

Pravděpodobnost a statistika - cvičení 9

Intervalové odhady

Simona Domesová

<http://home1.vsb.cz/~dom0015>

Statistická indukce (z minula)

= metoda, která dovoluje stanovit vlastnosti celku (základního souboru) na základě pozorování jeho části (náhodného výběru)

- např. ve výběru 100 lidí bude průměr IQ 110 → střední hodnota IQ bude v okolí 110 (V jakém okolí? S jakou pravděpodobností?)

Výběrové charakteristiky

populační parametr (konstanta)	výběrová charakteristika (náhodná veličina)
střední hodnota μ	výběrový průměr \bar{X}
medián $x_{0.5}$	výběrový medián $\tilde{X}_{0.5}$
směrodatná odchylka σ	výběrová směrodatná odchylka S
pravděpodobnost π	relativní četnost p

Odhady parametrů populace

- bodový odhad
- intervalový odhad

Bodový odhad vs. interval spolehlivosti

Studujeme určitou populaci a chceme odhadnout nějaký populační parametr (např. střední hodnotu, medián, směrodatnou odchylku). Odhadovaný parametr je tedy KONSTANTA.

Bodový odhad

= NÁHODNÁ VELIČINA, která nabývá hodnot blízkých odhadovanému parametru; této náhodné veličině říkáme výběrová charakteristika

Interval spolehlivosti

= interval, ve kterém skutečná hodnota odhadovaného parametru leží s pravděpodobností $1 - \alpha$

$$P(\text{odhadovaný parametr} \in \text{interval spolehlivosti}) = 1 - \alpha$$

- $1 - \alpha$... „spolehlivost odhadu“
- α ... „hladina významnosti“

Postup při určování oboustranného intervalu spolehlivosti

Studujeme určitou populaci, chceme odhadnout například střední hodnotu μ , přičemž směrodatnou odchylku σ známe.

1. je zadán náhodný výběr o rozsahu n ze studované populace (má-li tato populace konečný rozsah N , mělo by platit $n \leq 0.05 \cdot N$)
2. z náhodného výběru určíme odhad stř. hodnoty \bar{x}
3. předpokladem pro použití intervalových odhadů je normalita dat, ověříme tedy, zda zadaný náhodný výběr pochází z normálního rozdělení
4. není-li zadána hladina významnosti, obvykle volíme $\alpha = 0.05$
5. zvolíme vhodnou výběrovou charakteristiku (viz minulé cvičení); zde použijeme

$$\frac{\bar{X} - \mu}{\sigma} \sqrt{n} \rightarrow N(0; 1),$$

platí tedy

$$P\left(z_{\frac{\alpha}{2}} = -z_{1-\frac{\alpha}{2}} < \frac{\bar{X} - \mu}{\sigma} \sqrt{n} < z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha = F(z_{1-\frac{\alpha}{2}}) - F(z_{\frac{\alpha}{2}})$$

1. je zadán náhodný výběr o rozsahu n ze studované populace
2. z náhodného výběru určíme odhad stř. hodnoty \bar{x}
3. ověříme normalitu
4. není-li zadána hladina významnosti, obvykle volíme $\alpha = 0.05$
5. zvolíme vhodnou výběrovou charakteristiku (viz minulé cvičení); zde použijeme

$$\frac{\bar{X} - \mu}{\sigma} \sqrt{n} \rightarrow N(0; 1), \text{ platí tedy}$$

$$P\left(z_{\frac{\alpha}{2}} = -z_{1-\frac{\alpha}{2}} < \frac{\bar{X} - \mu}{\sigma} \sqrt{n} < z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha = F(z_{1-\frac{\alpha}{2}}) - F(z_{\frac{\alpha}{2}})$$

6. vyjádříme odhadovaný parametr (zde μ), dosadíme \bar{x} za \bar{X} , dosadíme kvantil $z_{1-\frac{\alpha}{2}}$

$$P\left(\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}} < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha,$$

→ oboustranným intervalem spolehlivosti je tedy $\left\langle \bar{x} - \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}}; \bar{x} + \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}} \right\rangle$

Limitní věty

Slabý zákon velkých čísel Mějme nekonečný náhodný výběr X_1, X_2, \dots z rozdělení se střední hodnotou μ a konečným rozptylem, kde X_1, X_2, \dots jsou nekorelované náhodné veličiny. Potom platí, že výběrový průměr \overline{X}_n vypočítaný z prvních n pozorování se pro $n \rightarrow \infty$ blíží ke střední hodnotě μ , což zapisujeme

$$\lim_{n \rightarrow \infty} [P(|\overline{X}_n - \mu| < \varepsilon)] = 1 \quad \forall \varepsilon > 0.$$

Centrální limitní věta Jsou-li X_i nezávislé náhodné veličiny se stejnou střední hodnotou μ a se stejným konečným rozptylem σ^2 , pak výběrový průměr má při dostatečně velkém počtu pozorování přibližně normální rozdělení, ať už X_i pocházejí z libovolného rozdělení.

$$\overline{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

Důsledky centrální limitní věty

Součet n hodnot:

$$\bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right) \rightarrow \bar{X}_n \cdot n = \sum_{i=1}^n X_i \sim N(n\mu, n\sigma^2)$$

Relativní četnost p binomického rozdělení:

$$p \sim N\left(\pi; \frac{\pi(1-\pi)}{n}\right)$$

Rozdíl výběrových průměrů:

$$\bar{X}_1 - \bar{X}_2 \sim N\left(\mu_x - \mu_y, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right)$$

Rozdíl relativních četností $p_1 - p_2$ binomického rozdělení:

$$p_1 - p_2 \sim N \left(\pi_1 - \pi_2; \frac{\pi_1(1 - \pi_1)}{n_1} + \frac{\pi_2(1 - \pi_2)}{n_2} \right)$$

Spojitá rozdělení využívaná při statistické indukci

χ^2 - rozdělení (Pearsonovo)

- Definován jako suma n kvadrátů normovaných normálních rozdělení

$$X_1, \dots, X_n \sim N(0; 1) : \sum_{i=1}^n X_i^2 \sim \chi_n^2$$

- Má jediný parametr - počet stupňů volnosti
- Použití při odhadu rozptylu

$$\frac{S^2}{\sigma^2} (n - 1) \sim \chi_{n-1}^2$$

Studentovo (t) rozdělení

- Máme-li $Z \sim N(0; 1)$ a $V \sim \chi_k^2$ pak náhodná veličina

$$T = \frac{Z}{\sqrt{V/k}}$$

má Studentovo t rozdělení.

- Má jediný parametr - počet stupňů volnosti
- Použití při odhadu střední hodnoty bez přesné znalosti rozptylu

$$\frac{\bar{X} - \mu}{S} \sqrt{n} \sim t_{n-1}$$

(při znalosti střední hodnoty používáme normální rozdělení)

- Pro vysoká n platí $t_n \rightarrow N(0; 1)$

Fisher-Snedecorovo (F) rozdělení

- Definován jako normovaný podíl dvou χ^2 rozdělení

$$V \sim \chi_m^2, w \sim \chi_n^2 : \frac{\frac{V}{m}}{\frac{W}{n}} \sim F_{m,n}$$

- Má dva parametry - počty stupňů volnosti obou χ^2 rozdělení
- Používá se k testování shody rozptylů