_b &= \sqrt{\frac{862}{474.82}} = 1.35 \end{aligned}$$

Ett 95 % k.i. för α ges då av

$$\begin{aligned} & a \pm t_{0.025}(n-2) s_a \\ = & 492 \pm 2.31 \cdot 12.60 = 492 \pm 29.11, \end{aligned}$$

och för β av

$$\begin{aligned} & b \pm t_{0.025}(n-2) s_b \\ = & -25.3 \pm 2.31 \cdot 1.35 = -25.26 \pm 3.12, \end{aligned}$$

Med 95 % tillförlitlighet ligger α i intervallet (463; 521) och β i intervallet (-28.4; -22.1).

Hypotesprövning

Vi vill testa hypotesen

$$H_0 : \beta = \beta_0$$

mot något av alternativen

$$H_1 : \beta \neq \beta_0$$

$$H_1 : \beta < \beta_0$$

$$H_1 : \beta > \beta_0.$$

Oftast vill man testa om $\beta = 0$, vilket innebär att det inte finns något linjärt samband. På motsvarande sätt kan man testa α .

Från oljeexemplet vill vi testa om vi har linjärt samband eller inte, dvs

$$H_0 : \beta = 0$$

$$H_1 : \beta \neq 0,$$

för $\alpha = 0.05$. Då $b \sim N(\beta; \sigma_b^2)$ har vi att testvariabeln

$$t = \frac{b - \beta_0}{s_b} \sim t(n-2) \text{ då } H_0 \text{ är sann.}$$

Nollhypotesen förkastas om $|t_{obs}| > 2.31$. Det observerade värdet är

$$t_{obs} = \frac{-25.3 - 0}{1.35} = -18.7$$

Nollhypotesen förkastas. Ekvivalenta tolkningar: Det kan anses statistiskt påvisat att

- det finns ett linjärt samband mellan temperatur och oljeförbrukning
- temperaturen förklarar en del av variationen i oljeförbrukningen

En alternativ testvariabel är

$$F = \frac{MSR}{MSE} \sim F(1, n - 2) \text{ då } H_0 \text{ är sann.}$$

Nollhypotesen förkastas om $F_{obs} > 5.32$. Det observerade testvärdet är

$$F_{obs} = \frac{302866/1}{6894/(10 - 2)} = 351$$

Samma slutsats som tidigare. Man kan visa att i den här testsituationen är kvadraten av t -värdet = F -värdet.

Test av intercept

$$H_0 : \alpha = 0$$

$$H_1 : \alpha \neq 0,$$

på signifikansnivån 0.05. Då $a \sim N(\alpha; \sigma_a^2)$ har vi att testvariabeln

$$t = \frac{a - \alpha_0}{s_a} \sim t(n - 2) \text{ då } H_0 \text{ är sann.}$$

Nollhypotesen förkastas om $|t_{obs}| > 2.31$. Det observerade värdet är

$$t_{obs} = \frac{492 - 0}{12.60} = 39.05$$

Nollhypotesen förkastas. Det kan anses statistiskt påvisat att interceptet skall vara med i modellen.