

(Det tas forbehold om feil i løsningsforslaget.)

Oppgave 1

a) $E(X) = \sum_{x=0}^4 x \cdot P(X = x) = 0 \cdot 0.7 + 1 \cdot 0.15 + \dots + 4 \cdot 0.02 = 0.54$

$$E(X^2) = \sum_{x=0}^4 x^2 \cdot P(X = x) = 0^2 \cdot 0.7 + 1^2 \cdot 0.15 + \dots + 4^2 \cdot 0.02 = 1.24$$

$$\text{Var}(X) = E(X^2) - \{E(X)\}^2 = 1.24 - 0.54^2 = 0.9484.$$

K har fordelingen:	<table style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="border-right: 1px solid black; padding: 5px 10px;">x</th><th style="padding: 5px 10px;">0</th><th style="padding: 5px 10px;">1</th><th style="padding: 5px 10px;">2</th><th style="padding: 5px 10px;">3</th><th style="padding: 5px 10px;">4</th></tr> </thead> <tbody> <tr> <td style="border-right: 1px solid black; padding: 5px 10px;">k</td><td style="padding: 5px 10px;">0</td><td style="padding: 5px 10px;">80</td><td style="padding: 5px 10px;">90</td><td style="padding: 5px 10px;">100</td><td style="padding: 5px 10px;">110</td></tr> <tr> <td style="border-right: 1px solid black; padding: 5px 10px;">$P(K = k)$</td><td style="padding: 5px 10px;">0.7</td><td style="padding: 5px 10px;">0.15</td><td style="padding: 5px 10px;">0.08</td><td style="padding: 5px 10px;">0.05</td><td style="padding: 5px 10px;">0.02</td></tr> </tbody> </table>	x	0	1	2	3	4	k	0	80	90	100	110	$P(K = k)$	0.7	0.15	0.08	0.05	0.02
x	0	1	2	3	4														
k	0	80	90	100	110														
$P(K = k)$	0.7	0.15	0.08	0.05	0.02														

Da får vi:

$$E(K) = \sum_k k \cdot P(K = k) = 0 \cdot 0.7 + 80 \cdot 0.15 + \dots + 110 \cdot 0.02 = 26.4$$

$$E(K^2) = \sum_k k^2 \cdot P(K = k) = 0^2 \cdot 0.7 + 80^2 \cdot 0.15 + \dots + 110^2 \cdot 0.02 = 2350$$

$$\text{Var}(K) = E(K^2) - \{E(K)\}^2 = 2350 - 26.4^2 \approx 1653.$$

- b) La $Y = X_1 + X_2 + X_3 + X_4 + X_5$ være antall produkter med feil i løpet av uke med fem dager.

$$P(\text{minst ett feilprodukt en uke})$$

$$= 1 - P(\text{ingen feilprodukt en uke})$$

$$= 1 - P(\text{ingen feilprodukt dag } 1 \cap \dots \cap \text{ingen feilprodukt dag } 5)$$

$$= 1 - P(X_1 = 0 \cap X_2 = 0 \cap X_3 = 0 \cap X_4 = 0 \cap X_5 = 0)$$

$$= 1 - P(X_1 = 0)P(X_2 = 0)P(X_3 = 0)P(X_4 = 0)P(X_5 = 0) = 1 - 0.7^5 = 0.83$$

(Her er komplementsetningen benyttet og at antall feilprodukter ulike dager er antatt å være uavhengige begivenheter.)

$$P(\text{ett feilprodukt dag } 1 \text{ og ingen de andre fire dagene en uke}) = 0.15 \cdot (0.7^4) = 0.0360;$$

$$P(\text{akkurat ett feilprodukt en uke}) = 5 \cdot 0.15 \cdot (0.7^4) = 0.18.$$

- c) La K_i være kostnaden som følge av produkter med feil på dag $i = 1, 2, \dots, n = 252$. Vi har da at alle K_i 'ene er uavhengige og har samme fordeling som K i punkt a). Videre har vi at kostnaden i løpet av et helt år, som følge av produkter med feil, kan skrives $Y = K_1 + K_2 + \dots + K_n$. Da blir forventet kostnad i løpet av et helt år:

$$E(Y) = E(K_1 + K_2 + \dots + K_n) = nE(K) = 252 \cdot 26.4 = 6652.8.$$

$\text{Var}(Y) = \text{Var}(K_1 + K_2 + \dots + K_n) = n\text{Var}(K) = 252 \cdot 1653 = 416556$, og siden Y er en sum av u.i.f. tilfeldige variable, har vi at Y er tilnærmet normalfordelt; $N(6652.8, \sqrt{416556})$.

Da får vi: $P(Y < 8000) = P\left(\frac{Y - \text{E}(Y)}{\text{SD}(Y)} < \frac{8000 - 6652.8}{\sqrt{416556}}\right) \approx P(Z < 2.09) = 0.9817$, der $Z \sim N(0, 1)$.

Oppgave 2

a) $\text{E}(X) = np = 61 \cdot 0.6 = 36.6$; $\text{SD}(X) = \sqrt{np(1-p)} = \sqrt{61 \cdot 0.6 \cdot 0.4} = 3.83$.
 $P(X = 0) = \binom{61}{0} 0.4^{61} = 0.4^{61} = 5.3 \cdot 10^{-25} \approx 0$
 $P(X \geq 30) = 1 - P(X \leq 29) \approx 1 - P(Z \leq \frac{29 + 0.5 - 36.6}{3.83})$
 $= 1 - P(Z \leq -1.85) = 1 - 0.0322 = 0.9678$. (Her er $Z \sim N(0, 1)$.)

b) Vi har $\text{E}(I_j) = 0(1-p) + 1p = p$, og

$$\text{E}(X) = \text{E}(I_1 + I_2 + \dots + I_{61}) = \text{E}(I_1) + \text{E}(I_2) + \dots + \text{E}(I_{61}) = 61p = np.$$

Vi har videre at $\text{E}(I_j^2) = 0^2(1-p) + 1^2p = p$, og derfor at $\text{Var}(I_j) = p - p^2 = p(1-p)$.

I_j 'ene er uavhengige som følge av at X er antatt binomisk fordelt. Og da får vi:

$$\text{Var}(X) = \text{Var}(I_1 + I_2 + \dots + I_{61}) = \text{Var}(I_1) + \text{Var}(I_2) + \dots + \text{Var}(I_{61}) = 61p(1-p) = np(1-p).$$

c) Forventning under H_0 : $np = 61 \cdot 0.6 = 36.6$.

Test: forkast H_0 dersom $X > 41$. Signifikansnivå = $P(X > 41 | p = 0.6)$, og

$$\begin{aligned} P(X > 41 | p = 0.6) &= 1 - P(X \leq 41 | p = 0.6) \approx 1 - p(Z \leq \frac{41 + 0.5 - 36.6}{\sqrt{61 \cdot 0.6(1-0.6)}}) \\ &= 1 - P(Z \leq 1.28) = 1 - 0.8997 = 0.1003 = \text{signifikansnivået til testen.} \end{aligned}$$

Signifikansnivået er sannsynligheten for å konkludere med H_1 når i virkeligheten H_0 er riktig. Dvs.: sannsynligheten for å hevde at det har vært klimaendring i form av økt antall nedbørsdager, når det i virkeligheten ikke er noen endring.

d) Teststørrelse: $\frac{\hat{p} - 0.6}{\sqrt{0.6(1-0.6)/61}}$, Nullfordeling: tilnærmet $N(0, 1)$.

Test med signifikansnivå 5%: forkast H_0 dersom $\frac{\hat{p} - 0.6}{\sqrt{0.6(1-0.6)/61}} \geq z_{0.05} = 1.645$.

(Alternativt: forkast H_0 dersom

$$X = n\hat{p} \geq n \cdot 0.6 + z_{0.05} \sqrt{n \cdot 0.6(1-0.6)} = 61 \cdot 0.6 + 1.645 \sqrt{61 \cdot 0.6(1-0.6)} = 42.9 \approx 43.$$

)

e) Datafordelingen har betydelig mer spredning enn normalfordelingen. Det ser vi også av at dataene har estimert standardavvik på 7.94, mens det i normaltilnærmedlingsfordelingen er et standardavvik på kun 3.83.

Normalfordelingen er basert på at X er binomisk fordelt. Dette forutsetter igjen at hvorvidt det er *nedbør på ulike dager er uavhengige begivenheter* (I_j 'ene uavhengige). Dette er neppe tilfellet. Antakelig er det heller slik at dersom det er nedbør i dag, så er det høyere sannsynlighet for nedbør imorgen, enn om det ikke var nedbør i dag. Dette vil medføre at indikatorvariablene (I_j 'ene) for hvorvidt det regner ulike dager, blir *positivt korrelert*. Da får vi at $X = I_1 + I_2 + \dots + I_{61}$, vil ha større varians enn om I_j 'ene er uavhengige, som er forutsetning for at X skal være binomisk fordelt.

Siden X -data fra Bergen har en fordeling med større spredning enn det vi finner i binomisk, $B(n = 61, p = 0.6)$, fordeling, vil en test med forkastningsområde $(41, \infty)$ ha signifikansnivå større enn 0.1003 dersom den brukes på Data fra Bergen.

Oppgave 3

a)

$$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{3i} + \epsilon_i, \quad i = 1, \dots, 40$$

Designmatrisen:

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{21} & x_{31} \\ 1 & x_{12} & x_{22} & x_{32} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1n} & x_{2n} & x_{3n} \end{bmatrix} = \begin{bmatrix} 1 & 240 & 98 & 140 \\ 1 & 237 & 92 & 140 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 274 & 102 & 95 \end{bmatrix}$$

Regresjonslinje: $\hat{y} = 73.8 + 0.186x_1 - 0.221x_2 - 0.058x_3$

Estimatet av β_1 , koeffisienten foran x_1 , er 0.186. Det betyr at for hvert sekund inneværende utbrudd varer, øker tiden til neste utbrudd med 0.186 minutt.

Prediksjon: $\hat{y}_0 = 73.8 + 0.186 \cdot 240 - 0.221 \cdot 90 - 0.058 \cdot 120 = 91.5$ (minutter).

b) Test for koeffisient til hver av x -variablene:

$j = 1$: $H_0 : \beta_1 = 0$ mot $H_1 : \beta_1 \neq 0$; p -verdi = 0.000; dvs. forkast H_0 .

$j = 2$: $H_0 : \beta_2 = 0$ mot $H_1 : \beta_2 \neq 0$; p -verdi = 0.065; dvs. behold H_0 .

$j = 3$: $H_0 : \beta_3 = 0$ mot $H_1 : \beta_3 \neq 0$; p -verdi = 0.491; dvs. behold H_0 .

Forutsetter at Y_i 'ene er uavhengige og normalfordelte med konstant varians. (Alt.: ϵ_i 'ene er uif. $\mathcal{N}(0, \sigma^2)$.)

c)

$$\begin{aligned} \text{Var}(\hat{\beta}_0 + \hat{\beta}_1 x_{10} - Y_0) &= \text{Var}(\bar{Y} + (x_{10} - \bar{x})\hat{\beta}_1 - Y_0) \\ &= \text{Var}(\bar{Y}) + \text{Var}\{(x_{10} - \bar{x})\hat{\beta}_1\} + \text{Var}(Y_0) \end{aligned}$$

$$\begin{aligned}
 &= \text{Var}(\bar{Y}) + (x_{10} - \bar{x})^2 \text{Var}(\hat{\beta}_1) + \text{Var}(Y_0) \\
 &= \frac{\sigma^2}{n} + (x_{10} - \bar{x})^2 \text{Var}(\hat{\beta}_1) + \sigma^2
 \end{aligned}$$

Videre har vi:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_{1i} - \bar{x}) Y_i}{S_{xx}}$$

og da:

$$\begin{aligned}
 \text{Var}(\hat{\beta}_1) &= \text{Var} \left\{ \frac{\sum_{i=1}^n (x_{1i} - \bar{x}) Y_i}{S_{xx}} \right\} = \left(\frac{1}{S_{xx}} \right)^2 \sum_{i=1}^n (x_{1i} - \bar{x})^2 \underbrace{\text{Var}(Y_i)}_{\sigma^2} \\
 &= \left(\frac{1}{S_{xx}} \right)^2 S_{xx} \sigma^2 = \frac{\sigma^2}{S_{xx}}
 \end{aligned}$$

Da har vi:

$$\begin{aligned}
 \text{Var}(\hat{\beta}_0 + \hat{\beta}_1 x_{10} - Y_0) &= \frac{\sigma^2}{n} + (x_{10} - \bar{x})^2 \text{Var}(\hat{\beta}_1) + \sigma^2 \\
 &= \frac{\sigma^2}{n} + (x_{10} - \bar{x})^2 \frac{\sigma^2}{S_{xx}} + \sigma^2 \\
 &= \sigma^2 \left\{ 1 + \frac{1}{n} + \frac{(x_{10} - \bar{x})^2}{S_{xx}} \right\}
 \end{aligned}$$

d) Vi har:

$$\frac{\hat{\beta}_0 + \hat{\beta}_1 x_{10} - Y_0}{\sqrt{S^2 \left\{ 1 + \frac{1}{n} + \frac{(x_{10} - \bar{x})^2}{S_{xx}} \right\}}} \sim t(n-2)$$

$$S^2 = \hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \{Y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{1i})\}^2.$$

Fra dette kan vi utlede:

$$P\left(\hat{\beta}_0 + \hat{\beta}_1 x_{10} - t_{0.025,38} \sqrt{S^2 \left\{ 1 + \frac{1}{n} + \frac{(x_{10} - \bar{x})^2}{S_{xx}} \right\}} \leq Y_0 \leq \hat{\beta}_0 + \hat{\beta}_1 x_{10} + t_{0.025,38} \sqrt{S^2 \left\{ 1 + \frac{1}{n} + \frac{(x_{10} - \bar{x})^2}{S_{xx}} \right\}}\right) = 0.95$$

som gir prediksjonsintervallet:

$$\left(\hat{\beta}_0 + \hat{\beta}_1 x_{10} - t_{0.025,38} \sqrt{S^2 \left\{ 1 + \frac{1}{n} + \frac{(x_{10} - \bar{x})^2}{S_{xx}} \right\}}, \hat{\beta}_0 + \hat{\beta}_1 x_{10} + t_{0.025,38} \sqrt{S^2 \left\{ 1 + \frac{1}{n} + \frac{(x_{10} - \bar{x})^2}{S_{xx}} \right\}} \right)$$

Insatt data: (76.17, 104.88)