

TILASTOMATEMATIIKKA

Harjoitus 4 ratkaisut, kevät 2018

1. Laitteen käyttämättömyysajan jakauman tiheysfunktio on

$$f(t) = \begin{cases} \theta^2 t e^{-\theta t}, & t \geq 0, \\ 0, & t < 0. \end{cases}$$

Jakauman parametrin θ likiarvon määrittämiseksi tehtiin havainnot monen samanlaisen laitteen käyttämättömyysajoista, jotka voidaan olettaa toisistaan riippumattomiksi. Havainnoiksi saatiin t_1, t_2, \dots, t_n . Määrittää parametrin θ likiarvon laskukaava suurimman uskottavuuden (maximum likelihood) menetelmällä.

Ratkaisu: Muodostetaan uskottavuusfunktio

$$L(\theta) = f(t_1; \theta) \cdots f(t_n; \theta) = \theta^2 t_1 e^{-\theta t_1} \cdots \theta^2 t_n e^{-\theta t_n} = \theta^{2n} t_1 \cdots t_n e^{-\theta(t_1 + \cdots + t_n)}$$

Derivaataksi saadaan tulon derivoimissäännöllä

$$\begin{aligned} L'(\theta) &= 2n\theta^{2n-1} t_1 \cdots t_n e^{-\theta(t_1 + \cdots + t_n)} - \theta^{2n} t_1 \cdots t_n (t_1 + \cdots + t_n) e^{-\theta(t_1 + \cdots + t_n)} \\ &= \theta^{2n-1} t_1 \cdots t_n e^{-\theta(t_1 + \cdots + t_n)} (2n - \theta(t_1 + \cdots + t_n)). \end{aligned}$$

Minimikohdaksi ja siten suurimman uskottavuuden estimaatiksi saadaan

$$\hat{\theta} = \frac{2n}{t_1 + \cdots + t_n} = \frac{2}{\bar{t}},$$

missä $\bar{t} = \frac{1}{n} \sum_{k=1}^n t_k$ on havaintojen aritmeettinen keskiarvo.

2. Järven kirjolohikannan suuruutta arvioidaan seuraavalla menetelmällä (capture-recapture method). Ensimmäisessä vaiheessa pyydetään 500 kirjolohta, jotka merkitään ja lasketaan vapaaksi. Toisessa vaiheessa pyydetään 200 kirjolohta ja lasketaan merkittyjen kirjolohien lukumäärä X . Tavallisesti oletetaan, että X noudattaa binomijakaumaa $\text{Bin}(n, p)$, missä p on todennäköisyys sille, että toisessa vaiheessa pyydetty kirjolohi on merkitty.
- a) Kuinka suuri on n ? Laske parametrin p arvo, jos tiedetään, että kirjolohien lukumäärä järvessä on $N = 2000$ tai $N = 5000$.
- b) Kokeessa havaittiin 40 kirjolohta. Määrää järven kirjolohikannan 95% luottamusväli.

Ratkaisu:

- a) Nyt $X =$ ”toisessa vaiheessa pyydetty kirjolohi on merkitty” $\sim \text{Bin}(n, p)$, joten $n = 200$ ja p on tuntematon parametri. Koska p ilmoittaa järvessä olevien kirjolohien suhteellisen osuuden, niin p tunnetaan, jos järvessä olevien kirjolohien määrä N tunnetaan. Erityisesti, jos $N = 2000$, niin

$$p = \frac{500}{N} = \frac{500}{2000} = \frac{1}{4}.$$

Jos taas $N = 5000$, niin

$$p = \frac{500}{5000} = \frac{1}{10}.$$

- b) Nyt N on tuntematon, jota pitäisi estimoida capture-recapture-menetelmällä. Estimoidaan suhteellista osuutta p estimaattorilla

$$p^* = \frac{X}{n},$$

jolle $E(p^*) = p$ ja $\sigma_{p^*} = \sqrt{\frac{p(1-p)}{n}}$. Standardisoimalla saadaan testimuuttujaksi

$$Z = \frac{p^* - E(p^*)}{\sigma_{p^*}} = \frac{\frac{X}{200} - p}{\sqrt{\frac{p(1-p)}{200}}} \sim N(0, 1) \quad \text{likimain,}$$

sillä $n = 200$ on ”suuri”.

Määrätään kaksisuuntainen symmetrinen luottamusväli. Sitä varten määrätään normaalijakuman taulukosta luku r_0 siten, että

$$P(-r_0 < Z \leq r_0) = \Phi(r_0) - \Phi(-r_0) = 2\Phi(r_0) - 1 = 0.95 \Leftrightarrow \Phi(r_0) = 0.975 \xrightarrow{\text{taulukosta}} r_0 = 1.96.$$

Muokataan epäyhtälö

$$-1.96 \leq Z \leq 1.96$$

muotoon

$$\frac{X}{200} - 1.96\sqrt{\frac{p(1-p)}{200}} \leq p \leq \frac{X}{200} + 1.96\sqrt{\frac{p(1-p)}{200}}.$$

Epäyhtälön ylä- ja alarajalla estimoidaan havainnoista $p = \hat{p} = \frac{40}{200} = \frac{1}{5}$ ja $\hat{X} = 40$, josta saadaan suhteellisen osuuden p luottamusväliksi

$$I_p = [0.145, 0.255].$$

Koska toisaalta $p = \frac{500}{N}$, saadaan kirjolohien lukumäärälle N luottamusväli

$$I_N = [1957, 3459].$$

3. Lentokoneen siipipäällysten niiteille on asetettu laatuvaatimukseksi vähintään 400 N (Newton) odotettavissa oleva vetolujuus ainakin 99 % varmuudella. Laatua testattiin aika ajoin ottamatta 20 niitin umpimähkäinen otos ja vetorasittamalla niitit poikki. Erään otoksen vetorasitustulokset olivat

401, 405, 390, 385, 399, 360, 378, 408, 410, 365, 400, 402, 383, 388, 389, 403, 395, 397, 402, 391.

Minkä rajan yläpuolella niittien odotettavissa oleva vetolujuus on mittaustulosten mukaan 99 % varmuudella? Toteutuiko niittien laatuvaatimus? Niittien vetolujuutta voidaan pitää normaalijakautuneena suureena.

Ratkaisu: Koska hajonta σ on tuntematon, käytetään t -jakautunutta testimuuttujaa

$$T = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1},$$

missä \bar{X} on havaintojen aritmeettinen keskiarvo, μ on vetolujuuden odotusarvo. Olemme kiinnostuneita yksisuuntaisesta luottamusvälistä $[a, \infty[$, missä a saadaan määrättyä ehdosta

$$P(T \leq r_0) = 0.99.$$

Koska havaintoja on yhteensä 20, niin vapausasteiden lukumäärä on $n - 1 = 19$. Taulukosta saadaan

$$r_0 = 2.539.$$

Epäyhtälöstä

$$T \leq r_0$$

saadaan

$$\mu \geq \mu_l = \bar{X} - r_0 S / \sqrt{n}.$$

Estimoidaan \bar{X} ja S otoksesta otoskeskiarvolla $\bar{x} = 392.55$ ja otoshajonnalla $s = 13.379$. Sijoittamalla saadut estimaatit alarajaan μ_l saadaan alarajaksi $a = \tilde{\mu}_l \approx 385$ ja siten luottamusväliksi

$$I_\mu = [385, \infty[.$$

Koska luottamusvälin alaraja on laatuvaatimuksen alapuolella, ei laatuvaatimus toteudu tämän otoksen perusteella.

4. Tutkittiin henkilöiden ruumiinlämpöä mittaamalla 130 henkilön ruumiinlämpö. Mittausten tuloksiksi saatiin $\bar{x} = 36.805$ ja $s = 0.407$ yksikkönä [°C]. Määrää ruumiinlämmön odotusarvon 95% luottamusväli käyttämällä
- t -jakaumaa ja sille annettua taulukkoa.
 - t -jakaumaa laskemalla kynnyisarvo graafisella laskimella tai vaikkapa Excelillä.
 - normaalijakaumaa, missä on arvioitu $\sigma \approx s$.

Mitä voit näiden tietojen perusteella sanoa normaalijakauman käytöstä odotusarvon estimoinnissa suurilla n :n arvoilla?

Ratkaisu:

$$Z = \frac{\bar{x} - \mu}{s/\sqrt{n}} \sim t_{n-1}$$

missä $n = 130$, $\bar{x} = 36,805$ ja $s = 0,407$. Määrätään ruumiinlämmön odotusarvon 95%:n luottamusväli vaatimalla, että on voimassa

$$P(-t_p \leq Z \leq t_p) \geq 0,95$$

Tällöin saadaan odotusarvon μ luottamusväliksi laskettua

$$\begin{aligned} -t_p &\leq \frac{\bar{x} - \mu}{s/\sqrt{n}} \leq t_p \\ -t_p \cdot \frac{s}{\sqrt{n}} &\leq \bar{x} - \mu \leq +t_p \cdot \frac{s}{\sqrt{n}} \\ \bar{x} - t_p \cdot \frac{s}{\sqrt{n}} &\leq \mu \leq \bar{x} + t_p \cdot \frac{s}{\sqrt{n}} \end{aligned}$$

johon voidaan sijoittaa tehtävän arvot $n = 130$, $\bar{x} = 36,805$ ja $s = 0,407$

$$36,805 - t_p \cdot 0,035696 \leq \mu \leq 36,805 + t_p \cdot 0,035696$$

- a) t -jakauman taulukkoa käyttäen. $t_p = 1,98$, joten saadaan

$$\begin{aligned} 36,805 - 0,0707 &\leq \mu \leq 36,805 + 0,0707 \\ 36,73 &\leq \mu \leq 36,88 \end{aligned}$$

- b) t -jakaumalla laskemalla kynnyisarvo koneella. $t_p = 1,9785$, joten saadaan

$$\begin{aligned} 36,805 - 0,0706259274 &\leq \mu \leq 36,805 + 0,0706259274 \\ 36,734 &\leq \mu \leq 36,876 \end{aligned}$$

- c) normaalijakaumaa, jossa on arvioitu $\sigma \simeq s$. $t_p = 1,96$, joten saadaan

$$\begin{aligned} 36,805 - 0,06996 &\leq \mu \leq 36,805 + 0,06996 \\ 36,74 &\leq \mu \leq 36,87 \end{aligned}$$

Normaalijakaumaa voi hyvin käyttää suurilla n :n arvoilla approksimoimaan t -jakaumaa, sillä t -jakauma lähestyy normaalijakaumaa vapausasteiden kasvaessa.

5. Osakkeiden hinnan mallittamisessa käytetään kuuluisaa Black-Scholesin mallia, jonka mukaan osakkeen hinta ajanhetkellä t on satunnaismuuttuja

$$H(t) = H(0) \cdot \exp\left(\left(b - \frac{1}{2}\sigma^2\right)t + \sigma W(t)\right),$$

missä $H(0)$ on osakkeen hinta ajanhetkellä $t = 0$, $b, \sigma > 0$ ovat vakioita ja $W(t) \sim N(0, t)$ on satunnaismuuttuja. Oletetaan, että $H(0) = 100$, $b = 0.1$ ja $\sigma = 0.3$ (Vertaa harjoitus 2 tehtävä 5).

- a) Laske osakkeen hinnan odotusarvo ajanhetkellä $t = 1$ (**Vihje:** neliöi odotusarvossa esiintyvä eksponentti ja käytä integroinnissa sopivaa sijoitusta).
- b) Määrittää ajanhetkellä $t = 1$ osakkeen hinnalle väli, jolla hinta on 95% todennäköisyydellä, eli väli $[a_1, a_2]$, jolle $P(a_1 \leq H(1) \leq a_2) = 0.95$, laskemalla normaalijakauman avulla sellainen luku r_0 , että $P(-r_0 \leq W(1) \leq r_0) = 0.95$.

Ratkaisu:

- a) Osakkeen hinta hetkellä $t = 1$ on

$$H(1) = H(0)e^{(b - \frac{\sigma^2}{2}) \cdot 1 + \sigma W(1)} = H(0)e^{b - \frac{\sigma^2}{2}} e^{\sigma Z},$$

missä $Z \sim N(0, 1)$. Merkitään $c = H(0)e^{b - \frac{\sigma^2}{2}}$, jolloin

$$\begin{aligned} E(H(1)) &= c \cdot E(e^{\sigma Z}) \\ &= c \int_{-\infty}^{\infty} e^{\sigma x} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \\ &= c \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\sigma)^2 + \frac{\sigma^2}{2}} dx \\ &= c \cdot e^{\frac{\sigma^2}{2}} \underbrace{\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx}_{=\Phi(\infty) - \Phi(-\infty) = 1} \\ &= H(0)e^{b - \frac{\sigma^2}{2}} e^{\frac{\sigma^2}{2}} = H(0)e^b = \underline{110,52} \end{aligned}$$

- b) Muokataan vaadittua ehtoa käyttäen a)-kohdan määritystä c :lle:

$$\begin{aligned} P(a_1 \leq H(0)e^{b - \frac{\sigma^2}{2}} e^{\sigma W(1)} \leq a_2) \\ &= P\left(\frac{a_1}{c} \leq e^{\sigma W(1)} \leq \frac{a_2}{c}\right) \\ &= P\left(\frac{1}{\sigma} \ln \frac{a_1}{c} \leq W(1) \leq \frac{1}{\sigma} \ln \frac{a_2}{c}\right) \\ &= P(-r_0 \leq W(1) \leq r_0) = 0,95 \end{aligned}$$

Koska tässä on $W(1) \sim N(0, 1)$, niin standardisoidun normaalijakauman taulukosta nähdään, että $r_0 = 1,96$, joten

$$a_1 = ce^{-\sigma r_0} \simeq 58,68 \quad \text{ja} \quad a_2 = ce^{\sigma r_0} \simeq 190,22$$

Siispä osakkeen hinta hetkellä $t = 1$ on 95%:n todennäköisyydellä välillä $\underline{[58,68, 190,22]}$.