


Regresjonsanalyse: Konfidensintervall og prediksjonsintervall

Litt repetisjon:


Har to variabler	:	y	Responsvariabel	Eller	Lungkreft
		x	Forklaringsvariabel		Røyking
			Prediktor		Fyrstikker i lomma
			Kovariat		



Korrelasjonsanalyse: $H_0: \rho = 0$

Tester ved å bruke r .

Bivariat / Symmetrisk



Regresjonsanalyse: $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$

Stigningstallet for linja:

Viser hvor mange enheter y forventes å øke, når x øker én enhet.


Tester for om det er en sammenheng: $H_0: \beta_1 = 0$

ved å bruke $\hat{\beta}_1$

95%
Konfidensintervall for β_1 :


$\hat{\beta}_1 =$ (formel)

$$\frac{\hat{\beta}_1 - \beta_1}{S.E.(\hat{\beta}_1)} \sim T_{n-2}$$



$$\frac{\bar{x} - \mu}{\frac{sd}{\sqrt{n}}} \sim T_{n-1}$$


SE(\bar{x})



Her : $n = 153$

$df = n - 2 = 151$

Table D



$$P(-1.984 < \frac{\hat{\beta}_1 - \beta_1}{S.E.(\hat{\beta}_1)} < 1.984) = 0.95$$

$$P\left(\underbrace{-1.984}_{\text{margin}} < \frac{\hat{\beta}_1 - \beta_1}{SE(\hat{\beta}_1)} < 1.984\right) = 0.95$$

$$P(-2 < \frac{\hat{\beta}_1 - \beta_1}{SE} < 2) = 0.95$$

$$P\left(\underbrace{-2.626}_{\text{margin}} < \frac{\hat{\beta}_1 - \beta_1}{SE(\hat{\beta}_1)} < 2.626\right) = 0.99$$

$$P\left(\hat{\beta}_1 - \underbrace{1.984}_{-2.626} \cdot SE(\hat{\beta}_1) < \beta_1 < \hat{\beta}_1 + \underbrace{1.984}_{+2.626} \cdot SE(\hat{\beta}_1)\right) = \underbrace{0.95}_{0.99}$$

→ 95% KI for β_1 er (les fra R-utskrift): $1.7892 \pm 1.984 \cdot 0.2385$

$[1.32, 2.26]$ Intervallet inneholder ikke 0
 → Forkast H_0 på nivå 0.05

→ 99% KI for β_1 er (les fra R)


$1.7892 \pm 2.626 \cdot 0.2385$

$[1.15, 2.43]$ → inneholder ikke 0
 → Forkast H_0 på nivå 0.01



Konfidensintervallene for β_0 og β_1 , viser oss usikkerheten i hvor regresjonslinja går.

Mer spesifikt: KI for β_1 viser oss usikkerheten i effektmaatet, altså tallet for sammenhengen mellom x og y .



Prediksjonsintervall er et intervall som beregnes for en spesifikk x^* verdi, og som forteller oss hvor stor variasjon i y verdier vi kan forvente for denne x^* -verdien.

Ligningen for sammenhengen (modellen) er:

$$y_i = \beta_0 + \beta_1 \cdot x_i + \varepsilon_i \quad \varepsilon_i \sim N(0,1)$$

Modell: $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$ $\varepsilon_i \sim N(0,1)$

Hva forventer vi at y skal være, når $x = x^*$?

$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x^*$ Hent $\hat{\beta}_0$ og $\hat{\beta}_1$ fra R-utskrift

Prediksjonsintervall for \hat{y} , og er gitt ved:

$\hat{y} \pm t_{0.025} \cdot SE(\hat{y})$

$SE(\hat{y}) = s \cdot \sqrt{1 + \frac{1}{n} + \frac{(x^* - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$

$sd(x) = \sqrt{\frac{1}{n-1} \sum (x_i - \bar{x})^2}$

$(sd(x))^2 \cdot (n-1) = \sum (x_i - \bar{x})^2$

$SE(\hat{y}) = s \cdot \sqrt{1 + \frac{1}{n} + \frac{(x^* - \bar{x})^2}{(sd(x))^2 \cdot (n-1)}}$

$s = \frac{\sum (y - \hat{y})^2}{n-2}$

Fra R-utskrift for Summary(lm)
Residual standard error

Fra deskriptiv statistikk for x