

1. (a) Vi vill räkna ut sannolikheten att det inte regnar på lördagen givet att det är sol på torsdagen. Vi vet alltså att Markovkedjan befinner sig i tillståndet "soligt" och vill räkna ut sannolikheten för de olika tillstånden två dagar senare. Låt  $p^{(2)}$  vara en radvektor som innehåller sannolikheterna för tillstånden "soligt", "mulet" resp "regnigt" för vädret på lördagen. Enligt Chapman-Kolmogorovs sats ges  $p^{(2)}$  av

$$p^{(2)} = p^{(0)}P^2 = (1 \ 0 \ 0) \begin{pmatrix} 0.7 & 0.3 & 0 \\ 0.2 & 0.4 & 0.4 \\ 0 & 0.5 & 0.5 \end{pmatrix}^2 = (0.55 \ 0.33 \ 0.12).$$

Sannolikheten att åka till stranden ges av  $0.55 + 0.33 = 0.88$ .

Alternativ lösning:  $P(\text{"Stranden på lördag"}) = P(\text{"ej regn på lördag"}) = 1 - P(\text{"regn på lördag"})$ . För att det skall regna på lördag måste Markovkedjan göra övergångarna "Soligt" till "Mulet" följt av "Mulet" till "Regnigt". Detta ger att  $P(\text{"regn på lördag"}) = P_{12}P_{23} = 0.3 \cdot 0.4 = 0.12$  ger  $P(\text{"Stranden på lördag"}) = 1 - 0.12 = 0.88$ .

- (b) Låt radvektorn  $\pi = (\pi_1 \ \pi_2 \ \pi_3)$  beteckna den stationära fördelningen för sommarvädret. Vi har då att  $\pi$  fås som lösningen till ekvationsystemet  $\pi P = \pi$ . Sätter vi värdena från P fås

$$\begin{aligned} -0.3\pi_1 + 0.2\pi_2 &= 0 \\ 0.3\pi_1 - 0.6\pi_2 + 0.5\pi_3 &= 0 \\ 0.4\pi_2 - 0.5\pi_3 &= 0 \end{aligned}$$

Från den första ekvationen får vi  $\pi_1 = (2/3)\pi_2$  och från den sista fås  $\pi_3 = (4/5)\pi_2$ . Vi använder nu detta samt att  $\pi_1 + \pi_2 + \pi_3 = 1$  detta ger  $(2/3 + 1 + 4/5)\pi_2 = 1$  vilket ger  $\pi_2 = 15/37$ . Detta ger i sin tur att  $\pi_1 = (2/3)(15/37) = 10/37$  och  $\pi_3 = (4/5)(15/37) = 12/37$ . Vi får alltså att den stationära fördelningen ges av  $\pi = (10/37 \ 15/37 \ 12/37)$ . Så i genomsnitt är det soligt  $10/37$  av tiden mulet  $15/37$  av tiden och regnigt  $12/37$  av tiden.

2.  $X =$  antal felaktiga i stickprovet  $\in \text{Bin}(1000, p)$ ,  $x = 25$ ,  $p^* = x/n = 0.025$ . Vi vill testa om andelen felaktiga minskat. Vi kan då använda följande hypoteser  $H_0: p = 0.03$ ,  $H_1: p < 0.03$ .

Om  $H_0$  sann så  $1000 \cdot 0.03 \cdot 0.97 = 29.1 > 10$  och  $p^* \lesssim N\left(0.03, \sqrt{\frac{0.03 \cdot 0.97}{1000}}\right) = N(0.03, 0.0054)$

Eftersom  $\frac{p^* - 0.03}{0.0054} = \frac{0.025 - 0.03}{0.0054} = -0.927 \not\leq -\lambda_\alpha = -\lambda_{0.05} = -1.64$  kan  $H_0$  inte förkastas.

Andelen felaktiga är inte signifikant mindre än tidigare.

Alternativ lösning: Gör ensidigt uppåt begränsat konfidensintervall för p. Vi kollar först att  $np^*(1-p^*) > 10$ . Vi har  $p^* = 25/1000 = 0.025$  ger  $np^*(1-p^*) = 1000 \cdot 0.025 \cdot 0.975 = 24.375 > 10$  så normalapproximation OK. Bilda approximativt ensidigt konfidensintervall enligt

$$I_p = [0, p^* + \lambda_\alpha \cdot d(p^*)] = [0, 0.025 + 1.6449\sqrt{0.025 \cdot 0.975/1000}] = [0, 0.0331]$$

Eftersom 0.03 ligger i konfidensintervallet kan vi inte förkasta att andelen felaktiga är samma som innan.

Alternativ lösning2: Använd direktmetoden efter normalapproximation. Vi kollar först att  $np^*(1-p^*) > 10$ . Vi har  $p^* = 25/1000 = 0.025$  ger  $np^*(1-p^*) = 1000 \cdot 0.025 \cdot 0.975 = 24.375 > 10$  så normalapproximation OK. Vi räknar approximativt ut sannolikheten att få 25 eller färre felaktiga givet att andelen felaktiga är 3%. Utan halvkorrektion

$$P(X \leq 25, p = 0.03) \approx \Phi((25-30)/\sqrt{0.03 \cdot 0.97 \cdot 1000}) = \Phi(-0.9269) = 1 - \Phi(0.9269) \approx 0.1762 > 0.05.$$

Med halvkorrektion

$$P(X \leq 25, p = 0.03) \approx \Phi((25.5 - 30) / \sqrt{0.03 \cdot 0.97 \cdot 1000}) = \Phi(-0.8342) = 1 - \Phi(0.8342) \approx 0.2033 > 0.05.$$

Vi kan inte förkasta att andelen felaktiga är samma som innan, (vare sig med eller utan halvkorrektion).

3. Eftersom skillnaden i järnhalt är stor mellan de olika groparna och värdena på A och C-nivå ser ut att samvariera ansätter vi modellen stickprov i par:

$x_k$  - Fe-halt på A-nivå i grop  $k \in N(\mu_k, \sigma_1)$ ,

$y_k$  - Fe-halt på C-nivå i grop  $k \in N(\mu_k + \Delta, \sigma_2)$ ,

och de intressanta hypoteserna är  $H_0: \Delta = 0$ ,  $H_1: \Delta \neq 0$ .

Bilda differenser  $z_k = y_k - x_k$ :

$$2.81, 4.35, 2.83, 2.32, 0.41, -40.35, 4.62, 3.72, -0.63, -0.57$$

Enligt modellen är  $z_1, \dots, z_{10} \in N(\Delta, \sqrt{\sigma_1^2 + \sigma_2^2}) = N(\Delta, \sigma)$

$$\bar{z} = 1.951 \text{ och } s_z = \sqrt{\frac{1}{10-1} \sum_{k=1}^{10} (z_k - \bar{z})^2} = 2.064.$$

$$\text{Testkvantitet } t = \frac{\bar{z} - 0}{\frac{s_z}{\sqrt{10}}} = \sqrt{10} \frac{1.951}{2.064} = 2.989.$$

Eftersom  $|t| > t_{0.025}(9) = 2.26$  förkastas  $H_0$  på nivå 0.05. Det finns alltså en signifikant skillnad i genomsnittlig järnhalt mellan olika nivåer.

Alternativt kan ett 95 % konfidensintervall för  $\Delta$  göras:

$$\begin{aligned} I_\Delta &= (\bar{z} \pm t_{0.025}(9) \frac{s_z}{\sqrt{10}}) = \\ &= (1.951 \pm 2.26 \frac{2.064}{\sqrt{10}}) = (1.951 \pm 1.475) = \\ &= (0.48, 3.43). \end{aligned}$$

Eftersom intervallet ej täcker över 0 är slutsatserna de samma som ovan vid hypotestestet.

4. Låt  $T$  vara en stokastisk variabel som anger typen av lampa.  $T$  kan anta värdena L, N och E. Låt  $X$  vara en stokastisk variabel som beskriver en slumpmässigt vald lampas lystid.

- (a) Enligt satsen om total sannolikhet ges tätheten för  $X$  av

$$f_X(x) = f_{X|T=L}(x)P(T=L) + f_{X|T=N}(x)P(T=N) + f_{X|T=E}(x)P(T=E).$$

Nu använder vi att de betingade fördelningarna för  $X$  är exponentialfördelningar med väntevärden 400, 700 och 1000 för L, N respektive E-lampor. Vi vet också att andelarna är 0.4, 0.35 och 0.25 för L, N respektive E-lampor. Detta ger att

$$f_X(x) = 0.4 \frac{1}{400} e^{-\frac{x}{400}} + 0.35 \frac{1}{700} e^{-\frac{x}{700}} + 0.25 \frac{1}{1000} e^{-\frac{x}{1000}}.$$

- (b) Vill beräkna  $P(T = y | X = 600)$  för  $y = L$ ,  $y = N$  och  $y = E$ . Bayes sats ger

$$P(T = y | X = x) = \frac{f_{X|T=y}(x)P(T = y)}{f_{X|T=L}(x)P(T = L) + f_{X|T=N}(x)P(T = N) + f_{X|T=E}(x)P(T = E)}$$

Sätter vi in siffrorna från uppgiften fås

$$P(T = L | X = 600) \approx 0.39, \quad P(T = N | X = 600) \approx 0.37, \quad P(T = E | X = 600) \approx 0.24.$$

- (c) Först behöver vi räkna ut  $P(T = y | X \geq 600)$  för  $y = L$ ,  $y = N$  och  $y = E$ . Precis som i (b) kan vi använda Bayes-sats vilket ger

$$P(T = y | X \geq x) = \frac{P(X \geq x | T = y)P(T = y)}{P(X \geq x | T = L)P(T = L) + P(X \geq x | T = N)P(T = N) + P(X \geq x | T = E)P(T = E)}.$$

För beräkna detta uttryck behöver vi först beräkna de ingående sannolikheterna

$$P(X \geq x|T = L) = \int_x^\infty \frac{1}{400} e^{-\frac{y}{400}} dy = e^{-\frac{x}{400}}$$

På samma sätt fås

$$P(X \geq x|T = N) = e^{-\frac{x}{700}}, \quad P(X \geq x|T = E) = e^{-\frac{x}{1000}}.$$

Sätter vi nu in dessa uttryck med  $x = 600$  i uttrycket för  $P(T = y|X \geq 600)$  fås

$$P(T = L|X \geq 600) \approx 0.24, \quad P(T = N|X \geq 600) \approx 0.40, \quad P(T = E|X \geq 600) \approx 0.36.$$

Vi ser att den största betingade sannolikheten ges av  $P(T = N|X \geq 600)$ . Vi utgår alltså då från att  $T = N$ . Låt  $X_N$  vara en exponentialfördelad stokastisk variabel med väntevärde 700. Vi vill beräkna sannolikheten

$$\begin{aligned} P(X_N \geq 600 + 500|X_N \geq 600) &= \frac{P(X_N \geq 600 + 500 \cap X_N \geq 600)}{P(X_N \geq 600)} = \frac{P(X_N \geq 1100)}{P(X_N \geq 600)} \\ &= \frac{e^{-1100/700}}{e^{-600/700}} = e^{-500/700} \approx 0.49 \end{aligned}$$

Alternativt kunde vi utgått från att exponentialfördelningen är så kallat minneslös och direkt fått  $P(X_N \geq 600 + 500|X_N \geq 600) = P(X_N \geq 500) = e^{-500/700} \approx 0.49$ .

5. Vi har efter vår transformation överfört problemet på en standard linjär regressionsmodell. Så vi behöver beräkna de olika summorna som behövs för att beräkna skattningarna. Först har vi att  $\bar{x} = \sum_{i=1}^{20} x_i/20$ ,  $\bar{z} = \sum_{i=1}^{20} z_i/20$ . Sedan kan vi beräkna

$$\begin{aligned} S_{xz} &= \sum_{i=1}^{20} (x_i - \bar{x})(z_i - \bar{z}) = \left( \sum_{i=1}^{20} x_i z_i \right) - \left( \sum_{i=1}^{20} x_i \right) \bar{z} - \left( \sum_{i=1}^{20} z_i \right) \bar{x} + 20\bar{x}\bar{z} \\ &= \left( \sum_{i=1}^{20} x_i z_i \right) - \left( \sum_{i=1}^{20} x_i \right) \left( \sum_{i=1}^{20} z_i \right) / 20 \end{aligned}$$

På samma sätt fås

$$S_{xx} = \left( \sum_{i=1}^{20} x_i^2 \right) - \left( \sum_{i=1}^{20} x_i \right)^2 / 20$$

och

$$S_{zz} = \left( \sum_{i=1}^{20} z_i^2 \right) - \left( \sum_{i=1}^{20} z_i \right)^2 / 20$$

Sätter vi nu in siffrorna från uppgiften fås

$$\bar{x} \approx 11.397, \quad \bar{z} \approx 0.6275, \quad S_{xx} \approx 134.08, \quad S_{xz} \approx 62.698, \quad S_{zz} \approx 29.695.$$

- (a) Skattningarna av  $\alpha$ ,  $\beta$  och  $\sigma$  fås enligt formelsamlingen som

$$\alpha^* = \bar{z} - \bar{x} S_{xz} / S_{xx} \approx -4.7006, \quad \beta^* = S_{xz} / S_{xx} \approx 0.4676, \quad \sigma^* = s = \sqrt{(S_{zz} - S_{xz}^2 / S_{xx}) / (n - 2)} \approx 0.1455.$$

- (b) Vi vill nu göra ett 99% intervall för uppmätt transformerad effekt ( $Z$ ) då  $x = 11m/s$ , dvs vi vill göra ett prediktionsintervall för  $Z$ . Enligt formelsamling gäller

$$I_{Z(x_0)} = \left[ \alpha^* + x_0 \beta^* \pm t_{0.005}(n-2) s \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}} \right].$$

Sätter vi in siffror fås

$$I_{Z(11)} = \left[ -4.7006 + 11 \cdot 0.4676 \pm 0.1455 \sqrt{1 + \frac{1}{20} + \frac{0.1560}{134.08}} \right] = [0.0134 \ 0.8722].$$

- (c) För att få ett intervall för uppmätt effekt  $Y$  utnyttjar vi att  $Z$  är en monotont växande transformation av  $Y$  och därmed är  $Y$  en monotont växande transformation av  $Z$ . Vi kan därmed få att prediktionsintervall för  $Y$  genom att transformera gränserna i intervall för  $Z$ . För att göra detta måste vi först bestämma hur  $Y$  beror på  $Z$ . Vi har att

$$\begin{aligned}\ln(Y/(1-Y)) &= Z \\ Y/(1-Y) &= e^Z \\ Y &= e^Z(1-Y) \\ Y(1+e^Z) &= e^Z \\ Y &= \frac{e^Z}{1+e^Z}\end{aligned}$$

Applicerar vi det här sambandet på  $Z$ :s intervall fås

$$I_{Y(11)} = [0.5034 \ 0.7052],$$

dvs effekten blir mellan 503 W och 705 W med 99% sannolikhet.

6. Antag att  $x_1$ ,  $x_2$  och  $x_3$  är oberoende observationer av en stokastisk variabel med täthet

$$f_X(x) = \begin{cases} \frac{1}{9! \theta^{10}} x^9 e^{-x/\theta} & x \geq 0 \\ 0 & x < 0. \end{cases}$$

- (a) Likelihood funktionen ges nu av

$$L(\theta, x_1, x_2, x_3) = f_X(x_1)f_X(x_2)f_X(x_3).$$

För att hitta ML-skattningen av  $\theta$  skall vi maximera  $L$  map på  $\theta$ . Detta görs lättast genom att vi först bildar log-likelihood funktionen  $l(\theta, x_1, x_2, x_3) = \ln(L(\theta, x_1, x_2, x_3))$ . Sätter in uttrycket för  $f_X$  fås (givet att  $x_1$ ,  $x_2$  och  $x_3 > 0$ )

$$l(\theta, x_1, x_2, x_3) = 3 \ln(9!) - 30 \ln(\theta) + 9 \ln(x_1 x_2 x_3) - \frac{x_1 + x_2 + x_3}{\theta}$$

För att maximera deriverar vi map  $\theta$  då fås

$$\frac{\partial}{\partial \theta} l(\theta, x_1, x_2, x_3) = -\frac{30}{\theta} + \frac{x_1 + x_2 + x_3}{\theta^2}.$$

Vi sätter uttrycket lika med noll och löser för  $\theta$  då fås

$$\theta_{ML}^* = \frac{x_1 + x_2 + x_3}{30} = (11.045 + 10.474 + 13.593)/30 \approx 1.1704.$$

- (b) Vi vill nu räkna ut medelfelet för  $\theta_{ML}^*$ , dvs standardavvikelsen med eventuella parametrar ersatta av sina skattningar. Tittar vi närmare på  $X$ :s täthetsfunktion ser vi att  $X$  kommer från en gamma-fördelning med parametrarna  $p = 10$  och  $\lambda = 1/\theta$ . Eftersom  $\theta_{ML}^* = (x_1 + x_2 + x_3)/30$  fås

$$D(\theta_{ML}^*) = \sqrt{V(\theta_{ML}^*)} = 1/30 \sqrt{V(X_1) + V(X_2) + V(X_3)} = \sqrt{3V(X)}/30 = \sqrt{3}D(X)/30.$$

Vi utnyttjar nu att  $X$  är gamma-fördelad. Formelsamlingen ger  $V(X) = p/\lambda^2 = 10\theta^2$  vilket ger  $D(X) = \sqrt{10}\theta$ . Sätter vi in detta i uttrycket för  $D(\theta_{ML}^*)$  och ersätter  $\theta$  med sin skattning  $\theta_{ML}^*$  fås medelfelet som

$$D(\theta_{ML}^*) = 1.1704/\sqrt{30} \approx 0.21368.$$

- (c) En gamma-fördelning med parameter  $p=10$  kan ses som en summa av tio exponentialfördelade oberoende variabler. Eftersom  $X_1, X_2$  och  $X_3$  är oberoende och likafördelade gamma variabler med  $p=10, \lambda = 1/\theta$  fås att  $X_1 + X_2 + X_3$  är gamma-fördelad med  $p=30$  och  $\lambda = 1/\theta$ . Vi kan således se  $\theta_{ML}^*$  kan ses som en omskalning av en fördelning som kan ses som en summa av 30 oberoende likafördelade exponential variabler. Så vi kan enligt CGS anta att  $\theta_{ML}^*$  approximativt normalfördelad med väntevärde  $p\lambda/30 = 30\theta/30 = \theta$  och standardavvikelse  $\sqrt{p}\theta/30 = \theta/\sqrt{30}$ . Vi vill testa  $H_0 : \theta = 1$  mot  $H_1 : \theta > 1$  på nivån 5%. Vi gör nu ett nedåt begränsat approximativt 95% konfidensintervall för  $\theta$  enligt

$$I_\theta = [\theta_{ML}^* - \lambda_\alpha d(\theta_{ML}^*), \infty] = [0.81893, \infty].$$

Eftersom vårt 95% konfidensintervall täcker över punkten  $\theta = 1$  kan vi inte förkasta  $H_0$ .

---