

10. loeng: Hinnangu standardvea leidmise meetodeid

November 2, 2020

Kasutatud Natalja Lepiku slaide

Eristame: **punkthinnang** tundmatule parameetrile θ on valimivaatluste põhjal leitud arv $\hat{\theta}$, millele vastab **hinnangufunktsioon** (ehk arvutuseeskiri) $\hat{\theta}$.

Parameetri hindamiseks võime pakkuda mitu erinevat eeskirja (näiteks aritmeetiline keskmine ja mediaan).

See, kui hea on hinnang, on määratud hinnangufunktsiooni jaotusega. Jaotuse abil saame uurida **hinnangu omadusi**:

- Hinnang on **nihketa**, kui kehtib $E\hat{\theta} = \theta$. Siinjuures on $B = E\hat{\theta} - \theta$ hinnangu nihe.
- Hinnangu **ruutkeskmine viga** on $MSE(\hat{\theta}) = E(\hat{\theta} - \theta)^2 (= D\hat{\theta} + B^2)$.
- Hinnang on **mõjus**, kui $\lim_{n \rightarrow \infty} MSE(\hat{\theta}) = 0$.
- Nihketa hinnang $\hat{\theta}_1$ on **efektiivsem** kui nihketa hinnang $\hat{\theta}_2$ kui kehtib $D\hat{\theta}_1 \leq D\hat{\theta}_2$ (range võrrotus peab kehtima vähemalt ühe parameetri võimaliku väärtuse koral.)

Parameetriline bootstrap

Olgu valimi x_1, x_2, \dots, x_n kohta teada, et see on pärit jaotusest $F(\theta)$, kus θ on tundmatu.

Valimi põhjal leitakse hinnang $\hat{\theta}$, näiteks $\hat{\theta} = 27,96$ (1. näites mediaanil põhinev hinnang).

Nüüd kasutades arvutit genereerime bootstrap valimeid jaotusest $F(27,96)$ sama mahuga n ning iga bootstrap valimi põhjal arvutame bootstrap hinnangu $\hat{\theta}^*$:

1. bootstrap valim: $x_1^*, x_2^*, \dots, x_n^*$, punkthinnang $\hat{\theta}_1^*$
2. bootstrap valim: $x_1^*, x_2^*, \dots, x_n^*$, punkthinnang $\hat{\theta}_2^*$
- ...
- B . bootstrap valim: $x_1^*, x_2^*, \dots, x_n^*$, punkthinnang $\hat{\theta}_B^*$.

B on suur (näiteks 1000 ja rohkem).

Parameetriline bootstrap (jätkub)

Tähistame $\bar{\theta}^* = \sum_{i=1}^B \hat{\theta}_i^* / B$ - bootstrap hinnangute keskmine.

Siis hinnangu $\hat{\theta}$ **standardviga bootstrap meetodil** on

$$\sqrt{\hat{D}\hat{\theta}}_{BS} = \sqrt{\frac{1}{B-1} \sum_{i=1}^B (\hat{\theta}_i^* - \bar{\theta}^*)^2}.$$

Mitteparameetriline bootstrap

Erineb eespool mainitust selle poolest, et me ei kasuta X jaotust F . On olemas valim, mille kohta me ei tea, mis jaotuse klassist see pärit on. Meid huvitab ÜK parameeter θ .

Kasutades arvutit võtame olemasolevast valimist bootstrap valimeid sama mahuga n kasutades lihtsat juhuvalikut tagasipanekuga.

Iga bootstrap valimi põhjal arvutame bootstrap hinnangu $\hat{\theta}^*$.

Hinnangu $\hat{\theta}$ **standardviga** leitakse analoogiliselt eelmise versiooniga,

$$\sqrt{\hat{D}\hat{\theta}}_{BS} = \sqrt{\frac{1}{B-1} \sum_{i=1}^B (\hat{\theta}_i^* - \bar{\theta}^*)^2}.$$

Bootstrap-meetodi rakenduse näide (1)

Normaaljaotusega juhuslike suuruste valim:

24.46, 25.61, 26.25, 26.42, 26.66, 27.15, 27.31, 27.54, 27.74, 27.94,
27.98, 28.04, 28.28, 28.49, 28.50, 28.87, 29.11, 29.13, 29.50, 30.88

Hindame keskväärtust neljal erineval viisil:

$$\begin{aligned}\hat{\mu}_1 &= \bar{x} = 27.793; & \hat{\mu}_2 &= (x_{(10)} + x_{(11)})/2 = 27.960; \\ \hat{\mu}_3 &= (x_{(1)} + x_{(20)})/2 = 27.670; & \hat{\mu}_4 &= \bar{x}_{\text{karb}} = 27.838.\end{aligned}$$

Hinnangu $\hat{\mu}_1$ standardviga on lihtne leida:

kuna $X_i \sim N(\mu, \sigma)$, $i = 1, \dots, 20$, millest $\bar{X} \sim N(\mu, \sigma/\sqrt{20})$

$$\sqrt{\hat{D}\hat{\mu}_1} = \sqrt{\hat{D}\bar{X}} = \hat{\sigma}/\sqrt{20} = 1,461/\sqrt{20} = 0,327.$$

Teiste hinnangute standardvea leidmine analüütiliselt pole nii triviaalne.
Kasutame siinkohal parameetrilist bootsrapi.

Parameetrilise BS-meetodi rakenduse näide (2)

R-i kood $\hat{\mu}_1$ standardvea leidmise kood bootstrap-meetodil:

```
x=c(24.46,25.61,26.25,26.42,26.66,27.15,27.31,27.54,27.74,27.94,27.98,  
    28.04,28.28,28.49,28.50,28.87,29.11,29.13,29.50,30.88)
```

```
k=10000
```

```
# Valimikeskmine:
```

```
mu1=mean(x)
```

```
bt_mu1=rep(NA,k)
```

```
for(i in 1:k){  
  valim=rnorm(20,mu1,sd(x))  
  bt_mu1[i]=mean(valim)  
}  
sd(bt_mu1)
```

Vastus: 0,328


Hinnangute $\hat{\mu}_2, \hat{\mu}_3$ ja $\hat{\mu}_4$ bootstrap-hinnangute leidmiseks võib kasutada vastavalt: `median`, `(min(x)+max(x))/2` ja `mean(x, trim=0.1)`.

Parameetrilise BS-meetodi rakenduse näide (3)

Tulemused:

$$\sqrt{\hat{D}\hat{\mu}_1} = 0,328; \quad \sqrt{\hat{D}\hat{\mu}_2} = 0,398; \quad \sqrt{\hat{D}\hat{\mu}_3} = 0,554; \quad \sqrt{\hat{D}\hat{\mu}_4} = 0,334.$$

Bootstrap-hinnangute karpdiagrammid



Mitteparameetrilise BS-meetodi rakenduse näide (1)

R-i kood $\hat{\mu}_1$ standardvea leidmise kood mitteparameetrilisel bootstrap-meetodil:

```
x=c(24.46,25.61,26.25,26.42,26.66,27.15,27.31,27.54,27.74,27.94,27.98,  
    28.04,28.28,28.49,28.50,28.87,29.11,29.13,29.50,30.88)
```

```
k=10000
```

```
teeta1=rep(NA,k) #valimikeskmine  
teeta2=rep(NA,k) #mediaan  
teeta3=rep(NA,k) #(Maximum+Minimum)/2  
teeta4=rep(NA,k) #Kärbitud keskmine (2 min ja 2 max elementi on  
ära jäetud)
```

```
for(i in 1:k){  
  valim=sample(x, 20, replace=TRUE) #valik TGA mahuga 20  
  esialgsest valimist  
  teeta1[i]=mean(valim)  
  teeta2[i]=median(valim)  
  teeta3[i]=(min(valim)+max(valim))/2  
  teeta4[i]=mean(valim,trim=0.1)  
}
```


Mitteparameetrilise BS-meetodi rakenduse näide (2)

Hinnangute jaotus karpdiagrammi abil:

```
boxplot(teeta1, teeta2, teeta3, teeta4,  
names=c(expression(theta[1]),expression(theta[2]),expression(theta[3]),  
expression(theta[4])),  
main="Mitteparameetrilise bootstrap-hinnangute karpdiagrammid")
```

Mitteparameetrilise BS-meetodi rakenduse näide (3)

Mitteparameetrilise bootstrap-hinnangute karpdiagrammid



– veel üks alternatiiv standardvea hindamiseks.

Pakkugu θ asemel huvi hoopis selle funktsioon $g(\theta)$ ja oletame, et oskame hinnata θ mõjusa hinnangu $\hat{\theta}$ abil. Mida oskame sel juhul öelda funktsiooni hinnangu $g(\hat{\theta})$ kohta (nihketa? mõjus?)?

Sageli on abiks Taylori ritta arendamise tehnika parameetri θ ümbruses, mis töötab hästi siis kui $\hat{\theta}$ on mõjus hinnang θ -le ning valimimaht on suur. Meetodit nimetatakse veel Delta meetodiks.

Delta meetod:

- sobib kasutamiseks mittelineaarsete hinnangute korral;
- meetod annab ligikaudse tulemuse;
- meetodit rakendatakse suurte valimite korral;
- põhineb hinnangu arendamisel Taylori ritta.

Lemma

Olgu $g(\theta)$ huvipakkuv mittelineaarne funktsioon ning $\hat{\theta}$ mõjus hinnang parameetritele θ keskväärtusega $E\hat{\theta} = \theta$ ja dispersiooniga $D\hat{\theta}$. Kui $g(\hat{\theta})$ differentseeruv ja $g'(\theta) \neq 0$, siis funktsiooni $g(\hat{\theta})$ ligikaudne keskväärtus ja dispersioon avalduvad järgmiselt:

$$E[g(\hat{\theta})] \approx g(\theta), \quad D[g(\hat{\theta})] \approx g'(\theta)^2 D[\hat{\theta}].$$

Tõestus.

Arendame funktsiooni $g(\hat{\theta})$ Taylori ritta punkti θ ümbruses ja võtame sellest ainult lineaarse liikme:

$$g(\hat{\theta}) \approx g(\theta) + g'(\theta)(\hat{\theta} - \theta).$$

Leiame lineaarliikme keskväärtuse:

$$E[g(\hat{\theta})] \approx E[g(\theta)] + g'(\theta)(E\hat{\theta} - \theta) = g(\theta)$$

ja dispersiooni:

$$D[g(\hat{\theta})] \approx D[g(\theta)] + D[g'(\theta)(\hat{\theta} - \theta)] = g'(\theta)^2 D[\hat{\theta} - \theta] = g'(\theta)^2 D[\hat{\theta}].$$

Delta meetodi kasutamise näide (1)

Näide

Olgu antud suur valim x_1, \dots, x_n jaotusest $\text{Exp}(\lambda)$, kus λ on huvipakkuv parameeter.

Varasemast teame, et $EX_i = \frac{1}{\lambda}$ ja $DX_i = \frac{1}{\lambda^2}$, $i = 1, \dots, n$.

Kuna $\frac{1}{\lambda}$ on jaotuse keskvärtus, siis selle hindamiseks sobib valimikeskmine \bar{x} :
 $\frac{1}{\lambda} = \bar{x}$, millest $\hat{\lambda} = \frac{1}{\bar{x}}$.

Mida osakme öelda hinnangu $\hat{\lambda}$ keskvärtuse ja dispersiooni kohta? Rakendame Delta meetodit.

Siin on $\theta = EX$, $\hat{\theta} = \bar{X}$, $g(\hat{\theta}) = 1/\bar{X}$. Peame teadma veel $E\hat{\theta}$ ja $D\hat{\theta}$:

$$E\hat{\theta} = E\bar{X} = \dots = \lambda^{-1} \quad \text{ja} \quad D\hat{\theta} = D\bar{X} = \dots = (n\lambda^2)^{-1}.$$

Rakendame lemmat hinnangu keskvärtuse leidmiseks:

$$E[g(\hat{\theta})] \approx g(\theta) = \frac{1}{1/\lambda} = \lambda,$$

järelikult tegemist on ligikaudselt nihketa hinnanguga.

Delta meetodi kasutamise näide (2)

Näide (jätkub)

Meil oli $\theta = \lambda^{-1}$, $\hat{\theta} = \bar{X}$, $g(\hat{\theta}) = (\bar{X})^{-1}$, $E\hat{\theta} = \lambda^{-1}$ ja $D\hat{\theta} = (n\lambda^2)^{-1}$.
Ligikaudse dispersiooni saamiseks kirjutame esmalt välja $g'(\theta)$:

$$g'(\theta) = g'(\hat{\theta}) \Big|_{\hat{\theta}=\theta} = (\bar{X}^{-1})' \Big|_{\bar{X}=1/\lambda} = -\bar{X}^{-2} \Big|_{\bar{X}=1/\lambda} = -\lambda^2.$$

Lemma järgi $D[g(\hat{\theta})] \approx g'(\theta)^2 D[\hat{\theta}]$, millest

$$D(\bar{X}^{-1}) \approx \lambda^4 \cdot \frac{1}{n\lambda^2} = \frac{\lambda^2}{n}.$$

Seega, hinnang $\hat{\lambda} = \frac{1}{\bar{X}}$ on ligikaudselt mõjus hinnang parameetrile λ .

Delta meetod asümptootiliselt normaaljaotusega hinnangute korral.

Olgu hinnangu $\hat{\theta}_n$ asümptootiliseks jaotuseks normaaljaotus,

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0; \sigma_\theta^2).$$

Siis on ka $g(\hat{\theta}_n)$ asümptootilise normaaljaotusega,

$$\sqrt{n}(g(\hat{\theta}_n) - g(\theta)) \xrightarrow{d} N(0; \sigma_\theta^2 g'(\theta)^2),$$

kui g' eksisteerib ja $g'(\theta) \neq 0$.

Mitmemõõtmeline versioon Delta meetodist

Olgu hinnangute vektori $\hat{\theta}_n = (\hat{\theta}_{n,1}; \dots; \hat{\theta}_{n,k})^T$ asümptootiliseks jaotuseks mitmemõõtmeline normaaljaotus,

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N_k(0; \Sigma).$$

Siis on ka $\mathbf{g}(\hat{\theta}_n)$ asümptootilise normaaljaotusega,

$$\sqrt{n}(\mathbf{g}(\hat{\theta}_n) - \mathbf{g}(\theta)) \xrightarrow{d} N(0; \mathbf{g}'(\theta)\Sigma\mathbf{g}'(\theta)^T),$$

kui \mathbf{g}' eksisteerib ja $\mathbf{g}'(\theta) \neq 0$.