

Lösningsförslag till valda uppgifter i
SANNOLIKHETSTEORI och STATISTIKTEORI med TILLÄMPNINGAR
av Blom, Enger, Englund, Grandell & Holst.

Version 28 februari 2005

Fel i lösningarna mottas tacksamt till mattsson@math.kth.se.

Notera att lösningarna på vissa ställen utnyttjar andra, mer fullständiga, tabeller än vad som normalt är tillgängliga för studenterna. Därför kan t.ex. kvantiler i normalfördelningen och $t(n)$ -fördelningar i lösningarna vara bestämda med mycket god noggrannhet.

11.1 Definitionen är att en skattning θ_{obs}^* är väntevärdevärdesriktig skattning av en parameter θ om $E(\theta^*) = \theta$.

1. Nej, skattningen $\theta_{\text{obs}}^* = \theta^*(x_1, \dots, x_n)$ kan vara vilken funktion av x_1, \dots, x_n som helst, inte nödvändigtvis ett medelvärde.
2. Nej, inte heller ett viktat medelvärde. Tag som exempel skattningen s^2 av variansen för en stokastisk variabel.
3. Ja, en tolkning av väntvärdet $E(\theta^*)$ är att det är det genomsnittliga värdet av ett stort antal försök. (Stora talens lag säger att medelvärdet konvergerar mot väntvärdet.)
4. Nej, av flera skäl. Ett — det finns ingenting i väntevärdesriktigheten som säger att det är ett väntevärde som skattas. Två — skattningen θ_{obs}^* är ett utfall av en stokastisk variabel och ger olika skattningar i olika försök.
5. Nej, skattningen θ_{obs}^* är ett utfall av en stokastisk variabel och ger olika skattningar i olika försök.
6. Ja, detta är definitionen av väntevärdesriktighet.

11.2 Låt x_1, \dots, x_n vara batteriernas uppmätta livslängder. Vi modellerar dessa som utfall av oberoende och likafördelade stokastiska variabler X_1, \dots, X_n , med $\mu = E(X_i)$ och $\sigma^2 = V(X_i)$.

Väntevärdet μ skattas med

$$\mu_{\text{obs}}^* = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 5.2$$

och variansen σ^2 med

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left(\left(\sum_{i=1}^n x_i^2 \right) - n\bar{x}^2 \right) = 1.7,$$

det vill säga, standardavvikelsen σ skattas med $s = \sqrt{1.7} = 1.3038$.

Skattningen $\mu_{\text{obs}}^* = \bar{x}$ är ett utfall av stickprovsvariabeln

$$\mu^* = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

som har väntevärde

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \mu,$$

vilket visar att skattningen μ_{obs}^* är väntevärdesriktig, och varians

$$V(\bar{X}) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \{\text{oberoende}\} = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{\sigma^2}{n},$$

det vill säga $D(\bar{X}) = \sigma/\sqrt{n}$. Standardavvikelsen $D(\bar{X}) = \sigma/\sqrt{n}$ skattas med $s/\sqrt{n} = 0.5831$ och kallas för medelflelet för \bar{x} .

11.3 Låt X beskriva uppmätt halt av ämnet. Modell:

$$X = \text{halt} + \text{mätfel} = \mu + \epsilon$$

där ϵ är en stokastisk variabel med $E(\epsilon) = 0$ och $D(\epsilon) = \sigma^2 = 0.5$. Då är

$$E(X) = E(\mu + \epsilon) = \mu + E(\epsilon) = \mu$$

och $V(X) = V(\mu + \epsilon) = V(\epsilon) = \sigma^2$. Skatningen \bar{x} av μ beskrivs av stickprovsvariabeln

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

som har

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} n\mu = \mu,$$

det vill säga \bar{x} är en väntevärdesriktig skatning av μ , och

$$V(\bar{X}) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \{\text{oberoende}\} = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \underbrace{\frac{\sigma^2}{n}}_{=\sigma^2}.$$

Om n är stor så är $\sum_{i=1}^n X_i$ approximativt normalfördelad, det vill säga,

$$\bar{X} \text{ är approximativt } N\left(\mu, \frac{\sigma}{\sqrt{n}}\right).$$

Alltså är

$$\begin{aligned} P(|\bar{X} - \mu| \leq 0.25) &= P(-0.25 \leq \bar{X} - \mu \leq 0.25) = P\left(\frac{-0.25}{\sigma/\sqrt{n}} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \frac{0.25}{\sigma/\sqrt{n}}\right) \\ &\approx \Phi(0.5\sqrt{n}) - \Phi(-0.5\sqrt{n}) = 2\Phi(0.5\sqrt{n}) - 1 = 0.99. \end{aligned}$$

Alltså är $1 - \Phi(0.5\sqrt{n}) = 0.005$ men $1 - \Phi(\lambda_{0.005}) = 0.005$ där $\lambda_{0.005} = 2.5758$, vilket ger

$$0.50\sqrt{n} = \lambda_{0.005} \quad \text{eller} \quad n = \left(\frac{\lambda_{0.005}}{0.50}\right)^2 = 26.54,$$

alltså välj $n \geq 27$.

Om man inte kan förutsätta normalfördelning ger Tjebychovs olikhet en övre gräns för vad n behöver vara.

$$0.01 = P(|\bar{X} - \mu| > 0.25) \leq \frac{V(\bar{X})}{0.25^2} = \frac{\sigma^2/n}{0.25^2}$$

Vilket ger

$$n \leq \frac{\sigma^2}{0.25^2 \cdot 0.01} = 400,$$

det vill säga oavsett fördelning behöver inte mer än 400 mätningar göras.

Det är viktigt att se skillnaden på μ , parametern i fördelningen, \bar{x} , skatningen av parameterns värde, och \bar{X} , den stokastiska variabel som beskriver skatningen.

11.4

11.5 Låt X_1 och X_2 vara oberoende och binomialfördelade, X_i är $\text{Bin}(1, p)$, $i = 1, 2$, med observerade värden x_1 respektive x_2 . Då är $E(X_i) = p$ och $V(X_i) = p(1-p)$.

Låt

$$p_{\text{obs}}^* = x_1 \quad \text{och} \quad \hat{p}_{\text{obs}} = \frac{x_1 + x_2}{2}.$$

Dessa skattningar modelleras av

$$p^* = X_1 \quad \text{och} \quad \hat{p} = \frac{X_1 + X_2}{2}.$$

Möjliga värden på X_i är $\{0, 1\}$ så möjliga värden på p^* ges av $\{0, 1\}$ medan för \hat{p} är det $\{0, 1/2, 1\}$.

b) Vi har att

$$E(p^*) = E(X_1) = p \quad E(\hat{p}) = E\left(\frac{X_1 + X_2}{2}\right) = \frac{1}{2}E(X_1) + \frac{1}{2}E(X_2) = \frac{p}{2} + \frac{p}{2} = p$$

så båda skattningarna p_{obs}^* och \hat{p}_{obs} är väntevärdesriktiga.

c) Vidare så är, eftersom X_1 och X_2 är oberoende,

$$V(p^*) = V(X_1) = p(1-p) \quad V(\hat{p}) = V\left(\frac{X_1 + X_2}{2}\right) = \frac{1}{4}V(X_1) + \frac{1}{4}V(X_2) = \frac{p(1-p)}{2}.$$

Eftersom $V(\hat{p}) < V(p^*)$ för alla $p \in (0, 1)$ är skattningen \hat{p}_{obs} effektivare än skattningen p_{obs}^* .

11.6 Låt x_1, \dots, x_n vara utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n . Väntevärdet μ skattas dels med

$$\mu_{\text{obs}}^* = \bar{x} \quad \text{och dels med} \quad \hat{\mu}_{\text{obs}} = \frac{x_1 + x_2}{2}.$$

a) Båda dessa skattningar är väntevärdesriktiga eftersom

$$E(\mu^*) = E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} n\mu = \mu$$

och

$$E(\hat{\mu}) = E\left(\frac{1}{2}(X_1 + X_n)\right) = \frac{1}{2}E(X_1) + \frac{1}{2}E(X_n) = \frac{\mu}{2} + \frac{\mu}{2} = \mu.$$

b) Eftersom X_1, \dots, X_n är oberoende så är

$$V(\mu^*) = V(\bar{X}) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{1}{n^2} n\sigma^2 = \frac{\sigma^2}{n}$$

och

$$V(\hat{\mu}) = V\left(\frac{1}{2}(X_1 + X_n)\right) = \frac{1}{4}V(X_1) + \frac{1}{4}V(X_n) = \frac{\sigma^2}{2}.$$

Om $n > 2$ är $V(\mu^*) < V(\hat{\mu})$ och skattningen μ_{obs}^* är effektivare än skattningen $\hat{\mu}_{\text{obs}}$. Notera även att $V(\mu^*) \rightarrow 0$ då $n \rightarrow \infty$ medan $V(\hat{\mu})$ är konstant, så skattningen μ_{obs}^* är en konsistent skattning av μ men $\hat{\mu}$ är det inte.

11.7 Den stokastiska variabeln X är binomialfördelad, X är $\text{Bin}(n, p)$ och Y är hypergeometriskt fördelad, Y är $\text{Hyp}(N, n, p)$. Låt $p^* = X/n$ och $\hat{p} = Y/n$.

a) Då är

$$E(p^*) = E\left(\frac{X}{n}\right) = \frac{1}{n}E(X) = \frac{1}{n}np = p$$

och

$$V(p^*) = V\left(\frac{1}{n}X\right) = \frac{1}{n^2}V(X) = \frac{1}{n^2}np(1-p) = \frac{p(1-p)}{n}.$$

Vidare så är

$$E(\hat{p}) = E\left(\frac{Y}{n}\right) = \frac{1}{n}E(Y) = \frac{1}{n}np = p$$

och

$$\begin{aligned} V(\hat{p}) &= V\left(\frac{1}{n}Y\right) = \frac{1}{n^2}V(Y) = \frac{1}{n^2}np(1-p)\frac{N-n}{N-1} = \frac{p(1-p)}{n} \cdot \frac{N-n}{N-1} = V(p^*) \underbrace{\frac{N-n}{N-1}}_{\leq 1} \\ &\leq V(p^*), \end{aligned}$$

med likhet endast om $n = 1$.

b) För $n > 1$ är $V(\hat{p}) < V(p^*)$ och skattningen \hat{p}_{obs} är effektivare än skattningen p_{obs}^* .

c) Med observationer erhålls skattningarna $p_{\text{obs}}^* = \hat{p}_{\text{obs}} = 23/100 = 0.23$ av andelen.

Stickprovsvariablernas varianser skattas med hjälp av skattningarna av p . Det vill säga,

$$V(p^*) = \frac{p(1-p)}{n} \text{ skattas med } \frac{0.23 \cdot (1 - 0.23)}{100} = 0.001771$$

och

$$V(\hat{p}) = \frac{p(1-p)}{n} \frac{N-n}{N-1} \text{ skattas med } \frac{0.23 \cdot (1 - 0.23)}{100} \frac{1000 - 100}{1000 - 1} = 0.00160.$$

Detta medför att standardavvikelserna $D(p^*)$ och $D(\hat{p})$ skattas med 0.0421 respektive 0.0399. Dessa skattningar kallas för medelfelen för p_{obs}^* respektive \hat{p}_{obs} .

11.8 Att θ_{obs}^* och $\hat{\theta}_{\text{obs}}$ är väntevärdesriktiga skattningar av en parameter θ betyder att motsvarande stickprovsvariabler uppfyller $E(\theta^*) = \theta$ och $E(\hat{\theta}) = \theta$. Med skattningen

$$\tilde{\theta}_{\text{obs}} = a\theta_{\text{obs}}^* + (1-a)\hat{\theta}_{\text{obs}}$$

så är

$$E(\tilde{\theta}) = E(a\theta^* + (1-a)\hat{\theta}) = a\underbrace{E(\theta^*)}_{=\theta} + (1-a)\underbrace{E(\hat{\theta})}_{=\theta} = \theta$$

för alla värden a , så $\tilde{\theta}_{\text{obs}}$ är en väntevärdesriktig skattning av θ oavsett värdet på a . Vidare så är

$$\begin{aligned} V(\tilde{\theta}) &= V(a\theta^* + (1-a)\hat{\theta}) = \{\text{oberoende}\} = a^2\underbrace{V(\theta^*)}_{=\sigma_1^2} + (1-a)^2\underbrace{V(\hat{\theta})}_{=\sigma_2^2} \\ &= a^2\sigma_1^2 + (1-a)^2\sigma_2^2 = g(a), \end{aligned}$$

en funktion av a . Den effektivaste skattningen erhålls om a väljs så att variansen $g(a)$ minimeras. Detta a bestäms som lösningen till

$$0 = \frac{d}{da}g(a) = \sigma_1^2 \cdot 2a + \sigma_2^2 \cdot 2(1-a)(-1) = 2[a(\sigma_1^2 + \sigma_2^2) - \sigma_2^2],$$

där lösningen är

$$a = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}.$$

Teckenstudium av andraderivatan visar att det är ett minimum som vi fått fram. Alltså, den effektivaste skattningen fås om

$$\tilde{\theta}_{\text{obs}} = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}\theta_{\text{obs}}^* + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\hat{\theta}_{\text{obs}}.$$

11.9 Låt x_1, \dots, x_n vara utfallen av de stokastiska variablerna X_1, \dots, X_n som antas vara oberoende och $N(\mu, \sigma^2)$ -fördelade.

a) Om μ är känd så kan variansen σ^2 skattas med $(\hat{\sigma}^2)_{\text{obs}}$ där

$$(\hat{\sigma}^2)_{\text{obs}} = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$

Denna skattning är väntevärdesriktig eftersom

$$E(\hat{\sigma}^2) = E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2\right) = \frac{1}{n} \sum_{i=1}^n \underbrace{E((X_i - \mu)^2)}_{=\sigma^2} = \frac{1}{n} n\sigma^2 = \sigma^2.$$

Med de $n = 4$ observationerna x_1, \dots, x_4 och $\mu = 1457.0$ så är

$$(\hat{\sigma}^2)_{\text{obs}} = \frac{1}{n} \sum_{i=1}^n (x_i - 1457.0)^2 = 0.8175.$$

b) Om μ är okänd måste väntevärdet skattas. En väntevärdesriktig skattning av σ^2 är s^2 där

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2.$$

vilket, då μ skattas med $\bar{x} = 1457.4$, ger skattningen $s^2 = 0.84917$.

Att s^2 är väntevärdesriktig ges av följande uträkning.

$$\begin{aligned} E(S^2) &= E\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2\right) = E\left(\frac{1}{n-1} \sum_{i=1}^n X_i^2 - 2\bar{X}X_i + \bar{X}^2\right) \\ &= E\left(\frac{1}{n-1} \left(\left(\sum_{i=1}^n X_i^2\right) - 2\bar{X} \left(\sum_{i=1}^n X_i\right) + n\bar{X}^2 \right)\right) \\ &= E\left(\frac{1}{n-1} \left(\left(\sum_{i=1}^n X_i^2\right) - 2\bar{X}n\bar{X} + n\bar{X}^2 \right)\right) = E\left(\frac{1}{n-1} \left(\left(\sum_{i=1}^n X_i^2\right) - n\bar{X}^2 \right)\right) \\ &= \frac{1}{n-1} \left(\left(\sum_{i=1}^n E(X_i^2)\right) - nE(\bar{X}^2) \right) = \frac{1}{n-1} \left(\left(\sum_{i=1}^n \mu^2 + \sigma^2\right) - n(\mu^2 + \frac{\sigma^2}{n}) \right) \\ &= \frac{1}{n-1} (n\mu^2 + n\sigma^2 - n\mu^2 - \sigma^2) = \frac{1}{n-1} (n-1)\sigma^2 = \sigma^2. \end{aligned}$$

c) Nej, av uträkningarna ovan framgår att endast $E(X_i)$ och $V(X_i)$ har utnyttjats.

11.10 Den stokastiska variabeln X har sannolikhetsfunktion $p_X(k) = (1-\theta)^{k-1}\theta$ för $k = 1, 2, 3, \dots$ där $0 < \theta < 1$. Låt x_1, \dots, x_n vara ett stickprov av X .

a) Då observationerna är utfall av oberoende stokastiska variabler blir Likelihoodfunktionen

$$\begin{aligned} L(\theta) &= p_{X_1, \dots, X_n}(x_1, \dots, x_n) = p_{X_1}(x_1) \cdots p_{X_n}(x_n) = (1-\theta)^{x_1-1}\theta \cdots (1-\theta)^{x_n-1}\theta \\ &= \theta^n (1-\theta)^{\sum_{i=1}^n x_i - n}. \end{aligned}$$

b) Vi söker det värde på θ som maximerar $L(\theta)$. Det är samma värde som maximerar den logaritmerade likelihoodfunktionen

$$\ln(L(\theta)) = n \ln(\theta) + \ln(1-\theta) \left(\sum_{i=1}^n x_i - n \right).$$

Detta maximum bestäms som lösningen till

$$\begin{aligned} 0 &= \frac{d}{d\theta} \ln(L(\theta)) = \frac{d}{d\theta} \left[n \ln(\theta) + \ln(1-\theta) \left(\sum_{i=1}^n x_i - n \right) \right] = \frac{n}{\theta} - \frac{1}{1-\theta} \underbrace{\left(\sum_{i=1}^n x_i - n \right)}_{=n\bar{x}} \\ &= \frac{n}{\theta(1-\theta)} (1-\theta\bar{x}). \end{aligned}$$

Alltså är $\theta = 1/\bar{x}$ det värde som ger maximum. (Kontroll av andraderivatan ger att det verkligen är ett maximum som erhållits.) Alltså, ML-skattningen av θ är

$$\theta_{\text{obs}}^* = \frac{1}{\bar{x}}.$$

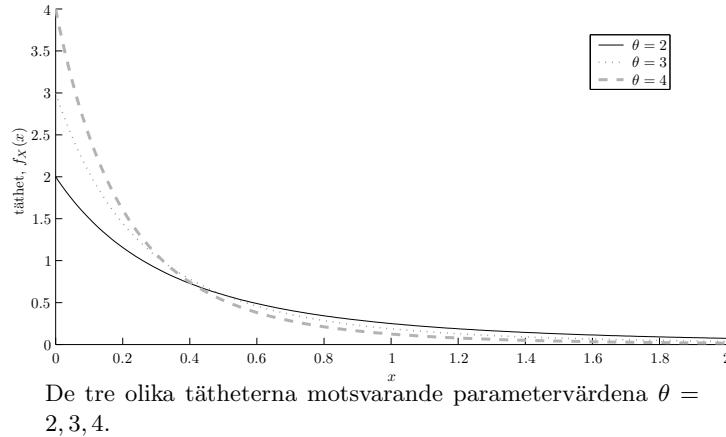
Med $(x_1, \dots, x_n) = (4, 5, 4, 6, 4, 1)$ är $\bar{x} = 4$ och $\theta_{\text{obs}}^* = 1/\bar{x} = 1/4$.

Notera att X är ffg(θ)-fördelad och har väntevärde $E(X) = 1/\theta$. Om detta väntevärde skattas med \bar{x} fås $\theta_{\text{obs}}^* = 1/\bar{x}$ som skattning av θ .

11.11 Den stokastiska variabeln X har täthetsfunktion

$$f_X(x) = \theta(1+x)^{-(\theta+1)}, \quad x \geq 0,$$

där möjliga värden på parametern θ är 2, 3 eller 4. De tre möjliga täheterna för X visas i figuren nedan.



Med stickprovet x_1, x_2 blir likelihoodfunktionen

$$L(\theta) = p_{X_1, X_2}(x_1, x_2) = p_{X_1}(x_1)p_{X_2}(x_2) = \theta(1+x_1)^{-(\theta+1)}\theta(1+x_2)^{-(\theta+1)} = \theta^2 [(1+x_1)(1+x_2)]^{-(\theta+1)}.$$

Med observationerna $(x_1, x_2) = (0.2, 0.8)$ blir $L(\theta) = \theta^2 \cdot (2.16)^{-(\theta+1)}$ och

| Parameter | $L(\theta)$ |
|--------------|-------------|
| $\theta = 2$ | 0.39692 |
| $\theta = 3$ | 0.41345 |
| $\theta = 4$ | 0.34029 |

så valet $\theta = 3$ ger maximum. Alltså, ML-skattningen av θ är $\theta_{\text{obs}}^* = 3$.

11.12 Låt x_1, \dots, x_n vara antalet telefonsamtal under olika dagar. Vi ansätter modellen att x_1, \dots, x_n är utfall av oberoende Poisson(μ)-fördelade stokastiska variabler X_1, \dots, X_n .

Maximum likelihoodskattningen av μ är det värde på μ som maximerar

$$L(\mu) = p_{X_1, \dots, X_n}(x_1, \dots, x_n) = p_{X_1}(x_1) \cdots p_{X_n}(x_n) = \frac{\mu^{x_1}}{x_1!} e^{-\mu} \cdots \frac{\mu^{x_n}}{x_n!} e^{-\mu} = \frac{\mu^{\sum_{i=1}^n x_i}}{x_1! \cdots x_n!} e^{-n\mu}.$$

Det är samma μ som maximerar

$$\ln(L(\mu)) = \ln\left(\frac{\mu^{\sum_{i=1}^n x_i}}{x_1! \cdots x_n!} e^{-n\mu}\right) = \ln(\mu) \sum_{i=1}^n x_i - n\mu - \sum_{i=1}^n \ln(x_i!).$$

Detta maximum bestäms som det μ som löser

$$0 = \frac{d}{d\mu} \ln(L(\mu)) = \frac{d}{d\mu} \left[\ln(\mu) \sum_{i=1}^n x_i - n\mu - \sum_{i=1}^n \ln(x_i!) \right] = \frac{1}{\mu} \sum_{i=1}^n x_i - n$$

vilket ger $\mu = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$. Kontroll av andraderivatan ger att detta är ett maximum. Skatningen $\mu_{\text{obs}}^* = \bar{x}$ av μ beskrivs av stickprovsvariabeln $\mu^* = \bar{X}$ som har

$$E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \mu,$$

vilket ger att \bar{x} är en väntevärdesriktig skattning av μ , och

$$V(\bar{X}) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} V\left(\sum_{i=1}^n X_i\right) = \{\text{oberoende}\} = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{\mu}{n},$$

det vill säga $D(\bar{X}) = \sqrt{\mu/n}$.

Med observationer x_1, \dots, x_8 :

115 82 108 106 118 87 99 92

får skatningen $\bar{x} = 100.88$. En skattning av $D(\bar{X}) = \sqrt{\mu/n}$ ges av

$$\sqrt{\frac{\mu_{\text{obs}}^*}{n}} = \sqrt{\frac{100.88}{8}} = 3.551$$

och kallas för skattningens medelfel.

11.13 Låt x_1, \dots, x_n vara de uppmätta tiderna mellan fel hos den komplicerade tekniska utrustningen. Med modellen att x_1, \dots, x_n är utfall av oberoende exponential(λ)-fördelade stokastiska variabler X_1, \dots, X_n är likelihoodfunktionen

$$L(\lambda) = f_{X_1, \dots, X_n}(x_1, \dots, x_n) = f_{X_1}(x_1) \cdots f_{X_n}(x_n) = \lambda e^{-\lambda x_1} \cdots \lambda e^{-\lambda x_n} = \lambda^n e^{-\lambda \sum_{i=1}^n x_i}.$$

Det värde på λ som maximerar $L(\lambda)$ är samma som maximerar

$$\ln(L(\lambda)) = \ln\left(\lambda^n e^{-\lambda \sum_{i=1}^n x_i}\right) = n \ln(\lambda) - \lambda \underbrace{\sum_{i=1}^n x_i}_{=n\bar{x}} = n \ln(\lambda) - \lambda n \bar{x}.$$

Maximum bestäms som det λ som löser

$$0 = \frac{d}{d\lambda} \ln(L(\lambda)) = \frac{d}{d\lambda} [n \ln(\lambda) - \lambda n \bar{x}] = \frac{n}{\lambda} - n \bar{x} = n \left(\frac{1}{\lambda} - \bar{x} \right),$$

det vill säga $\lambda = 1/\bar{x}$. Kontroll av andraderivatan ger att detta är ett maximum. Skatningen $\lambda_{\text{obs}}^* = 1/\bar{x}$ av λ beskrivs av $\lambda^* = 1/\bar{X}$. Den har för $t \geq 0$ fördelningsfunktion

$$F_{\lambda^*}(t) = P(\lambda^* \leq t) = P\left(\frac{1}{\bar{X}} \leq t\right) = P\left(\sum_{i=1}^n X_i \geq \frac{n}{t}\right) = 1 - F_{\sum X_i}(n/t)$$

det vill säga

$$f_{\lambda^*}(t) = \frac{d}{dt} F_{\lambda^*}(t) = \frac{n}{t^2} f_{\sum X_i}(n/t).$$

En summa av n stycken oberoende $\exp(\lambda)$ -fördelade stokastiska variabler har täthet

$$f_{\sum X_i}(x) = \frac{\lambda^n x^{n-1}}{\Gamma(n)} e^{-\lambda x}, \quad x \geq 0,$$

så

$$f_{\lambda^*}(t) = \frac{n}{t^2} \frac{\lambda^n (n/t)^{n-1}}{\Gamma(n)} e^{-\lambda n/t}, \quad t \geq 0.$$

Alltså är

$$\begin{aligned} E(\lambda^*) &= \int_{-\infty}^{\infty} t f_{\lambda^*}(t) dt = \int_0^{\infty} \frac{\lambda^n (n/t)^n}{\Gamma(n)} e^{-\lambda n/t} dt = \{u = n/t\} = n \int_0^{\infty} \frac{\lambda^n u^{n-2}}{\Gamma(n)} e^{-\lambda u} du \\ &= \{\Gamma(n) = (n-1)\Gamma(n-1)\} = \frac{n}{n-1} \lambda \underbrace{\int_0^{\infty} \frac{\lambda^{n-1} u^{n-2}}{\Gamma(n-1)} e^{-\lambda u} du}_{=f_Y(u)} = \frac{n}{n-1} \lambda \neq \lambda \end{aligned}$$

vilket visar att skattningen inte är väntevärdesriktig, men att $(n-1)\lambda_{\text{obs}}^*/n$ är det. Tätheten $f_Y(u)$ var tätheten för en summa av $n-1$ stycken oberoende $\exp(\lambda)$ -fördelade stokastiska variabler och den integreras till 1 över intervallet $[0, \infty)$.

11.14 Låt x_1, \dots, x_n vara utfall av X_1, \dots, X_n där de stokastiska variablerna är oberoende och har täthetsfunktion

$$f_X(x) = \theta x^{\theta-1}, \quad 0 < x < 1.$$

Likelihoodfunktionen blir

$$L(\theta) = f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \{\text{ober.}\} = f_{X_1}(x_1) \cdots f_{X_n}(x_n) = \theta x_1^{\theta-1} \cdots \theta x_n^{\theta-1} = \theta^n (x_1 \cdots x_n)^{\theta-1}.$$

Det är samma θ som maximerar

$$\ln(L(\theta)) = \ln(\theta^n (x_1 \cdots x_n)^{\theta-1}) = n \ln(\theta) + (\theta-1) \sum_{i=1}^n \ln(x_i).$$

Maximum bestäms som det θ som löser

$$0 = \frac{d}{d\theta} \ln(L(\theta)) = \frac{d}{d\theta} \left[n \ln(\theta) + (\theta-1) \sum_{i=1}^n \ln(x_i) \right] = \frac{n}{\theta} + \sum_{i=1}^n \ln(x_i)$$

det vill säga $\theta = -n / \sum_{i=1}^n \ln(x_i)$. Kontroll av andraderivatan ger att detta är ett maximum. (Notera att $\ln(x_i) < 0$ för $0 < x_i < 1$.) Alltså, maximum-likelihoodmetodens skattning av θ är $\theta_{\text{obs}}^* = -n / \sum_{i=1}^n \ln(x_i)$.

11.15 Låt x_1, \dots, x_n vara utfall av X_1, \dots, X_n där de stokastiska variablerna är oberoende och Rayleigh(a)-fördelade, det vill säga har täthetsfunktion

$$f_X(x) = (x/a) e^{-x^2/2a} \quad x \geq 0.$$

Likelihoodfunktionen blir

$$\begin{aligned} L(a) &= f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \{\text{ober.}\} = f_{X_1}(x_1) \cdots f_{X_n}(x_n) = \frac{x_1}{a} e^{-x_1^2/2a} \cdots \frac{x_n}{a} e^{-x_n^2/2a} \\ &= \frac{x_1 \cdots x_n}{a^n} e^{-\frac{1}{2a} \sum_{i=1}^n x_i^2}. \end{aligned}$$

Vi söker det värde på a som maximerar $L(a)$, och det är samma a som maximerar

$$\ln(L(a)) = \ln\left(\frac{x_1 \cdots x_n}{a^n} e^{-\frac{1}{2a} \sum_{i=1}^n x_i^2}\right) = -n \ln(a) + \sum_{i=1}^n \ln(x_i) - \frac{1}{2a} \sum_{i=1}^n x_i^2.$$

Detta maximum bestäms som det a som löser

$$0 = \frac{d}{da} \ln(L(a)) = \frac{d}{da} \left[-n \ln(a) + \sum_{i=1}^n \ln(x_i) - \frac{1}{2a} \sum_{i=1}^n x_i^2 \right] = -\frac{n}{a} + \frac{1}{2a^2} \sum_{i=1}^n x_i^2 = \frac{-1}{a} \left[n - \frac{1}{2a} \sum_{i=1}^n x_i^2 \right]$$

vilket medför att $a = \frac{1}{2n} \sum_{i=1}^n x_i^2$. Kontroll av andraderivatan ger att detta är ett maximum. Således, maximum-likelihoodskattningen av a är $a_{\text{obs}}^* = \frac{1}{2n} \sum_{i=1}^n x_i^2$.

11.16 Låt X_1, \dots, X_n vara oberoende och likformigt fördelade på intervallet $[-\theta, \theta]$, $\theta > 0$, med observerade värden x_1, \dots, x_n , det vill säga de stokastiska variablerna har täthetsfunktion

$$f_X(x) = \frac{1}{2\theta} \quad \text{för } -\theta \leq x \leq \theta.$$

Maximum likelihoodskattningen är det värde på θ som maximerar

$$L(\theta) = f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \{\text{oberoende}\} = \prod_{i=1}^n f_{X_i}(x_i) = \prod_{i=1}^n \frac{1}{2\theta} = (2\theta)^{-n}$$

för $-\theta \leq x_1, \dots, x_n \leq \theta$. Eftersom $L(\theta)$ är avtagande i θ skall man göra θ så liten som möjligt. Kravet $-\theta \leq x_1, \dots, x_n \leq \theta$, det vill säga $|x_1|, \dots, |x_n| \leq \theta$, gör att det minsta möjliga värdet på θ ges av $\theta = \max(|x_1|, \dots, |x_n|)$. Alltså, maximum-likelihoodskattningen av θ är $\theta_{\text{obs}}^* = \max(|x_1|, \dots, |x_n|)$.

Eftersom denna skattning omöjliggen kan överskatta θ kommer den ha ett systematiskt fel, $E(\theta^*) < \theta$.

11.17 Den stokastiska variabeln X har täthetsfunktion

$$f_X(x) = \theta(1+x)^{-(\theta+1)}, \quad x \geq 0,$$

där möjliga värden på parametern θ är 2, 3 eller 4. Nu är

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x f_X(x) dx = \int_0^{\infty} x \cdot \frac{\theta}{(1+x)^{\theta+1}} dx = \left[\frac{-x}{(1+x)^{\theta}} \right]_0^{\infty} + \int_0^{\infty} \frac{1}{(1+x)^{\theta}} dx \\ &= \left[\frac{-1/(\theta-1)}{(1+x)^{\theta-1}} \right]_0^{\infty} = \frac{1}{\theta-1}. \end{aligned}$$

Med $n = 2$ observationer $(x_1, x_2) = (0.2, 0.8)$ är minsta-kvadratskattningen av θ är det värde som minimerar

$$Q(\theta) = \sum_{i=1}^n (x_i - E(X_i))^2 = \left(0.2 - \frac{1}{\theta-1}\right)^2 + \left(0.8 - \frac{1}{\theta-1}\right)^2$$

För de olika värdena på θ erhålls

| Parameter | $Q(\theta)$ |
|--------------|-------------|
| $\theta = 2$ | 0.68 |
| $\theta = 3$ | 0.18 |
| $\theta = 4$ | 0.24 |

så valet $\theta = 3$ ger minimum. Alltså, MK-skattningen av θ är $\theta_{\text{obs}}^* = 3$.

11.18 Låt X_1, X_2, X_3 beskriva mätningarna på vinkeln AOC och X_4, X_5 på vinkeln AOB. Modell: X_1, \dots, X_n är oberoende och

$$E(X_1) = E(X_2) = E(X_3) = \theta_1 + \theta_2 \quad E(X_4) = E(X_5) = \theta_1$$

och $V(X_i) = \sigma^2$. Minsta kvadratmetodens skattning av (θ_1, θ_2) är det värde på (θ_1, θ_2) som minimerar

$$\begin{aligned} Q(\theta_1, \theta_2) = \sum_{i=1}^n (x_i - E(X_i))^2 &= (x_1 - (\theta_1 + \theta_2))^2 + (x_2 - (\theta_1 + \theta_2))^2 + (x_3 - (\theta_1 + \theta_2))^2 \\ &\quad + (x_4 - \theta_1)^2 + (x_5 - \theta_1)^2. \end{aligned}$$

Derivering med avseende på θ_1 och θ_2 ger

$$\begin{aligned}\frac{\partial}{\partial \theta_1} Q(\theta_1, \theta_2) &= -2(x_1 - (\theta_1 + \theta_2)) - 2(x_2 - (\theta_1 + \theta_2)) - 2(x_3 - (\theta_1 + \theta_2)) \\ &\quad - 2(x_4 - \theta_1) - 2(x_5 - \theta_1) \\ &= -2 \left[\sum_{i=1}^5 x_i - 5\theta_1 - 3\theta_2 \right] \\ \frac{\partial}{\partial \theta_2} Q(\theta_1, \theta_2) &= -2(x_1 - (\theta_1 + \theta_2)) - 2(x_2 - (\theta_1 + \theta_2)) - 2(x_3 - (\theta_1 + \theta_2)) \\ &= -2[x_1 + x_2 + x_3 - 3\theta_1 - 3\theta_2]\end{aligned}$$

Sätts derivatorna till 0 fås ekvationssystemet

$$\begin{cases} 5\theta_1 + 3\theta_2 = x_1 + x_2 + x_3 + x_4 + x_5 \\ 3\theta_1 + 3\theta_2 = x_1 + x_2 + x_3 \end{cases}$$

med lösningen

$$(\theta_1^*)_{\text{obs}} = \frac{x_4 + x_5}{2} \quad (\theta_2^*)_{\text{obs}} = \frac{x_1 + x_2 + x_3}{3} - (\theta_1^*)_{\text{obs}}.$$

b) Skattningen $(\theta_1^*)_{\text{obs}}$ är väntevärdesriktig ty

$$E(\theta_1^*) = E\left(\frac{1}{2}X_4 + \frac{1}{2}X_5\right) = \frac{1}{2}E(X_4) + \frac{1}{2}E(X_5) = \frac{1}{2}\theta_1 + \frac{1}{2}\theta_1 = \theta_1.$$

Vidare så är

$$\begin{aligned}E(\theta_2^*) &= E\left(\frac{1}{3}X_1 + \frac{1}{3}X_2 + \frac{1}{3}X_3 - \theta_1^*\right) = \frac{1}{3}E(X_1) + \frac{1}{3}E(X_2) + \frac{1}{3}E(X_3) - E(\theta_1^*) \\ &= \frac{1}{3}(\theta_1 + \theta_2) + \frac{1}{3}(\theta_1 + \theta_2) + \frac{1}{3}(\theta_1 + \theta_2) - \theta_1 = \theta_2\end{aligned}$$

så även $(\theta_2^*)_{\text{obs}}$ är väntevärdesriktig.

c) Skattningarna $(\theta_1^*)_{\text{obs}}$ och $(\theta_2^*)_{\text{obs}}$ är utfall av stokastiska variabler med varians

$$V(\theta_1^*) = V\left(\frac{1}{2}X_4 + \frac{1}{2}X_5\right) = \{\text{oberoende}\} = \frac{1}{2^2}\sigma^2 + \frac{1}{2^2}\sigma^2 = \frac{\sigma^2}{2}.$$

respektive

$$\begin{aligned}V(\theta_2^*) &= V\left(\frac{1}{3}X_1 + \frac{1}{3}X_2 + \frac{1}{3}X_3 - \theta_1^*\right) = \{\text{oberoende}\} = \frac{1}{3^2}\sigma^2 + \frac{1}{3^2}\sigma^2 + \frac{1}{3^2}\sigma^2 + (-1)^2V(\theta_1^*) = \frac{\sigma^2}{3} + \frac{\sigma^2}{2} \\ &= \frac{5}{6}\sigma^2.\end{aligned}$$

11.19 Låt x_1, x_2, x_3 vara mätningar på vinkeln vid B och x_4, \dots, x_7 de vid C. Minsta-kvadratmetodens skattning av θ är det värde på θ som minimerar

$$\begin{aligned}Q(\theta) &= \sum_{i=1}^7 (x_i - E(X_i))^2 = \sum_{i=1}^3 (x_i - \theta)^2 + \sum_{i=4}^7 (x_i - (90 - \theta))^2 \\ &= (x_1 - \theta)^2 + (x_2 - \theta)^2 + (x_3 - \theta)^2 \\ &\quad + (x_4 - (90 - \theta))^2 + (x_5 - (90 - \theta))^2 + (x_6 - (90 - \theta))^2 + (x_7 - (90 - \theta))^2\end{aligned}$$

Funktionens maximipunkt hittas genom att derivatan sätts till noll.

$$\begin{aligned}\frac{d}{d\theta} Q(\theta) &= -2 \sum_{i=1}^3 (x_i - \theta) - 2 \sum_{i=4}^7 (90 - x_i - \theta) \\ &= -2(x_1 + x_2 + x_3 + (90 - x_4) + \dots + (90 - x_7) - 7\theta) = 0.\end{aligned}$$

Detta ger

$$\theta_{\text{obs}}^* = \frac{x_1 + x_2 + x_3 + (90 - x_4) + \dots + (90 - x_7)}{7},$$

eller, med siffror, $\theta_{\text{obs}}^* = 61.17$. Minsta-kvadratskattningen av vinkeln vid C blir då $90 - 61.17 = 28.83$.

Skattningen beskrivs av stickprovsvariabeln

$$\theta^* = \frac{X_1 + X_2 + X_3 + (90 - X_4) + (90 - X_5) + (90 - X_6) + (90 - X_7)}{7}.$$

Den har väntevärde

$$\begin{aligned} E(\theta^*) &= E\left(\frac{X_1 + X_2 + X_3 + (90 - X_4) + (90 - X_5) + (90 - X_6) + (90 - X_7)}{7}\right) \\ &= \frac{1}{7}\left(\underbrace{E(X_1)}_{=\theta} + \dots + \underbrace{E(X_3)}_{=\theta} + (90 - \underbrace{E(X_4)}_{=90-\theta}) + \dots + (90 - \underbrace{E(X_7)}_{=90-\theta})\right) = \frac{1}{7} \cdot 7\theta = \theta, \end{aligned}$$

vilket innebär att skattningen θ_{obs}^* är väntevärdesriktig. Vidare,

$$\begin{aligned} V(\theta^*) &= V\left(\frac{X_1 + X_2 + X_3 + (90 - X_4) + (90 - X_5) + (90 - X_6) + (90 - X_7)}{7}\right) \\ &= \frac{1}{7^2}\left(\underbrace{V(X_1)}_{=\sigma^2} + \dots + \underbrace{V(X_3)}_{=\sigma^2} + (-1)^2 \underbrace{V(X_4)}_{=\sigma^2} + \dots + (-1)^2 \underbrace{V(X_7)}_{=\sigma^2}\right) = \frac{\sigma^2}{7} \end{aligned}$$

så $D(\theta^*) = \sigma/\sqrt{7} = 0.1/\sqrt{7} = 0.0378$. Skattningen $90 - \theta_{\text{obs}}^*$ är ett utfall från en stokastisk variabel med samma standardavvikelse.

11.20 Låt x_1, \dots, x_n vara mätningarna av våglängden θ . Dessa mätvärden är utfall av de oberoende stokastiska variablerna X_1, \dots, X_n där $E(X_i) = \theta$. Minsta-kvadratskattningen av θ är det värde på θ som minimerar

$$Q(\theta) = \sum_{i=1}^n \frac{1}{V(X_i)} (x_i - E(X_i))^2.$$

Med mätningarna

| | | | | | |
|-------------|------|------|------|------|------|
| x_i | 79.1 | 80.0 | 81.3 | 81.9 | 81.7 |
| $100D(X_i)$ | 2 | 1 | 2 | 3 | 1 |

får

$$10000 Q(\theta) = \frac{1}{2^2}(x_1 - \theta)^2 + \frac{1}{1^2}(x_2 - \theta)^2 + \frac{1}{2^2}(x_3 - \theta)^2 + \frac{1}{3^2}(x_4 - \theta)^2 + \frac{1}{1^2}(x_5 - \theta)^2$$

Lösning av

$$0 = \frac{d}{d\theta}[10000Q(\theta)] = 2 \left[\frac{1}{4}x_1 + x_2 + \frac{1}{4}x_3 + \frac{1}{9}x_4 + x_5 - \frac{47}{18}\theta \right] = 2 \left[210.9 - \frac{47}{18}\theta \right]$$

ger skattningen $\theta_{\text{obs}}^* = 210.9 \cdot 18/47 = 80.77$ Ångström.

11.21

11.22

11.23 Låt $x = 16$ vara ett utfall av en binomialfördelad stokastisk variabel X , X är $\text{Bin}(n, p)$ där $n = 25$.

ML-skattning: Den logaritmerade likelihoodfunktionen är

$$\ln(L(p)) = \ln \left(\binom{n}{x} \right) + x \ln(p) + (n - x) \ln(1 - p)$$

så lösning av

$$0 = \frac{d}{dp} \ln(L(p)) = \frac{x}{p} - \frac{n - x}{1 - p} = \frac{1}{p(1 - p)} [x - np]$$

ger, då $p(1 - p) \neq 0$, att $p = x/n$. Alltså, maximum-likelihoodskattningen är $p_{\text{obs}}^* = x/n$.

MK-skattning: Väntevärdet $E(X) = np$ så minsta-kvadratskattningen av p är det värde på p som minimerar

$$Q(p) = (x - E(X))^2 = (x - np)^2.$$

Eftersom $(x - np)^2 \geq 0$ med likhet om $x = np$ fås skattningen $p_{\text{obs}}^* = x/n$.

Med värden fås skattningen $p_{\text{obs}}^* = x/n = 16/25 = 0.64$

b) Skattningen $p_{\text{obs}}^* = x/n$ är ett utfall av en stokastisk variabel med varians

$$V(p^*) = V\left(\frac{1}{n}X\right) = \frac{1}{n^2} \underbrace{V(X)}_{=np(1-p)} = \frac{p(1-p)}{n}$$

så standardavvikelsen är $D(p^*) = \sqrt{p(1-p)/n}$.

c) En skattning av $D(p^*) = \sqrt{p(1-p)/n}$ är

$$\sqrt{\frac{p_{\text{obs}}^*(1-p_{\text{obs}}^*)}{n}} = \sqrt{\frac{0.64(1-0.64)}{25}} = 0.096$$

och kallas medelfelet för skattningen p_{obs}^* .

11.24 Låt x_1 och x_2 vara antalet färgblinda som forskare A respektive B har funnit. Vi ansätter modellen att x_1 och x_2 är utfall av oberoende stokastiska variabler X_1 och X_2 där X_1 är $\text{Bin}(n_1, p) = \text{Bin}(1000, p)$ och X_2 är $\text{Bin}(n_2, p) = \text{Bin}(2000, p)$.

Likelihoodfunktionen är

$$L(p) = p_{X_1, X_2}(x_1, x_2) = \{\text{oberoende}\} = p_{X_1}(x_1)p_{X_2}(x_2) = \binom{n_1}{x_1} p^{x_1} (1-p)^{n_1-x_1} \binom{n_2}{x_2} p^{x_2} (1-p)^{n_2-x_2}$$

så den logaritmerade likelihoodfunktionen är

$$\ln(L(p)) = \ln\left(\binom{n_1}{x_1} \binom{n_2}{x_2}\right) + (x_1 + x_2) \ln(p) + (n_1 + n_2 - x_1 - x_2) \ln(1-p).$$

Lösning av

$$0 = \frac{d}{dp} \ln(L(p)) = \frac{x_1 + x_2}{p} - \frac{(n_1 + n_2) - (x_1 + x_2)}{1-p} = \frac{1}{p(1-p)} [(x_1 + x_2) - (n_1 + n_2)p]$$

ger skattningen $p_{\text{obs}}^* = (x_1 + x_2)/(n_1 + n_2) = 201/3000 = 0.067$. Notera att detta kan ses som att man slår samman de två observationsserierna till en och betraktar den relativa frekvensen av färgblinda i den sammanslagna serien.

11.25 Låt x_1, \dots, x_n vara antalet fartyg som passerat Helsingborg under tidsperioder av längder t_1, \dots, t_n . Vi ansätter modellen att x_1, \dots, x_n är utfall av oberoende Poissonfördelade stokastiska variabler X_1, \dots, X_n där $E(X_i) = \lambda t_i$.

Likelihoodfunktionen blir

$$L(\lambda) = p_{X_1, \dots, X_n}(x_1, \dots, x_n) = \{\text{oberoende}\} = p_{X_1}(x_1) \cdots p_{X_n}(x_n) = \frac{(\lambda t_1)^{x_1}}{x_1!} e^{-\lambda t_1} \cdots \frac{(\lambda t_n)^{x_n}}{x_n!} e^{-\lambda t_n}.$$

Det λ som maximerar $L(\lambda)$ är samma λ som maximerar

$$\ln(L(\lambda)) = \sum_{i=1}^n (x_i \ln(\lambda) + x_i \ln(t_i) - \ln(x_i!) - \lambda t_i).$$

Detta maximum bestäms som det λ som löser

$$0 = \frac{d}{d\lambda} \ln(L(\lambda)) = \sum_{i=1}^n \left(\frac{x_i}{\lambda} - t_i \right) = \frac{1}{\lambda} \left(\sum_{i=1}^n x_i \right) - \left(\sum_{i=1}^n t_i \right)$$

vilket ger skattningen

$$\lambda_{\text{obs}}^* = \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^n t_i}.$$

Med de $n = 3$ observationerna

| | Observationstid, t_i | 30 | 30 | 40 |
|--------------------|------------------------|----|----|----|
| Antal fartyg x_i | | 10 | 12 | 18 |

fås skattningen $\lambda_{\text{obs}}^* = 40/100 = 0.40$ fartyg per minut.

b) Skattningen λ_{obs}^* är ett utfall av en stokastisk variabel med varians

$$V(\lambda^*) = V\left(\frac{\sum_{i=1}^n X_i}{\sum_{i=1}^n t_i}\right) = \{\text{oberoende}\} = \frac{1}{(\sum_{i=1}^n t_i)^2} \sum_{i=1}^n V(X_i) = \frac{\lambda}{\sum_{i=1}^n t_i},$$

det vill säga med standardavvikelse

$$D(\lambda^*) = \sqrt{\frac{\lambda}{\sum_{i=1}^n t_i}} = \frac{\sqrt{\lambda}}{10}.$$

11.26 Låt $x = 32$ vara antalet bostadssökande av $n = 50$ undersökta som redan har en bostad. Ansätt modellen att x är ett utfall av en hypergeometriskt fördelad stokastisk variabel X . Låt N beteckna antalet personer i bostadskö och p andelen av dessa som redan har en bostad.

Väntevärde $E(X) = np$ så minsta-kvadratskattningen av p är det värde på p som minimerar

$$Q(p) = (x - E(X))^2 = (x - np)^2.$$

Eftersom $(x - np)^2 \geq 0$ med likhet om $x = np$ fås skattningen $p_{\text{obs}}^* = x/n$.

a) Med värden fås skattningen $p_{\text{obs}}^* = x/n = 32/50 = 0.64$

b) Eftersom $V(X) = np(1-p)(N-n)/(N-1)$ är skattningen p_{obs}^* är ett utfall av en stokastisk variabel med varians

$$V(p^*) = V\left(\frac{X}{n}\right) = \frac{1}{n^2}V(X) = \frac{p(1-p)}{n} \frac{N-n}{N-1}.$$

Standardavvikelsen $D(p^*) = \sqrt{\frac{p(1-p)}{n} \frac{N-n}{N-1}}$ skattas då $N = 100$ med

$$\sqrt{\frac{p_{\text{obs}}^*(1-p_{\text{obs}}^*)}{n} \frac{N-n}{N-1}} = \sqrt{\frac{0.64(1-0.64)}{50} \frac{100-50}{100-1}} = 0.048242$$

c) och då $N = 1000$ med

$$\sqrt{\frac{p_{\text{obs}}^*(1-p_{\text{obs}}^*)}{n} \frac{N-n}{N-1}} = \sqrt{\frac{0.64(1-0.64)}{50} \frac{1000-50}{1000-1}} = 0.066197.$$

11.27

11.28

11.29 Låt x_1, \dots, x_n vara resultaten av mätningarna av kvadratens sida. Dessa antas vara utfall av oberoende $N(\sqrt{\theta}, \sigma)$ -fördelade stokastiska variabler där σ är känd och θ är kvadratens (okända) area.

Maximum-likelihoodskattningen av θ är det θ som maximerar

$$\begin{aligned} L(\theta) &= f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \{\text{oberoende}\} = f_{X_1}(x_1) \cdots f_{X_n}(x_n) \\ &= \frac{1}{\sqrt{2\pi\sigma}} e^{-(x_1 - \sqrt{\theta})^2/2\sigma^2} \cdots \frac{1}{\sqrt{2\pi\sigma}} e^{-(x_n - \sqrt{\theta})^2/2\sigma^2}. \end{aligned}$$

Det är samma θ som maximerar

$$\ln(L(\theta)) = \ln \left(\prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-(x_i - \sqrt{\theta})^2/2\sigma^2} \right) = -n \ln(\sqrt{2\pi}\sigma) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \sqrt{\theta})^2$$

och detta maximum bestäms som lösningen till

$$0 = \frac{d}{d\theta} \ln(L(\theta)) = \frac{1}{2\sqrt{\theta}\sigma^2} \sum_{i=1}^n (x_i - \sqrt{\theta}) = \frac{1}{2\sqrt{\theta}\sigma^2} \underbrace{\left(\sum_{i=1}^n x_i - n\sqrt{\theta} \right)}_{=n\bar{x}} = \frac{n}{2\sqrt{\theta}\sigma^2} (\bar{x} - \sqrt{\theta}),$$

vilket ger $\sqrt{\theta} = \bar{x}$ eller $\theta = \bar{x}^2$. Alltså, ML-skattningen av θ är $\theta_{\text{obs}}^* = (\bar{x})^2$.

b) Skattningen θ_{obs}^* är inte väntevärdesriktig eftersom

$$E(\theta^*) = E(\bar{X}^2) = V(\bar{X}) + (E(\bar{X}))^2 = \frac{\sigma^2}{n} + (\sqrt{\theta})^2 = \frac{\sigma^2}{n} + \theta \neq \theta,$$

men med $\hat{\theta}_{\text{obs}} = \bar{x}^2 - \sigma^2/n$ får en väntevärdesriktig skattning.

11.30 Låt X beskriva antalet dragna kolor med olika färg tills två med samma färg erhålls. Möjliga värden på X ges av $S_X = \{1, 2, \dots, N\}$. (Notera att antalet dragna kolor är $X + 1$.)

Händelsen $X = 1$ är att de två första kulorna har samma färg, det vill säga $P(X = 1) = 1/N$. Händelsen $X = k$, $k > 1$ är att de första k kulorna har olika färg och kula $k + 1$ har någon av de tidigare k dragna färgerna. Alltså,

$$P(X = k) = \underbrace{\frac{N}{N} \cdot \frac{N-1}{N} \cdots \frac{N-(k-1)}{N}}_{k \text{ st}} \cdot \frac{k}{N} = \frac{N!}{(N-k)!N^k} \cdot \frac{k}{N}, \quad k = 1, 2, \dots, N.$$

Med utfallet $x = 3$ blir likelihoodfunktionen

$$L(N) = \frac{N!}{(N-x)!N^x} \cdot \frac{x}{N} = \frac{(N-1)(N-2)3}{N^3}$$

vilken är avtagande för stora N . För olika värden på N fås

| | N | $L(N)$ |
|---|---------|--------|
| 3 | 0.22222 | |
| 4 | 0.28125 | |
| 5 | 0.28800 | |
| 6 | 0.27778 | |
| 7 | 0.26239 | |
| 8 | 0.24609 | |

Maximum ges med valet $N = 5$.

Anmärkning. Om man vill få en uppfattning om var detta maximum ligger någonstans kan man för tillfället låta N vara kontinuerlig i uttrycket $\frac{(N-1)(N-2)3}{N^3}$. Logaritmering och derivering ger att maximum nås i det N som löser

$$0 = \frac{d}{dN} \ln(L(N)) = \frac{d}{dN} [\ln(N-1) + \ln(N-2) + \ln(3) - 3\ln(N)] = \frac{-(N-3-\sqrt{3})(N-3+\sqrt{3})}{N(N-1)(N-2)}$$

det vill säga $N = 3 + \sqrt{3} = 4.73$. Alltså erhålls tillåtet maximum då $N = 4$ eller $N = 5$. Av dessa två är $L(N)$ störst då $N = 5$.

11.31

12.1 Låt X vara χ^2 -fördelad med 24 frihetsgrader. Bestäm a så att $P(X < a) = 0.95$. Då är

$$0.05 = 1 - P(X \leq a) = 1 - F_X(a) = 1 - F_X(\chi_{0.05}^2)$$

det vill säga $a = \chi_{0.05}^2 = 36.415$.

Bestäm b och c , $b < c$, så att $P(b < X < c) = 0.95$. Vi antar att händelsen $X \notin (b, c)$ är sådan att $P(X \leq b) = 0.025$ och $P(X \geq c) = 0.025$.

Då är

$$0.025 = 1 - P(X \leq c) = 1 - F_X(c) = 1 - F_X(\chi_{0.025}^2)$$

dvs $c = \chi_{0.025}^2 = 39.364$ och

$$0.975 = 1 - P(X \leq b) = 1 - F_X(b) = 1 - F_X(\chi_{0.975}^2)$$

dvs $b = \chi_{0.975}^2 = 12.401$.

12.2 Om Z, Z_1, Z_2, \dots, Z_n är oberoende $N(0, 1)$ så är

$$X = \sum_{i=1}^n Z_i^2$$

χ^2 -fördelad med n frihetsgrader, $X \sim \chi^2(n)$. För Z är

$$E(Z^2) = V(Z) + (E(Z))^2 = 1 + 0^2 = 1$$

så

$$E(X) = E\left(\sum_{i=1}^n Z_i^2\right) = \sum_{i=1}^n \underbrace{E(Z_i^2)}_{=1} = n.$$

Vidare, enligt ledning är $E(Z^4) = 3$ vilket medför att

$$V(Z^2) = E(Z^4) - (E(Z^2))^2 = 3 - 1^2 = 2$$

och

$$V(X) = V\left(\sum_{i=1}^n Z_i^2\right) = \{\text{oberoende}\} = \sum_{i=1}^n \underbrace{V(Z_i^2)}_{=2} = 2n.$$

12.3 Om Z, Z_1, Z_2, \dots, Z_n är oberoende $N(0, 1)$ så är

$$X = \sum_{i=1}^n Z_i^2$$

$\chi^2(n)$ -fördelad. Ur uppgift 12.2 är

$$E(X) = n \quad V(X) = 2n,$$

och enligt centrala gränsvärdessatsen är X approximativt normalfördelad, X är approximativt $N(n, \sqrt{2n})$. Det vill säga

$$1 - \Phi(\lambda_\alpha) = \alpha = P(X > \chi_\alpha^2) = P\left(\frac{X - n}{\sqrt{2n}} > \frac{\chi_\alpha^2 - n}{\sqrt{2n}}\right) \approx 1 - \Phi\left(\frac{\chi_\alpha^2 - n}{\sqrt{2n}}\right)$$

ger att

$$\lambda_\alpha \approx \frac{\chi_\alpha^2 - n}{\sqrt{2n}}$$

eller

$$\chi_\alpha^2 \approx n + \sqrt{2n}\lambda_\alpha.$$

12.4

12.5 Låt x beteckna antalet konfidensintervall som innehåller den därfor avsedda konstanten. Då är x ett utfall av en binomialfördelad stokastisk variabel X , X är $\text{Bin}(n, p)$, där $n = 15$ är antalet konfidensintervall och $p = 0.90$ är konfidensgraden för varje intervall.

- a) Med X som $\text{Bin}(n, p) = \text{Bin}(15, 0.90)$ är $P(X = n) = p^n = 0.90^{15} = 0.20589$.
- b) Typvärdet k , det värde som maximerar $P(X = k)$, är $k = 14$ då $P(X = 14) = 15p^{14}(1-p) = 0.34315$, alltså 14 av 15 intervall träffar och ett intervall missar.

12.6 Låt glödlampornas livslängder beskrivas av den stokastiska variabeln X med täthetsfunktion

$$f_X(x) = \frac{1}{\theta} e^{-x/\theta}, x \geq 0.$$

Detta är exponentialfördelningen med intensitet $1/\theta$, det vill säga väntevärde θ . Fördelningsfunktionen är för $t \geq 0$

$$F_X(t) = \int_{-\infty}^t f_X(x) dx = \int_0^t \frac{1}{\theta} e^{-x/\theta} dx = 1 - e^{-t/\theta}.$$

Nu är för $c > 0$

$$P(\theta < cX) = P\left(X > \frac{\theta}{c}\right) = 1 - F_X\left(\frac{\theta}{c}\right) = e^{-(\theta/c)/\theta} = e^{-1/c}.$$

Alltså, med $c = -1/\ln(0.975)$ är $P(\theta < cX) = 0.975$ och med $c = -1/\ln(0.025)$ är $P(\theta < cX) = 0.025$. Alltså,

$$P\left(\frac{X}{-\ln(0.025)} < \theta < \frac{X}{-\ln(0.0975)}\right) = 0.95$$

och ett 95% konfidensintervall för θ är

$$\frac{x}{-\ln(0.025)} < \theta < \frac{x}{-\ln(0.0975)}.$$

Med observationen $x = 1000$ erhålls intervallet

$$271.09 \leq \theta \leq 39498 \quad (95\%).$$

12.7 Konfidensgraden väljs fortfarande till 95%. Med $c = -1/\ln(0.05)$ är $P(\theta < cX) = 0.05$ vilket ger

$$P\left(\frac{X}{-\ln(0.05)} < \theta\right) = 0.95$$

och ett 95% konfidensintervall för θ är

$$\frac{x}{-\ln(0.05)} < \theta.$$

Med observationen $x = 1000$ erhålls intervallet

$$333.81 \leq \theta \quad (95\%)$$

eller, omformulerat, $\theta \in [333.81, \infty)$.

12.8

12.9 Låt X beskriva resultatet av en avståndsmätning. Modell:

$$X = \text{avstånd} + \text{mätfel} = \mu + \epsilon$$

där ϵ är $N(0, \sigma)$, $\sigma = 5 \cdot 10^{-3}$. Då är $X \sim N(\mu, \sigma)$. Låt X_1, \dots, X_n beskriva resultaten av n oberoende avståndsmätningar med observerade värden x_1, \dots, x_n . Väntevärdet $\mu = E(X)$ skattas med \bar{x} som beskrivs av \bar{X} , där

$$\bar{X} \text{ är } N\left(\mu, \frac{\sigma}{\sqrt{n}}\right).$$

Alltså är

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

så med sannolikhet $1 - \alpha$ är

$$-\lambda_{\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \lambda_{\alpha/2}$$

eller, omformat, med sannolikhet $1 - \alpha$ är

$$\bar{X} - \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}}.$$

Med $n = 4$ observationer fås $\bar{x} = 1132.155$. Konfidensgrad $1 - \alpha = 0.95$ ger $\lambda_{\alpha/2} = \lambda_{0.025} = 1.9600$ och intervallet

$$\mu \in \bar{x} \pm \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} = 1132.155 \pm 1.96 \frac{5 \cdot 10^{-3}}{\sqrt{4}} = 1132.155 \pm 0.0048999 \quad (95\%)$$

eller

$$1132.150 \leq \mu \leq 1132.160 \quad (95\%).$$

12.10 Låt x_1, \dots, x_n vara utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n där $\sigma = 2$. Väntevärdet $\mu = E(X)$ skattas med \bar{x} som beskrivs av \bar{X} , där

$$\bar{X} \text{ är } N\left(\mu, \frac{\sigma}{\sqrt{n}}\right).$$

Alltså är

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

så med sannolikhet $1 - \alpha$ är

$$-\lambda_{\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \lambda_{\alpha/2}$$

eller, omformat, med sannolikhet $1 - \alpha$ är

$$\bar{X} - \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}}.$$

Med $n = 4$ observationer fås $\bar{x} = 45.2$. Konfidensgrad $1 - \alpha = 0.95$ ger $\lambda_{\alpha/2} = \lambda_{0.025} = 1.9600$ och intervallet

$$\mu \in \bar{x} \pm \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} = 45.2 \pm 1.96 \frac{2}{\sqrt{4}} = 45.2 \pm 1.96 \quad (95\%)$$

eller

$$43.24 \leq \mu \leq 47.16 \quad (95\%).$$

12.11 Låt x_1, \dots, x_n vara utfall av oberoende $N(\mu + \Delta, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n där $\sigma = 0.05$ och $\Delta = 0.10$. Om väntevärdet $\mu + \Delta$ skattas med \bar{x} kan pH-halten μ skattas med $\bar{x} - \Delta$. Denna skattning beskrivs av $\bar{X} - \Delta$, där

$$\bar{X} - \Delta \text{ är } N\left(\mu, \frac{\sigma}{\sqrt{n}}\right).$$

Alltså är

$$\frac{(\bar{X} - \Delta) - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

så med sannolikhet $1 - \alpha$ är

$$-\lambda_{\alpha/2} \leq \frac{(\bar{X} - \Delta) - \mu}{\sigma/\sqrt{n}} \leq \lambda_{\alpha/2}$$

eller, omformat, med sannolikhet $1 - \alpha$ är

$$(\bar{X} - \Delta) - \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq (\bar{X} - \Delta) + \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}}.$$

Med $n = 4$ observationer fås $\bar{x} = 8.2$. Konfidensgrad $1 - \alpha = 0.99$ ger $\lambda_{\alpha/2} = \lambda_{0.005} = 2.5758$ och intervallet

$$\mu \in (\bar{x} - \Delta) \pm \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} = (8.2 - 0.1) \pm 2.5758 \frac{0.05}{\sqrt{4}} = 8.1 \pm 0.0644 \quad (99\%)$$

eller

$$8.0356 \leq \mu \leq 8.1644 \quad (99\%).$$

12.12 Konfidensintervallet för väntevärdet med konfidensgrad $1 - \alpha$ ges av

$$\bar{x} \pm \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}},$$

det vill säga har bredden

$$L_{1-\alpha,n} = 2\lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

Med konfidensgrad $1 - \alpha = 0.90$ fås $\lambda_{\alpha/2} = \lambda_{0.05} = 1.6449$.

a) Vi söker n så att $L(0.90, n) = L(0.90, 5)/2$ [alternativt $L(0.90, 5)/10$].

$$2\lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} = 2\lambda_{\alpha/2} \frac{\sigma}{\sqrt{5}} / 2$$

ger $\sqrt{n} = 2\sqrt{5}$, eller $n = 4 \cdot 5 = 20$. Med en tiondel så brett fås $\sqrt{n} = 10\sqrt{5}$ eller $n = 100 \cdot 5 = 500$.

b) Vi söker n så att $L(0.99, n) = L(0.90, 5)$.

$$2\lambda_{0.005} \frac{\sigma}{\sqrt{n}} = 2\lambda_{0.05} \frac{\sigma}{\sqrt{5}}$$

ger $\sqrt{n} = \sqrt{5}\lambda_{0.005}/\lambda_{0.05}$ eller, med $\lambda_{0.005} = 2.5758$, $n = 5(\lambda_{0.005}/\lambda_{0.05})^2 = 12.26$, det vill säga 13 observationer.

c) Vi söker n så att $L(0.99, n) = L(0.90, 5)/2$ [alternativt $L(0.90, 5)/10$].

$$2\lambda_{0.005} \frac{\sigma}{\sqrt{n}} = 2\lambda_{0.05} \frac{\sigma}{\sqrt{5}} / 2$$

ger $\sqrt{n} = 2\sqrt{5}\lambda_{0.005}/\lambda_{0.05}$ eller, med $\lambda_{0.005} = 2.5758$, $n = 4 \cdot 5(\lambda_{0.005}/\lambda_{0.05})^2 = 49.047$, dvs. 50 stycken. Med en tiondel så brett fås $n = (10)^2 \cdot 5(\lambda_{0.005}/\lambda_{0.05})^2 = 1226.2$, dvs. 1227 stycken.

Notera att i denna lösning utnyttjade vi aldrig det uppmätta intervallet $[7.02, 7.14]$ eftersom vi inte behövde bestämma \bar{x} eller σ .

12.13 Låt x_1, \dots, x_n vara avkastningen i ton under $n = 10$ dagar. Dessa modelleras som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n . Alltså är $\bar{X} \sim N(\mu, \sigma/\sqrt{n})$ och

$$\frac{\bar{X} - \mu}{S/\sqrt{n}}$$

där S^2 ges av

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Således, med sannolikhet $1 - \alpha$ är

$$-\bar{t}_{\alpha/2} \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq \bar{t}_{\alpha/2},$$

vilket omskrivet ger att med sannolikhet $1 - \alpha$ är

$$\bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}}.$$

Med $n = 10$ observationer och konfidensgrad $1 - \alpha = 0.95$ fås ur $t(n-1) = t(9)$ -tabell att $t_{\alpha/2} = t_{0.025} = 2.26$. Vidare beräknas

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 7.51 \quad s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = 0.1543$$

$s = \sqrt{s^2} = 0.3929$, så konfidensintervallet blir

$$\mu \in \bar{x} \pm t_{\alpha/2} \frac{s}{\sqrt{n}} = 7.51 \pm 0.281 = [7.229, 7.791] \quad (95\%).$$

12.14 Från uppgift 12.11 vet vi att

$$\frac{(\bar{X} - \Delta) - \mu}{\sigma/\sqrt{n}} \sim N(0, 1).$$

Standardavvikelsen σ skattas med

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = 0.042426$$

så

$$\frac{(\bar{X} - \Delta) - \mu}{S/\sqrt{n}} \sim t(n-1)\text{-fördelad.}$$

Med sannolikhet $1 - \alpha$ är

$$(\bar{X} - \Delta) - t_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq (\bar{X} - \Delta) + t_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

där kvantilen $t_{\alpha/2}$ fås ur $t(n-1)$ -tabell.

Med $n = 4$ observationer fås $\bar{x} = 8.2$. Konfidensgrad $1 - \alpha = 0.99$ ger $t_{\alpha/2} = t_{0.005} = 5.8409$ och intervallet

$$\mu \in (\bar{x} - \Delta) \pm t_{\alpha/2} \frac{s}{\sqrt{n}} = (8.2 - 0.1) \pm 5.8409 \frac{0.042426}{\sqrt{4}} = 8.1 \pm 0.1239 \quad (99\%)$$

eller

$$7.9761 \leq \mu \leq 8.2239 \quad (99\%).$$

12.15

12.16 Baserat på observationer x_1, \dots, x_n av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler ges ett konfidensintervall, med konfidensgrad $1 - \alpha$, för μ av

$$\bar{x} - t_{\alpha/2} \frac{s}{\sqrt{n}} \leq \mu \leq \bar{x} + t_{\alpha/2} \frac{s}{\sqrt{n}}.$$

Intervallet $(\bar{x} - s, \bar{x} + s)$ har konfidensgrad åtminstone 99% om n är sådan att $t_{0.005}/\sqrt{n} < 1$.

| n | $t_{0.005}$ | $t_{0.005}/\sqrt{n}$ | n | $t_{0.005}$ | $t_{0.005}/\sqrt{n}$ |
|-----|-------------|----------------------|-----|-------------|----------------------|
| 1 | 63.657 | 63.657 | 7 | 3.4995 | 1.3227 |
| 2 | 9.9248 | 7.0179 | 8 | 3.3554 | 1.1863 |
| 3 | 5.8409 | 3.3723 | 9 | 3.2498 | 1.0833 |
| 4 | 4.6041 | 2.3020 | 10 | 3.1693 | 1.0022 |
| 5 | 4.0321 | 1.8032 | 11 | 3.1058 | 0.93644 |
| 6 | 3.7074 | 1.5136 | 12 | 3.0545 | 0.88177 |

Ur tabellen får vi att $n \geq 11$.

12.17 Skattningen

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

av σ^2 beskrivs av S^2 som är sådan att $(n-1)S^2/\sigma^2$ är en $\chi^2(n-1)$ -fördelad stokastisk variabel. Alltså kan man ur $\chi^2(n-1)$ -tabeller bestämma kvantilerna $\chi^2_{1-\alpha/2}$ och $\chi^2_{\alpha/2}$ så att

$$P\left(\chi^2_{1-\alpha/2} \leq \frac{(n-1)S^2}{\sigma^2} \leq \chi^2_{\alpha/2}\right) = 1 - \alpha$$

eller, omformulerat, med sannolikhet $1 - \alpha$ är

$$\frac{(n-1)S^2}{\chi^2_{\alpha/2}} \leq \sigma^2 \leq \frac{(n-1)S^2}{\chi^2_{1-\alpha/2}}.$$

Med $n = 8$ observationer och skattningen $s = 5.2$ fås ur $\chi^2(7)$ -tabell att $\chi^2_{0.975} = 1.69$ och $\chi^2_{0.025} = 16.0$. Alltså är ett 95% konfidensintervall för σ^2

$$11.821 = \frac{(8-1)(5.2)^2}{16.0} \leq \sigma^2 \leq \frac{(8-1)(5.2)^2}{1.69} = 112.01.$$

Motsvarande intervall för σ är

$$3.44 = \sqrt{11.821} \leq \sigma \leq \sqrt{112.01} = 10.6 \quad (95\%).$$

12.18

Låt x_1, \dots, x_n vara furuplankornas uppmätta längder. Dessa modelleras som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n . Väntevärdet μ skattas med \bar{X} som beskrivs av \bar{X} som är $N(\mu, \sigma/\sqrt{n})$. Alltså är

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)\text{-fördelad.}$$

och med sannolikhet $1 - \alpha$ är

$$-t_{\alpha/2}(n-1) \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq t_{\alpha/2}(n-1)$$

eller, omformulerat, med sannolikhet $1 - \alpha$ är

$$\mu \in \bar{X} \pm t_{\alpha/2}(n-1) \frac{S}{\sqrt{n}}.$$

Med observationer x_1, \dots, x_n , $n = 16$:

$$\begin{array}{cccccccc} 5.8 & 5.9 & 5.1 & 3.5 & 4.2 & 4.9 & 5.3 & 5.3 \\ 4.7 & 3.9 & 4.5 & 4.1 & 4.0 & 4.2 & 4.7 & 4.8 \end{array}$$

fås skattningarna

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 4.6812$$

och

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{0.46962} = 0.68529.$$

Med konfidensgrad $1 - \alpha = 0.95$ fås att $t_{\alpha/2}(15) = t_{0.025}(15) = 2.1314$ och konfidensintervallet blir

$$\mu \in 4.6812 \pm 2.1314 \frac{0.68529}{\sqrt{16}} = 4.6812 \pm 0.36517 = [4.3161, 5.0464] \quad (95\%).$$

b) Vi vet att

$$\frac{(n-1)S^2}{\sigma^2} \text{ är } \chi^2(n-1)\text{-fördelad}$$

om $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ där X_i är oberoende $N(\mu, \sigma)$. Alltså är

$$P \left(\chi^2_{1-\alpha/2} \leq \frac{(n-1)S^2}{\sigma^2} \leq \chi^2_{\alpha/2} \right) = 1 - \alpha.$$

Med $\alpha = 0.05$ fås ur $\chi^2(n-1) = \chi^2(15)$ -tabeller

$$P \left(6.26 \leq \frac{(n-1)S^2}{\sigma^2} \leq 27.5 \right) = 0.95.$$

Alltså med sannolikhet 95% är

$$\frac{(n-1)S^2}{27.5} \leq \sigma^2 \leq \frac{(n-1)S^2}{6.26}.$$

Med skattningen $s^2 = 0.46962$ fås intervallet

$$0.25627 = \frac{(n-1)s^2}{27.5} \leq \sigma^2 \leq \frac{(n-1)s^2}{6.26} = 1.1249 \quad (95\%)$$

eller

$$0.50623 = \sqrt{0.25627} \leq \sigma \leq \sqrt{1.1249} = 1.0606 \quad (95\%).$$

12.19

12.20

12.21 Låt X_1, \dots, X_{n_x} beskriva de uppmätta överhöjningarna för betongelement från fabrik A och Y_1, \dots, Y_{n_y} motsvarande för fabrik B. Modell: alla stokastiska variabler är oberoende och X_i är $N(\mu_x, \sigma)$ och Y_i är $N(\mu_y, \sigma)$. Då är

$$\frac{(\bar{X} - \bar{Y}) - (\mu_x - \mu_y)}{S \sqrt{\frac{1}{n_x} + \frac{1}{n_y}}} \text{ är } t(n_x + n_y - 2)\text{-fördelad,}$$

där

$$S^2 = \frac{(n_x - 1)S_x^2 + (n_y - 1)S_y^2}{n_x + n_y - 2}.$$

Alltså är med sannolikhet $1 - \alpha$

$$\mu_x - \mu_y \in \bar{X} - \bar{Y} \pm t_{\alpha/2} S \sqrt{\frac{1}{n_x} + \frac{1}{n_y}}$$

Med observationer

$$\bar{x} = 18.1, s_x = 5.0, n_x = 9 \quad \bar{y} = 14.6, s_y = 7.1, n_y = 16$$

fås

$$s = \sqrt{\frac{(n_x - 1)s_x^2 + (n_y - 1)s_y^2}{n_x + n_y - 2}} = \sqrt{41.572} = 6.4476.$$

Ur $t(n_x + n_y - 2) = t(23)$ -tabeller fås att med konfidensgrad $1 - \alpha = 0.99$ är $t_{\alpha/2} = t_{0.005} = 2.8073$ så konfidensintervallet blir

$$\mu_x - \mu_y \in 18.1 - 14.6 \pm 2.8073 \cdot 6.4476 \sqrt{\frac{1}{9} + \frac{1}{16}} = 3.5 \pm 7.54 \quad (99\%)$$

eller intervallet $[-4.04, 11.0]$.

12.22 Blodtrycksmätningarna före och efter behandling sammanfattas i tabellen:

| Person nr, i | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
|-------------------------------|----|----|----|----|-----|----|----|----|----|-----|
| Blodtryck före, x_i | 75 | 70 | 75 | 65 | 95 | 70 | 65 | 70 | 65 | 90 |
| Blodtryck efter, y_i | 85 | 70 | 80 | 80 | 100 | 90 | 80 | 75 | 90 | 100 |
| Förändring, $w_i = y_i - x_i$ | 10 | 0 | 5 | 15 | 5 | 20 | 15 | 5 | 25 | 10 |

Vi modellerar x_i som utfall av en $N(\mu_i, \sigma_1)$ -fördelad stokastiska variabel $X_i, i = 1, \dots, n$, och y_i som ett utfall av en $N(\mu_i + \Delta, \sigma_2)$ -fördelad stokastiska variabel $Y_i, i = 1, \dots, n$. Parametrarna μ_i är personens blodtryck före behandling och Δ är den genomsnittliga behandlingseffekten. Blodtrycksförändringarna $w_i = y_i - x_i$ är utfall av oberoende $N(\Delta, \sigma)$ -fördelade stokastiska variabler $W_1, \dots, W_n, i = 1, \dots, n$.

Vi skattar Δ med $\Delta_{\text{obs}}^* = \bar{w} = 11$ och σ med

$$s_w = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (w_i - \bar{w})^2} = 7.746.$$

Ur $t(n-1) = t(9)$ -tabell fås att $t_{0.025} = 2.2622$ och ett 95% konfidensintervall för Δ ges av

$$\Delta \in \bar{w} \pm t_{0.025} \frac{s}{\sqrt{n}} = 11 \pm 2.26 \cdot \frac{7.746}{\sqrt{10}} = 11 \pm 5.5 \quad (95\%).$$

12.23 Mätningarna x_1, \dots, x_n på lösningen med okänt pH-värde modelleras av oberoende $N(\mu + \Delta, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n .

Vidare, låt y_1, \dots, y_m vara de sex bestämningarna på en lösning med det kända pH-värdet 4.84. Dessa modelleras som utfall av oberoende $N(4.84 + \Delta, \sigma)$ -fördelade stokastiska variabler Y_1, \dots, Y_m .

En skattning av Δ är $\Delta_{\text{obs}}^* = \bar{y} - 4.84 = 4.7 - 4.84 = -0.14$. Detta är en väntevärdesriktig skattning ty

$$E(\Delta^*) = E(\bar{Y} - 4.84) = E(\bar{Y}) - 4.84 = 4.84 + \Delta - 4.84 = \Delta.$$

Vidare så är

$$V(\Delta^*) = V(\bar{Y} - 4.84) = V(\bar{Y}) = \frac{\sigma^2}{m}.$$

a) En skattning av $\mu + \Delta$ är $\bar{x} = 4.285$ så en skattning av μ fås som $\mu_{\text{obs}}^* = \bar{x} - \Delta_{\text{obs}}^* = 4.425$. Denna är väntevärdesriktig ty

$$E(\mu^*) = E(\bar{X} - \Delta^*) = E(\bar{X}) - E(\Delta^*) = (\mu + \Delta) - \Delta = \mu.$$

b) Här är

$$V(\mu^*) = V(\bar{X} - \Delta^*) = \{ \text{oberoende} \} = V(\bar{X}) + (-1)^2 V(\Delta^*) = \frac{\sigma^2}{n} + \frac{\sigma^2}{m} = \frac{(n+m)\sigma^2}{nm}$$

så $D(\mu^*) = \sigma \sqrt{\frac{n+m}{nm}}$.

c) För att skatta $D(\mu^*)$ måste σ skattas. Från x_1, \dots, x_n har vi skatningen

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = 0.072342$$

och från y_1, \dots, y_m har vi att σ kan skattas med

$$s_y = \sqrt{\frac{1}{m-1} \sum_{i=1}^m (y_i - \bar{y})^2} = 0.089443.$$

Båda dessa skatningar kombineras till s , där

$$s^2 = \frac{(n-1)s_x^2 + (m-1)s_y^2}{(n-1) + (m-1)} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^m (y_i - \bar{y})^2}{n+m-2} = 0.0069625$$

så $s = 0.083442$. Standardavvikelsen $D(\mu^*) = \sigma \sqrt{\frac{n+m}{nm}}$ skattas med

$$s \sqrt{\frac{n+m}{nm}} = 0.083442 \sqrt{\frac{4+6}{24}} = 0.053861,$$

det vill säga medelfelet $d(\mu^*) = 0.054$.

d) Ur $t(n+m-2) = t(8)$ -tabeller fås $t_{0.025} = 2.306$ och ett 95% konfidensintervall för μ ges av

$$\mu \in \mu_{\text{obs}}^* \pm t_{0.025} d(\mu^*) = 4.425 \pm 2.306 \cdot 0.053861 = 4.425 \pm 0.124 \quad (95\%).$$

12.24 Observationerna x_1, \dots, x_n och y_1, \dots, y_n sammanfattas av tabellen:

| Förare, i | 1 | 2 | 3 | 4 | 5 |
|--|-----|-----|------|-----|-----|
| Förlitning däcktyp A, x_i | 1.0 | 0.9 | 0.7 | 1.5 | 0.5 |
| Förlitning däcktyp B, y_i | 0.9 | 0.7 | 0.8 | 1.2 | 0.5 |
| Förlitningsskillnad, $w_i = x_i - y_i$ | 0.1 | 0.2 | -0.1 | 0.3 | 0 |

De uppmätta parvisa förlitningsskillnaderna w_1, \dots, w_n modelleras som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler W_1, \dots, W_n där μ mäter hur mycket mer i genomsnitt A-däck slits än B-däck.

Parametrarna μ och σ^2 skattas med

$$\bar{w} = \frac{1}{n} \sum_{i=1}^n w_i = 0.10 \quad \text{respektive} \quad s_w^2 = \frac{1}{n-1} \sum_{i=1}^n (w_i - \bar{w})^2 = 0.025$$

så σ skattas med $s_w = \sqrt{0.025} = 0.1581$.

Med $n = 5$ observationer w_1, \dots, w_n och konfidensgrad $1 - \alpha = 0.95$ fås ur $t(n-1) = t(4)$ -tabell att $t_{\alpha/2} = t_{0.025} = 2.7764$, så det observerade intervallet för den genomsnittliga skillnaden i däckförlitning blir

$$\mu \in \bar{w} \pm t_{\alpha/2} \frac{s_w}{\sqrt{n}} = 0.10 \pm 0.1963 = [-0.0963, 0.2963] \quad (95\%).$$

12.25 a) Observationerna x_1, \dots, x_{n_1} av levervärden för personer utan medicinering modelleras som utfall av $N(\mu_x, \sigma)$ -fördelade stokastiska variabler. Observationerna y_1, \dots, y_{n_2} av levervärden för personer med behandling modelleras som utfall av $N(\mu_y, \sigma)$ -fördelade stokastiska variabler. Samtliga stokastiska variabler förutsätts vara oberoende.

Med $n_1 = 50$ och $n_2 = 25$ erhöll man

$$\bar{x} = 148.2 \quad \bar{y} = 151.7 \quad s_x = 10.0 \quad s_y = 8.0$$

så skillnaden $\mu_y - \mu_x$ skattas med $\bar{y} - \bar{x} = 3.5$.

Standardavvikelsen σ skattas med s där

$$s^2 = \frac{(n_1 - 1)s_x^2 + (n_2 - 1)s_y^2}{(n_1 - 1) + (n_2 - 1)} = \frac{\sum_{i=1}^{n_1} (x_i - \bar{x})^2 + \sum_{i=1}^{n_2} (y_i - \bar{y})^2}{n_1 + n_2 - 2} = 88.164$$

så $s = 9.3896$. Eftersom $D(\bar{Y} - \bar{X}) = \sigma \sqrt{\frac{1}{n_2} + \frac{1}{n_1}}$ så är medelfelet $d(\bar{Y} - \bar{X}) = s \sqrt{\frac{1}{n_2} + \frac{1}{n_1}} = 2.3$.

Ur $t(n_1 + n_2 - 2) = t(73)$ -tabeller fås $t_{0.025} = 1.993$ och ett 95% konfidensintervall för $\mu_y - \mu_x$ ges av

$$\mu_y - \mu_x \in (\bar{y} - \bar{x}) \pm t_{0.025} d(\bar{Y} - \bar{X}) = 3.5 \pm 1.993 \cdot 2.3 = 3.5 \pm 4.5 = [-1.08, 8.08] \quad (95\%).$$

b) Observationerna x_1, \dots, x_n av levervärden för personer före medicinering och y_1, \dots, y_n motsvarande efter medicinering, sammanfattas av

$$n = 25 \quad \bar{x} = 149.0 \quad \bar{y} = 150.9.$$

Förändringarna $z_i = y_i - x_i$ modelleras av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler Z_1, \dots, Z_n . Den genomsnittliga höjningen μ skattas med $\bar{z} = \bar{y} - \bar{x} = 1.9$ och σ skattas med $s_z = 1.6$.

Eftersom $D(\bar{Z}) = \sigma / \sqrt{n}$ så är medelfelet $d(\bar{Z}) = s_z / \sqrt{n} = 0.32$.

Ur $t(n - 1) = t(24)$ -tabeller fås $t_{0.025} = 2.064$ och ett 95% konfidensintervall för μ ges av

$$\mu \in \bar{z} \pm t_{0.025} d(\bar{Z}) = 1.9 \pm 2.064 \cdot 0.32 = 1.9 \pm 0.66 = [1.24, 2.56] \quad (95\%).$$

12.26

12.27 Låt x_1, \dots, x_{n_1} vara utfall av $N(\mu_1, \sigma)$ -fördelade stokastiska variabler och y_1, \dots, y_{n_2} vara utfall av $N(\mu_2, \sigma)$ -fördelade stokastiska variabler. Alla stokastiska variabler antas vara oberoende.

Skillnaden $\mu_1 - \mu_2$ skattas med $\bar{x} - \bar{y} = 49.2 - 37.4 = 11.8$. Vidare är $D(\bar{X} - \bar{Y}) = \sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$ där σ skattas med

$$s = \sqrt{\frac{(n_1 - 1)s_x^2 + (n_2 - 1)s_y^2}{(n_1 - 1) + (n_2 - 1)}} = \sqrt{\frac{\sum_{i=1}^{n_1} (x_i - \bar{x})^2 + \sum_{i=1}^{n_2} (y_i - \bar{y})^2}{n_1 + n_2 - 2}} = 2.157.$$

Alltså är medelfelet $d(\bar{X} - \bar{Y}) = s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} = 1.0785$. Ur $t(n_1 + n_2 - 2) = t(16)$ -tabeller fås $t_{0.05} = 1.7459$ och ett 90% konfidensintervall för $\mu_1 - \mu_2$ ges av

$$\mu_1 - \mu_2 \in \bar{x} - \bar{y} \pm t_{0.05} d(\bar{X} - \bar{Y}) = 11.8 \pm 1.7459 \cdot 1.0785 = 11.8 \pm 1.88 = [9.92, 11.8] \quad (90\%).$$

12.28

12.29 Låt x_1, \dots, x_n vara studietiderna för de $n = 25$ personerna som undersökts. Dessa modelleras som utfall av oberoende och likafördelade stokastiska variabler X_1, \dots, X_n med $E(X) = \mu$ och $D(X) = \sigma$. Väntevärde skattas med $\bar{x} = 49.3$ och σ med $s = 9.3$. Skattningen \bar{x} har medelfel $s/\sqrt{n} = 1.86$.

Med Centrala gränsvärdessatsen är $\sum_{i=1}^n X_i$ approximativt normalfördelad och således är \bar{X} approximativt $N(\mu, \sigma/\sqrt{n})$. Ett konfidensintervall för μ ges av

$$\mu \in \bar{x} \pm \lambda_{0.025} \frac{s}{\sqrt{n}} = 49.3 \pm 1.96 \cdot 1.86 = 49.3 \pm 3.65 = [45.654, 52.946] \quad (\approx 95\%).$$

- 12.30** Låt x_1, \dots, x_n , $n = 30$, vara de uppmätta föroreningshalterna uppströms och y_1, \dots, y_r , $r = 40$, motsvarande nedströms. Vi ansätter modellen att x_1, \dots, x_n är utfall av likafördelade stokastiska variabler X_1, \dots, X_n med $E(X) = \mu_x$ och $D(X) = \sigma_x^2$. På motsvarande sätt är y_1, \dots, y_r utfall av likafördelade Y_1, \dots, Y_r där $E(Y) = \mu_y$ och $D(Y) = \sigma_y^2$. Alla stokastiska variabler förutsätts vara oberoende.

Skillnaden $\mu_y - \mu_x$ skattas med $\bar{y} - \bar{x} = 86.1 - 13.2 = 72.9$. Skattningen $\bar{y} - \bar{x}$ är ett utfall av en stokastisk variabel $\bar{Y} - \bar{X}$ med standardavvikelse $D(\bar{Y} - \bar{X}) = \sqrt{\frac{\sigma_y^2}{r} + \frac{\sigma_x^2}{n}}$. Alltså har skattningen $\bar{y} - \bar{x}$ medelfel

$$d(\bar{Y} - \bar{X}) = \sqrt{\frac{s_y^2}{r} + \frac{s_x^2}{n}} = \sqrt{\frac{(38.7)^2}{40} + \frac{(2.80)^2}{30}} = 6.1403.$$

Med Centrala gränsvärdessatsen är $\sum_{i=1}^n X_i$ och $\sum_{i=1}^r Y_i$ approximativt normalfördelade och således är $\bar{Y} - \bar{X}$ approximativt $N\left(\mu_y - \mu_x, \sqrt{\frac{\sigma_y^2}{r} + \frac{\sigma_x^2}{n}}\right)$. Ett konfidensintervall för skillnaden $\mu_y - \mu_x$ ges av

$$\mu_y - \mu_x \in \bar{y} - \bar{x} \pm \lambda_{0.025} \sqrt{\frac{s_y^2}{r} + \frac{s_x^2}{n}} = 72.9 \pm 1.96 \cdot 6.1403 = 72.9 \pm 12.04 = [60.87, 84.94] \quad (\approx 95\%).$$

- 12.31** Av $n = 600$ undersökta enheter befanns $x = 24$ vara felaktiga. Om partiet är mycket stort kan vi modellera x som ett utfall av en binomialfördelad stokastisk variabel X , det vill säga X är $\text{Bin}(n, p)$ där p är andelen felaktiga enheter i partiet.

Vi skattar p med $p_{\text{obs}}^* = x/n = 0.04$. Skattningen p_{obs}^* beskrivs av $p^* = X/n$ som har

$$V(p^*) = V\left(\frac{1}{n}X\right) = \frac{1}{n^2} \underbrace{V(X)}_{np(1-p)} = \frac{p(1-p)}{n}$$

och standardavvikelse $D(p^*) = \sqrt{p(1-p)/n}$. Medelfelet för skattningen p_{obs}^* är

$$d(p^*) = \sqrt{\frac{p_{\text{obs}}^*(1-p_{\text{obs}}^*)}{n}} = \sqrt{\frac{0.040(1-0.040)}{600}} = 0.008.$$

Eftersom $V(X) = np(1-p)$ skattas med $np_{\text{obs}}^*(1-p_{\text{obs}}^*) = 23.04$ vilket är större än 10 kan binomialfördelningen approximeras med normalfördelningen. Alltså är även $p^* = X/n$ approximativt normalfördelad. Med $1 - \alpha = 0.95$ är $\lambda_{\alpha/2} = \lambda_{0.025} = 1.96$ och ett konfidensintervall för p ges av

$$p \in p_{\text{obs}}^* \pm \lambda_{0.025} d(p^*) = 0.040 \pm 1.96 \cdot 0.008 = 0.040 \pm 0.0157 = [0.024, 0.056] \quad (\approx 95\%).$$

12.32

- 12.33** Låt x_1 och x_2 vara antalet sympatisörer med det borgerliga blocket i oktober och november. Vi modellerar x_1 och x_2 som utfall av oberoende binomialfördelade stokastiska variabler X_1 och X_2 , där X_1 är $\text{Bin}(n_1, p_1)$ och X_2 är $\text{Bin}(n_2, p_2)$. Förändringen $p_2 - p_1$ skattas med $(p_2)_{\text{obs}}^* - (p_1)_{\text{obs}}^* = 0.456 - 0.465 = -0.009$. Eftersom

$$V(p_2^* - p_1^*) = \{\text{ober.}\} = V(p_2^*) + (-1)^2 V(p_1^*) = \frac{1}{n_2^2} V(X_2) + \frac{1}{n_1^2} V(X_1) = \frac{p_2(1-p_2)}{n_2} + \frac{p_1(1-p_1)}{n_1}$$

fås medelfelet för $(p_2)_{\text{obs}}^* - (p_1)_{\text{obs}}^*$ till

$$\begin{aligned} d(p_2^* - p_1^*) &= \sqrt{\frac{(p_2)_{\text{obs}}^*(1-(p_2)_{\text{obs}}^*)}{n_2} + \frac{(p_1)_{\text{obs}}^*(1-(p_1)_{\text{obs}}^*)}{n_1}} = \sqrt{\frac{0.456(1-0.456)}{1689} + \frac{0.465(1-0.465)}{1704}} \\ &= 0.017113. \end{aligned}$$

Varianserna $V(X_1) = n_1 p_1(1-p_1)$ och $V(X_2) = n_2 p_2(1-p_2)$ skattas med $n_1(p_1)_{\text{obs}}^*(1-(p_1)_{\text{obs}}^*) = 423.91$ respektive $n_2(p_2)_{\text{obs}}^*(1-(p_2)_{\text{obs}}^*) = 418.98$. Eftersom båda är större än 10 (med rågel!) kan binomialfördelningarna approximeras med normalfördelningar och även $p_2^* - p_1^*$ kan antas vara approximativt normalfördelad.

Med $1 - \alpha = 0.95$ fås $\lambda_{\alpha/2} = \lambda_{0.025} = 1.96$ och ett konfidensintervall för förändringen $p_2 - p_1$ ges av

$$p_2 - p_1 \in (p_2)_{\text{obs}}^* - (p_1)_{\text{obs}}^* \pm \lambda_{0.025} d(p_2^* - p_1^*) = -0.009 \pm 1.96 \cdot 0.017 = -0.009 \pm 0.0335 \quad (\approx 95\%).$$

12.34 Låt $x = 36$ vara antalet defekta bland de $n = 1000$ undersökta enheterna. Vi modellerar x som ett utfall av en hypergeometriskt fördelad stokastisk variabel X , X är Hypergeo(N, n, p) där $N = 100000$ och p är andelen defekta.

Andelen p skattas med $p_{\text{obs}}^* = x/n = 0.036$. Eftersom $V(X) = np(1-p)(N-n)/(N-1)$ skattas till

$$np_{\text{obs}}^*(1-p_{\text{obs}}^*) \frac{N-n}{N-1} = 1000 \cdot 0.036(1-0.036) \cdot 0.99 = 34.357$$

vilket är större än 10 kan den hypergeometriska fördelningen approximeras med en normalfördelning och även $p^* = X/n$ är approximativt normalfördelad. Medelfelet för p_{obs}^* är

$$d(p^*) = \sqrt{\frac{p_{\text{obs}}^*(1-p_{\text{obs}}^*)}{n} \cdot \frac{N-n}{N-1}} = \sqrt{\frac{0.036(1-0.036)}{1000} \cdot 0.99} = 0.0058615.$$

Med $1 - \alpha = 0.95$ fås $\lambda_{\alpha/2} = \lambda_{0.025} = 1.96$ och ett konfidensintervall för andelen defekta p ges av

$$p \in p_{\text{obs}}^* \pm \lambda_{0.025} d(p^*) = 0.036 \pm 1.96 \cdot 0.0058615 = 0.036 \pm 0.0115 \quad (\approx 95\%).$$

b) Det totala antalet defekta i partiet Np skattas med $Np_{\text{obs}}^* = 3600$. Denna skattning har medelfel

$$d(Np^*) = N \sqrt{\frac{p_{\text{obs}}^*(1-p_{\text{obs}}^*)}{n} \cdot \frac{N-n}{N-1}} = 586.15$$

Ett konfidensintervall för antalet defekta ges av

$$Np \in Np_{\text{obs}}^* \pm \lambda_{0.025} d(Np^*) = 3600 \pm 1.96 \cdot 586.15 = 3600 \pm 1149 \quad (\approx 95\%).$$

12.35

12.36

12.37 Låt x_1, \dots, x_n vara antal samtal under det aktuella tidsintervallet för de olika dagarna. Dessa modelleras som utfall av oberoende Poisson(μ)-fördelade stokastiska variabler X_1, \dots, X_n . Parametern μ (väntevärdet) skattas med

$$\mu_{\text{obs}}^* = \bar{x} = 100.88 \text{ samtal.}$$

Skattningen beskrivs av

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

där

$$Y = X_1 + \dots + X_n$$

är Poissonfördelad med väntevärde

$$E(Y) = E(X_1 + \dots + X_n) = E(X_1) + \dots + E(X_n) = n\mu$$

som skattas med $\sum x_i = 807$ vilket är större än 15 med råge. Alltså kan Poissonfördelningen för Y approximeras med normalfördelning, men då är även \bar{X} approximativt normalfördelad. Alltså,

$$\bar{X} \text{ är approximativt } N\left(\mu, \sqrt{\frac{\mu}{n}}\right)$$

Ett konfidensintervall för m med konfidensgrad approximativt $1 - \alpha = 0.95$ ges av

$$\mu \in \bar{x} \pm \lambda_{\alpha/2} \sqrt{\frac{\bar{x}}{n}} = 100.88 \pm 6.9599 = [93.9, 107.8] \quad (\approx 95\%).$$

12.38

12.39

12.40

13.1 Låt x vara antalet gånger som Pål svarar rätt.

- a) Om Pål chansar ansätter vi modellen att är x ett utfall av en binomialfördelad stokastisk variabel X , X är $\text{Bin}(n, p)$ med $n = 15$ och $p = 0.5$.
- b) I binomialfördelningen är

$$P(X \geq 11) = \sum_{k=11}^{15} \binom{n}{k} p^k (1-p)^{n-k} = 0.05923.$$

Om man har tillgång till fördelningsfunktionen för binomialfördelningen kan sannolikheten erhållas enligt

$$P(X \geq 11) = 1 - P(X < 11) = 1 - P(X \leq 10) = 1 - F_X(10) = 1 - 0.94077 = 0.05923.$$

13.2

13.3

13.4 Låt X beskriva en glödlampas lystid i timmar. Med modellen att X är exponentiaffördelad med väntevärde $\theta > 0$ har X täthetsfunktion

$$f_X(x) = \frac{1}{\theta} e^{-x/\theta}, \quad x \geq 0.$$

Fördelningsfunktionen för X blir då för $t > 0$

$$F_X(t) = P(X \leq t) = \int_{-\infty}^t f_X(x) dx = \int_0^t \frac{1}{\theta} e^{-x/\theta} dx = 1 - e^{-t/\theta}.$$

- a) Ekvationen $\alpha = P(X < a) = F_X(a) = 1 - e^{-a/\theta}$ ger $a = -\theta \ln(1 - \alpha)$ och med $\theta = 1000$ erhålls $a = -1000 \ln(1 - \alpha)$.
- b) Med $\alpha = 0.05$ är $a = -1000 \ln(1 - 0.05) = 51.293$. Vi förkastar hypotesen $\theta = 1000$ till förmån för hypotesen $\theta < 1000$ på signifikansnivå 5% om $x < 51.293$. Här är $x = 75$ och hypotesen $\theta = 1000$ förkastas ej.
- c) Med $x = 50 < 51.293$ förkastas hypotesen $\theta = 1000$ på nivå 5% till förmån för hypotesen $\theta < 1000$.
- d) Om a väljs så att $a = x = 45$ är

$$P(X < a) = F_X(a) = 1 - e^{-a/\theta} = 1 - e^{-45/1000} = 0.044003.$$

Alltså, den lägsta signifikansnivå hypotesen $\theta = 1000$ kan förkastas på, givet observationen $x = 45$, är 4.4%.

13.5 Låt x vara antalet spel till första vinst. Vi modellerar x som ett utfall av den ffg(p)-fördelade stokastiska variabeln X , det vill säga

$$p_X(k) = (1-p)^{k-1}p, \quad k = 1, 2, 3, \dots$$

Då är

$$P(X > k) = (1-p)^k, \quad k = 0, 1, 2, 3, \dots$$

Med $H_0 : p = 0.2$ och $H_1 : p < 0.2$ så förkastas H_0 till förmån för H_1 för stora värden på x . Med förkastelseområde $\{x, x+1, x+2, \dots, x\}$ är signifikansnivån för testet

$$P(X \geq x | H_0) = P(X > x-1 | H_0) = (1-p)^{x-1} \Big|_{p=0.20} = (0.80)^{x-1}.$$

Med utfallet $x = 11$ förkastas H_0 på (lägsta) signifikansnivå

$$P(X \geq 11 | H_0) = P(X > 10 | H_0) = (0.80)^{10} = 0.1074.$$

Alltså, vi förkastar inte H_0 på nivå 10%.

13.6 Med x_1, \dots, x_n som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n är \bar{x} ett utfall av \bar{X} som är $N(\mu, \sigma/\sqrt{n})$ -fördelad. Ett test av

$$H_0 : \mu = 0.5 \text{ (oskyldig)} \quad \text{mot} \quad H_1 : \mu > 0.5 \text{ (skyldig)}$$

görs på signifikansnivå $\alpha = 1\%$ om H_0 förkastas då $\bar{x} > 0.5 + \lambda_{0.01}\sigma/\sqrt{n}$. Eftersom $P(\text{Förkasta sann } H_0) \leq \alpha$ kommer sannolikheten för att en oskyldig person förklaras skyldig vara högst 1%, dvs alternativ 2 är en riktig tolkning.

I alternativ 3 beskrivs sannolikheten för fel av andra slaget, det vill säga $P(\text{ej förkasta falsk } H_0)$ och den begränsas inte av signifikansnivån. Alternativ 1 och 4 är en form av omvänta betingade sannolikheter: givet att hypotesen förkastas, vad är sannolikheten...

13.7 Vi modellerar de uppmätta planklängderna x_1, \dots, x_n som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n . Vi vill testa hypotesen

$$H_0 : \sigma = 0.4 \quad \text{mot} \quad H_1 : \sigma \neq 0.4$$

på signifikansnivå $\alpha = 0.05$.

Alternativ 1. Med skattningen $s^2 = 0.46962$ fås ett konfidensintervall för σ med konfidensgrad $1 - \alpha = 0.95$ av (uppgift 12.18b)

$$0.50623 = \sqrt{\frac{(n-1)s^2}{27.5}} \leq \sigma \leq \sqrt{\frac{(n-1)s^2}{6.26}} = 1.0606 \quad (95\%).$$

Eftersom 0.4 inte ingår i intervallet förkastas $H_0 : \sigma = 0.4$ till förmån för H_1 på risknivå $\alpha = 0.05$.

Alternativ 2. Vi förkastar H_0 då s är mycket större eller mycket mindre än 0.4, alternativt då

$$\frac{(n-1)s^2}{0.4^2}$$

är väldigt stor eller väldigt liten. Då H_0 är sann så är

$$\frac{(n-1)S^2}{0.4^2} \quad \text{en} \quad \chi^2(n-1)\text{-fördelad stokastisk variabel.}$$

Alltså, med $\alpha = 0.05$ så är

$$P\left(6.26 \leq \frac{(n-1)S^2}{0.4^2} \leq 27.5\right) = 0.95.$$

Vi förkastar H_0 till förmån för H_1 om vi observerar att $(n - 1)s^2/0.4^2$ mindre än 6.26 eller större än 27.5. Här:

$$\frac{(n - 1)s^2}{0.4^2} = 44.027$$

så H_0 förkastas på nivå $\alpha = 0.05$.

13.8 Vi modellerar den uppmätta grumligheten x_1, \dots, x_n som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n där $\sigma = 0.2$. Vi vill testa hypotesen

$$H_0 : \mu = 4.0 \quad \text{mot} \quad H_1 : \mu > 4.0$$

på signifikansnivå $\alpha = 0.05$.

Alternativ 1: Vi förkastar H_0 för stora värden på \bar{x} , alternativ, då $(\bar{x} - 4)/(\sigma/\sqrt{n})$ är stor. Då H_0 är sann är

$$\frac{\bar{X} - 4}{\sigma/\sqrt{n}} \sim N(0, 1)$$

så $P((\bar{X} - 4)/(\sigma/\sqrt{n}) > \lambda_{0.05}|H_0) = 0.05$.

Alltså, H_0 förkastas om $(\bar{x} - 4)/(\sigma/\sqrt{n}) > \lambda_{0.05}$. Här är $\lambda_{0.05} = 1.6449$ och $\bar{x} = 4.1$ och

$$\frac{\bar{x} - 4}{\sigma/\sqrt{n}} = \frac{4.1 - 4}{0.2/\sqrt{10}} = 1.5811 < \lambda_{0.05},$$

så H_0 förkastas ej på nivå 5%.

Alternativ 2: Vi förkastar H_0 för stora värden på \bar{x} . Då H_0 är sann är

$$P(\bar{X} > x|H_0) = P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} > \frac{x - \mu}{\sigma/\sqrt{n}} \mid H_0\right) = 1 - \Phi\left(\frac{x - 4.0}{0.2/\sqrt{10}}\right).$$

Med observationen $\bar{x} = 4.1$ fås att den lägsta signifikansnivån H_0 kan förkastas på är

$$P(\bar{X} > 4.1|H_0) = 1 - \Phi\left(\frac{4.1 - 4.0}{0.2/\sqrt{10}}\right) = 1 - \Phi(1.5811) = 0.056923 > 0.05.$$

Alltså kan vi inte förkasta H_0 på nivå 5%.

13.9 Teststorheten

$$\frac{\bar{X} - 4}{\sigma/\sqrt{n}}$$

är normalfördelad med väntevärde

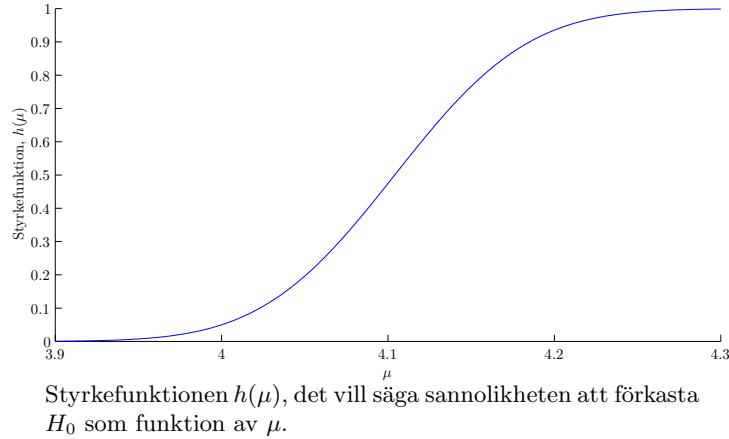
$$E\left(\frac{\bar{X} - 4}{\sigma/\sqrt{n}}\right) = \frac{E(\bar{X}) - 4}{\sigma/\sqrt{n}} = \frac{\mu - 4}{\sigma/\sqrt{n}}$$

och varians

$$V\left(\frac{\bar{X} - 4}{\sigma/\sqrt{n}}\right) = \frac{V(\bar{X})}{\sigma^2/n} = \frac{\sigma^2/n}{\sigma^2/n} = 1.$$

Styrkefunktionen blir då

$$\begin{aligned} h(\mu) &= P(\text{Förkasta } H_0) = P\left(\frac{\bar{X} - 4}{\sigma/\sqrt{n}} > \lambda_{0.05}\right) = P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} > \lambda_{0.05} + \frac{4 - \mu}{\sigma/\sqrt{n}}\right) \\ &= 1 - \Phi\left(\lambda_{0.05} + \frac{4 - \mu}{\sigma/\sqrt{n}}\right). \end{aligned}$$



$$\begin{aligned} h(3.8) &= 1 - \Phi\left(1.6449 + \frac{4-3.8}{0.2/\sqrt{10}}\right) = 1 - \Phi(4.8071) = 7.7 \cdot 10^{-7} \\ h(4.3) &= 1 - \Phi\left(1.6449 + \frac{4-4.3}{0.2/\sqrt{10}}\right) = 1 - \Phi(-3.0986) = 0.99903. \end{aligned}$$

13.10 Låt x_1, \dots, x_n vara de uppmätta smältpunkterna. Vi modellerar x_1, \dots, x_n som utfall av oberoende och likafördelade stokastiska variabler X_1, \dots, X_n , där

$$X = \text{smältpunkt} + \text{mätfel} = \mu + \epsilon$$

där ϵ är $N(0, \sigma)$, $\sigma = 2.3$. Då är $X_i \sim N(\mu, \sigma)$. Vi vill testa:

$$H_0 : \mu = \mu_0 = 1050^\circ \quad \text{mot} \quad H_1 : \mu \neq \mu_0$$

på nivå $\alpha = 0.05$.

Vi förkastar H_0 för stora värden på $|\bar{x} - \mu_0|$, alternativt stora värden på $|z|$ där

$$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$$

som då H_0 är sann är ett utfall på Z , en $N(0, 1)$ -fördelad stokastisk variabel.

Alternativ 1: Alltså, om H_0 är sann så är $P(|Z| > \lambda_{\alpha/2}) = \alpha$. Med $\alpha = 0.05$ är $\lambda_{\alpha/2} = 1.96$ och vi förkastar H_0 till förmån för H_1 om vi observerar ett utfall $|z| > 1.96$. Här fås

$$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{1050.9 - 1050}{2.3/\sqrt{10}} = 1.2649$$

så H_0 förkastas ej till förmån för H_1 på nivå $\alpha = 0.05$.

Alternativ 2: Vi observerar utfallet

$$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{1050.9 - 1050}{2.3/\sqrt{10}} = 1.2649.$$

Om H_0 är sann är

$$P(|Z| > 1.2649) = 2(1 - \Phi(1.2649)) = 0.2059$$

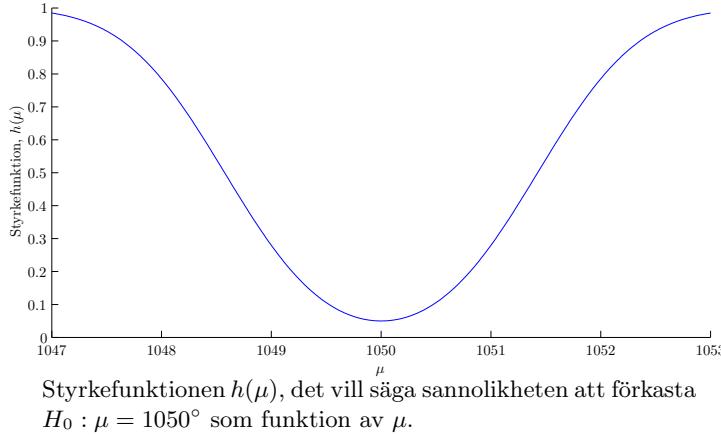
så den lägsta signifikansnivå vi skulle förkasta H_0 på är 0.2059, det vill säga vi förkastar inte H_0 på nivå 5%.

Styrkefunktionen $h(\mu)$ kan bestämmas som

$$\begin{aligned} h(\mu) &= P(\text{förkasta } H_0) = P\left(\left|\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}\right| > \lambda_{\alpha/2}\right) = 1 - P\left(-\lambda_{\alpha/2} \leq \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \leq \lambda_{\alpha/2}\right) \\ &= 1 - P\left(-\lambda_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma/\sqrt{n}} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \lambda_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma/\sqrt{n}}\right) \\ &= 1 - \left(\Phi\left(\lambda_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma/\sqrt{n}}\right) - \Phi\left(-\lambda_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma/\sqrt{n}}\right)\right) \end{aligned}$$

Vi beräknar

$$h(1051) = 0.27968 \quad h(1053) = 0.9848.$$



13.11

13.12 Om σ inte är känd så skattas den med stickprovsstandardavvikelsen $s = 2.028$.

Vi förkastar H_0 för stora värden på $|\bar{x} - \mu_0|$, alternativt stora värden på $|t|$ där

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

som då H_0 är sann är ett utfall av en $t(n-1)$ -fördelad stokastisk variabel T . Alltså, om H_0 är sann så är $P(|T| > t_{\alpha/2}) = \alpha$. Med $\alpha = 0.05$ är $t_{\alpha/2} = 2.2622$ och vi förkastar H_0 till förmån för H_1 om vi observerar $|t| > 2.2622$. Här fås

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{1050.9 - 1050}{2.028/\sqrt{10}} = 1.4345$$

så H_0 förkastas ej till förmån för H_1 på nivå $\alpha = 0.05$.

13.13 Ur uppgift 12.24 fås att ett konfidensintervall för den genomsnittliga förslitningsskillnaden μ är

$$\mu \in \bar{w} \pm t_{\alpha/2} \frac{s_w}{\sqrt{n}} = 0.10 \pm 0.1963 = [-0.0963, 0.2963] \quad (95\%).$$

Eftersom $\mu = 0$ inte är ett orimligt värde på förslitningsskillnaden, 0 ingår i konfidensintervallet, kan inte hypotesen $H_0 : \mu = 0$ förkastas till förmån för $H_1 : \mu \neq 0$ på nivå 5%.

13.14

13.15 Låt x_1, \dots, x_n vara de uppmätta Hg-halterna i gäddorna. Dessa modelleras som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n .

a) Vi vill med $\mu_0 = 0.9$ testa hypotesen

$$H_0 : \mu = \mu_0 \quad \text{mot} \quad H_1 : \mu > \mu_0$$

på nivå $\alpha = 0.05$.

Vi förkastar H_0 för stora värden på

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

som då H_0 är sann är ett utfall av en $t(n-1)$ -fördelad stokastisk variabel T . Alltså, om H_0 är sann så är $P(T > t_\alpha) = \alpha$. Med $\alpha = 0.05$ är $t_\alpha = 1.8331$ och vi förkastar H_0 till förmån för H_1 om vi observerar $t > 1.8331$. Här fås

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{0.97 - 0.9}{0.33015/\sqrt{10}} = 0.67048$$

så H_0 förkastas ej till förmån för H_1 på nivå $\alpha = 0.05$.

b) Vi vill med $\mu_0 = 1.1$ testa hypotesen

$$H_0 : \mu = \mu_0 \quad \text{mot} \quad H_1 : \mu < \mu_0$$

på nivå $\alpha = 0.05$.

Vi förkastar H_0 för små värden på

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

som då H_0 är sann är ett utfall av en $t(n-1)$ -fördelad stokastisk variabel T . Alltså, om H_0 är sann så är $P(T < t_{1-\alpha}) = \alpha$. Med $\alpha = 0.05$ är $t_{1-\alpha} = -1.8331$ och vi förkastar H_0 till förmån för H_1 om vi observerar $t < -1.8331$. Här fås

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{0.97 - 1.1}{0.33015/\sqrt{10}} = -1.2452$$

så H_0 förkastas ej till förmån för H_1 på nivå $\alpha = 0.05$.

13.16 Observationerna x_1, \dots, x_n och y_1, \dots, y_n sammanfattas av tabellen:

| Person, i | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
|-----------------------------|-----|-----|-----|-----|-----|-----|-----|-----|
| Morgon, x_i | 172 | 168 | 180 | 181 | 160 | 163 | 165 | 177 |
| Kväll, y_i | 172 | 167 | 177 | 179 | 159 | 161 | 166 | 175 |
| Skillnad, $w_i = x_i - y_i$ | 0 | 1 | 3 | 2 | 1 | 2 | -1 | 2 |

De uppmätta parvisa längdskillnaderna w_1, \dots, w_n modelleras som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler W_1, \dots, W_n där μ mäter hur mycket längre i genomsnitt personerna är på morgonen än på kvällen.

Parametrarna μ och σ^2 skattas med

$$\bar{w} = \frac{1}{n} \sum_{i=1}^n w_i = 1.25 \quad \text{respektive} \quad s_w^2 = \frac{1}{n-1} \sum_{i=1}^n (w_i - \bar{w})^2 = 1.6429$$

så σ skattas med $s_w = \sqrt{1.6429} = 1.2817$.

Vi vill testa

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

på nivå $\alpha = 0.05$.

Alternativ 1: Vi förkastar H_0 för stora värden på $|t|$ där

$$t = \frac{\bar{w} - 0}{s/\sqrt{n}}$$

som då H_0 är sann är ett utfall av en $t(n-1)$ -fördelad stokastisk variabel T . Alltså, om H_0 är sann så är $P(|T| > t_{\alpha/2}) = \alpha$. Med $\alpha = 0.05$ är $t_{\alpha/2} = 2.3646$ och vi förkastar H_0 till förmån för H_1 om vi observerar $|t| > 2.3646$. Här fås

$$t = \frac{\bar{w} - 0}{s/\sqrt{n}} = \frac{1.25 - 0}{1.2817/\sqrt{8}} = 2.7584$$

så H_0 förkastas till förmån för H_1 på nivå $\alpha = 0.05$.

Alternativ 2: Med $n = 8$ observationer w_1, \dots, w_n och konfidensgrad $1 - \alpha = 0.95$ fås ur $t(n-1) = t(7)$ -tabell att $t_{\alpha/2} = t_{0.025} = 2.3646$, så konfidensintervallet för den genomsnittliga längdskillnaden blir

$$\mu \in \bar{w} \pm t_{\alpha/2} \frac{s_w}{\sqrt{n}} = 1.25 \pm 1.072 = [0.17844, 2.3216] \text{ cm} \quad (95\%).$$

Eftersom $\mu = 0$ inte är ett rimligt värde enligt konfidensintervallet förkastas hypotesen $H_0 : \mu = 0$ till förmån för $H_1 : \mu \neq 0$ på nivå 5%.

13.17 Låt x_1, \dots, x_n vara mätningarna av molekulvikt A och y_1, \dots, y_m motsvarande för B. Dessa värden modelleras som utfall av $N(\mu_1, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n respektive $N(\mu_2, \sigma)$ -fördelade stokastiska variabler Y_1, \dots, Y_m . Alla stokastiska variabler antas vara oberoende.

Vi vill testa:

$$H_0 : \mu_1 = \mu_2 \quad \text{mot} \quad H_1 : \mu_1 \neq \mu_2.$$

Dessa hypoteser formuleras som

$$H_0 : \mu_1 - \mu_2 = 0 \quad \text{mot} \quad H_1 : \mu_1 - \mu_2 \neq 0.$$

Vi förkastar H_0 till förmån för H_1 för stora värden på $|t|$ där

$$t = \frac{\bar{x} - \bar{y}}{s \sqrt{\frac{1}{n} + \frac{1}{m}}}$$

och s är skattningen av σ som ges av

$$s^2 = \frac{(n-1)s_x^2 + (m-1)s_y^2}{(n-1) + (m-1)} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^m (y_i - \bar{y})^2}{n+m-2}.$$

Om H_0 är sann så är t ett utfall på en $t(n+m-2)$ -fördelad stokastisk variabel T . Ur $t(6+8-2) = t(12)$ -tabell fås att $P(|T| > t_{0.025}) = 0.05$ för $t_{0.025} = 2.1788$. Alltså, om H_0 förkastas då $|t| > 2.1788$ så har testet signifikansnivå 5%.

b) Med observationer

| | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| x_1, \dots, x_6 | 174.18 | 174.30 | 174.23 | 174.29 | 174.36 | 174.25 | | |
| y_1, \dots, y_8 | 174.19 | 174.40 | 174.20 | 174.35 | 174.32 | 174.14 | 174.27 | 174.34 |

fås

$$\bar{x} = 174.27, s_x = 0.062423 \quad \bar{y} = 174.28, s_y = 0.091486$$

vilket ger

$$s = 0.080659 \quad \text{och} \quad t = \frac{\bar{x} - \bar{y}}{s \sqrt{\frac{1}{n} + \frac{1}{m}}} = \frac{174.27 - 174.28}{0.080659 \sqrt{\frac{1}{6} + \frac{1}{8}}} = -0.18174.$$

Eftersom $|t| < 2.1788$ kan inte H_0 förkastas på nivå 5%.

13.18

13.19

- 13.20** Låt x_1, \dots, x_n vara de uppmätta alkoholhalterna i flaskorna. Vi modellerar x_1, \dots, x_n som utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n , där $\sigma = 0.10$. Vi vill testa:

$$H_0 : \mu = 3.0\% = \mu_0 \quad \text{mot} \quad H_1 : \mu < \mu_0$$

på nivå $\alpha = 0.01$. Signifikansnivån begränsar sannolikheten för att förkasta en korrekt nollhypotes, det vill säga att dra slutsatsen att en flaska har liten alkoholhalt fast den egentligen är hög.

Vi förkastar H_0 då för små värden på

$$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$$

som om H_0 är sann är ett utfall på en $N(0, 1)$ -fördelad stokastisk variabel Z .

Alternativ 1: Ur $N(0, 1)$ -tabell får att $\lambda_{0.01} = 2.3263$ och $P(Z < -2.3263) = 0.01$. Vi observerar utfallet

$$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{2.98 - 3.0}{0.10/\sqrt{10}} = -0.632 > -\lambda_{0.01}.$$

Vi förkastar inte H_0 på nivå 1%.

Alternativ 2: Vi observerar utfallet

$$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{2.98 - 3.0}{0.10/\sqrt{10}} = -0.632.$$

Vi har att då H_0 är sann så är

$$P(\text{Förkasta } H_0) = P(Z < -0.632) = \Phi(-0.632) = 1 - \Phi(0.632) = 0.26354$$

vilket är den längsta signifikansnivå H_0 kan förkastas på. Vi kan inte förkasta H_0 på nivå 1%.

- 13.21** Låt x_1, \dots, x_n och y_1, \dots, y_n vara de slumpmässiga stickproven av de $10 + 10$ oberoende $N(\mu_1, \sigma_1)$ -respektive $N(\mu_2, \sigma_2)$ -fördelade stokastiska variablerna X_1, \dots, X_n och Y_1, \dots, Y_n , där $\sigma_1 = 0.3$ och $\sigma_2 = 0.4$.

Vi vill prova hypotesen

$$H_0 : \mu_1 = \mu_2 \quad \text{mot} \quad H_1 : \mu_1 \neq \mu_2$$

på nivå $\alpha = 0.01$.

a) Vi förkastar H_0 för stora värden på $|z|$ där

$$z = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}}$$

som om H_0 är sann är ett utfall av en $N(0, 1)$ -fördelad stokastisk variabel Z . På nivå $\alpha = 0.01$ förkastas H_0 om $|z| > \lambda_{0.01/2} = 2.5758$.

Om $\mu_1 - \mu_2 = 0.6$ är sannolikheten för att H_0 förkastas

$$\begin{aligned} P(|Z| > \lambda_{0.005}) &= 1 - P(-\lambda_{0.005} \leq Z \leq \lambda_{0.005}) = 1 - P\left(-\lambda_{0.005} \leq \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \lambda_{0.005}\right) \\ &= 1 - P\left(-\lambda_{0.005} - \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \lambda_{0.005} - \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}}\right) \\ &= 1 - P\left(-\lambda_{0.005} - 3.7947 \leq \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \lambda_{0.005} - 3.7947\right) \\ &= 1 - (\Phi(-1.2189) - \Phi(-6.3706)) = 0.8886. \end{aligned}$$

b) Ekvationen

$$1 - P \left(-\lambda_{0.005} - \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \lambda_{0.005} - \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \right) = 0.99$$

ger approximativt att

$$P \left(\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \leq \lambda_{0.005} - \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \right) \approx 0.01$$

det vill säga

$$\lambda_{0.005} - \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \approx -\lambda_{0.01}$$

eller

$$\sqrt{n} \approx \frac{(\lambda_{0.01} + \lambda_{0.005})\sqrt{\sigma_1^2 + \sigma_2^2}}{\mu_1 - \mu_2} = \frac{(2.3263 + 2.5758)\sqrt{0.3^2 + 0.4^2}}{0.6} = 4.0851$$

eller $n \approx 16.68$. Alltså, minst 17 observationer krävs för att erhålla önskvärd styrka. (Styrkan är då 0.99115).

13.22

13.23

13.24

13.25 Låt x_1, \dots, x_n vara observationer på oberoende $\text{Po}(\mu)$ -fördelade stokastiska variabler X_1, \dots, X_n .

Vi vill testa

$$H_0 : \mu = 0.2 = \mu_0 \quad \text{mot} \quad H_1 : \mu > \mu_0.$$

Vi förkastar H_0 för stora värden på $y = \sum_{i=1}^n x_i$ som om H_0 är sann är ett utfall på en $\text{Po}(n\mu_0) = \text{Po}(10)$ -fördelad stokastisk variabel Y . Vi observerar utfallet $y = 19$. Om H_0 är sann är

$$P(\text{Förkasta } H_0) = P(Y \geq 19) = 1 - P(Y \leq 18) = 1 - \sum_{k=0}^{18} \frac{10^k}{k!} e^{-10} = 1 - 0.99281 = 0.00719.$$

Detta är den längsta signifikansnivå som H_0 kan förkastas på och vi ser att vi kan förkasta H_0 på nivå 1%.

13.26

13.27

13.28 Låt x_1, \dots, x_r vara antalet marsvinsungar med färg motsvarande kategori $1, \dots, r$. Dessa modelleras som utfall av de (beroende) $\text{Bin}(n, p_i)$ -fördelade stokastiska variablerna X_1, \dots, X_r .

Enligt den genetiska modellen är p_i , sannolikheten att en unge får färg i , $9/16, 3/16$ och $4/16$ för $i = 1, 2, 3$. Formellt, vi vill testa

$$H_0 : p_1 = \frac{9}{16}, p_2 = \frac{3}{16}, p_3 = \frac{4}{16}$$

på nivå $\alpha = 0.05$. Enligt modellen så är

| | Kategori (färg) | | | |
|-------------------------|-----------------|-----------|---------|----|
| | 1 (röd) | 2 (svart) | 3 (vit) | |
| Observerat antal: x_i | 43 | 10 | 34 | 87 |
| Hypotes: p_i | $9/16$ | $3/16$ | $4/16$ | 1 |
| Förväntat antal: np_i | 48.938 | 16.312 | 21.750 | 87 |

Vi förkastar H_0 för stora värden på

$$q = \sum_{i=1}^r \frac{(x_i - np_i)^2}{np_i}$$

som om H_0 är sann är ett utfall på en (approximativt) $\chi^2(r-1)$ -fördelad stokastisk variabel. Ur $\chi^2(3-1) = \chi^2(2)$ -tabeller får man att $\chi^2_{0.05} = 5.99$. Med utfallet $q = 10.063 > \chi^2_{0.05}$ så förkastas H_0 på nivå 5%. (Vi förkastar även på 1%, testets p-värde är 0.65%.)

- 13.29** Låt x_1, \dots, x_r vara antalet utlånade böcker under de olika veckodagarna, med n som det totala antalet utlånade böcker under veckan,

$$n = \sum_{i=1}^r x_i = 623.$$

Notera att n egentligen borde modelleras som ett utfall av en stokastisk variabel, men vi kommer att räkna som om n vore fix. Då kan x_1, \dots, x_r modelleras som utfall av de (beroende) $\text{Bin}(n, p_i)$ -fördelade stokastiska variablerna X_1, \dots, X_r .

Vi vill testa en hypotes om att utlåningen är densamma oavsett veckodag mot att den varierar mellan veckodagar. Formellt: vi vill testa

$$H_0 : p_1 = p_2 = \dots = p_r = \frac{1}{r} \quad \text{mot} \quad H_1 : \text{inte } H_0$$

på signifikansnivå $\alpha = 0.05$. Enligt H_0 så är

| Kategori (veckodag) | | | | | | |
|-------------------------|---------|---------|---------|---------|---------|-----|
| | 1 (mån) | 2 (tis) | 3 (ons) | 4 (tor) | 5 (fre) | |
| Observerat antal: x_i | 135 | 108 | 120 | 114 | 146 | 623 |
| Hypotes: p_i | 1/5 | 1/5 | 1/5 | 1/5 | 1/5 | 1 |
| Förväntat antal: np_i | 124.6 | 124.6 | 124.6 | 124.6 | 124.6 | 623 |

Vi förkastar H_0 för stora värden på

$$q = \sum_{i=1}^r \frac{(x_i - np_i)^2}{np_i}$$

som om H_0 är sann är ett utfall på en (approximativt) $\chi^2(r-1)$ -fördelad stokastisk variabel. Ur $\chi^2(5-1) = \chi^2(4)$ -tabeller får man att $\chi^2_{0.05} = 9.49$. Med utfallet $q = 7.8266 < \chi^2_{0.05}$ så förkastas inte H_0 på nivå 5%.

På nivå $\alpha = 0.10$ får man ur $\chi^2(4)$ -tabeller att $\chi^2_{0.10} = 7.78 < q$. Alltså förkastar vi H_0 på nivå 10%. (Testets p-värde är 9.81%).

- 13.30** En stokastisk variabel X kan anta värdena $S_X = \{0, 1, 2, 3\}$. Vi vill testa hypotesen

$$H_0 : X \text{ är } \text{Bin}(3, \frac{1}{4}) \quad \text{mot} \quad H_1 : X \text{ är ej } \text{Bin}(3, \frac{1}{4})$$

på nivå $\alpha = 0.01$ med hjälp av $n = 4096$ oberoende observationer av X . Med de möjliga värdena på X som kategorier är enligt H_0 sannolikheten att få en observation i kategori $i \in S_X$

$$p_i = P(X = i) = \binom{3}{i} p^i (1-p)^{3-i} = \binom{3}{i} \left(\frac{1}{4}\right)^i \left(1 - \frac{1}{4}\right)^{3-i}, \quad i = 0, \dots, 3.$$

Låt x_i vara antalet utfall av X i kategori i , $i \in S_X$. Om H_0 är sann så är

| i | 0 | 1 | 2 | 3 | |
|----------------------------|-----------------|-----------------|----------------|----------------|------|
| observerad frekvens, x_i | 1764 | 1692 | 552 | 88 | 4096 |
| Hypotes, p_i | $\frac{27}{64}$ | $\frac{27}{64}$ | $\frac{9}{64}$ | $\frac{1}{64}$ | 1 |
| Förväntat antal, np_i | 1728 | 1728 | 576 | 64 | 4096 |

Vi förkastar H_0 för stora värden på

$$q = \sum_{i=1}^r \frac{(x_i - np_i)^2}{np_i}$$

som om H_0 är sann är ett utfall på en (approximativt) $\chi^2(r-1)$ -fördelad stokastisk variabel. Ur $\chi^2(4-1) = \chi^2(3)$ -tabeller får man att $\chi^2_{0.01} = 11.35$. Med utfallet $q = 11.5 > \chi^2_{0.01}$ så förkastas H_0 på nivå 1%.

- 13.31** Låt x_{ij} vara antalet observationer i kategori j , $j = 1, \dots, r$, i population i , $i = 1, \dots, s$. Vi modellerar x_{ij} som ett utfall av en $\text{Bin}(n_i, p_j^{(i)})$ -fördelad stokastisk variabel X_{ij} .

| x_{ij} | Kategori (kön) | | Totalt: $m_1 = 267$ | $m_2 = 233$ | $N = 500$ |
|---------------|----------------|-------------|---------------------|-------------|-------------|
| | 1 (män) | 2 (kvinnor) | | | |
| Population 1: | 46 | 54 | | | $100 = n_1$ |
| Population 2: | 78 | 72 | | | $150 = n_2$ |
| Population 3: | 143 | 107 | | | $250 = n_3$ |
| | | | | | |

Vi vill testa om fördelningen av män och kvinnor skiljer sig mellan populationerna. Med H_0 som hypotesen att det inte finns någon skillnad,

$$H_0 : p_j^{(1)} = p_j^{(2)} = \dots = p_j^{(s)} \quad \text{för alla } j = 1, \dots, r,$$

så skattas p_j , sannolikheten att en utvald person har kön motsvarande kategori j , med

$$(p_j)^*_{\text{obs}} = \frac{1}{N} \sum_{i=1}^s x_{ij} = \frac{m_j}{N} \quad (p_1)^*_{\text{obs}} = \frac{267}{500}, \quad (p_2)^*_{\text{obs}} = \frac{233}{500}.$$

Vi kan då skatta det förväntade antalet observationer i kategori j i serie i , $E(X_{ij}) = n_i p_j$, med $n_i (p_j)^*_{\text{obs}} = \frac{n_i m_j}{N}$.

| $\frac{n_i m_j}{N}$ | Kategori (kön) | | Totalt: 267 | 233 | 500 |
|---------------------|----------------|-------------|---------------|-------|-------|
| | 1 (män) | 2 (kvinnor) | | | |
| Population 1: | 53.4 | 46.6 | | | 100 |
| Population 2: | 80.1 | 69.9 | | | 150 |
| Population 3: | 133.5 | 116.5 | | | 250 |
| | | | | | |

Vi jämför de observerade antalen x_{ij} med de skattade förväntade antalen $\frac{n_i m_j}{N}$ med

$$q = \sum_{i=1}^s \sum_{j=1}^r \frac{(x_{ij} - \frac{n_i m_j}{N})^2}{\frac{n_i m_j}{N}}$$

som om H_0 är sann är ett utfall av en (approximativt) $\chi^2((s-1)(r-1))$ -fördelad stokastisk variabel. Vi förkastar H_0 för stora värden på q . Ur $\chi^2((3-1)(2-1)) = \chi^2(2)$ -tabeller får man att $\chi^2_{0.10} = 4.61$. Vi observerar utfallet $q = 3.7694 < \chi^2_{0.10}$ så vi förkastar inte H_0 på nivå 10%. Det är på nivå 10% ingen signifikant skillnad i könsfördelning mellan populationerna.

- 13.32** De $n = 100$ observationerna på den förmodat ffg-fördelade stokastiska variabeln delas in i 9 kategorier:

| Observerad frekvens: x_i | Kategori (värde) | | | | | | | | Totalt: $100 = n$ |
|----------------------------|------------------|----|----|----|---|---|---|---|-------------------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | |
| | 42 | 23 | 10 | 11 | 8 | 2 | 3 | 1 | 0 |

Notera att den sista kategorin är bara implicit given i uppgiften.

Låt p_i vara sannolikheten att en observation hamnar i kategori i enligt statistikerns modell. Om ffg($1/2$)-antagandet stämmer är $p_i = (1 - 1/2)(1/2)^{i-1} = 2^{-i}$, $i < 9$, och $p_9 = 2^{-8}$, och det förväntade antalet observationer i kategori i , $E(X_i) = np_i$.

| Observerad frekvens: x_i | Kategori (värde) | | | | | | | | Totalt: 100 |
|----------------------------|------------------|----------|----------|----------|----------|----------|----------|----------|---------------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | |
| | 42 | 23 | 10 | 11 | 8 | 2 | 3 | 1 | 0 |
| Hypotes: p_i | 2^{-1} | 2^{-2} | 2^{-3} | 2^{-4} | 2^{-5} | 2^{-6} | 2^{-7} | 2^{-8} | 2^{-8} |
| Förväntat antal: np_i | 50 | 25 | 12.5 | 6.25 | 3.125 | 1.5625 | 0.78125 | 0.39062 | 0.39062 |

Kategorier med ett lågt förväntat antal, $np_i < 5$, slås samman för att öka det förväntade antalet. Här gör vi sammanslagningar till $r = 5$ kategorier:

| | Kategori (värde) | | | | | |
|----------------------------|------------------|----------|----------|----------|----------|-----|
| | 1 | 2 | 3 | 4 | ≥ 5 | |
| Observerad frekvens: x_i | 42 | 23 | 10 | 11 | 14 | 100 |
| Hypotes: p_i | 2^{-1} | 2^{-2} | 2^{-3} | 2^{-4} | 2^{-4} | 1 |
| Förväntat antal: np_i | 50 | 25 | 12.5 | 6.25 | 6.25 | 100 |

Vi förkastar hypotesen om att observationerna kommer från en ffg(1/2)-fördelning för stora värden på

$$q = \sum_{i=1}^r \frac{(x_i - np_i)^2}{np_i}$$

som då hypotesen stämmer är ett utfall från en (approximativt) $\chi^2(r-1)$ -fördelad stokastisk variabel. Ur $\chi^2(5-1) = \chi^2(4)$ -tabeller får man att $\chi^2_{0.05} = 9.4877$. Vi observerar utfallet $q = 15.16 > \chi^2_{0.05}$ så vi förkastar hypotesen på nivå 5%.

På nivå 1% fås $\chi^2_{0.01} = 13.277$ så hypotesen förkastas även på nivå 1%. (Testets p-värde är 0.438%).

13.33 De $n = 300$ observationerna på den förmodat Poisson(μ)-fördelade stokastiska variabeln delas in i 4 kategorier beroende på dess värde:

| | Kategori (värde) | | | | |
|----------------------------|------------------|----|---|----------|-----|
| | 0 | 1 | 2 | ≥ 3 | |
| Observerad frekvens: x_i | 249 | 42 | 9 | 0 | 300 |

Låt p_i vara sannolikheten att en observation hamnar i kategori i . Om Poisson(μ)-antagandet stämmer skattas μ med

$$\mu_{\text{obs}}^* = 0 \cdot \frac{249}{300} + 1 \cdot \frac{42}{300} + 2 \cdot \frac{9}{300} = 0.2$$

Med denna skattning erhålls skattningarna

$$(p_0)_{\text{obs}}^* = \frac{(\mu_{\text{obs}}^*)^0}{0!} e^{-\mu_{\text{obs}}^*} \quad (p_1)_{\text{obs}}^* = \frac{(\mu_{\text{obs}}^*)^1}{1!} e^{-\mu_{\text{obs}}^*} \quad (p_2)_{\text{obs}}^* = \frac{(\mu_{\text{obs}}^*)^2}{2!} e^{-\mu_{\text{obs}}^*} \quad (p_3)_{\text{obs}}^* = 1 - \sum_{i=0}^2 (p_i)_{\text{obs}}^*.$$

De (skattade) förväntade antalet observationer i kategori i är $n(p_i)_{\text{obs}}^*$.

| | Kategori (värde) | | | | |
|--|------------------|---------|----------|-----------|-----------|
| | 0 | 1 | 2 | ≥ 3 | |
| Observerad frekvens: x_i | 249 | 42 | 9 | 0 | 300 = n |
| Hypotes: $(p_i)_{\text{obs}}^*$ | 0.81873 | 0.16375 | 0.016375 | 0.0011485 | 1 |
| Förväntat antal: $n(p_i)_{\text{obs}}^*$ | 245.62 | 49.124 | 4.9124 | 0.34454 | 300 |

Kategorier med ett lågt (skattat) förväntat antal, $n(p_i)_{\text{obs}}^*$, slås samman för att öka det förväntade antalet. Här gör vi sammanslagningar till $r = 3$ kategorier:

| | Kategori (värde) | | | |
|--|------------------|---------|----------|-----------|
| | 0 | 1 | ≥ 2 | |
| Observerad frekvens: x_i | 249 | 42 | 9 | 300 = n |
| Hypotes: $(p_i)_{\text{obs}}^*$ | 0.81873 | 0.16375 | 0.017523 | 1 |
| Förväntat antal: $n(p_i)_{\text{obs}}^*$ | 245.62 | 49.124 | 5.2569 | 300 |

Vi förkastar en hypotes om Poisson(μ)-fördelning för stora värden på

$$q = \sum_{i=1}^r \frac{(x_i - n(p_i)_{\text{obs}}^*)^2}{n(p_i)_{\text{obs}}^*}$$

som då hypotesen stämmer är ett utfall av en (approximativt) $\chi^2(r-1-1)$ -fördelad stokastisk variabel. En extra frihetsgrad har försvarat då parametern μ ersattes med skattningen μ_{obs}^* . Ur $\chi^2(3-1-1) = \chi^2(1)$ -tabeller får man att $\chi^2_{0.05} = 3.8415$. Vi observerar utfallet $q = 3.7448 < 3.8415$ så vi förkastar inte hypotesen på nivå 5%. Vi kan inte utesluta att observationerna kommer från en Poissonfördelning.

På nivå 10% fås $\chi^2_{0.10} = 2.7055 < q$ så hypotesen förkastas på nivå 10%. (Testets p-värde är 5.30%).

13.34

13.35 Låt x_{ij} vara antalet observationer i kategori (i, j) , $j = 1, \dots, r$, $i = 1, \dots, s$. Beteckna det totala antalet skadade med $N = \sum_{i=1}^s \sum_{j=1}^r x_{ij} = 500$. Notera att N egentligen borde modelleras som ett utfall av en stokastisk variabel, men vi kommer att räkna som om N vore fix. Då kan x_{ij} modelleras som utfall av en $\text{Bin}(N, p_{ij})$ -fördelad stokastisk variabel X_{ij} .

| | | Säkerhetsbälte | | $n_1 = 244$ | $n_2 = 256$ | $N = 500$ |
|--------------|-----------|----------------|---------------|-------------|-------------|-----------|
| | | 1 (användes) | 2 (använt ej) | | | |
| Personskador | 1 (lätta) | 101 | 143 | | | |
| | 2 (svåra) | 58 | 198 | | | |
| | | $m_1 = 159$ | $m_2 = 341$ | | | |

Vi skattar fördelningen för personskador med

$$(p_i)_{\text{obs}}^* = \frac{n_i}{N}, \quad (p_1)_{\text{obs}}^* = \frac{244}{500}, \quad (p_2)_{\text{obs}}^* = \frac{256}{500}.$$

Vi skattar fördelningen för användandet av säkerhetsbälte med

$$(q_i)_{\text{obs}}^* = \frac{m_i}{N}, \quad (q_1)_{\text{obs}}^* = \frac{159}{500}, \quad (q_2)_{\text{obs}}^* = \frac{341}{500}.$$

Om graden av personskada är oberoende av användandet av säkerhetsbälte, $p_{ij} = p_i q_j$, kan p_{ij} skattas med $(p_i)_{\text{obs}}^* \cdot (q_j)_{\text{obs}}^*$ och det förväntade antalet observationer med

$$N(p_i)_{\text{obs}}^* \cdot (q_j)_{\text{obs}}^* = \frac{n_i m_j}{N}.$$

| | | Säkerhetsbälte | | 244 | 256 | 500 |
|--------------|-----------|----------------|---------------|-----|-----|-----|
| | | 1 (användes) | 2 (använt ej) | | | |
| Personskador | 1 (lätta) | 77.592 | 166.408 | | | |
| | 2 (svåra) | 81.408 | 174.592 | | | |
| | | 159 | 341 | | | |

Vi förkastar en hypotes om oberoende mellan grad av personskada och användande av säkerhetsbälte för stora värden på

$$q = \sum_{i=1}^s \sum_{j=1}^r \frac{(x_{ij} - \frac{n_i m_j}{N})^2}{\frac{n_i m_j}{N}}$$

som om hypotesen stämmer är ett utfall av en (approximativt) $\chi^2((s-1)(r-1))$ -fördelad stokastisk variabel. Ur $\chi^2((2-1)(2-1)) = \chi^2(1)$ -tabeller får man att $\chi^2_{0.01} = 6.63$. Vi observerar utfallet $q = 20.2235 > \chi^2_{0.01}$ så vi förkastar hypotesen om oberoende på nivå 1%. Använtandet av säkerhetsbälte och graden av personskada är inte oberoende. (Testets p-värde är $\approx 6.9 \cdot 10^{-6}$.)

14.1 Låt y_1, \dots, y_n vara de uppmätta ljusextinktionerna vid koncentrationerna x_1, \dots, x_n . Vi ansätter modellen att y_1, \dots, y_n är utfall av oberoende $N(\alpha + \beta x_i, \sigma)$ -fördelade stokastiska variabler Y_1, \dots, Y_n .

| | | | | | | | |
|----------------------------------|------|------|------|------|------|------|------|
| Koncentration, x_1, \dots, x_n | 0.40 | 0.70 | 1.00 | 1.20 | 1.40 | 1.70 | 2.00 |
| Extinktion, y_1, \dots, y_n | 0.23 | 0.34 | 0.42 | 0.55 | 0.61 | 0.77 | 0.84 |

Observationerna sammanfattas av storheterna

$$\bar{x} = 1.20, \quad \bar{y} = 0.537$$

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = 1.86, S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = 0.741, S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = 0.298.$$

Parametrarna β och α skattas med

$$\beta_{\text{obs}}^* = \frac{S_{xy}}{S_{xx}} = 0.398 \quad \text{respektive} \quad \alpha_{\text{obs}}^* = \bar{y} - \beta_{\text{obs}}^* \bar{x} = 0.0591$$

Variansen σ^2 skattas med

$$s^2 = \frac{1}{n-2} [S_{yy} - \beta_{\text{obs}}^* S_{xy}] = 0.0013888,$$

det vill säga σ skattas med $s = 0.025052$.

- a) Per enhet ökar extinktionen med faktorn β som skattas med $\beta_{\text{obs}}^* = 0.398$.
- b) En skattning av $E(Y(1.20)) = \alpha + \beta \cdot 1.20$ är $\alpha_{\text{obs}}^* + \beta_{\text{obs}}^* \cdot 1.20 = 0.53714$. Skattningen $\alpha_{\text{obs}}^* + \beta_{\text{obs}}^* \cdot 1.20$ är ett utfall av en stokastisk variabel med varians

$$\begin{aligned} V(\alpha^* + \beta^* \cdot 1.2) &= V(\bar{Y} - \beta^* \bar{x} + \beta^* \cdot 1.2) = V(\bar{Y} + \beta^*(1.2 - \bar{x})) = \{\text{oberoende}\} \\ &= V(\bar{Y}) + (1.2 - \bar{x})^2 V(\beta^*) = \frac{\sigma^2}{n} + (1.2 - \bar{x})^2 \frac{\sigma^2}{S_{xx}}. \end{aligned}$$

Alltså, standardavvikelsen är

$$D(\alpha^* + \beta^* \cdot 1.2) = \sigma \sqrt{\frac{1}{n} + \frac{(1.2 - \bar{x})^2}{S_{xx}}} = \sigma \sqrt{\frac{1}{7} + \frac{(1.2 - 1.2)^2}{S_{xx}}} = \sigma / \sqrt{7}.$$

- c) En skattning av $E(Y(0)) = \alpha$ är $\alpha_{\text{obs}}^* = 0.0591$. Skattningen α_{obs}^* är ett utfall av en stokastisk variabel med varians

$$V(\alpha^*) = V(\bar{Y} - \beta^* \bar{x}) = \{\text{oberoende}\} = V(\bar{Y}) + (-\bar{x})^2 V(\beta^*) = \frac{\sigma^2}{n} + \bar{x}^2 \frac{\sigma^2}{S_{xx}}.$$

Alltså, standardavvikelsen är

$$D(\alpha^*) = \sigma \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}} = \sigma \sqrt{\frac{1}{7} + \frac{(1.2)^2}{1.86}} = 0.9576\sigma.$$

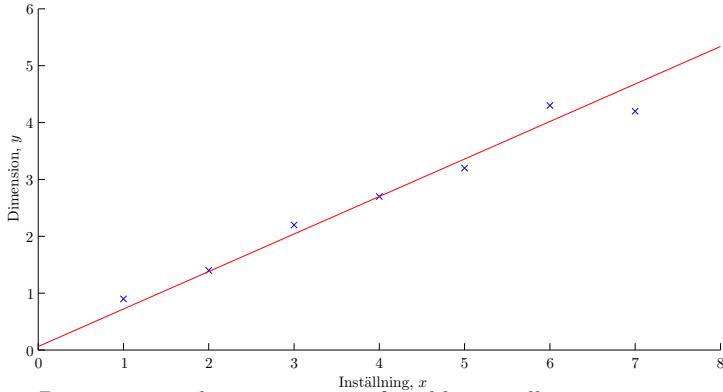
- d) En skattning av σ är $s = 0.025052$.

14.2

14.3

- 14.4** Låt y_1, \dots, y_n vara de uppmätta dimensionerna vid inställningarna x_1, \dots, x_n . Vi ansätter modellen att y_1, \dots, y_n är utfall av oberoende $N(\alpha + \beta x_i, \sigma)$ -fördelade stokastiska variabler Y_1, \dots, Y_n .

| | | | | | | | |
|--------------------------------|-----|-----|-----|-----|-----|-----|-----|
| Inställning, x_1, \dots, x_n | 1.0 | 2.0 | 3.0 | 4.0 | 5.0 | 6.0 | 7.0 |
| Dimension, y_1, \dots, y_n | 0.9 | 1.4 | 2.2 | 2.7 | 3.2 | 4.3 | 4.2 |



De uppmätta dimensionerna y för olika inställningar x markerade med kryss med den skattade regressionslinjen inritad.

Observationerna sammanfattas av storheterna

$$\bar{x} = 4.0, \quad \bar{y} = 2.7$$

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = 28, \quad S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = 16.7, \quad S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = 10.24.$$

b) Parametrarna β och α skattas med

$$\beta_{\text{obs}}^* = \frac{S_{xy}}{S_{xx}} = 0.59643 \quad \text{respektive} \quad \alpha_{\text{obs}}^* = \bar{y} - \beta_{\text{obs}}^* \bar{x} = 0.31429.$$

Variansen σ^2 skattas med

$$s^2 = \frac{1}{n-2} [S_{yy} - \beta_{\text{obs}}^* S_{xy}] = 0.055929,$$

det vill säga σ skattas med $s = 0.23649$.

c) Om man önskar att $2.5 = E(Y(x)) = \alpha + \beta x$ skall x väljas så att $x = (2.5 - \alpha)/\beta$. Denna storhet skattas med $(2.5 - \alpha_{\text{obs}}^*)/\beta_{\text{obs}}^* = 3.6647$.

d) Skatningen α_{obs}^* är ett utfall av den normalfördelade stokastiska variabeln α^* , där

$$\alpha^* \quad \text{är} \quad N \left(\alpha, \sigma \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}} \right).$$

Ur $t(n-2) = t(7-2)$ -tabell erhålls att $t_{0.025} = 2.57$. Alltså ges ett konfidensintervall för α av

$$\alpha \in \alpha_{\text{obs}}^* \pm t_{0.025} s \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}} = 0.31429 \pm 2.57 \cdot 0.19987 = 0.314 \pm 0.514 \quad (95\%).$$

Skatningen β_{obs}^* är ett utfall av den normalfördelade stokastiska variabeln β^* , där

$$\beta^* \quad \text{är} \quad N \left(\beta, \frac{\sigma}{\sqrt{S_{xx}}} \right).$$

Alltså ges ett konfidensintervall för β av

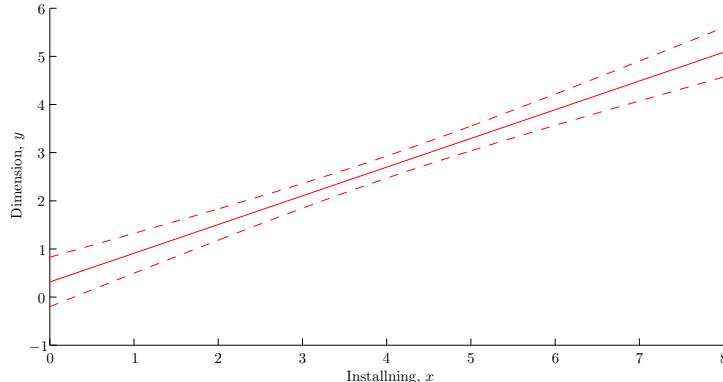
$$\beta \in \beta_{\text{obs}}^* \pm t_{0.025} \frac{s}{\sqrt{S_{xx}}} = 0.59643 \pm 2.57 \cdot 0.044693 = 0.596 \pm 0.115 \quad (95\%).$$

e) För en punkt x_0 skattas $E(Y(x_0)) = \alpha + \beta x_0$ av $\alpha_{\text{obs}}^* + \beta_{\text{obs}}^* x_0$ som är ett utfall av $\alpha^* + \beta^* x_0$, där

$$\alpha^* + \beta^* x_0 \quad \text{är} \quad N \left(\alpha + \beta x_0, \sigma \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}} \right).$$

Alltså ges ett konfidensintervall för $\alpha + \beta x_0$ av

$$\alpha + \beta x_0 \in \hat{\alpha}_{\text{obs}}^* + \hat{\beta}_{\text{obs}}^* x_0 \pm t_{0.025} s \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}}.$$



Regressionslinjen (heldragen) med konfidensintervallet för väntevärdet $E(Y(x))$ som funktion av x (streckade linjer).

14.5 Vi gör mätningar i punkter x svarande mot $x = 1/\lambda^2$ och får följande observationer:

| | λ_i | $x_i = 1/\lambda_i^2$ | y_i |
|--|-------------|------------------------|-------|
| | 6232 | $2.5748 \cdot 10^{-8}$ | 19.38 |
| | 5571 | $3.2221 \cdot 10^{-8}$ | 25.62 |
| | 5100 | $3.8447 \cdot 10^{-8}$ | 30.10 |

Data kan sammanfattas med

$$\bar{x} = 3.2138 \cdot 10^{-8} \quad \bar{y} = 25.033$$

$$S_{xx} = \sum (x_i - \bar{x})^2 = 8.0638 \cdot 10^{-17} \quad S_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y}) = 6.8137 \cdot 10^{-8} \quad S_{yy} = \sum (y_i - \bar{y})^2 = 57.975.$$

Vi ansätter modellen att y_1, \dots, y_n är utfall av oberoende $N(\alpha + \beta x_i, \sigma)$ -fördelade stokastiska variabler Y_1, \dots, Y_n .

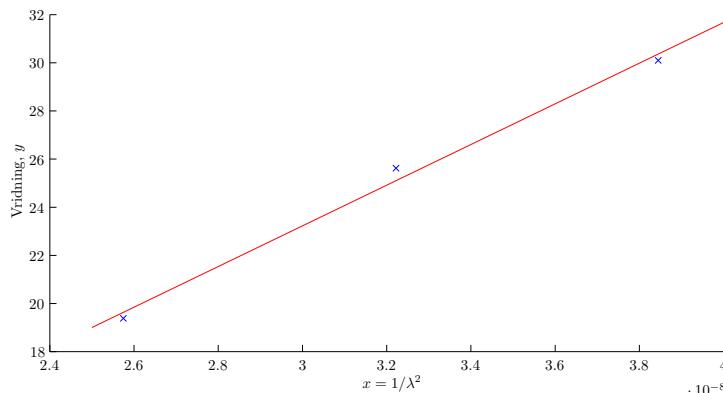
a) Parametrarna β och α skattas med

$$\hat{\beta}_{\text{obs}}^* = \frac{S_{xy}}{S_{xx}} = 8.45 \cdot 10^8 \quad \text{respektive} \quad \hat{\alpha}_{\text{obs}}^* = \bar{y} - \hat{\beta}_{\text{obs}}^* \bar{x} = -2.123.$$

Variansen σ^2 skattas med

$$s^2 = \frac{1}{n-2} [S_{yy} - \hat{\beta}_{\text{obs}}^* S_{xy}] = 0.40141,$$

det vill säga σ skattas med $s = 0.63357$.



De tre mätningarna på vridningen som funktion av $1/\lambda^2$, där λ är ljusets våglängd, med inritad regressionslinje.

c) Skatningen β_{obs}^* är ett utfall av den normalfördelade stokastiska variabeln β^* , där

$$\beta^* \text{ är } N\left(\beta, \frac{\sigma}{\sqrt{S_{xx}}}\right).$$

Ur $t(n - 2) = t(3 - 2)$ -tabell erhålls att $t_{0.025} = 12.706$ (!). Alltså ges ett konfidensintervall för β av

$$\beta \in \beta_{\text{obs}}^* \pm t_{0.025} \frac{s}{\sqrt{S_{xx}}} = 8.45 \cdot 10^8 \pm 12.706 \cdot 7.0555 \cdot 10^7 = (8.45 \pm 8.96) \cdot 10^8 \quad (95\%).$$

14.6

14.7 a) Om hypotesen $\beta_1 = 0$ förkastas till förmån för $\beta_1 \neq 0$ har testet p-värde $8.3 \cdot 10^{-6}$. Detta är den lägsta signifikansnivå hypotesen kan förkastas på och speciellt förkastas den på nivå 5%.

Om hypotesen $\beta_2 = 0$ förkastas till förmån för $\beta_2 \neq 0$ har testet p-värde 0.132. Detta är den lägsta signifikansnivå hypotesen kan förkastas på. Alltså, hypotesen förkastas ej på nivå 5%.

b) Förändringen $\beta_1 + \beta_2$ skattas med $(\beta_1)_{\text{obs}}^* + (\beta_2)_{\text{obs}}^* = 1.423 - 0.176 = 1.247$.

c) Skatningen $(\beta_1)_{\text{obs}}^* + (\beta_2)_{\text{obs}}^*$ är ett utfall av en stokastisk variabel $\beta_1^* + \beta_2^*$ med varians

$$V(\beta_1^* + \beta_2^*) = V(\beta_1^*) + V(\beta_2^*) + 2C(\beta_1^*, \beta_2^*),$$

det vill säga standardavvikelsen skattas till

$$d(\beta_1^* + \beta_2^*) = \sqrt{(0.247)^2 + (0.112)^2 + 2 \cdot (-0.00248)} = 0.2619.$$

14.8