

PRAVDEPODOBNOSŤ a ŠTATISTIKA

Základy teórie odhadu

doc. RNDr. Štefan Peško, CSc.

Katedra matematických metód a operačnej analýzy, FRI ŽU

29. apríla 2019

Budeme sa venovať dvom princípom odhadu neznámych parametrov základného súboru.

Stretne sa tu s problémom dôsledného rozlišovania náhodnej premennej a jej realizácie - hodnoty. Dodržíme zaužívanú konvenciu napr. takto: výberový priemer z náhodného výberu $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ označíme $\bar{\mathbf{X}}$, ale keď sa tento výber bude realizovať konkrétnymi hodnotami x_1, x_2, \dots, x_n potom dostaneme konkrétnu realizáciu - aritmetický priemer \bar{x} náhodnej premennej $\bar{\mathbf{X}}$.

Predpokladajme, že máme k dispozícii náhodný výber $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ so základného súboru s rozdelením $f_{\mathbf{X}}(x, \boldsymbol{\theta})$ závislým od neznámeho reálneho alebo (vo všeobecnom prípade) vektora parametrov $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m) \in \mathbb{R}^m$.

Na základe tohoto výberu chceme, čo najpresnejšie určiť hodnotu parametra $\boldsymbol{\theta}$, ktorý je prvkom parametrického priestoru Θ .

Poznámka:

$\Theta = \{(\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma^2 > 0\}$ je príkladom parametrického priestoru z normálneho rozdelenia $N(\mu, \sigma^2)$.

Rozoznávame **bodové** a **intervalové** odhady parametrov.

Nech náhodný výber $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ závisí od neznámeho parametra θ . Potom **bodovým odhadom** parametra θ rozumieme štatistiku $\mathbf{T}_n = T(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$, ktorá každej množine pozorovaných hodnôt priradí hodnotu odhadovaného parametra, ktorú označíme $\hat{\theta}$.

Poznámka:

Bodový odhad teda predstavuje nejakú reálnu funkciu definovanú na \mathcal{R}^n , kde n je rozsah náhodného výberu, kým $\hat{\theta}$ je už konkrétnou odhadovanou hodnotou parametra θ .

Bodový odhad štatistiky \mathbf{T}_n parametra θ nazývame

- **nestranný (nevychýlenný)** odhad, ak pre každé $\theta \in \Theta$ platí

$$E(\mathbf{T}_n) = \theta,$$

- **asymptoticky nevychýlený** odhad, ak $\lim_{n \rightarrow \infty} E(\mathbf{T}_n) = \theta$,
- **efektívny (najlepší nevychýlený)** odhad, ak \mathbf{T}_n je nestranný odhad a pre ľubovoľný nestranný odhad \mathbf{T}_n^* platí

$$D(\mathbf{T}_n) \leq D(\mathbf{T}_n^*),$$

- **konzistentný** odhad, ak pre ľubovoľné $\varepsilon > 0$ platí

$$\lim_{n \rightarrow \infty} \mathcal{P}(|\mathbf{T}_n - \theta| \geq \varepsilon) = 0$$

t.j. ak \mathbf{T}_n s rastúcim n konverguje podľa pravdepodobnosti k θ .

Nestrannosť je síce dôležitá vlastnosť „dobrých“ odhadov, ale nie vždy možno na nej trvať. Požiadavka, že vychýlenie odhadu je nulové znamená, že „v priemere“ odhaduje priamo parameter θ , pričom výraz „v priemere“ sa vzťahuje k opakovanému výberu.

Predstavme si, že máme viacero bodových odhadov. Napr. miesto výberového priemeru \bar{X} sa použije len pozorovanie X_1 . Potom sa rozhodneme pre efektívny odhad, ktorý menej kolíše okolo odhadovanej hodnoty.

Pri skúmaní asymptotického chovania odhadu len jedného parametra stačí, aby postupnosť stredných hodnôt konvergovala k odhadovanému parametru a postupnosť jeho rozptylov konvergovala k nule, ako uvádza nasledujúce tvrdenie.

Tvrdenie 23

Nech $\lim_{n \rightarrow \infty} E(\mathbf{T}_n) = \theta$, $\lim_{n \rightarrow \infty} D(\mathbf{T}_n) = 0$, potom je \mathbf{T}_n konzistentný odhad parametra θ .

Dôkaz: Zvoľme ľubovoľné $\varepsilon > 0$. Potom z Čebyševovej nerovnosti platí pre každé n

$$\mathcal{P}(|\mathbf{T}_n - E(\mathbf{T}_n)| < \varepsilon/2) \geq 1 - \frac{D(\mathbf{T}_n)}{(\varepsilon/2)^2}. \quad (*)$$

Súčasne je pre $n > n_0$ vždy $|E(\mathbf{T}_n) - \theta| < \varepsilon/2$. Pre $n > n_0$ však platí

$$\begin{aligned} \mathcal{P}(|\mathbf{T}_n - \theta| < \varepsilon) &= \mathcal{P}(|\mathbf{T}_n - E(\mathbf{T}_n)| < \varepsilon/2, |E(\mathbf{T}_n) - \theta| < \varepsilon/2) \\ &= \mathcal{P}(|\mathbf{T}_n - E(\mathbf{T}_n)| < \varepsilon/2), \end{aligned}$$

lebo druhá náhodná udalosť je istá. Posledná pravdepodobnosť podľa Čebyševovej nerovnosti (*) konverguje podľa pp. k 1.

Príklad 9.1

Uvažujme náhodný výber $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ z $N(\mu, \sigma^2)$. Ako odhad rozptylu σ^2 sa niekedy používa štatistika

$$\mathbf{S}_*^2 = \frac{1}{n} \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}})^2.$$

Tento odhad nie je nestranným odhadom σ^2 , lebo platí

$$E(\mathbf{S}_*^2) = E\left(\frac{n-1}{n} \mathbf{S}^2\right) = \frac{n-1}{n} \sigma^2.$$

Zrejme platí $\lim_{n \rightarrow \infty} \mathbf{S}_*^2 = \sigma^2$. Možno odvodiť, že $D(\mathbf{S}^2) = \frac{2\sigma^4}{n-1}$ takže

$$\lim_{n \rightarrow \infty} D(\mathbf{S}_*^2) = \lim_{n \rightarrow \infty} D\left(\frac{n-1}{n} \mathbf{S}^2\right) = \lim_{n \rightarrow \infty} \frac{2\sigma^4(n-1)}{n^2} = 0.$$

Štatistika \mathbf{S}_*^2 je nielen asymptoticky nestranným a ale aj konzistentným odhadom rozptylu σ^2 .

Nech $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ je náhodný výber z rozdelenia, ktoré závisí od parametra $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$. Predpokladajme, že pre každé $\boldsymbol{\theta} \in \Theta$ existujú počiatkové momenty $\nu_k = E(\mathbf{X}_i^k)$, $k = 1, 2, \dots, m$.

Realizácie výberových počiatkových momentov sú dané pre $k = 1, 2, \dots, m$ vzťahom

$$\nu_k = \frac{1}{n} \sum_{i=1}^n x_i^k.$$

Odhady parametra $\boldsymbol{\theta}$ **momentovou metódou** dostaneme tak, že za odhady, označíme ich $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m)$, vezmeme riešenia systému rovníc

$$\nu_k = v_k, \quad k = 1, 2, \dots, m.$$

Poznámka:

Keby týchto m -rovníc nestačilo na jednoznačne určenie odhadov, potom pridáme ešte ďalšie $\nu_k = v_k$, $k = m + 1, m + 2, \dots$, kým nezískame potrebný počet rovníc, čo je možné ak také ν_k existujú.

Príklad 9.2

Nech (x_1, x_2, \dots, x_n) je realizácia náhodného výberu z exponenciálneho rozdelenia $Exp(\lambda)$. Odhadnite parameter λ momentovou metódou.

Hustota pravdepodobnosti exponenciálneho rozdelenia je $f(t, \lambda) = \lambda e^{-\lambda t}$, $t \geq 0$.

Počiatkový moment $\nu_1 = E(\mathbf{X}) = \frac{1}{\lambda}$. Realizáciou výberového počiatkového momentu je $\nu_1 = \bar{x}$.

Momentová metóda tu spočíva v riešení rovnice $\nu_1 = \nu_1$, odkiaľ dostávame odhad

$$\hat{\lambda} = \frac{1}{\bar{x}}.$$

Metóda maximálnej vierohodnosti

Nech $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ je náhodný výber a (x_1, x_2, \dots, x_n) jeho realizácia, ktoré závisí od parametrov $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$.

Združenú hustotu pravdepodobnosti pri pevných výberových hodnotách $\mathbf{X}_i = x_i, i = 1, 2, \dots, n$ ako funkciu parametra θ nazveme **vierohodnostnou funkciou** a označíme

$$L(x_1, x_2, \dots, x_n, \boldsymbol{\theta}) = \prod_{i=1}^n f(x_i, \boldsymbol{\theta}).$$

Metóda maximálnej vierohodnosti spočíva v tom, že za hodnoty $\hat{\boldsymbol{\theta}}$ sa zvolia také hodnoty $\boldsymbol{\theta} \in \Theta$, ktoré pri daných hodnotách x_i maximalizujú vierohodnostnú funkciu alebo jej logaritmus.

Maximálne vierohodný odhad $\hat{\boldsymbol{\theta}}$ potom určíme riešením systému m -rovníc

$$\frac{\partial \ln(L(x_1, x_2, \dots, x_n, \theta_1, \theta_2, \dots, \theta_m))}{\partial \theta_i} = 0, \quad i = 1, 2, \dots, m.$$

V prípade diskretného rozdelenia určeného pravdepodobnostnou funkciou $p(x_i, \theta)$, $i = 1, 2, \dots, m$ je **vierohodnostná funkcia**

$$L(x_1, x_2, \dots, x_n, \theta) = \prod_{i=1}^n p(x_i, \theta).$$

a maximálne vierohodný odhad $\hat{\theta}$ sa hľadá tiež pomocou derivácie logaritmu vierohodnostnej funkcie t.j.

$$\frac{\partial(\sum_{i=1}^n \ln(p(x_1, x_2, \dots, x_n, \theta_1, \theta_2, \dots, \theta_m)))}{\partial \theta_i} = 0, \quad i = 1, 2, \dots, m.$$

Príklad 9.3

Majme náhodný výber $(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_n)$ z alternatívneho rozdelenia $A(p)$. Hľadáme vierohodný odhad parametra p z jeho realizácii (y_1, y_2, \dots, y_n) .

Združené rozdelenie náhodného vektora je dané

$$L(y_1, y_2, \dots, y_n, p) = \prod_{i=1}^n p^{y_i} (1-p)^{1-y_i} = p^y (1-p)^{n-y},$$

kde $y = \sum_{i=1}^n y_i$. Logaritmus vierohodnostnej funkcie je v tvare

$$\ln(L(y_1, y_2, \dots, y_n, p)) = y \ln(p) + (n-y) \ln(1-p).$$

Pri hľadaní jej maxima vyriešime rovnicu

$$\frac{\partial \ln(L(y_1, y_2, \dots, y_n, p))}{\partial p} = \frac{y}{p} - \frac{n-y}{1-p} = 0,$$

ktorá vedie k odhadu $\hat{p} = \frac{y}{n} = \frac{1}{n} \sum_{i=1}^n y_i = \bar{y}$.

Príklad 9.4

Majme náhodný výber z normálneho rozdelenia $N(\mu, \sigma^2)$. Hľadáme vierohodný odhad oboch parametrov.

Vierohodnostná funkcia má pre $\mu \in \mathfrak{R}, \sigma^2 > 0$ tvar

$$L(x_1, x_2, \dots, x_n, \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}} = \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} e^{-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}},$$

a tak logaritmus vierohodnostnej funkcie

$$\ln(L(x_1, x_2, \dots, x_n, \mu, \sigma^2)) = -\frac{n}{2} \ln(2\pi\sigma^2) + \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2.$$

Derivovaním dostaneme

$$\frac{\partial \ln(L)}{\partial \mu} = -\frac{2}{2\sigma^2} \sum_{i=1}^n (x_i - \mu) = -\frac{1}{\sigma^2} \left(\sum_{i=1}^n x_i - n\mu \right) = 0 \Rightarrow \hat{\mu} = \bar{x},$$

$$\frac{\partial \ln(L)}{\partial \sigma^2} = \frac{n}{2} \frac{2\pi}{2\pi\sigma^2} - \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$

Pozor! Odhadovali sme parameter σ^2 a preto sme derivovali podľa σ^2 a nie podľa σ . Po dosadení vypočítaných odhadov $\hat{\mu}, \hat{\sigma}^2$ do matice druhých derivácií dostaneme negatívne definitnú maticu

$$\begin{pmatrix} -\frac{n}{\hat{\sigma}^2} & 0 \\ 0 & -\frac{n}{(2\hat{\sigma}^2)^2} \end{pmatrix},$$

čo znamená, že nájdené riešenie sústavy rovníc sú skutočne maximálne vierohodné odhady.

Poznámka: Možno dokázať, že metóda maximálnej vierohodnosti nám dáva neustranný odhad hľadaného parametra zatiaľ čo odhad momentovou metódou môže byť vychýlený.

Intervalový odhad

Úlohou je nájsť na základe náhodného výberu $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ taký interval, ktorý by obsahoval neznámu hodnotu parametra θ s pravdepodobnosťou $1 - \alpha$.

Nech sú dané dve štatistiky \mathbf{T}_D a \mathbf{T}_H náhodného výberu a platí

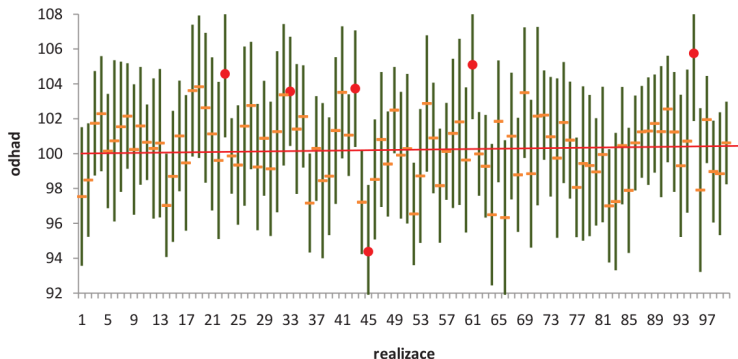
$$\mathcal{P}(\mathbf{T}_D \leq \theta \leq \mathbf{T}_H) = 1 - \alpha.$$

Hovoríme, že $\langle \mathbf{T}_D, \mathbf{T}_H \rangle$ je $100(1 - \alpha)\%$ -tný interval spoľahlivosti parametra θ so **spoľahlivosťou** $1 - \alpha$.

Vopred zvolenému číslu $\alpha, \alpha \in (0, 1)$ hovoríme **hladina významnosti** (riziko). V praxi sa najčastejšie volí $\alpha = 0.01$ a $\alpha = 0.05$

Intervalový odhad parametra θ so spoľahlivosťou $1 - \alpha$ je interval $\langle t_D, t_H \rangle$, kde t_D, t_H sú hodnoty štatistík $\mathbf{T}_D, \mathbf{T}_H$ štatistického súboru (x_1, x_2, \dots, x_n) ,

Príklad 9.4



Obr. 1: Simulácia 95%-tných intervalových odhadov strednej hodnoty (spoľahlivosť $1 - \alpha = 0,95$) získaných na základe 100 opakovaných výberov rozsahu $n = 30$ z populácie so strednou hodnotou $\theta = 100$. 6 intervalov zo 100 (●) neobsahuje skutočnú strednú hodnotu.

Orandžové úsečky zodpovedajú priemerom jednotlivých výberov.

Spôľahlivosť intervalového odhadu $1 - \alpha$ udáva, že pri opakovaných výberoch s konštantným rozsahom n z daného základného súboru približne $100(1 - \alpha)\%$ intervalových odhadov obsahuje skutočnú hodnotu odhadovaného parametra θ a $100\alpha\%$ intervalových odhadov ho neobsahuje.

Spôľahlivosť odhadu $1 - \alpha$ požadujeme blízkou jednej, resp. 100%. Čím je vyššia spoľahlivosť odhadu, tým širší intervalový odhad získame (hľadaná hodnota se v ňom musí nachádzať s vyššou pravdepodobnosťou). Ak chceme intervalový odhad zúžiť (spresniť), potom treba zväčšiť rozsah výberu n .

Jednostranné intervaly spoľahlivosti

Pri jednostranných intervaloch spoľahlivosti sa udáva buď dolná alebo horná hranica intervalu.

Ak je daná dolná hranica intervalu \mathbf{T}_D hovoríme o **ľavostrannom intervale spoľahlivosti** (\mathbf{T}_D, ∞) , pre ktorý platí

$$\mathcal{P}(\theta \geq \mathbf{T}_D) = 1 - \alpha.$$

Ak je daná horná hranica intervalu \mathbf{T}_H hovoríme o **pravostrannom intervale spoľahlivosti** (∞, \mathbf{T}_H) , pre ktorý platí

$$\mathcal{P}(\theta \leq \mathbf{T}_H) = 1 - \alpha.$$

Dvojstranný interval spoľahlivosti

Ak nás zaujímajú obe hranice odhadu hovoríme o **dvojstrannom intervale spoľahlivosti** $\langle \mathbf{T}_D, \mathbf{T}_H \rangle$, ktorý hľadá tak, aby platilo

$$\mathcal{P}(\theta \geq \mathbf{T}_D) = \frac{\alpha}{2}, \quad \mathcal{P}(\theta \leq \mathbf{T}_H) = \frac{\alpha}{2}.$$

Tieto podmienky zaručujú, že platí

$$\mathcal{P}(\mathbf{T}_D \leq \theta \leq \mathbf{T}_H) = 1 - \alpha,$$

a navyše zabezpečia i to, že je takýto dvostranný interval má najmenšiu dĺžku.

Ako nájsť intervalový odhad?

Pripomeňme, že $100p\%$ kvantil pre **spojitú** náhodnú premennú \mathbf{X} je číslo x_p , pre ktoré platí $\mathcal{P}(\mathbf{X} < x_p) = \mathcal{P}(\mathbf{X} \leq x_p) = F(x_p) = p$.

Nech je x_p kvantil výberovej štatistiky $T(\mathbf{X})$, ktorej pp. rozdelenie poznáme. Pre ľubovoľné $\alpha \in (0, 1)$ platí

$$\mathcal{P}\left(x_{\frac{\alpha}{2}} \leq T(\mathbf{X}) \leq x_{1-\frac{\alpha}{2}}\right) = F(x_{1-\frac{\alpha}{2}}) - F(x_{\frac{\alpha}{2}}) = 1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha,$$

$$\mathcal{P}(T(\mathbf{X}) \leq x_{1-\alpha}) = F(x_{1-\alpha}) = 1 - \alpha,$$

$$\mathcal{P}(T(\mathbf{X}) \geq x_{\alpha}) = 1 - F(x_{\alpha}) = 1 - \alpha.$$

Poznámka:

Všeobecné metódy intervalových odhadov sú podstatne náročnejšie. My sa ďalej obmedzíme len na intervaly spoľahlivosti pre parametre z normálneho rozdelenia a z neho odvodených rozdelení.

Tvrdenie 24

Nech $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ je náhodný výber z $N(\mu, \sigma^2)$. Ak je rozptyl σ^2 **známy**, potom majú intervaly spoľahlivosti pre parameter μ tvar

$$\bar{\mathbf{X}} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{\mathbf{X}} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}},$$
$$\mu \geq \bar{\mathbf{X}} - z_{1-\alpha} \frac{\sigma}{\sqrt{n}}, \mu \leq \bar{\mathbf{X}} + z_{1-\alpha} \frac{\sigma}{\sqrt{n}}.$$

Dôkaz: Vieme, že $\bar{\mathbf{X}} \sim N(\mu, \frac{\sigma^2}{n})$, $T(\mathbf{X}) = \frac{\bar{\mathbf{X}} - \mu}{\sqrt{\frac{\sigma^2}{n}}} = \frac{\bar{\mathbf{X}} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$.

Potom môžeme tvrdiť (pre kvatily z $N(0, 1)$ platí $z_p = -z_{1-p}$), že

$$1 - \alpha = \mathcal{P}\left(z_{\frac{\alpha}{2}} \leq T(\mathbf{X}) \leq z_{1-\frac{\alpha}{2}}\right) = \mathcal{P}\left(z_{\frac{\alpha}{2}} \leq \frac{\bar{\mathbf{X}} - \mu}{\sigma} \sqrt{n} \leq z_{1-\frac{\alpha}{2}}\right) =$$
$$\mathcal{P}\left(-z_{1-\frac{\alpha}{2}} \leq \frac{\bar{\mathbf{X}} - \mu}{\sigma} \sqrt{n} \leq z_{1-\frac{\alpha}{2}}\right) = \mathcal{P}\left(\bar{\mathbf{X}} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{\mathbf{X}} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right).$$

Analogicky sa odvodja jednostranné intervaly spoľahlivosti.

Príklad 9.5

Kontrola podniku testovala životnosť batérií. Kontrolóri vybrali z produkcie podniku náhodne 50 autobatérií a zistili, že výberový priemer doby života je 950 hodín a výberová smerodajná odchýlka je 100 hodín. So spoľahlivosťou 95% určte intervalový odhad strednej doby života batérií.

Budeme predpokladať, že životnosť batérií možno modelovať normálnym rozdelením $N(\mu, \sigma^2)$. Vzhľadom na to, že rozsah výberu $n = 50$ je väčší než 30 môžeme rozptyl σ^2 aproximovať výberovým rozptylom $s^2 = 100$ t.j. $\sigma \approx s$. Ide teda o intervalový odhad strednej hodnoty μ pri známom rozptyle σ^2

$$\left\langle \bar{x} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{x} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right\rangle.$$

Zo zadania máme spoľahlivosť $0.95 = 1 - \alpha$ t.j. hladinou významnosti $\alpha = 0.05$, výberový priemer $\bar{x} = 950$, výberovú smerodajnú odchýlkou $s = 10$. Kvantil $z_{0.975} = 1.96$ a tak po dosadení $\mu \in \langle 922.3, 977.7 \rangle$.

Tvrdenie 25

Nech $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ je náhodný výber z $N(\mu, \sigma^2)$. Ak sú oba parametre **neznáme** potom majú intervaly spoľahlivosti pre μ tvar

$$\bar{\mathbf{X}} - t_{1-\frac{\alpha}{2}}(n-1) \frac{\mathbf{S}}{\sqrt{n}} \leq \mu \leq \bar{\mathbf{X}} + t_{1-\frac{\alpha}{2}}(n-1) \frac{\mathbf{S}}{\sqrt{n}},$$
$$\mu \geq \bar{\mathbf{X}} - t_{\alpha}(n-1) \frac{\mathbf{S}}{\sqrt{n}}, \mu \leq \bar{\mathbf{X}} + t_{\alpha}(n-1) \frac{\mathbf{S}}{\sqrt{n}}.$$

Dôkaz: Vieme, že $\bar{\mathbf{X}} \sim N(\mu, \frac{\sigma^2}{n})$ a zvolíme výberovú štatistiku

$$T(\mathbf{X}) = \frac{\bar{\mathbf{X}} - \mu}{\mathbf{S}} \sqrt{n} \sim t(n-1).$$

Ďalej postupujeme ako v tvrdení 23 pre obojstranný i obe jednostranné intervaly spoľahlivosti.

Poznámka:

Vidíme, že záleží na tom či poznáme alebo nepoznáme niektorý parameter základného súboru.

Príklad 9.6

Obchodný reťazec BILLA zadal štúdiu o počte zákazníkov v novej predajni v piatok popoludní. Boli získané takéto počty zákazníkov za jeden mesiac 3756, 2987, 3042, 4206, 3597. Treba s 95% spoľahlivosťou určiť intervalový odhad počtu zákazníkov v piatok popoludní.

Budeme predpokladať, že počet zákazníkov možno modelovať normálnym rozdelením $N(\mu, \sigma^2)$. Vzhľadom na to, že rozsah výberu $n = 5$ je menší než 30, ide tu o intervalový odhad strednej hodnoty μ pri neznámom rozptyle σ^2 .

$$\left\langle \bar{x} - t_{1-\frac{\alpha}{2}}(n-1) \frac{s}{\sqrt{n}}, \bar{x} + t_{1-\frac{\alpha}{2}}(n-1) \frac{s}{\sqrt{n}} \right\rangle.$$

Zo zadania máme spoľahlivosť $0.95 = 1 - \alpha$ t.j. hladinou významnosti $\alpha = 0.05$, výberový priemer $\bar{x} = 3517.6$, výberovú smerodajnú odchylkou $s = 511.1$. Kvantil $t_{0.975}(4) = 2.78$ a tak po dosadení $\mu \in \langle 2882.2, 4153.0 \rangle$.

Pri analýze znaku základného súboru nás obyčajne nezajímá len jeho stredná hodnota μ ale aj jeho variabilita. Najčastejšou mierou je jeho rozptyl σ^2 . Známa stredná hodnota pri neznámom rozptyle nie je v praxi častý prípad a tak sa obmedzíme len na opačný prípad.

Tvrdenie 26

Nech $(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$ je náhodný výber z $N(\mu, \sigma^2)$. Ak je stredná hodnota μ **neznámy**, potom majú intervaly spoľahlivosti pre parameter σ^2 tvar

$$\frac{(n-1)\mathbf{S}^2}{\chi_{1-\frac{\alpha}{2}}^2(n-1)} \leq \sigma^2 \leq \frac{(n-1)\mathbf{S}^2}{\chi_{\frac{\alpha}{2}}^2(n-1)},$$
$$\sigma^2 \geq \frac{(n-1)\mathbf{S}^2}{\chi_{1-\alpha}^2(n-1)}, \quad \sigma^2 \leq \frac{(n-1)\mathbf{S}^2}{\chi_{\alpha}^2(n-1)}.$$

9.1* Uvažujme náhodný výber \mathbf{X} rozsahu n z rozdelenia s konečným rozptylom σ^2 . Určte konštantu c tak, aby štatistika

$$\mathbf{D} = c \sum_{i=2}^n (\mathbf{X}_i - \mathbf{X}_{i-1})^2 \text{ bola nestranným odhadom rozptylu } \sigma^2.$$

9.2 Nech (x_1, x_2, \dots, x_n) je realizácia náhodného výberu z rovnomerného rozdelenia $R(a, b)$, kde a, b sú neznáme parametre. Momentovou metódou odhadnite a a b .

$$[\hat{b}, \hat{a} = \bar{x} \pm \sqrt{3s_*^2}].$$

9.3* Výberovým šetrením chceme odhadnúť priemernú mzdu učiteľov ZŠ. Z minuloročných štatistických výkazov sa vie, že smerodajná odchýlka bola 125 Eur. Odhad chceme previesť s 95% spoľahlivosťou, pričom sme ochotný pripustiť maximálnu chybu 50 Eur. Aký veľký by mal byť rozsah náhodného výberu? $[|\bar{x} - \mu| = 50]$.