

(Det tas forbehold om feil i løsningsforslaget.)

### Oppgave 1

a) Antall utvalg (uordnede) på  $s = 2$  av totalt  $N = 12$ :  $\binom{12}{2} = 66$ .

Antall par der begge kan jobben:  $\binom{9}{2} = 36$ ,

og antall par der 1 kan jobben (og 1 ikke kan):  $\binom{9}{1} \cdot \binom{3}{1} = 27$  — dvs. det er  $36 + 27 = 63$  par der en eller begge kan jobben (der høyest 1 ikke kan jobben).

To velges tilfeldig:  $P(\text{ingen kan jobben}) = \frac{\text{antall utvalg der begge ikke kan}}{\text{totalt antall utvalg}} = \frac{3}{66} = \frac{1}{22}$ .

### Oppgave 2

La  $O_1 =$  finne olje i reservoar 1, og  $O_2 =$  finne olje i reservoar 2. Vi har da:  $P(O_1) = 0.6$ ,  $P(O_2) = 0.7$ ,  $P(\text{finne olje i begge reservoarene}) = P(O_1 \cap O_2) = 0.45$ .

a) Finne olje i minst ett av reservoarene  $= O_1 \cup O_2$ ;  $P(O_1 \cup O_2) = P(O_1) + P(O_2) - P(O_1 \cap O_2) = 0.6 + 0.7 - 0.45 = 0.85$

Ikke finne olje i noen av de to  $= (O_1 \cup O_2)^C$ ;  $P((O_1 \cup O_2)^C) = 1 - P(O_1 \cup O_2) = 1 - 0.85 = 0.15$

b) Finne olje i kun reservoar 1  $= O_1 \cap O_2^C$ ;  $P(O_1 \cap O_2^C) = P(O_1) - P(O_1 \cap O_2) = 0.6 - 0.45 = 0.15$  — bruk Venndiagram !  $P(O_2|O_1) = \frac{P(O_2 \cap O_1)}{P(O_1)} = \frac{0.45}{0.6} = 0.75$

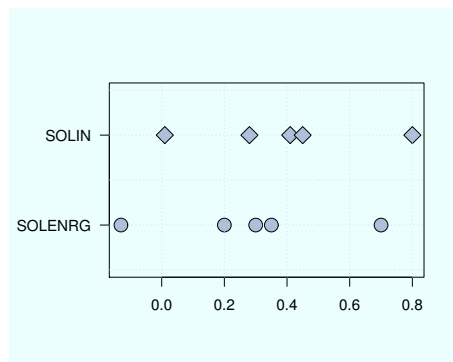
c) Finne olje i kun reservoar 1 eller kun reservoar 2  $= (O_1 \cap O_2^C) \cup (O_1^C \cap O_2)$ ;  $P\{(O_1 \cap O_2^C) \cup (O_1^C \cap O_2)\} = P(O_1) + P(O_2) - 2P(O_1 \cap O_2) = 0.6 + 0.7 - 2 \cdot 0.45 = 0.4$  — bruk Venndiagram !

### Oppgave 3

Selskap	gj.sn.	datamed.	datastd.
SOLENRG	0.28	0.30	0.298
SOLIN	0.39	0.41	0.287

a) Merk: *datastd.* (for  $x_i$ 'ene)  
 $= \sqrt{\frac{1}{5-1} \sum_{i=1}^5 (x_i - \bar{x})^2} = \sqrt{0.356/4} = 0.298$ ; tilsvarende for  $y_i$ 'ene:  $\sqrt{0.329/4} = 0.287$ . Dette er estimat av  $\sigma_X = SD(X_i)$  og  $\sigma_Y = SD(Y_i)$ , hhv.

Prikkdigram til de to datasettene i figur til høyre.



- b) Vi antar at målingene kommer fra en normalfordeling:  $X_1, \dots, X_5$  er u.i.f.  $N(\mu_X, \sigma_X)$ . Et 95% konfidensintervall for  $\mu_X$  er da gitt ved:

$$\left( \bar{x} - t_{0.025,4} \cdot s_X \sqrt{\frac{1}{5}}, \quad \bar{x} + t_{0.025,4} \cdot s_X \sqrt{\frac{1}{5}} \right)$$

Her er  $s_X$  estimat av  $\sigma_X$ :  $s_X = \sqrt{\frac{1}{4} \sum_{i=1}^5 (x_i - \bar{x})^2}$ , og  $t_{0.025,4} = 2.776$ . Innsatt data:

$$\left( 0.28 - 2.776 \cdot 0.30 \sqrt{\frac{1}{5}}, \quad 0.28 + 2.776 \cdot 0.30 \sqrt{\frac{1}{5}} \right) = (-0.09, 0.65)$$

- c) Vi vil teste:  $H_0 : \mu_X = 0$  mot  $H_1 : \mu_X > 0$ .

Teststørrelse:  $T = \frac{\bar{X}}{s_X / \sqrt{5}}$ ; store verdier av  $T$  indikerer at  $H_1$  er riktig.

Nullfordeling:  $T \sim t(4)$ . Forkastningsområde:  $[t_{0.05,4}, \infty)$ ,  $t_{0.05,4} = 2.132$ .

Utfall av teststørrelse:  $\frac{0.28}{0.30 / \sqrt{5}} = 2.09 < 2.132$ . Siden utfallet ikke er i forkastningsområdet, beholdes  $H_0$ . Dataene gir ikke grunnlag for å hevde at det er positiv forventet verdistigning for selskapet SOLENRG.

- d) I tillegg til det nevnt i b), antar vi at også  $y_i$ -dataene kommer fra en normalfordeling,  $Y_1, \dots, Y_5$  er u.i.f.  $N(\mu_Y, \sigma_Y)$ . Og vi antar at  $X_i$ 'ene uavhengige av  $Y_i$ 'ene. Videre kan vi anta at variansene er like:  $\sigma_X^2 = \sigma_Y^2$  som ikke synes urimelig ut fra dataene.

Et 95% konfidensintervall for  $\mu_X - \mu_Y$  er da gitt ved:

$$\left( \bar{x} - \bar{y} - t_{0.025,8} \cdot s_p \sqrt{\frac{1}{5} + \frac{1}{5}}, \quad \bar{x} - \bar{y} + t_{0.025,8} \cdot s_p \sqrt{\frac{1}{5} + \frac{1}{5}} \right) = (-0.54, 0.32)$$

Her er  $s_p = \sqrt{\frac{\sum_{i=1}^5 (x_i - \bar{x})^2 + \sum_{i=1}^5 (y_i - \bar{y})^2}{5+5-2}} = 0.29$ ;  $t_{0.025,8} = 2.306$ .

- e) Vi vil teste:  $H_0 : \mu_X - \mu_Y = 0$  mot  $H_1 : \mu_X - \mu_Y \neq 0$ .

Det enkleste er å bruke konfidensintervallet fra d) for å gjennomføre testen. Siden 0 er inneholdt i konfidensintervallet beholdes  $H_0$ . Det er ikke grunnlag for å hevde at det er forskjell i virkeligheten. Dette er en test med 5% signifikansnivå, siden intervallet har konfidensgrad 95%.

- f) Vi antar at  $d_i$ 'ene er utfall av fem tilfeldige variable  $D_1, \dots, D_5$  som er u.i.f.  $N(\mu_D, \sigma_D)$ . Et 95% konfidensintervall for  $\mu_D = \mu_X - \mu_Y$  er da gitt ved:

$$\left( \bar{d} - t_{0.025,4} \cdot s_D \sqrt{\frac{1}{5}}, \quad \bar{d} + t_{0.025,4} \cdot s_D \sqrt{\frac{1}{5}} \right) = (-0.24, 0.02)$$

Her er  $s_D = \sqrt{\frac{\sum_{i=1}^5 (d_i - \bar{d})^2}{5-1}} = 0.106$ ;  $t_{0.025,4} = 2.776$ .

Vi kan bruke dette intervallet til å teste:  $H_0 : \mu_D = 0$  mot  $H_1 : \mu_D \neq 0$ .

Siden 0 er inneholdt i konfidensintervallet beholdes  $H_0$ . Det er ikke grunnlag for å hevde at det er forskjell i virkeligheten. Dette er en test med 5% signifikansnivå, siden intervallet har konfidensgrad 95%.

Siden  $\mu_D = \mu_X - \mu_Y$  er dette er det samme som å teste:  $H_0 : \mu_X - \mu_Y = 0$  mot  $H_1 : \mu_X - \mu_Y \neq 0$ .

Konklusjonen blir den samme som ved toutvalgstesten i punkt e).

#### Oppgave 4

Modell:  $Y_i = \alpha + \beta x_i + e_i$  der  $e_1, \dots, e_n$  er u.i.f.  $N(0, \sigma)$  ( $n = 10$ ).


(Fra utskriften: estimat av  $\alpha$ : 0.75; estimat av  $\beta$ : 0.97.

a) Dvs. estimert regresjonslinje:

$$\hat{y} = 0.75 + 0.97x.)$$

Prediksjoner: for dose  $x_0 = 5$ :  $\hat{y} = 0.75 + 0.97 \cdot 5 = 5.6$ .

for dose  $x_0 = 9$ :  $\hat{y} = 0.75 + 0.97 \cdot 9 = 9.48$ .



b) Dersom i virkeligheten  $\beta = 0$ , betyr det at gitt dose ikke har sammenheng med målt konsentrasjon; dersom  $\beta \neq 0$ , betyr det at det er sammenheng. Vi vil derfor teste:

$$H_0 : \beta = 0 \quad \text{mot} \quad H_1 : \beta \neq 0$$

Testobservator

$$T = \frac{\hat{\beta}}{\sqrt{\frac{S^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim t_{n-2} \text{ under } H_0$$

Her er  $S^2$  estimator for  $\sigma^2$  (estimat:  $0.3564^2$ ). Vi forkaster  $H_0$  dersom  $T \leq -t_{\gamma/2, n-2} = -t_{0.025, 8} = -2.306$  eller  $T \geq t_{\gamma/2, n-2} = 2.306$  ( $\gamma = 0.05$  er signifikansnivå). Fra utskrift: beregnet verdi av  $T$ : 14.022; Dvs. forkast  $H_0$  — det er sammenheng mellom dose og forventet målt konsentrasjon i kroppen. (Vi kan også lese av  $p$ -verdien: 0.000000649 som er (mye!) mindre enn 0.05.)

c) Konstantleddet,  $\alpha$ , i modellen  $Y_i = \alpha + \beta x_i + e_i$  skal være null; da vil forventet målt konsentrasjon i kroppen være null dersom en pasient ikke har fått noen dose ( $x_0 = 0$ ) (regresjonslinjen går gjennom origo).

Vi kan teste:  $H_0 : \alpha = 0$  mot  $H_1 : \alpha \neq 0$ . Regresjonsanalysen viser  $p$ -verdi: 0.138; dvs. behold  $H_0$ ; dataene gir ikke grunnlag for å hevde at  $\alpha \neq 0$ .

d) I denne situasjonen er summen av kvadrerte avvik:

$$\text{SSE}(b) = \sum_{i=1}^n (y_i - bx_i)^2$$

Vi deriverer SSE mht.  $b$ :

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

Vi setter den deriverte lik null og løser likningen mht.  $b$ :  $\Rightarrow b = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$  (løsningen er et minimumspunkt, fordi den andrederiverte er positiv). Dvs. minstekvadratersestimatoren av  $\beta$  i modellen  $Y_i = \beta x_i + E_i$  er

$$\hat{\beta} = \frac{\sum_{i=1}^n x_i Y_i}{\sum_{i=1}^n x_i^2}$$

### Oppgave 5

Vi har:  $P(-t_{0.025,9} \leq \frac{\hat{\beta} - \beta}{\sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2}} \leq t_{0.025,9}) = 0.95$ , der  $\hat{\beta}$  som i 4d); estimat av  $\beta$ :  $472.4/436 = 1.08$ . (Merk at frihetsgradene nå er  $9 = n - 1$ ; det er bare en forventningsparameter som estimeres.)

Vi har (denne utledningen under er strengt tatt ikke nødvendig for full skåre ;-)) Resultatet under streken er. ):

$$\begin{aligned} -t_{0.025,9} &\leq \frac{\hat{\beta} - \beta}{\sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2}} \leq t_{0.025,9} \\ &\Downarrow \\ -t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} &\leq \hat{\beta} - \beta \leq t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} \\ &\Downarrow \\ -\hat{\beta} - t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} &\leq -\beta \leq -\hat{\beta} + t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} \\ &\Downarrow \\ \hat{\beta} - t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} &\leq \beta \leq \hat{\beta} + t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} \end{aligned}$$

Dette betyr at:  $P\left(\hat{\beta} - t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2} \leq \beta \leq \hat{\beta} + t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2}\right) = 0.95$ , og derfor er et 95% konfidensintervall for  $\beta$  gitt ved:

$$\left(\hat{\beta} - t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2}, \hat{\beta} + t_{0.025,9} \sqrt{S_E^2 / \sum_{i=1}^{10} x_i^2}\right)$$

Innsatt data:  $\left(1.08 - 2.262 \sqrt{0.3889^2 / 436}, 1.08 + 2.262 \sqrt{0.3889^2 / 436}\right) = (1.04, 1.12)$