

Løsningsforslag STAT100 Vår 2014

- 1) Hvis forventet mengde *E. coli* er lavere i B er altså
- $$\mu_A > \mu_B \Rightarrow \mu_A - \mu_B > 0$$

Dette blir H_1 som vi ønsker å påvise.

H_0 blir da $\mu_A - \mu_B = 0$ (ingen forskjell)

e) er korrekt.

- 2) Målinger er gjort begge steder i de samme månedene. En evt måned til måned variasjon som påvirker begge steder kan skape avhengighet mellom målinger i samme måned. Derfor blir man knytt ved å analysere som parvise data.
- d) er korrekt.

- 3) En-utvalgs t-test på differansen.

Testobservator:

$$T = \frac{\hat{\mu}_0 - \mu_0}{s_0 / \sqrt{n}} = \frac{10,30 - 0}{10,54 / \sqrt{10}} = 3,09$$

b) er korrekt.

- 4) En utvalgs t-test har generelt $n-1$ frihetsgrader.
- Her: $n=10$, dvs 9 frihetsgrader

a) er korrekt.

$$5) H_0: p = 0.5 \quad H_1: p > 0.5$$

La X være antall måneder av $n=10$ at B har lavere *E. coli* konsentrasjon enn A.

Da er $X \sim B(10, p)$. Hvis $p > 0.5$ er B bedre enn A (lavere bakteriekons).

Vi observerer $X=9$.

Under H_0 er $X \sim B(10, 0.5)$.

p -verdi for hypotesetest er $P(X \geq 9 | H_0 \text{ er sann})$
dvs $P(X \geq 9)$ når $p=0.5$

$$\begin{aligned} P(X \geq 9) &= 1 - P(X \leq 8) \\ &= 1 - 0.989 \quad (\text{jfr. tabell E.1}) \\ &= 0.011 \end{aligned}$$

c) er korrekt

6) To-utvalgs t -test

$$\begin{aligned} S_p^2 &= \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2} = \dots = \frac{S_1^2 + S_2^2}{2} = \frac{11.83^2 + 10.93^2}{2} \\ &= 129.71 \end{aligned}$$

$$S_p = 11.39$$

Testobservator:

$$T = \frac{213.7 - 203.4}{11.39 \sqrt{\frac{1}{10} + \frac{1}{10}}} = 2.02$$

c) er korrekt.

7) $n_1 + n_2 - 2 = 10 + 10 - 2 = 18$ frihetsgrader
e) er korrekt.

8) Vet at $MSG = \frac{SSG}{k-1} \Leftrightarrow SSG = MSG \cdot (k-1)$
Her er $k = 3$ (gjødseltype)

$$MSG = 7.4533$$

Dermed : $SSG = 7.4533 \cdot (3-1) = 14.907$

b) er korrekt

9) $F = \frac{MSG}{MSE} = \frac{7.4533}{1.2178} = 6.12$

e) er korrekt.

10) Residual : $Y_{ij} - \bar{Y}_i$ der i er gjødseltype
 j er observasjon
under gjødseltype
For vite at for $i=1$ (type A) for en eller
annen j er $Y_{ij} = 26.0$.

Av utskrift ser vi at $\bar{Y}_i = 25.0$ for $i=1$

$$\hat{\epsilon}_{ij} = 26.0 - 25.0 = 1.0$$

d) er korrekt.

$$11) \hat{\theta} = \frac{\bar{Y}_1 - \bar{Y}_2}{2} - \bar{Y}_3 = \frac{(25.0 - 24.7)}{2} - 22.5 = 2.35$$

e) er korrekt.

12) A og B er kunstgjedder. Hvis de har højere gennemsnitsforventning end C vil $\theta > 0$, dermed

$$H_0: \theta = 0 \quad \text{mot} \quad H_1: \theta > 0$$

d) er korrekt.

$$13) \theta = 1 \cdot \mu_1 + (-1) \cdot \mu_2 + 0 \cdot \mu_3$$
$$c_1 = 1 \quad c_2 = -1 \quad c_3 = 0$$

Forventningsrett estimator er

$$\hat{\theta} = 1 \cdot \bar{Y}_1 + (-1) \cdot \bar{Y}_2 + 0 \cdot \bar{Y}_3$$


Denne har standardfeil

$$SE(\hat{\theta}) = \sqrt{MSE \cdot \sum_{i=1}^3 \frac{c_i^2}{n_i}}$$
$$= \sqrt{1.2178 \left(\frac{1^2}{4} + \frac{(-1)^2}{4} + \frac{0^2}{4} \right)}$$
$$= 0.78$$


a) er korrekt.

14) c) er korrekt.

15) Linearitet er OK siden det ikke er noe kurve å se i plottet.
Dvs ikke noe stikt:




eller



f.eks.

Konstant varians er OK siden variasjonen synes å være den samme i alle tre grupper



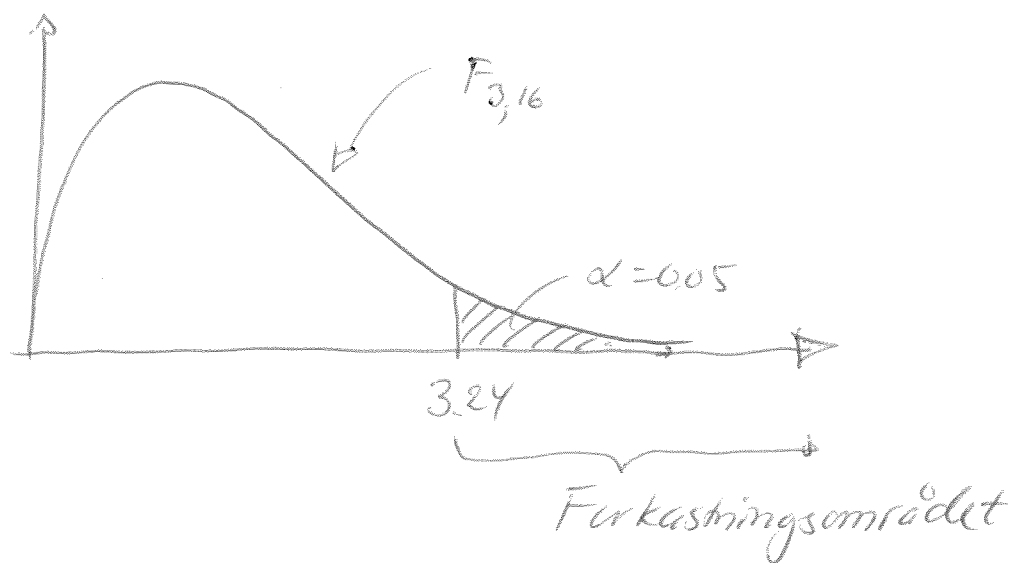
Samme spredning rundt 0
for residualene

d) er korrekt.

16) σ beskriver uforklart variasjon, dvs den som ikke kan fanges opp av faktoren gjødseltype. Denne antas å være den samme i alle grupper. Mao, for en eller annen gjødseltype vil avling variere av andre årsaker. Denne variasjonen beskrives av σ .

a) er korrekt.

- 17) Testobservatoren F har 3 og 16 frihetsgrader. Av tabell for F med testnivå $\alpha = 0,05$ finner vi i kolonne 3 og rad 16 tallet 3.24. Altså



b) er korrekt.

- 18) Vi uttaler oss aldri om sannsynligheten for at en hypotese er korrekt, så ej må være feil? Alle de andre er korrekte utsagn om testnivået α .

e) er korrekt.

- 19) Et 99% KI for θ blir

$$\hat{\theta} \pm t_{0,005, n-k} \cdot SE(\hat{\theta}) \quad \text{der } t_{0,005, 16} = 2.921$$

Dette gir

$$-32 \pm 2.921 \cdot 10.95 = [-63.98, -0.015]$$

c) er korrekt.

20) Hypoteser : $H_0 : \theta = -10$ $H_1 : \theta < -10$

Under H_0 er testobservatoren :

$$T = \frac{\hat{\theta} - \theta_0}{SE(\hat{\theta})} = \frac{-32 - (-10)}{10,95} = -2,01$$

t -fordelt med $n-k = 20-4 = 16$ frihetsgrader.

Forkast H_0 hvis $T < -t_{0,05,16} (= -1,746)$

Vi ser at $-2,01 < -1,746$ og vi forkaster H_0 på 5% nivå

d) er korrekt.

21)

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

Standardfeilen til estimeren blir

$$SE(\hat{\theta}) = \sqrt{MSE \left(\frac{1^2}{5} + \frac{(-1)^2}{5} \right)} = 10,95$$

Siden øvre grense i intervallet er lik

$$\hat{\theta} + t_{\frac{\alpha}{2}, 16} \cdot SE(\hat{\theta}) = -2,78 \quad (\text{oppgitt})$$

$$\text{og } \hat{\theta} = \bar{y}_3 - \bar{y}_4 = 196 - 222 = -26$$

$$SE(\hat{\theta}) = 10,95$$

Setter vi at

$$-26 + t_{\frac{\alpha}{2}, 16} \cdot 10,95 = -2,78$$

↑

$$t_{\frac{\alpha}{2}, 16} = \frac{-2,78 + 26}{10,95} = 2,12$$

Av rad 16 i t -tabell finner vi at $t = 2,12$ for areal lik 0,025. Dette arealet er altså $\frac{\alpha}{2}$. Dermed er $\alpha = 0,05$ og vi har et 95% intervall. c) er korrekt.

$$22) R^2 = \frac{SS_G}{SS_T} = \frac{SS_G}{SS_G + SS_E} = \frac{4820}{4820 + 4800} = 0.501$$

c) er korrekt.

23) La utvalgsstandardavviket for gerd i være S_i .

$$\text{Da vil } MSE = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2 + (n_3-1)S_3^2 + (n_4-1)S_4^2}{n-k}$$

(utvidet S_p^2 til fire grupper)

Siden det er like mange observasjoner i alle grupper kan den forenkles til

$$MSE = \frac{S_1^2 + S_2^2 + S_3^2 + S_4^2}{4}$$

Alle tall er kjente unntatt S_3 . Setter mn:

$$300 = \frac{15.81^2 + 18.71^2 + S_3^2 + 19.24^2}{4}$$



$$4 \cdot 300 - 15.81^2 - 18.71^2 - 19.24^2 = S_3^2$$



$$S_3 = \sqrt{4 \cdot 300 - 15.81^2 - 18.71^2 - 19.24^2} = \underline{15.16}$$

b) er korrekt.

24) Fra modell 1:

β er forventet endring i utgifter dersom antall senger økes med 1.

10 flere senger gir forventet endring lik 10β

Siden $\hat{\beta} = 1412.1$ vil estimert endring med 10 ekstra senger være $10 \cdot 1412.1 = \underline{14121}$

e) er korrekt

25) 95% KI for β :

$$\hat{\beta} \pm t_{0.025, 8} \cdot SE(\hat{\beta})$$

$$= 1412.1 \pm 2.306 \cdot 224.2$$

$$= [895.1, 1929.1]$$

a) er korrekt.

26) Fra modell 2 estimatet:

$$\hat{y} = -719.3 + 1866.2 \cdot x$$

For $x = 40$

$$\hat{y} = -719.3 + 1866.2 \cdot 40 = 73928.7$$

e) er korrekt.

27) Et 95% PI for y

$$\hat{y} \pm t_{0,025,8} \cdot s \cdot \sqrt{1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{(s/SE(\hat{\beta}))^2}}$$

for $x = \bar{x}$
blir denne = 0

Vet at $\hat{y} = 102295$

$$s = 30920$$

$$n = 10$$

$$t_{0,025,8} = 2.306$$

Dermed :

$$102295 \pm 2.306 \cdot 30920 \cdot \sqrt{1 + \frac{1}{10}}$$
$$= [27513, 177077]$$

b) er korrekt.

28) c) er korrekt

29) For en regresjonsmodell

$$y_i = \alpha + \beta x_i + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma)$$

vil $E(y|x) = \alpha + \beta x_i$

Altså er d) ikke antatt

d) er korrekt svar

30) Hvis sammenheng er positiv vil $\beta > 0$
Dermed er $H_1: \beta > 0$
og $H_0: \beta = 0$

a) er korrekt.

31) For modell 2, er det effekt av sykehusseger?
 $H_0: \beta = 0$ $H_1: \beta \neq 0$

Testobservator:

$$T = \frac{\hat{\beta} - 0}{SE(\hat{\beta})} = \frac{1866.2}{527.7} = 3.536$$

e) er korrekt.

32) Bare alternativ d) sier noe om hvor godt modellen forklarer variasjon i responsen.
d) er korrekt

33) La X_{33} være antall som jobber med salg/service i varehandelen.

Har observert $X_{33} = 56$

Under H_0 om uavhengighet mellom næring og yrke vil denne ha forventning:

$$E(X_{33} | H_0 \text{ sann}) = E_{33} = \frac{R_3 \cdot K_3}{n} = \frac{79 \cdot 70}{182} = 30.4$$

a) er korrekt.

34) La q_{31} være bidraget.

$$q_{31} = \frac{(X_{31} - \bar{E}_{31})^2}{E_{31}} = \frac{(13 - 27.8)^2}{27.8} = 7.9$$

c) er korrekt.

35) Testobservatoren Q er kji-kvadratfordelt med med $(r-1)(k-1) = (4-1)(3-1) = 6$ fr. grader.

Fra tabell over χ^2_6 finner vi for $\alpha = 0.01$ at $\chi^2_{0.01,6} = 16.81$

d) er korrekt.

36) Fra tabell over kji-kvadratkomponentene finner vi summen av disse, $Q = 1.04$.

Under H_0 om uavhengighet er $Q \sim \chi^2_4$

og fra tabell finner vi at $\chi^2_{0.05,4} = 9.49$

Siden $Q < \chi^2_{0.05,4}$ beholdes H_0 om uavhengighet.

e) er korrekt.

37) Q er egentlig tilnærmet χ^2 -fordelt under H_0 . Tilnærmingen blir dårlig dersom forventet antall i noen celler er lavt. (parallell til $np \geq 5$ & $n(1-p) \geq 5$ regelen i binomisk normaltilnærming)

b) er korrekt.

38) SS_E har $n-k$ frihetsgrader i ANOVA-modellene vi betrakter i STAT100.

Her er $n = 13 \cdot 3 = 39$ og $k = 3$

Dermed $39 - 3 = 36$ frihetsgrader

c) er korrekt.

$$39) \quad SS_G = \sum_{i=1}^3 n_i (\bar{y}_i - \bar{y})^2$$

$$= 13 (29.47 - 27.83)^2 + 13 (30.86 - 27.83)^2 + 13 (23.15 - 27.83)^2$$

$$= 439$$

a) er korrekt.

40) Figur øverst til venstre antyder at variasjonen er forskjellig i de tre gruppene.

Figur øverst til høyre gir ikke klar indikasjon om at residualenes fordeling ikke er normal.

Nederste figur viser at residualene har en trend over tid innen de tre gruppene.

Dette antyder at ϵ_i -ene ikke er uavhengige.

b) er mest korrekt uttalelse.