

(Det tas forbehold om feil i løsningsforslaget.)

Oppgave 1

a)  $P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2) = 5/30 + 5/30 - (5/30)(5/30) = 275/900 = 0.306$   
 $P(A_1 \cap A_2) = P(A_1)P(A_2) = (5/30)(5/30) = 25/900 = 1/36$ , siden begivenhetene  $A_1$  og  $A_2$  er antatt uavhengige.

$$P(A_1 \cap \bar{A}_2) = P(A_1)(1 - P(A_2)) = (5/30)(1 - 5/30) = 5/36$$


b) To begivenheter A og B er statistisk uavhengige dersom  $P(A|B) = P(A)$ .

$$P(A_2|A_1) = \frac{P(A_2 \cap A_1)}{P(A_1)} = \frac{2/30}{5/30} = 2/5 = 0.4.$$

$$P(A_2|\bar{A}_1) = \frac{P(A_2 \cap \bar{A}_1)}{P(\bar{A}_1)} = \frac{P(A_2 \cap \bar{A}_1)}{1 - P(A_1)}.$$

Vi trenger å finne  $P(A_2 \cap \bar{A}_1)$ . Men vi har at  $P(A_2) = P(A_2 \cap \bar{A}_1) + P(A_2 \cap A_1)$  (jf. figur tilhøyre), som gir at  $P(A_2 \cap \bar{A}_1) = P(A_2) - P(A_2 \cap A_1) = 5/30 - 2/30 = 3/30 = 1/10$ .

$$\text{Derfor: } P(A_2|\bar{A}_1) = \frac{3/30}{25/30} = \frac{3}{25} = 0.12.$$




Oppgave 2

a) Til høyre under vises histogram og prikkdiagram over dataene.

Første kvartil:  $\frac{1}{2}(95 + 96) = 95$   
 Tredje kvartil:  $\frac{1}{2}(123 + 133) = 128$   
 Kvartilavvik:  $128 - 95 = 33$   
 Variasjonsbredde:  $142 - 80 = 62$   
 Median:  $\frac{1}{2}(116 + 116) = 116$

Det kan være stor forskjell mellom median og gjennomsnitt dersom dataene er usymmetrisk fordelt.



b)  $X \sim N(100, 20)$

$$\begin{aligned} P(X < 80) &= P\left(\frac{X - 100}{20} < \frac{80 - 100}{20}\right) \\ &= P(Z < -1) = 0.1587 \end{aligned}$$

(Her er  $Z \sim N(0, 1)$ .)

$$\begin{aligned} P(X > 140) &= P\left(\frac{X - 100}{20} > \frac{140 - 100}{20}\right) \\ &= P(Z > 2.0) = 1 - P(Z < 2.0) = 1 - 0.9772 = 0.0228 \end{aligned}$$

$$\begin{aligned} P(90 < X < 120) &= P(X < 120) - P(X < 90) \\ &= P(Z < 1.0) - P(Z < -0.5) = 0.8413 - 0.3085 = 0.5328 \end{aligned}$$

$$\text{Var}\left(\frac{X_1 + X_2}{2}\right) = \dots = \frac{20^2}{2} = 200$$

$$\begin{aligned} P\left(\frac{X_1 + X_2}{2} > 140\right) &= P\left(\frac{\frac{X_1 + X_2}{2} - 100}{\sqrt{200}} > \frac{140 - 100}{\sqrt{200}}\right) \\ &= P(Z > 2.83) = 1 - P(Z < 2.83) = 1 - 0.9977 = 0.0023 \end{aligned}$$

c\*) Vi antar at dataene  $x_1, \dots, x_{20}$  er utfall av  $n = 20$  u.i.f. tilfeldige variable  $X_1, \dots, X_{20}$ , normalfordelte med  $E(X_i) = \mu_X$  og  $\text{SD}(X_i) = \sigma_X$ .

Da er et 95% konfidensintervall for  $\mu_X$  gitt ved:

$$\left(\bar{X} - t_{0.025,19}\sqrt{\frac{S^2}{20}}, \quad \bar{X} + t_{0.025,19}\sqrt{\frac{S^2}{20}}\right)$$

Vi har at  $t_{0.025,19} = 2.093$ . Innsatt data blir utregnet intervall:

$$\left(113.45 - 2.093\sqrt{\frac{18.94^2}{20}}, \quad 113.45 + 2.093\sqrt{\frac{18.94^2}{20}}\right) = (104.59, \quad 122.31)$$


d) Vi vil teste:  $H_0 : \mu_X = 100$  mot  $H_1 : \mu_X > 100$

*t*-test:

Dersom  $H_0$  er korrekt er

$$\underbrace{\frac{\bar{X} - 100}{\sqrt{S^2/20}}}_{\text{teststørrelse}} \sim \underbrace{t(19)}_{\text{nullfordeling}}$$

Nullfordeling: *t*(19)-tetthet.



Med signifikansnivå 5%, dvs  $\alpha = 0.05$ , er *forkastningsområdet*  $[t_{0.05,19}, \infty)$ . Fra tabell:  $t_{0.05,19} = 1.729$

Utfall av teststørrelsen:  $\frac{113.45 - 100}{\sqrt{18.94^2/20}} = 3.18$

Siden utfallet 3.18 er i forkastningsområdet, blir konklusjonen forkast  $H_0$ . Dataene gir grunnlag for å påstå at forventet antall døgn med regn er høyere enn 100.

e) Test: forkast  $H_0$  dersom  $\frac{\bar{X} - 100}{\sqrt{20^2/20}} > z_{0.05} = 1.645$

Styrke:  $\gamma(\mu_X) = P\left(\frac{\bar{X} - 100}{\sqrt{20^2/20}} > 1.645 \mid \mu_X\right) = P\left(\frac{\bar{X} - \mu_X}{\sqrt{20^2/20}} > 1.645 + \frac{100 - \mu_X}{\sqrt{20^2/20}} \mid \mu_X\right)$   
 $= P\left(Z > 1.645 + \frac{100 - \mu_X}{\sqrt{20^2/20}}\right)$

Styrke i alternativet  $\mu_X = 110$ :

$$\gamma(110) = P\left(Z > 1.645 + \frac{100 - 110}{\sqrt{20^2/20}}\right) = P(Z > -0.59) = 1 - 0.2776 = 0.7224$$

### Oppgave 3


a\*) Toutvalgs  $t$ -test:

Anta like varianser; estimator:  $S_{\text{pooled}}^2 = \frac{(n_X - 1)S_X^2 + (n_Y - 1)S_Y^2}{n_X + n_Y - 2}$  der  
 $S_X^2 = \frac{1}{n_X - 1} \sum_{i=1}^{n_X} (X_i - \bar{X})^2$ , og  $S_Y^2 = \frac{1}{n_Y - 1} \sum_{i=1}^{n_Y} (Y_i - \bar{Y})^2$ .

Test (sign.nivå  $\alpha$ ) for:  $H_0 : \mu_X - \mu_Y = 0$  mot  $H_1 : \mu_X - \mu_Y > 0$

Forkast  $H_0$  dersom

$$\underbrace{\frac{\bar{X} - \bar{Y}}{S_{\text{pooled}} \sqrt{\frac{1}{n_X} + \frac{1}{n_Y}}}}_{\text{teststørrelse}} \geq t_{\alpha, n_X + n_Y - 2}$$



Skisse av  $t$ -tetthet

Skisse av  $t$ -fordeling og forkastningsområde.

*Nullfordeling:*  $t(n_X + n_Y - 2) = t(48)$

Med signifikansnivå 5%, dvs  $\alpha = 0.05$ , er *forkastningsområdet*  $[t_{0.05,48}, \infty)$ . Fra tabell:  $t_{0.05,48} = 1.677$

Utfall av  $S^2_{\text{pooled}}$ :  $\frac{(20 - 1)18.94^2 + (30 - 1)17.07^2}{20 + 30 - 2} = 318.04$

Utfall av teststørrelse:  $\frac{113.45 - 102.27}{\sqrt{318.04}\sqrt{\frac{1}{20} + \frac{1}{30}}} = 2.17$

Siden utfallet av teststørrelsen er i forkastningsområdet, kan vi forkaste  $H_0$ . Dvs.: det er grunnlag i dataene for å hevde at forventet antall regndager er høyere i den siste perioden.

b) Et 95% konfidensintervall for  $\mu_X - \mu_Y$  er i denne situasjonen gitt ved:

$$\left( \bar{X} - \bar{Y} - t_{0.025,48}\sqrt{S^2_{\text{pooled}}\left(\frac{1}{20} + \frac{1}{30}\right)}, \quad \bar{X} - \bar{Y} + t_{0.025,48}\sqrt{S^2_{\text{pooled}}\left(\frac{1}{20} + \frac{1}{30}\right)} \right)$$

Vi har at  $t_{0.025,48} = 2.011$ . Innsatt data blir utregnet intervall:

$$\left( 113.45 - 102.27 - 2.011\sqrt{318.04\left(\frac{1}{20} + \frac{1}{30}\right)}, \quad 113.45 - 102.27 + 2.011\sqrt{318.04\left(\frac{1}{20} + \frac{1}{30}\right)} \right) = (0.83, \quad 21.53)$$

c\*)  $Y_i = \alpha + \beta x_i + e_i, i = 1, \dots, 50$ . Her er  $e_1, \dots, e_{50}$  u.i.f. tilfeldige variable der  $e_i \sim N(0, \sigma)$ .

Estimat av  $\beta$ :  $b = \frac{s_{xy}}{s_{xx}} = \frac{4774.5}{10412.5} = 0.459$

Estimat av  $\alpha$ :  $a = \bar{y} - b\bar{x} = 106.74 - 0.459 \cdot 1984.5 = -804.1$

Fortolkning av estimert stigningstall ( $\beta$ ): forventet antall regndager øker med 0.459 for hvert år.

Prediksjon av forventet antall:

1970:  $-804.1 + 0.459 \cdot 1970 = 100.13$

2005:  $-804.1 + 0.459 \cdot 2005 = 116.2$


d)

Vi vil teste:  $H_0 : \beta = 0$  mot  $H_1 : \beta \neq 0$ .

*t*-test:

Dersom  $H_0$  er korrekt er

$$\underbrace{\frac{\hat{\beta}}{\sqrt{S^2/s_{xx}}}}_{\text{teststørrelse}} \sim \underbrace{t(48)}_{\text{nullfordeling}}$$



Skisse av *t*-tetthet

Skisse av *t*-fordeling og forkastningsområde.

Med signifikansnivå 5%, dvs  $\alpha = 0.05$ , er *forkastningsområdet*  $(-\infty, -t_{0.025,48}] \cup [t_{0.025,48}, \infty)$  (tosidig test). Fra tabell:  $t_{0.025,48} = 2.011$ .

$$\text{Utfall av teststørrelsen: } \frac{0.459}{\sqrt{303.7/10412.5}} = 2.69.$$

(Fra oppgaveteksten: Estimert av  $\text{Var}(e_i) = \sigma^2: \frac{SSE}{50-2} = \frac{14578.3}{48} = 303.7$ ).

Siden utfallet 2.69 er i forkastningsområdet, blir konklusjonen forkast  $H_0$ . Dataene gir grunnlag for å påstå at det er en trend over tid.

$$\text{e) } R^2 = \frac{SSR}{SST}, \quad SST = S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 \text{ og } SSR = SST - SSE.$$

$$R^2 = \frac{SSR}{SST} = \frac{SST - SSE}{SST} = \frac{16767.62 - 14578.3}{16767.62} = 0.1306$$

Dvs.: regresjonen forklarer (kun) ca. 13% av variasjonen.