

Løsningsforslag vår 2013 - STAT100

- 1) $n=20$ uavhengige forsøk med to mulige utfall i hvert forsøk (ja/nei) \rightarrow Binomisk
Ingen info om verdi på sannsynlighet $p \rightarrow$ ukjent

Svar: $X \sim \text{Bin}(20, p)$

2) $\hat{p} = \frac{8}{20} = 0.4$

$$SE(\hat{p}) = \sqrt{\frac{p(1-p)}{n}} = \sqrt{\frac{0.4 \cdot 0.6}{20}} = 0.11$$

Et tilnærmet 95% KI for p blir

$$[\hat{p} \pm z_{0.025} \cdot SE(\hat{p})] = [0.4 \pm 1.96 \cdot 0.11] \approx \underline{\underline{[0.18, 0.61]}}$$

3)

$$n \geq 4 \cdot p(1-p) \left(\frac{z_{\frac{\alpha}{2}}}{\epsilon} \right)^2 = 4 \cdot 0.5 \cdot 0.5 \left(\frac{1.96}{0.05} \right)^2 \approx \underline{\underline{1537}}$$

4) $X \sim B(400, p)$

Utfall: $X=160$

$$\hat{p} = \frac{160}{400} = 0.4$$

$$H_0: p = p_0 = 0.35 \quad H_1: p > 0.35$$

$$z = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} = \frac{0.4 - 0.35}{\sqrt{\frac{0.35 \cdot 0.65}{400}}} = \underline{\underline{2.10}}$$

5) Skal finne \hat{E}_{13} som under H_0 er lik $n \cdot \hat{p}_{13} = n \cdot p(A_1 | p(B_2))$

$$= n \cdot \frac{R_1}{n} \cdot \frac{K_3}{n} = \frac{R_1 \cdot K_3}{n} = \frac{140 \cdot 240}{437} = \underline{\underline{76.89}}$$

6) Testobservatoren Q er χ^2 -kvadratfordelt med $(3-1)(3-1) = 4$ frihetsgrader. Vi forkaster H_0 : Uafhængige rækker af talermer variable hvis $Q > \chi^2_{\alpha, 4}$ for testniveau α . Vi må finde i χ^2 -tabellen den største værdi i rækken 4 som er mindre end $Q = 16.7$.

Det er $\chi^2_{0.005, 4} = 14.86$

Det laveste testniveau som gir forkastning er da 0,005

7) $Q = \sum_{i=1}^3 \sum_{j=1}^3 g_{ij}$ der $g_{ij} = \frac{(X_{ij} - E_{ij})^2}{E_{ij}}$

I udskriften er alle g_{ij} givet nedenfor undtagen

$$g_{32} = \frac{(X_{32} - E_{32})^2}{E_{32}} = \frac{(65 - 77.99)^2}{77.99} = 2.16$$

Dermed blir

$$Q = 0.06 + 0.05 + 3.17 + 2.60 + 2.63 + 2.16 = \underline{\underline{10.67}}$$

8) Dette er den betingede sandsynligheden for at en nordmand altid bruger bilbælte, dvs $P(\text{altid bilbælte} | \text{nordmann}) = \frac{75}{140} = \underline{\underline{0.54}}$

PS. (Her får vi ikke besked om vi antager H_0 er sandt. Dersom vi skulle antage H_0 er sandt, ville det bli slik:

$$P(\text{altid bilbælte} | \text{nordmann}) = P(B_3 | A_1) = \frac{P(A_1 \cap B_3)}{P(A_1)}$$

$$= \frac{P(A_1) \cdot P(B_3)}{P(A_1)} = P(B_3) = \frac{240}{437} = \underline{\underline{0.55}}$$

9) $Y \sim N(\mu, \sigma)$ En-utvalgs situasjon

Skal teste om avl har ført til at μ har økt og blitt større enn $\mu_0 = 0.8$

Da blir riktig hypoteseer:

$$\underline{H_0: \mu = 0.8} \quad H_1: \mu > 0.8$$

10) Ukjent σ så vi må bruke T-test

$$T = \frac{\bar{Y} - \mu_0}{S_y / \sqrt{n}} = \frac{0.90 - 0.80}{0.211 / \sqrt{14}} = \underline{1.77}$$

11) En variant av minste kvadraters estimatoren for β

$$\text{er: } \hat{\beta} = r \cdot \frac{S_y}{S_x} = 0.95 \cdot \frac{0.211}{0.766} = \underline{0.026}$$

12) Et 95% KI for α (konstantleddet i modellen) er

$$[\hat{\alpha} \pm t_{\frac{\alpha}{2}, n-2} \cdot SE(\hat{\alpha})] = [0.130845 \pm 2.179 \cdot 0.002487] \\ = \underline{[-0.035, 0.295]}$$

(Da $t_{0.025, 12} = 2.179$)

13) Fra R-utskriften ser vi at p-verdien for $\hat{\alpha}$ teste

$H_0: \alpha = 0$ mot $H_1: \alpha \neq 0$ er 0.111.

Generelt forkaster man H_0 hvis p-verdi $< \alpha$.

Må, dersom $\alpha > 0.111$ forkaste H_0
testnivået

Generelt har vi også at dersom man forkaster H_0 for testnivå α (bilateral test) vil et $(1-\alpha) \cdot 100\%$ konfidensintervall ikke inneholde verdien under nullhypotesen.

Dermed vil et $(1-0.111) \cdot 100\%$ KI for konstantleddet α i modellen akkurat inneholde verdien 0, mens f.eks et $(1-0.12) \cdot 100\%$ altså et 88% KI ikke vil inneholde 0. (Dette svarer til en test på 12% nivå, noe som vil gi forkastning av H_0)

Riktig svar: 88% intervall

14) Et 95% KI for $E(y|x)$ er

$$\left[\hat{y} \pm t_{0.025,12} \cdot 5 \cdot \sqrt{\frac{1}{n} + \left(\frac{x - \bar{x}}{5 \cdot SE(\hat{\beta})} \right)^2} \right]$$

Bredden av intervalllet er

$$\begin{aligned} & 2 \cdot t_{0.025,12} \cdot 5 \cdot \sqrt{\frac{1}{n} + \left(\frac{x - \bar{x}}{5 \cdot SE(\hat{\beta})} \right)^2} \\ &= 2 \cdot 2.179 \cdot 0.06864 \cdot \sqrt{\frac{1}{14} + \left(\frac{30.56 - 27.56}{0.06864 / 0.002417} \right)^2} \\ &= \underline{0.081} \end{aligned}$$

15) Denne kan løses på flere måter, bl.a.:

a) I enkel lineær regresjon vil R^2 være lik r^2 der r = korrelasjonen mellom x og y .

$$\text{Dermed: } R^2 = 0,95^2 = \underline{\underline{0,90}}$$

b) Per definisjon er generelt (også i multipl regressjon)

$$R^2 = \frac{SSR}{SST}$$

Vi må finne SST som ikke er gitt i utskriften.

$$\text{Har at } SST = SSR + SSE$$

Videre vet vi at $MSE = \frac{SSE}{n-2}$ i enkel regresjon

$$\text{dvs } SSE = MSE \cdot (n-2)$$

Til slutt: $MSE = s^2$ som er gitt i utskrift

Da får vi samlet sett

$$R^2 = \frac{SSR}{SST} = \frac{SSR}{SSE + SSR} = \frac{SSR}{SSR + MSE(n-2)} = \frac{SSR}{SSR + s^2(n-2)}$$

$$\frac{0,52221}{0,52221 + 0,06864^2 \cdot (14-2)} = \underline{\underline{0,90}}$$

16) R^2 er andel av variasjonen i responsvariabelen som kan forklares ved den lineære sammenhengen til X (i regresjon), eller ved at de tilhører ulike nivåer av en gruppevariabel (i ANOVA-modeller).

Her har vi regresjon og alt. c) passer

17) σ er et mål på hvor mye responsvariabelen y vil variere dersom man holder x fast og gir x på én verdi. I regresjon antar vi at denne variasjonen er den samme uansett hvilken verdi av x vi observerer y ved.

AV. a) er riktig i denne sammenhengen

18) MSG i ANOVA med én gruppevariabel med k nivåer har alltid $k-1$ frihetsgrader. Her har vi $k=5$, dermed 4 frihetsgrader.

19) Hypoteser:

$H_0: \mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5$ mot H_1 minst to μ_i er forskjellige

Forkaster H_0 dersom $F = \frac{MSG}{MSE}$ blir større enn $F_{\alpha, k, n-k}$.

$$\text{Altså } F = \frac{MSG}{MSE} = \frac{0,08}{0,018} = \underline{\underline{4,44}}$$

20)

$$\hat{\theta} = \frac{(\bar{y}_1 + \bar{y}_2 + \bar{y}_3)}{3} - \frac{(\bar{y}_4 - \bar{y}_5)}{2} = \frac{(4,225 + 4,250 + 4,150)}{3} - \frac{(4,0 + 3,925)}{2}$$
$$= \underline{\underline{0,25}}$$

21) θ kan skrives slik:

$$\theta = \frac{1}{3}\mu_1 + \frac{1}{3}\mu_2 + \frac{1}{3}\mu_3 - \frac{1}{2}\mu_4 - \frac{1}{2}\mu_5$$

$c_1 = \frac{1}{3}$ $c_2 = \frac{1}{3}$ $c_3 = \frac{1}{3}$ $c_4 = -\frac{1}{2}$ $c_5 = -\frac{1}{2}$

Alt. b) er korrekt

22) Hvis snittet av forventningene for 1978 og 1980 er lavere enn snittet av de 3 årene før vil θ bli større enn 0

Vi skal derfor teste:

$H_0: \theta = 0$ mot $H_1: \theta > 0$

23) Vi kan skrive slik

$$\theta = \mu_3 - \mu_4 = 0 \cdot \mu_1 + 0 \cdot \mu_2 + 1 \cdot \mu_3 + (-1) \cdot \mu_4 + 0 \cdot \mu_5$$

som gir $c_1 = 0$, $c_2 = 0$, $c_3 = 1$, $c_4 = -1$, $c_5 = 0$

SE($\hat{\theta}$) er gitt ved

$$SE(\hat{\theta}) = \sqrt{MSE \cdot \sum \frac{c_i^2}{n_i}}$$

$$= \sqrt{MSE \left(\frac{c_1^2}{4} + \frac{c_2^2}{4} + \frac{c_3^2}{4} + \frac{c_4^2}{4} + \frac{c_5^2}{4} \right)}$$

$$= \sqrt{MSE \left(\frac{c_3^2}{4} + \frac{c_4^2}{4} \right)} \quad \text{siden } c_1 = c_2 = c_5 = 0$$

$$= \sqrt{0,018 \left(\frac{1^2}{4} + \frac{(-1)^2}{4} \right)} = \underline{\underline{0,095}}$$

24) Dette er MSE

25) MSE er et felles variansmål basert på utvalgsvariansene i alle k grupper. Siden vi antar at alle grupper har samme σ , Det kan vises at for $k=2$ er $S_p^2 = MSE$ og for $k > 2$ utvider vi S_p^2 formelen til k ledd som en variant av MSE:

$$\begin{aligned} MSE = (S_p^2) &= \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2 + \dots + (n_k-1)S_k^2}{n_1 + n_2 + \dots + n_k - k} \\ &= \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2 + \dots + (n_k-1)S_k^2}{n-k} \end{aligned}$$

Telleren er her det samme som SSE.

Siden alle $n_i = 4$ kan vi skrive:

$$3 \cdot S_1^2 + 3 \cdot S_2^2 + \dots + 3 \cdot S_5^2 = SSE$$

S_1 er ukjent og er den som skal beregnes. De andre er kjent. Dermed

$$3 \cdot S_1^2 + \underbrace{3 \cdot 0,129^2 + 3 \cdot 0,129^2 + 3 \cdot 0,141^2 + 3 \cdot 0,171^2}_{= 0,2472} = 0,27 \uparrow SSE$$

$$3 \cdot S_1^2 = 0,27 - 0,2472$$

$$S_1 = \sqrt{\frac{0,27 - 0,2472}{3}} = \underline{\underline{0,087}}$$

26) β i modellen angir forventet endring i y når x øker med én enhet.

$\hat{\beta}$ er den estimerte forventede endringen i y når x øker med én enhet.

At $\hat{\beta} = -1.17$ betyr at vi estimerer y til å avta med 1.17 når avstanden øker med 1 meter.

Alt. b) er korrekt.

27) $H_0: \beta = 0$ mot $\beta < 0$

Testobservator:

$$T = \frac{\hat{\beta} - 0}{SE(\hat{\beta})} = \frac{-1.17}{0.1264} = \underline{\underline{-9.259}}$$

28) Vi forkaster den ensidige testens H_0 dersom T blir veldig liten (stor negativ) og mer spesifikt dersom $T < -t_{\alpha, n-2}$

Her har vi $n-2 = 20-2 = 18$ frihetsgrader

Da får vi fra tabell over t -fordeling:

$$-t_{0.05, 18} = \underline{\underline{-1.734}}$$

29) Med tosidig alternativ vil p -verdien fordobles og det blir mindre sannsynlighet for p -verdi $< \alpha$ og forkastning.

Alt. e) er korrekt.

$$30) \hat{y} = 129.1644 + (-1.1704) \cdot 10 = \underline{\underline{117.5}}$$

31) Av utskriften merker vi oss at $\bar{x} = 59.95$.
Vi skal altså finne et prediksjonsintervall for $x = \bar{x}$ (der det er smalest)

Formelen sier at et $(1-\alpha) \cdot 100\%$ PI for y^*

$$\hat{y} \pm t_{\frac{\alpha}{2}, n-2} \cdot s \cdot \sqrt{1 + \frac{1}{n} + \left(\frac{x - \bar{x}}{s/SE(\hat{\beta})}\right)^2}$$

Leddene $\left(\frac{x - \bar{x}}{s/SE(\hat{\beta})}\right)^2$ blir 0 når $x = \bar{x}$

$$t_{0.025, 18} = 2.101$$

$$s = 18.15$$

$$SE(\hat{\beta}) = 0.1264$$

$$n = 20$$

$$\hat{y} = 59.0 \quad (\text{gitt i tekst})$$

Plugg inn og få

$$\left[59.0 \pm 2.101 \cdot 18.15 \cdot \sqrt{1 + \frac{1}{20} + 0} \right]$$

$$= \underline{\underline{[19.9, 98.1]}}$$

32) Tolkning: dersom vi går 58.95 meter fra veien vil den observerte svevestøvkonentrasjonen vi får med 95% sannsynlighet være mellom 19.9 og 98.1

AVA. c)

33) For $x = 59.5$ har vi at $\hat{y} = 59.0$ ifølge modellen.
Observert verdi er 45.0
Da blir residualen

$$e = y - \hat{y} = 45.0 - 59.0 = \underline{\underline{-14.0}}$$

34) Utvalgsstandardavvik:

$$s_y = \sqrt{\frac{1}{n-1} \sum_{i=1}^4 (y_i - \bar{y})^2} \quad (\text{Definisjon 2.3: bokst})$$

$$= \sqrt{\frac{1}{3-1} \left((1300 - 1112.5)^2 + (960 - 1112.5)^2 + (1150 - 1112.5)^2 + (1040 - 1112.5)^2 \right)}$$

$$= \underline{\underline{147.3}}$$

35) Antar $X \sim N(\mu, \sigma)$

$$\hat{\mu} = \bar{x} = 1145$$

$$\hat{\sigma} = s_x = 156.7$$

$H_0: \mu = 1000$ mot $H_1: \mu \neq 1000$

$$\text{Testobservator: } T = \frac{\bar{x} - \mu_0}{s_x / \sqrt{n}} = \frac{1145 - 1000}{156.7 / \sqrt{4}} = \underline{\underline{1.85}}$$

36) W er t -fordelt med 3 frihetsgrader

(En-utvalgs situasjon med $n = 4$ observasjoner og ukjent standardavvik σ)

37) I en ANOVA modell med én gruppevariabel med k nivåer og totalt N observasjoner, vil SSE ha $N - k$, dvs her: 24 - 4 = 20 frihetsgrader

- 38) SST har alltid $N-1$ frihetsgrader,
dvs $24-1 = \underline{\underline{23}}$
- 39) Et forventningsrett estimat for σ^2 er MSE
 $\hat{\sigma}^2 = MSE = \underline{\underline{150}}$
- 40) Sannsynligheten for at en observert
 F blir større enn F_α under H_0 er
lik α . Hvis dette skjer forkastes
 H_0 feilaktig (type I feil)
Dette kan alternativt uttrykkes ved
 $P(\text{Forkaste } H_0 \mid H_0 \text{ er sann})$