

# Sovellettu todennäköisyyslaskenta B

Antti Rasila

3. marraskuuta 2007

- 1 Varianssin luottamusväli, jatkoa
- 2 Bernoulli-jakauman odotusarvon luottamusväli
- 3 Otoskoon määrääminen
- 4 Estimaattorin valinta
- 5 Momenttimenetelmä
- 6 Suurimman uskottavuuden menetelmä
  - Diskreetti tapaus
  - Jatkuva tapaus

## Esimerkki (Laininen) 1/2

- Palkin paksuudeksi ( $n = 10$ ) mitattiin (tuumaa):  
2.11 2.02 2.20 1.98 2.14 1.99 2.09 2.19 2.23 2.10
- Oletetaan, että palkin paksuus  $X \sim N(\mu, \sigma)$ .
- Otoksesta voidaan laskea  $\bar{x} = 2.105$  ja  $s = 0.08786$ .  
Vapausasteparametri  $\nu = 10 - 1 = 9$ .
- Taulukosta saadaan  $t_{0.025} = 2.262$ , joten voidaan laskea

$$\mu = 2.105 \pm 2.262 \cdot \frac{0.08786}{\sqrt{10}}.$$

- Siis 95% luottamusväli on  $[2.04, 2.17]$  tuumaa.

## Esimerkki (Laininen) 2/2

- Varianssin luottamusväli muodostetaan 9-vapausasteisen  $\chi^2$ -jakauman avulla.
- Taulukosta (tai tietokoneella) saadaan  $\chi_{0.975}^2 = 2.70$  ja  $\chi_{0.025}^2 = 19.0$ .
- Sijoitus kaavaan antaa 95% luottamusväliksi

$$\frac{9}{19.0} \cdot 0.0879^2 \leq \sigma^2 \leq \frac{9}{2.70} \cdot 0.0879^2,$$

eli [0.0037,0.0258].

- Olkoon havainnot  $X_1, \dots, X_n$  yksinkertainen satunnaisotos Bernoulli-jakaumasta parametrilla  $p$ . Eli

$$X \sim \text{Bernoulli}(p).$$

- Suhteellinen frekvenssi

$$\hat{p} = \frac{f}{n}$$

on Bernoulli-jakauman *odotusarvoparametrin*  $p$  *harhaton estimaattori*.

- Olkoon

$n$  = havaintojen lukumäärä

$z_{\alpha/2}$  = häntätodennäköisyyttä  $\alpha/2$  vastaava piste standardoidusta normaalijakaumasta  $N(0, 1)$ .

- Suhteellisen frekvenssin  $\hat{p}$  odotusarvo ja varianssi ovat:

$$E(\hat{p}) = p$$
$$\text{Var}(\hat{p}) = \frac{pq}{n}$$

- Suhteellinen frekvenssi  $\hat{p}$  noudattaa suurissa otoksissa approksimatiivisesti normaalijakaumaa.
- Bernoulli-jakauman *odotusarvoparametrin  $p$  approksimatiivinen luottamusväli luottamustasolla  $(1 - \alpha)$*  on

$$\left( \hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}, \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right).$$

# Otoskoon määrittäminen 1/2

- Ennakkotiedon mukaan Bernoulli-jakauman odotusarvoparametrin arvoksi oletetaan  $p$ . Kuinka suuri otos on otettava, jotta  $p$ :lle voidaan muodostaa  $(1 - \alpha)$ -luottamusväli, jonka pituus on  $2A$ ?
- Parametrin  $p$  luottamusväli luottamustasolla  $(1 - \alpha)$  on

$$\left( \hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}, \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right).$$

- Ennakkotiedon perusteella oletetaan  $\hat{p} = p$ .

## Otoskoon määrääminen 2/2

- Jotta luottamusvälin pituus olisi  $2A$ , on oltava

$$z_{\alpha/2} \sqrt{\frac{p(1-p)}{n}} = A.$$

josta voidaan ratkaista *tarvittava otoskoko*  $n$ :

$$n = \left( \frac{z_{\alpha/2} \sqrt{p(1-p)}}{A} \right)^2.$$

- Huomaa, että otoskoko saavuttaa maksiminsa

$$n = \left( \frac{z_{\alpha/2}}{2A} \right)^2,$$

kun  $p = 1/2$ .



- Oletetaan, että aineistona on yksinkertainen satunnaisotos  $X_1, \dots, X_n$  jakaumasta

$$f_X(x; \theta_1, \dots, \theta_r).$$

- Satunnasmuuttujan  $X$  siis oletetaan noudattavan jakaumaa  $f_X(x; \theta_1, \dots, \theta_r)$  parametreilla  $\theta_1, \dots, \theta_r$ , mutta parametrien arvoja ei tunneta.
- Tehtävänä on muodostaa parametreille  $\theta_1, \dots, \theta_r$  estimaattorit  $\hat{\theta}_1, \dots, \hat{\theta}_r$ .
- Estimaattorien muodostamiseen on useita eri menetelmiä. Tällä kurssilla käsitellään *momenttimenetelmä* ja *suurimman uskottavuuden menetelmä*.

- Useasta jakaumasta  $f_X(x; \theta_1, \dots, \theta_r)$  voidaan määrittää teoreettisia momenteja  $m_k = E[X^k]$ , jotka ovat parametrien  $\theta_1, \dots, \theta_r$  funktioita.
- Näiden teoreettisten momenttien estimaattorit  $\hat{m}_k$  voidaan määrittää havaintoarvoista kaavalla

$$\hat{m}_k = \frac{1}{n} \sum_{i=1}^n x_i^k.$$

- Kun teoreettiset momentit asetetaan yhtäsuuriksi estimaattorien kanssa, saadaan yhtälöryhmä, josta voidaan ratkaista parametrien  $\theta_1, \dots, \theta_r$  estimaattorit.
- Jos halutaan määrittää estimaattorit  $r$ :lle parametrille, tarvitaan  $r$  yhtälöä. Tätä varten tulee määrittää  $r$  ensimmäistä teoreettista momenttia.

# Esimerkki (Laininen) 1/2

- Huollon kestoajan  $X$  tiheysfunktio on

$$f_X(x; \theta_1, \theta_2) = \begin{cases} \theta_1 e^{-\theta_1(x-\theta_2)}, & \text{kun } x \geq \theta_2, \\ 0, & \text{kun } x < \theta_2, \end{cases}$$

missä  $\theta_1, \theta_2 > 0$ .

- Olkoot  $x_1, \dots, x_n$  havaittuja huollon kestoajoja.
- Parametrien estimoimiseksi momenttimenetelmällä lasketaan integroimalla ensimmäinen ja toinen momentti:

$$m_1 = \int_{\theta_2}^{\infty} x \theta_1 e^{-\theta_1(x-\theta_2)} dx = \frac{1}{\theta_1} + \theta_2,$$

$$m_2 = \int_{\theta_2}^{\infty} x^2 \theta_1 e^{-\theta_1(x-\theta_2)} dx = \theta_2^2 + \frac{2}{\theta_1^2} + \frac{2\theta_2}{\theta_1}.$$

- Estimaatit  $\theta_1, \theta_2$  ratkaistaan yhtälöistä

$$\hat{m}_1 = \frac{1}{\hat{\theta}_1} + \hat{\theta}_2, \quad \hat{m}_2 = \theta_2^2 + \frac{2}{\theta_1^2} + \frac{2\theta_2}{\theta_1},$$

missä

$$\hat{m}_1 = \frac{1}{n} \sum_{i=1}^n x_i, \quad \hat{m}_2 = \frac{1}{n} \sum_{i=1}^n x_i^2.$$

- Ratkaisuksi saadaan

$$\hat{\theta}_1 = \frac{1}{\sqrt{\hat{m}_2 - \hat{m}_1^2}}, \quad \hat{\theta}_2 = \hat{m}_1 - \sqrt{\hat{m}_2 - \hat{m}_1^2}.$$

# Suurimman uskottavuuden menetelmä

- *Suurimman uskottavuuden menetelmän* ajatuksena on, että malli  $f_X(x; \theta_1, \dots, \theta_r)$  on paras, jos se tuottaa havaitun otoksen suurimmalla todennäköisyydellä.
- Menetelmässä muodostetaan *likelihood-funktio*

$$L(\theta_1, \dots, \theta_r),$$

joka kuvaa saadun otoksen todennäköisyyttä parametrien  $\theta_1, \dots, \theta_r$  funktiona.

- Kun likelihood-funktiota maksimoidaan parametrien  $\theta_1, \dots, \theta_r$  suhteen, ovat saadut satunnaismuuttujat  $\hat{\theta}_1, \dots, \hat{\theta}_r$  parametrien  $\theta_1, \dots, \theta_r$  *suurimman uskottavuuden estimaattorit*.

- Olkoon  $X_1, \dots, X_n$  yksinkertainen satunnaisotos diskreetistä jakaumasta, jonka pistetodennäköisyysfunktio on

$$f_X(x_i; \theta_1, \dots, \theta_r).$$

- Todennäköisyys otokselle  $x_1, \dots, x_n$  on

$$L(\theta_1, \dots, \theta_r) = f_X(x_1; \theta_1, \dots, \theta_r) \cdots f_X(x_n; \theta_1, \dots, \theta_r).$$

- Parametreille  $\theta_1, \dots, \theta_r$  tulee löytää sellaiset arvot, että  $L$  maksimoituu.

- $L$ :n maksimi löytyy pisteestä, jossa kaikki osittaisderivaatat ovat nolliä, eli

$$\frac{\partial L}{\partial \theta_i} = 0, \quad \forall i$$

- Funktion  $L$  *logaritmimuunnos*  $\ln(L)$  saa maksiminsa samassa pisteessä kuin  $L$ . Usein tarkastellaankin funktiota  $\ln(L)$ , koska logaritmimuunnos muuntaa tulomuotoisen likelkihood-funktion summaksi, jota on helpompi derivoida.

# Esimerkki

- Tiedonsiirtojärjestelmä siirtää merkkejä 0 ja 1. Merkki 1 voi vaihtua merkiksi 0 todennäköisyydellä  $p$ .
- Todennäköisyyden arvioimiseksi lähetetään 10000 kertaa merkki 1, jolloin todetaan, että merkki on vaihtunut 90 kertaa.
- Koska 10000 merkin siirrossa merkki on välittynyt oikein 9910 kertaa ja vaihtunut 90 kertaa, saadaan

$$L(p) = (1 - p)^{9910} p^{90}.$$

- Etsitään se parametrin  $p$  arvo, jolla  $L(p)$  saa maksiminsa:

$$\frac{\partial}{\partial p} L(p) = -9910(1 - p)^{9909} p^{90} + 90(1 - p)^{9910} p^{89} = 0.$$

- Ratkaistaan

$$\hat{p} = \frac{90}{10000} = 0.009.$$



- Olkoon  $X_1, \dots, X_n$  yksinkertainen satunnaisotos jatkuvasta jakaumasta, jonka tiheysfunktio on

$$f_X(x; \theta_1, \dots, \theta_r).$$

- Koska jatkuvassa tapauksessa kaikkien yksittäisten havaintosarjojen  $x_1, \dots, x_n$  todennäköisyys on nolla, likelihood-funktio

$$L(\theta_1, \dots, \theta_r) = f_X(x_1; \theta_1, \dots, \theta_r) \cdots f_X(x_n; \theta_1, \dots, \theta_r)$$

ei kuvaa havaintosarjan todennäköisyyttä. Tiheysfunktion arvojen tulona sitä voidaan kuitenkin perustellusti käyttää kuten diskreetissä tapauksessa.

- Oletetaan, että  $X$  on tasaisesti jakautunut välille  $[0, \theta]$ , missä parametri  $\theta > 0$  ja  $X$ :n tiheysfunktio on

$$f_X(x) = \begin{cases} 1/\theta, & \text{kun } x \in [0, \theta], \\ 0, & \text{muuten.} \end{cases}$$

- Likelihood-funktio on

$$L(\theta) = \begin{cases} 1/\theta^n, & \text{kun } \theta \geq \max\{x_1, \dots, x_n\}, \\ 0 & \text{muuten.} \end{cases}$$

- Nyt maksimi ei löydy derivoimalla, mutta voidaan päätellä tutkimalla funktiota  $L(\theta)$ .
- Suurin arvo saadaan selvästi, kun  $\hat{\theta} = \max\{x_1, \dots, x_n\}$ .