

# Kodutöö näidilahendus

## 1. Ülesanne

Hindame Tallinna börsi tootlust kasutades geomeetrilist keskmist.

```
# Defineerime funktsiooni, mis arvutab vaatluste geomeetrilise
keskmise:
GeomKeskmine=function(x){
  exp(mean(log(x)))
}

# Sisestame vaatlused ehk tootluste protsendid:
tootlused=c(47.2, 72.6, -23.9, 38.22, 11.38, -7.66, 19.06, 19.63,
  15.49, -6.38, 10.05, 5)

# Leiame keskmise tootluse:
gkeskm=GeomKeskmine(100+tootlused)-100
gkeskm
```

Ehk keskmine tootlus (geomeetriline keskmine) on 14,1

Kui täpne on saadud hinnang? Leiame hinnangu standardvea kasutades bootstrap-meetodit:

```
k=100000
BShinnangud=rep(NA,k) # Bootstrap hinnangud salvestame siia

for(i in 1:k){
  # Võtame tagasipanekuga valimi mahuga 12
  BSvalim=sample(tootlused, length(tootlused), replace=TRUE)
  # Leiame bootstrap-valimi põhjal hinnangu:
  BShinnangud[i]=GeomKeskmine(100+BSvalim)-100
}

# Bootstrap-meetodil leitud standardviga:
sd(BShinnangud)

# Ehk tootluse hinnang ja tema standardviga bootstrap-meetodil:
paste(round(gkeskm,1), "\u00B1", round(sd(BShinnangud),1))
```

Tallinna börsi keskmiseks tootluseks saame seega  $14.1 \pm 7$ . Standardvea hinnang 7 on leitud siin bootstrap-meetodit kasutades.

b) Leiame hinnangu täpsuse ka Delta-meetodil. Valimi keskmise ehk suuruse

$$\hat{\theta} = \overline{\ln(100 + \textit{tootlusprotsent})}$$

dispersiooni on kerge leida — hindame lihtsalt suuruste  $\ln(100 + \textit{tootlusprotsent})$  dispersiooni ja jagame saadud tulemuse vaatluste arvuga:

$$\begin{aligned}\hat{D}(\hat{\theta}) &= \hat{D}\left(\overline{\ln(100 + \textit{tootlusprotsent})}\right) \\ &= \hat{D}(\ln(100 + \textit{tootlusprotsent}))/n \\ &= 0,04853828/12 \\ &= 0,004044857.\end{aligned}$$

Meil on aga tarvis leida geomeetrilise keskmise hinnangu dispersiooni ehk juhusliku suuruse

$$\exp(\hat{\theta}) - 100$$

dispersiooni. Konstandi liitmine või lahutamine juhusliku suuruse dispersiooni ei muuda — seega võime suuruse  $-100$  dispersiooni leidmiseks vajalikke arvutusi tehes ka unustada.

Delta meetod ütleb, et

$$D\left(f(\hat{\theta})\right) \approx D(\hat{\theta}) \cdot \left(f'(\hat{\theta})\right)^2.$$

Antud juhul  $f(x) = \exp(x)$ ,  $f'(x) = \exp(x)$  ja  $(f'(\hat{\theta}))^2 = \exp(\hat{\theta})^2$ , seega

$$\hat{D}(f(\hat{\theta})) \approx 0,004044857 \cdot \exp(4.737454)^2 = 52,699 \dots$$

Antud arvutust tehes tasub meeles pidada, et praegu

$$\hat{\theta} = \overline{\ln(100 + \textit{tootlusprotsent})} = 4,737 \dots$$

Seega annab Delta meetod standardvea ligikaudseks hinnanguks  $\sqrt{52,699} = 7,259 \dots$

## 2. Ülesanne

Otsitava parameetri  $p$  hindamiseks võime kasutada suurima tõepära hinnangut. Suurima tõepära hinnangu leidmiseks paneme esmalt kirja tõepärafunktsiooni:

$$L(p) = \left(\frac{2p}{3}\right)^{n_0} \left(\frac{p}{3}\right)^{n_1} \left(\frac{2(1-p)}{3}\right)^{n_2} \left(\frac{1-p}{3}\right)^{n_3},$$

Kus  $n_0$  on valimis olevate nullide arv,  $n_1$  on nähtud ühtede arv jne.

Maksimiseerida on lihtsam log-tõepära, seega leiame ka selle:

$$l(p) = n_0 \log(2p/3) + n_1 \log(p/3) + n_2 \log(2(1-p)/3) + n_3 \log((1-p)/3),$$

Maksimumi leidmiseks võtame tuletise otsitava parameetri  $p$  järgi:

$$\frac{\partial l}{\partial p} = n_0/p + n_1/p + n_2/(2(1-p)/3) \cdot (-2/3) + n_3/((1-p)/3) \cdot (-1/3),$$

ja võrdsustame saadud tulemuse nulliga:

$$\begin{aligned} \frac{\partial l}{\partial p} &= 0 \\ 0 &= n_0/p + n_1/p + n_2/(2(1-p)/3) \cdot (-2/3) + n_3/((1-p)/3) \cdot (-1/3) \mid \cdot p(1-p), \\ 0 &= n_0(1-p) + n_1(1-p) - n_2p - n_3p \\ 0 &= (n_0 + n_1) - p(n_0 + n_1 + n_2 + n_3) \\ p &= (n_0 + n_1)/(n_0 + n_1 + n_2 + n_3). \end{aligned}$$

Kas saime tulemuseks ikka maksimumi? Kontrollime seda. Log-tõepära teine tuletis

$$\frac{\partial^2 l}{\partial p^2} = -n_0/p^2 - n_1/p^2 - n_2/(1-p)^2 - n_3/(1-p)^2$$

on negatiivne mistahes  $p$  väärtuse korral mis jääb vahemikku  $0 \dots 1$ , seega oleme tõepoolest leidnud tõepärafunktsiooni maksimumi.

Tuletatud üldvalemit kasutades saame leida hinnangu ka oma valimi jaoks:

$$\hat{p} = 5/10 = 0,5.$$

Hinnangu täpsuse ehk standardvea leidmiseks võime kasutada näiteks parameetrilist bootstrappi:

```

hinnang=function(x){sum(x<=1)/length(x)}
BShinnang=rep(NA, 100000)

for (i in 1:100000){
  valim=sample(0:3, 10, prob=c(1/3, 1/6, 1/3, 1/6), replace=TRUE)
  BShinnang[i]=hinnang(valim)
}
sd(BShinnang)

```

Ülaloodud programmi jooksutades saame standardvea ligikaudseks väärtuseks  $\approx 0,16$ . Seega leitud hinnang parameetrile  $p$  on  $0,5 \pm 0,16$ .

Antud juhul on võimalik leida ka täpsem hinnang standardveale. Nimelt võime tähele panna, et hinnang  $\hat{p}$ , on vaadeldav kui juhuslike suuruste  $X_i, i = 1, \dots, n$  keskmine, kusjuures  $X_i = 1$  kui esialgne juhuslik suurus omandab väärtuse 0 või 1. Muidu on juhusliku suuruse  $X_i$  väärtus null,  $X_i = 0$ . Bernoulli jaotusega juhuslike suuruste  $X_i$  keskmise dispersiooni on aga lihtne leida:

$$D(\hat{p}) = P(0 \text{ või } 1)(1 - P(0 \text{ või } 1))/n = p(1 - p)/n,$$

sest  $P(0 \text{ või } 1) = 2p/3 + p/3 = p$ . Seega alternatiivne hinnang hinnangu dispersioonile oleks  $\hat{D}(\hat{p}) = 0,5 \cdot 0,5/10 = 0,025$  ja standardveaks tuleks siis  $\sqrt{0,025} = 0,158$ .

### 3. Ülesanne

```

# Andmete tekitamine:
set.seed(1)
naised=rnorm(120, mean=168, sd=6)
mehed=rnorm(80, mean=182, sd=7)
pikkused=c(mehed, naised)
rm(naised, mehed)

# Paneme kirja log-tõepära
ll = function(arg, andmed){
  mu_mees=arg[1]
  sigma_mees=exp(arg[2])
  mu_naine=arg[3]
  sigma_naine=exp(arg[4])
  meeste_osakaal=80/200
  print(paste(mu_mees, sigma_mees, mu_naine, sigma_naine, meeste_
    osakaal))
  l=sum(log(dnorm(andmed, mean=mu_mees, sd=sigma_mees))*meeste_osakaal
    +

```

```

    dnorm(andmed, mean=mu_naine, sd=sigma_naine )*(1-meeste_osakaal)
  ))
  return(l)
}

# Maksimiseerime t ep arafunktsiooni numbriliste meetodite abil:
# Peame andma ligikaudsed (oletuslikud) v artused otsitavatele
# parameetritele:
tul=optim(c(180, log(10), 160, log(10)), ll,
  andmed=pikkused, control=list(fnscale=-1))

# Tulemused:

# Hinnatud meeste pikkuste keskv artus
tul$par[1]
# Hinnatud meeste pikkuste standardh alve
exp(tul$par[2])

# Hinnatud naiste pikkuste keskv artus
tul$par[3]
# Hinnatud naiste pikkuste standardh alve
exp(tul$par[4])

```

Seega saame praegu meeste keskmise pikkuse hinnanguks 180,77 cm (standardh alve 7,78) ja naiste keskmiseks pikkuseks 169,08 (standardh alve 5,47).

M otteaineks:

1. V ordle saadud tulemusi tegelike v artustega!
2. Kas oskaksid seda  lesannet lahendada ka siis, kui meeste osakaalu poleks teada?