

Løsning eksamen 14. mai 2019

Oppgave 1

a)

$$\begin{aligned} E(X) &= \sum_x xP(X=x) = 0 \cdot 0.05 + 1 \cdot 0.15 + 2 \cdot 0.20 + 3 \cdot 0.25 + 4 \cdot 0.35 = \underline{2.7} \\ E(X^2) &= \sum_x x^2P(X=x) = 0^2 \cdot 0.05 + 1^2 \cdot 0.15 + 2^2 \cdot 0.20 + 3^2 \cdot 0.25 + 4^2 \cdot 0.35 = 8.8 \\ \Rightarrow \text{Var}(X) &= E(X^2) - E(X)^2 = 8.8 - 2.7^2 = \underline{1.51} \\ Y &= 750X - 1150 \\ E(Y) &= E(750X - 1150) = 750E(X) - 1150 = 750 \cdot 2.7 - 1150 = \underline{875} \\ \text{Var}(Y) &= \text{Var}(750X - 1150) = 750^2 \text{Var}(X) = 750^2 \cdot 1.51 = \underline{849375} \end{aligned}$$

b)

$$\begin{aligned} E(W) &= E(Y_1) + E(Y_2) + \dots + E(Y_{300}) = 300 \cdot 875 = \underline{262500} \\ \text{Var}(W) &\stackrel{\text{uavh.}}{=} \text{Var}(Y_1) + \text{Var}(Y_2) + \dots + \text{Var}(Y_{300}) = 300 \cdot 849375 = 254812500 \\ \text{SD}(W) &= \sqrt{\text{Var}(W)} = \sqrt{254812500} = \underline{15962.85} \end{aligned}$$

$E(W)$ er forventet årlig fortjeneste.

SGT gir at en sum av mange uavhengige variable er tilnærmet normalfordelt

$$\Rightarrow W = Y_1 + \dots + Y_{300} \approx N(E(W), \text{SD}(W)) = N(262500, 15962.85)$$

$$\begin{aligned} P(W > 250000) &= 1 - P(W \leq 250000) \approx 1 - P\left(Z \leq \frac{250000 - 262500}{15962.85}\right) \\ &= 1 - P(Z \leq -0.78) = 1 - 0.2177 = \underline{0.78} \end{aligned}$$

Oppgave 2

a)

$$\begin{aligned} P(X < 0.15) &= P\left(\frac{X - 0.18}{0.02} < \frac{0.15 - 0.18}{0.02}\right) = P(Z < -1.50) = \underline{0.0668} \\ P(0.15 < X < 0.20) &= P(X < 0.20) - P(X < 0.15) \\ &= P\left(\frac{X - 0.18}{0.02} < \frac{0.20 - 0.18}{0.02}\right) - P\left(\frac{X - 0.18}{0.02} < \frac{0.15 - 0.18}{0.02}\right) \\ &= P(Z < 1.00) - P(Z < -1.50) = 0.8413 - 0.0668 = \underline{0.7745} \\ P(X < k) &= P\left(Z < \frac{k - 0.18}{0.02}\right) = 0.99 \Rightarrow \frac{k - 0.18}{0.02} = 2.33 \\ k &= 2.33 \cdot 0.02 + 0.18 = \underline{0.2266} \end{aligned}$$

Husk at $E(\bar{X}) = \mu$ og $\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$.

$$\begin{aligned} P(\bar{X} < 0.15) &= P\left(\frac{\bar{X} - E(\bar{X})}{\sqrt{\text{Var}(\bar{X})}} < \frac{0.15 - E(\bar{X})}{\sqrt{\text{Var}(\bar{X})}}\right) = P\left(Z < \frac{0.15 - 0.18}{\sqrt{\frac{0.02^2}{5}}}\right) \\ &= P(Z < -3.35) = \underline{0.0004} \end{aligned}$$

Sannsynligheten for at gjennomsnittet av 5 uavhengige målinger er mindre enn 0.15 er bare 0.004, og dette er mye mindre enn sannsynligheten for at en tilfeldig måling er mindre enn 0.15 som fra første spørsmål er 0.0668. Et gjennomsnitt har mindre varians enn enkeltmålinger og det er derfor mindre sannsynlig for at et gjennomsnitt skal falle så langt fra forventningsverdien enn at en enkeltmåling skal gjøre det.

b) $(1 - \alpha)100\%$ konfidensintervall for μ når σ kjent er gitt ved: $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$.

Med $\alpha = 0.01$ blir $z_{\alpha/2} = z_{0.005} = 2.575$, og med $\bar{x} = 0.142$, $n = 12$ og $\sigma = 0.02$ blir 99% konfidensintervallet:

$$[0.142 - 2.575 \frac{0.02}{\sqrt{12}}, 0.142 + 2.575 \frac{0.02}{\sqrt{12}}] = \underline{\underline{[0.127, 0.157]}}$$

Lengden til konfidensintervallet er:

$$\begin{aligned} L &= \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} - (\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 2z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \\ \text{Dvs: } L \leq 0.01 &\Rightarrow 2z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq 0.01 \Rightarrow 200z_{\alpha/2}\sigma \leq \sqrt{n} \\ n &\geq (200z_{\alpha/2}\sigma)^2 = (200 \cdot 2.575 \cdot 0.02)^2 = 10.3^2 = 106.09 \end{aligned}$$

Dvs det må gjøres minst 107 målinger for å få et konfidensintervall med ønsket lengde.

c) $H_0 : \mu \geq 0.15$ mot $H_1 : \mu < 0.15$

Situasjonen her er normalfordeling med ukjent μ og kjent σ . Dersom H_0 er korrekt er da

$$Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0, 1)$$

Med signifikansnivå 5%, dvs $\alpha = 0.05$, forkaster vi H_0 dersom $Z \leq -z_{0.05} = -1.645$.

Observert: $z = \frac{0.142 - 0.15}{0.02/\sqrt{12}} = -1.39$

Siden $-1.39 > -1.645$ blir konklusjonen at vi ikke forkaster H_0 . Dataene gir ikke grunnlag for å konkludere, på 5% nivå, at forventet mengde fosfor er mindre enn 0.15.

p -verdien blir her (siden vi har ensidig test av type "mindre enn"):

$$p\text{-verdi} = P(Z \leq z_{obs}) = P(Z < -1.39) = \underline{\underline{0.0823}}$$

Dvs vi forkaster ikke testen på 5% nivå.

d) Styrkefunksjonen gir oss sannsynligheten for å forkaste H_0 for ulike verdier av μ .

For beregning av styrke så bruker vi formelen på formelarket (eller side 29/33 i notatene om hypotesetesting, eller regel 6.16 i boka). Merk at vi har en test av typen hvor $H_1 : \mu < \mu_0$, og vi skal da bruke $\gamma(\mu) = P(Z \leq -z_{\alpha} + \frac{\mu_0 - \mu}{\sigma/\sqrt{n}})$. Med $\sigma = 0.02$, $n = 12$, $z_{\alpha} = z_{0.05} = 1.645$ og $\mu_0 = 0.15$ blir beregningen:

$$\begin{aligned} \gamma(0.14) &= P(Z \leq -1.645 + \frac{0.15 - 0.14}{0.02/\sqrt{12}}) = P(Z \leq 0.09) = \underline{\underline{0.54}} \\ \gamma(0.13) &= P(Z \leq -1.645 + \frac{0.15 - 0.13}{0.02/\sqrt{12}}) = P(Z \leq 1.82) = \underline{\underline{0.966}} \end{aligned}$$

En styrke på 95% betyr at $1 - \beta = 0.95$ eller $\beta = 0.05$ (der $\beta = P(\text{type II feil})$). Da er $z_{\beta} = z_{0.05} = 1.645$. Formelen på formelarket/forelesningsnotatene gir oss da at nødvendig utvalgsstørrelser blir

$$n = \frac{(z_{\beta} + z_{\alpha})^2 \sigma^2}{(\mu_0 - \mu)^2} = \frac{(z_{0.05} + z_{0.05})^2 \sigma^2}{(0.15 - 0.14)^2} = \frac{(1.645 + 1.645)^2 0.02^2}{(0.15 - 0.14)^2} = 43.3$$

Dvs de må gjøres minst 44 målinger for å få styrke på minst 0.95 (som er det samme som en sannsynlighet for type II feil på maks 0.05).

Oppgave 3:

a) Estimert regresjonsline: $\hat{y} = \hat{\alpha} + \hat{\beta}x = \underline{66.5 - 0.34 \cdot x}$.
År 2020 tilsvarer $x = 50$ og gir $\hat{y} = 66.5 - 0.34 \cdot 50 = \underline{49.5}$.

Fra det første residualplottet kan man sjekke om antagelsen om lineære sammenheng mellom x og forventningen til Y holder, og om antagelsen om lik varians i Y for alle x -verdier holder. Videre kan vi i denne spesielle situasjonen fra dette plottet også sjekket om det er avhengigheter over tid siden vi faktisk har innsamlingsrekkefølgen som x -variabel. Alle disse antagelsene ser ut til å være oppfylte siden vi ikke har noe bestemt mønster i residualene. Det andre residualplottet er en sjekk av om antagelsen om normalfordelt feilledd er oppfylt, og det ser også ok ut siden punktene her faller greit på den rette linjen. Dvs, antagelsene for regresjonsmodellen ser ut for å være oppfylte.

Dersom $\beta \neq 0$ i regresjonsmodellen betyr det at forventet lengde på issesongen har endret seg over tid, dvs vi skal teste:

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

Vi leser p -verdien for testen rett ut fra datautskriften. Vi ser at p -verdien $= 0.0097 < 0.05$ dvs vi forkaster H_0 og konkluderer med at forventet lengde på issesongen har endret seg over perioden vi har data fra. Siden den estimerte verdien på β er negativ kan vi konkludere at forventet lengde på issesongen er redusert.

Estimert forventet lengde på issesongen i 1971: $\hat{y} = 66.5 - 0.34 \cdot 1 = 66.16$. Estimert forventet lengde på issesongen i 2019: $\hat{y} = 66.5 - 0.34 \cdot 49 = 49.84$. Estimert endring: $66.16 - 49.84 = 16.32$, dvs en reduksjon på 16.3 dager i forventet lengde på issesongen.

Oppgave 4:

Siden vi har for eksponentialfordeling at $E(T) = 1/\lambda$ får vi her at $1/\lambda = 2.5$ dvs $\lambda = 0.4$

a) Vi kan finne sannsynligheten enten ved å integrere sannsynlighetstettheten, eller, litt enklere, ved å bruke den kumulative fordelingsfunksjonen: $P(T < t) = F(t) = 1 - e^{-\lambda t} = 1 - e^{-0.4t}$. Vi får da:

$$\begin{aligned} P(T < 1) &= F(1) = 1 - e^{-0.4 \cdot 1} = \underline{0.33} \\ P(1 < T < 2) &= P(T < 2) - P(T < 1) = F(2) - F(1) \\ &= 1 - e^{-0.4 \cdot 2} - (1 - e^{-0.4 \cdot 1}) = \underline{0.22} \\ P(T < t_{0.5}) &= F(t_{0.5}) = 1 - e^{-0.4 \cdot t_{0.5}} = 0.5 \\ 0.5 &= e^{-0.4 \cdot t_{0.5}} \Rightarrow t_{0.5} = \ln(0.5)/(-0.4) = \underline{1.73} \end{aligned}$$

b) Vi har en situasjon karakterisert ved:

- Flere enkeltforsøk som hvert resulterer i "suksess" eller ikke "suksess" - flere lysrør som feiler innen ett år eller ikke.
- Sannsynligheten for "suksess" er den samme i alle enkeltforsøk, p - samme sannsynlighet $p = 0.33$ for feil for hvert lysrør.
- Enkeltforsøkene er uavhengige - uavhengig fra rør til rør om de har feil.
- Et bestemt antall, n enkeltforsøk - et bestemt antall lysrør n som installeres.

Dermed er $X =$ "antall lysrør som feiler innen ett år" binomisk fordelt med parametre n og $p = 0.33$.

Med $X \sim \text{Bin}(10, 0.33)$ får vi:

$$\begin{aligned} P(X > 3) &= 1 - P(X \leq 3) = 1 - (P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3)) \\ &= 1 - \left(\binom{10}{0}(0.33)^0(1 - 0.33)^{10-0} + \binom{10}{1}(0.33)^1(1 - 0.33)^{10-1} \right. \\ &\quad \left. + \binom{10}{2}(0.33)^2(1 - 0.33)^{10-2} + \binom{10}{3}(0.33)^3(1 - 0.33)^{10-3} \right) \\ &= 1 - (0.0182 + 0.0898 + 0.1990 + 0.2614) = \underline{0.43} \end{aligned}$$

Siden $np(1 - p) = 100 \cdot 0.33 \cdot (1 - 0.33) = 22.1 > 5$ kan vi bruke tilnærming til normalfordeling:

$$\begin{aligned} P(X > 30) &= 1 - P(X \leq 30) \approx 1 - P\left(Z \leq \frac{30 + 0.5 - E(X)}{\sqrt{\text{Var}(X)}}\right) = 1 - P\left(Z \leq \frac{30 + 0.5 - np}{\sqrt{np(1 - p)}}\right) \\ &= 1 - P\left(Z \leq \frac{30 + 0.5 - 100 \cdot 0.33}{\sqrt{100 \cdot 0.33 \cdot 0.67}}\right) = 1 - P(Z \leq -0.53) = 1 - 0.2981 = \underline{0.70} \end{aligned}$$

(Om man utelater heltallskorleksjonen $+0.5$, får man enten svaret 0.74 dersom man starter ut som over, eller svaret 0.67 dersom man starter ut med $P(X > 30) = P(X \geq 31) = 1 - P(X < 31)$).

c)

$$\begin{aligned} E(\hat{\beta}) &= E\left(\frac{1}{n} \sum_{i=1}^n T_i\right) = \frac{1}{n} \sum_{i=1}^n E(T_i) = \frac{1}{n} \sum_{i=1}^n \beta = \frac{1}{n} n\beta = \underline{\underline{\beta}} \\ \text{Var}(\hat{\beta}) &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n T_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(T_i) = \frac{1}{n^2} \sum_{i=1}^n \beta^2 = \frac{1}{n^2} n\beta^2 = \underline{\underline{\frac{\beta^2}{n}}} \end{aligned}$$

Siden estimatoren $\hat{\beta} = \bar{T}$ er et gjennomsnitt av mer enn 30 uavhengige stokastiske variabler fra samme fordeling følger det fra sentralgrenseteoremet at estimatoren er tilnærmet normalfordelt. Vi har dermed at

$$P(-z_{\alpha/2} < \frac{\hat{\beta} - \beta}{\sqrt{\beta^2/n}} < z_{\alpha/2}) \approx P(-z_{\alpha/2} < \frac{\hat{\beta} - \beta}{\sqrt{\hat{\beta}^2/n}} < z_{\alpha/2}) = 1 - \alpha$$

som gir konfidensintervallet:

$$[\hat{\beta} - z_{\alpha/2} \sqrt{\hat{\beta}^2/n}, \hat{\beta} + z_{\alpha/2} \sqrt{\hat{\beta}^2/n}]$$

For et 95% intervall setter vi $\alpha = 0.05$ som gir $z_{\alpha/2} = z_{0.025} = 1.96$. Innsatt observerte data får vi:

$$[2.38 - 1.96 \cdot \sqrt{2.38^2/50}, 2.38 + 1.96 \cdot \sqrt{2.38^2/50}] = \underline{\underline{[1.7, 3.0]}}$$