

M5120 – cvičení

Číselné charakteristiky náhodného výběru a grafická zobrazení

Ondřej Pokora (pokora@math.muni.cz)

Ústav matematiky a statistiky, Přírodovědecká fakulta, Masarykova univerzita, Brno

(podzim 2015)



Výběrové momenty, histogram, ECDF

$$\text{Výběrový průměr: } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\text{Výběrový rozptyl: } S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Výběrová (empirická) distribuční funkce (ECDF):

$$\hat{F}(x) = F_n(x) = \frac{1}{n} |\{i \in 1, \dots, n : X_i \leq x\}|$$

Konstrukce histogramu: Rozpětí náhodného výběru rozdělíme na vhodný počet k (doporučeno $k \approx \sqrt{n}$) intervalů šířky r . V každém z nich pak počítáme relativní četnost $f_i = \frac{n_i}{n}$. Histogram se skládá z k obdélníků o základních délky r určených dělením rozpětí na intervaly a výškách $\frac{f_i}{r}$.

Výběrové kvantily

α -kvantil x_α je číslo, rozdělující **uspořádaný náhodný výběr** $X_{(1)} \leq \dots \leq X_{(n)}$ na dolní úsek, obsahující aspoň podíl α všech dat a na horní úsek obsahující aspoň podíl $1 - \alpha$ všech dat. Algoritmus výpočtu **výběrového α -kvantilu**:

$$n\alpha = \begin{cases} \text{celé číslo } c & \Rightarrow x_\alpha = \frac{X_{(c)} + X_{(c+1)}}{2} \\ \text{necelé číslo} & \Rightarrow x_\alpha = X_{(c)}, \text{ kde } c = \lceil n\alpha \rceil \end{cases}$$

Pro speciálně zvolená α užíváme názvů: $x_{0,50}$ – medián, $x_{0,25}$ – dolní kvartil, $x_{0,75}$ – horní kvartil, $x_{0,1}, \dots, x_{0,9}$ – decily, $x_{0,01}, \dots, x_{0,99}$ – percentily.


Charakteristikou variability je **kvartilová odchylka**: $q = x_{0,75} - x_{0,25}$ (**interquartile range, IQR**).

Krabicový graf (**boxplot**) je grafické znázornění číselných charakteristik

$$x_{0,50} - 1,5q \leq x_{0,25} \leq x_{0,50} \leq x_{0,75} \leq x_{0,50} + 1,5q.$$

Pozor, různé softwary (včetně R) vykreslují boxploty různými způsoby!

histogram a hustota



(vyberova) distribucni funkce

