


Vzorová úloha 3.1 Analýza velkého výběru

Na úloze **B2.25** *Koncentrace kyseliny močové v krvi dárců* ukážeme postup analýzy velkého výběru s odlehlými prvky pro určení typu rozdělení koncentrace kyseliny močové u 50 dárců krve. Jaká je míra polohy a rozptýlení uvedeného výběru?


Řešení:

1. Průzkumová (exploratorní) analýza dat

Z grafických diagnostik průzkumové analýzy dat jsou uvedeny pouze čtyři nejdůležitější.




Obr. 3.2 Kvantilový graf




Obr. 3.3 Diagramy rozptýlení a krabicové grafy

Grafy ukazují, že výběrové rozdělení je asymetrické a silně sešikmené. V horní části pořádkových statistik lze indikovat 3 až 5 podezřelých bodů, z nich se 3 jeví jako vysloveně odlehlé. Nelze proto použít klasických odhadů polohy a rozptýlení.



Obr. 3.4 Graf hustoty pravděpodobnosti



Obr. 3.5 Graf rozptýlení s kvantily

2. Ověření základních předpokladů o výběru:

Předpoklad o normalitě rozdělení je zamítnut, protože hodnota testovacího kritéria χ^2_{exp} je vyšší než tabulkový kvantil $\chi^2_{1-\alpha}(2)$. Předpoklad nezávislosti je přijat, protože hodnota testovacího kritéria je nižší než tabulkový kvantil. Data nejsou homogenní, mimo modifikované vnitřní hradby $B^*_D = 109.62 \mu\text{mol/l}$, $B^*_H = 602.38 \mu\text{mol/l}$ leží hodnota č. 17, a to $622.0 \mu\text{mol/l}$. Po odstranění této odlehlé hodnoty by byl aritmetický průměr $\bar{x} = 363.29 \mu\text{mol/l}$ a směrodatná odchylka $s = 63.875 \mu\text{mol/l}$. Protože se však jedná o biochemická data, nelze však odlehlou hodnotu vyloučit z dat. Znamenalo by to zde totiž ztrátu důležité biochemické informace.

Základní předpoklady výběru úlohy B2.25 (ADSTAT)

(a) Test normality: tabulkový kvantil $\chi^2_{1-\alpha}(2)$:	5.992
Odhad χ^2_{exp} statistiky:	29.199
Závěr: Předpoklad normality zamítnut na spočtené hladině významnosti $\alpha = 4.566\text{E}-07$.	
(b) Test nezávislosti: tabulkový kvantil $t_{1-\alpha/2}(n+1)$:	2.008
Odhad von Neumannovy statistiky t_n :	1.0266
Závěr: Předpoklad nezávislosti přijat na spočtené hladině významnosti $\alpha = 0.155$.	
(c) Detekce odlehlých bodů: metodou modifikované vnitřní hradby	
Dolní vnitřní hradba B^*_D :	109.62
Horní vnitřní hradba B^*_H :	602.38

Závěr: Ve výběru je 1 odlehlý bod, a to bod č. 17 (horní) o hodnotě 622.0.

(d) Opravené parametry výběru s vynechanými odlehlými hodnotami:

Odhad aritmetického průměru \bar{x} :	363.29
Odhad směrodatné odchylky s :	63.88
Odhad šikmosti \hat{g}_1 :	0.97
Odhad špičatosti \hat{g}_2 :	3.81

3. Mocnná transformace:

Při pokusu o transformaci dat poskytuje prostá mocnná transformace hodnotu opraveného průměru $\bar{x}_R = 350.91$ $\mu\text{mol/l}$, zatímco Box - Coxova transformace $\bar{x}_R = 362.17$ $\mu\text{mol/l}$, s odhadem šikmosti $g_1 = 0.81$ a špičatosti $g_2 = 3.38$, což je bližší parametrům normálního rozdělení. U mocnné transformace výpočet šikmosti a špičatosti selhává. Věrohodnější se zde proto jeví odhad, získaný metodou Boxovy-Coxovy transformace.

Box-Coxova transformace u dat výběru **úlohy B2.25** (ADSTAT)

Box-Coxova transformace:

Odhad optimálního exponentu λ	-2.13
Opravený odhad průměru původních dat \bar{x}_R	350.91

4. Odhady polohy, rozptylu a tvaru rozdělení:

Rozdělení souboru vykazuje mírné sešikmení. Soubor obsahuje jeden výrazně odlehlý bod. Mocnná transformace selhává, Box-Coxova transformace přináší zlepšení parametrů šikmosti a špičatosti souboru a je robustní vůči odlehlé hodnotě. Dobrým odhadem střední hodnoty se jeví také uřezané aritmetické průměry. Výpočet aritmetického průměru při vynechání odlehlého bodu podstatně zlepšuje variabilitu souboru a potvrzuje především robustnost retransformovaného průměru vůči odlehlé hodnotě.

Analýza jednorozměrného výběru dat **úlohy B2.25** (ADSTAT)

(1) Odhady klasických parametrů:

Odhad aritmetického průměru \bar{x}	368.46
Odhad směrodatné odchylky s	73.04
Odhad šikmosti \hat{g}_1	1.33
Odhad špičatosti \hat{g}_2	5.00
Dolní mez 95.0% intervalu spolehlivosti L_D	347.70
Horní mez 95.0% intervalu spolehlivosti L_H	389.22

(2) Odhady ostatních parametrů:

Odhad modu \hat{x}_M	293.00
Odhad polosumy \hat{x}_p	453.50

(3) Robustní odhady parametrů:

Medián $\tilde{x}_{0.5}$	356.00
Odhad směrodatné odchylky mediánu $s(\tilde{x}_{0.5})$	85.48
Dolní mez 95.0% intervalu spolehlivosti L_D	331.52
Horní mez 95.0% intervalu spolehlivosti L_H	380.48
Odhad 40%ního uřezaného průměru $\bar{x}(40\%)$	356.20
Odhad směrodatné odchylky $s(40\%)$	73.69
Odhad winsorizovaného průměru $\bar{x}_w(40\%)$	355.24
Odhad směrodatné odchylky $s_w(40\%)$	31.26

Dolní mez 95.0% intervalu spolehlivosti L_D	332.98
Horní mez 95.0% intervalu spolehlivosti L_H	379.42
Odhad M -odhadu střední hodnoty $\hat{\mu}_M$	358.17
Odhad směrodatné odchylky s_M	63.09
Dolní mez 95.0% intervalu spolehlivosti L_D	339.29
Horní mez 95.0% intervalu spolehlivosti L_H	377.05

(4) Hoggovy adaptivní odhady parametrů:

Hoggův průměr $\hat{\mu}_M$	356.46
Odhad směrodatné odchylky s_M	72.72
Dolní mez 95.0% intervalu spolehlivosti L_D	335.79
Horní mez 95.0% intervalu spolehlivosti L_H	377.13

Vzorová úloha 3.2 Analýza malého výběru dle Horna

Na úloze **B3.01** Střední hodnota haptoglobinu v lidském krevním séru ukážeme Hornův postup analýzy malých výběrů.

Řešení: (a) Užijeme Hornův postup pivotů pro malé výběry ($4 < n < 20$):

1. Pořádkové statistiky: seřadíme prvky od nejmenší do největší hodnoty

i	1	2	3	4	5	6	7	8
$x_{(i)}$	0.15	0.49	1.07	1.27	1.82	1.98	3.32	3.79

2. Hloubka pivotu: vyčíslíme hloubku pivotu

$$n = 8, \text{ sudé}$$

$$H = \text{int} \frac{\frac{n+1}{2} + 1}{2}$$

$$\text{int}(2.75) \approx 2$$

3. Pivoty:

$$\text{Dolní pivot } x_D = x_{(H)}$$

$$x_{(2)} = 0.49$$

$$\text{Horní pivot } x_H = x_{(n+1-H)}$$

$$x_{(7)} = 3.32$$

$$4. \text{ Pivotová polosuma } P_L = \frac{x_D + x_H}{2}$$

$$= 1.905$$

$$5. \text{ Pivotové rozpětí } R_L = x_H - x_D$$

$$3.32 - 0.49 = 2.83$$

6. 95%oní interval spolehlivosti střední hodnoty μ :

$$t_{L, 1-\alpha/2} = 0.564$$

$$P_L - R_L \times t_{L, 1-\alpha/2}(n) \leq \mu \leq P_L + R_L \times t_{L, 1-\alpha/2}(n)$$

$$1.905 - 2.83 \times 0.564 \leq \mu \leq 1.905 + 2.83 \times 0.564$$

$$0.31 \leq \mu \leq 3.50$$

7. Závěr: Bodový odhad míry polohy je 1.91, míry rozptýlení 2.83 a intervalový odhad míry polohy je

$$0.31 \leq \mu \leq 3.50.$$

(b) Užijeme také počítačové analýzy jednorozměrných dat: z průzkumové analýzy dat a ověření předpokladů o výběru plyne závěr, že rozdělení výběru pochází z Gaussova rozdělení, prvky výběru jsou nezávislé a ve výběru nejsou odlehlé body.

Analýza jednorozměrného výběru úlohy B3.01 (ADSTAT)

(1) **Test normality:** tabulkový kvantil $\chi^2_{1-\alpha}(2)$: 5.992

Odhad χ^2_{exp} statistiky: 0.809

Závěr: Předpoklad normality přijat na spočtené hladině významnosti $\alpha = 0.6674$.

(2) **Test nezávislosti:** tabulkový kvantil $t_{1-\alpha/2}(n+1)$: 2.262

Odhad von Neumannovy statistiky t_n : 1.077

Závěr: Předpoklad nezávislosti přijat na spočtené hladině významnosti $\alpha = 0.155$.

(3) **Detekce odlehlých bodů:** metodou modifikované vnitřní hradby

Závěr: Ve výběru nejsou odlehlé body.

(4) **Prostá mocninná transformace:**

Odhad optimálního exponentu λ 0.53

Odhad průměru transformovaných dat \bar{y} 1.246

Opravený odhad průměru původních dat \bar{x}_R 1.510

(5) **Box-Coxova transformace:**

Odhad optimálního exponentu λ 0.53

Odhad průměru transformovaných dat \bar{y}	0.461
Opravený odhad průměru původních dat \bar{x}_R	1.510
(6) Odhady klasických parametrů:	
Odhad aritmetického průměru \bar{x}	1.736
Odhad směrodatné odchylky s	1.283
Odhad šikmosti \hat{g}_1	0.46
Odhad špičatosti \hat{g}_2	1.99
Dolní mez 95.0% intervalu spolehlivosti L_D	0.664
Horní mez 95.0% intervalu spolehlivosti L_H	2.809
(7) Robustní odhady parametrů:	
Medián $\tilde{x}_{0.5}$	1.545
Odhad směrodatné odchylky mediánu $s(\tilde{x}_{0.5})$	1.347
Odhad 40%ního uřezaného průměru $\bar{x}(40\%)$	1.545
Odhad směrodatné odchylky $s(40\%)$	1.347
Dolní mez 95.0% intervalu spolehlivosti L_D	-0.821
Horní mez 95.0% intervalu spolehlivosti L_H	3.912
Odhad M -odhadu střední hodnoty $\hat{\mu}_M$	1.679
Odhad směrodatné odchylky s_M	1.234
Dolní mez 95.0% intervalu spolehlivosti L_D	0.602
Horní mez 95.0% intervalu spolehlivosti L_H	2.756
(8) Hoggovy adaptivní odhady parametrů:	
Hoggův průměr $\hat{\mu}_M$	1.736
Odhad směrodatné odchylky s_M	1.283
Dolní mez 95.0% intervalu spolehlivosti L_D	0.664
Horní mez 95.0% intervalu spolehlivosti L_H	2.809

Vzorová úloha 3.3 Test střední hodnoty (Test správnosti)

Na úloze *Test správnosti koncentrace vápníku* ukážeme užití testu správnosti. Výrobce kontrolního komerčního materiálu uvádí koncentraci vápníku 2.20 mmol/l. Jsou naměřené výsledky správné ?

Data: Koncentrace vápníku [mmol/l] v komerčním materiálu:

2.26 2.16 2.18 2.15 2.23 2.25 2.19 2.18 2.16 2.20
2.19 2.22 2.19 2.21 2.25 2.29 2.26 2.15 2.18

Řešení: Z exploratorní analýzy dat byla zjištěna mírná asymetrie, posun k nižším hodnotám, v horní části řady pořádkových statistik 3 podezřelé body. Ze základních předpokladů vyplývá, že data jsou homogenní, soubor neobsahuje odlehlé hodnoty. Data mají normální rozložení a jsou nezávislá.

Analýza jednorozměrných dat koncentrace vápníku (ADSTAT)

(1) Odhady klasických parametrů:

Odhad aritmetického průměru \bar{x}	2.205
Odhad směrodatné odchylky s	0.041
Odhad šikmosti \hat{g}_1	0.44
Odhad špičatosti \hat{g}_2	2.12
Dolní mez 95.0% intervalu spolehlivosti L_D	2.185
Horní mez 95.0% intervalu spolehlivosti L_H	2.225

(2) Robustní odhady parametrů:

Medián $\tilde{x}_{0.5}$	2.190
Odhad směrodatné odchylky mediánu $s(\tilde{x}_{0.5})$	0.056
Dolní mez 95.0% intervalu spolehlivosti L_D	2.161
Horní mez 95.0% intervalu spolehlivosti L_H	2.219
Odhad 40%ního uřezaného průměru $\bar{x}(40\%)$	2.194
Odhad směrodatné odchylky $s(40\%)$	0.040
Dolní mez 95.0% intervalu spolehlivosti L_D	2.171
Horní mez 95.0% intervalu spolehlivosti L_H	2.219
Odhad M -odhadu střední hodnoty $\hat{\mu}_M$	2.203
Odhad směrodatné odchylky s_M	0.041
Dolní mez 95.0% intervalu spolehlivosti L_D	2.183
Horní mez 95.0% intervalu spolehlivosti L_H	2.224

(3) Hoggovy adaptivní odhady parametrů:

Hoggův průměr $\hat{\mu}_M$	2.205
Odhad směrodatné odchylky s_M	0.041
Dolní mez 95.0% intervalu spolehlivosti L_D	2.185
Horní mez 95.0% intervalu spolehlivosti L_H	2.225

(4) Prostá mocninná transformace:

Odhad optimálního exponentu λ	-4.00
Opravený odhad průměru původních dat \bar{x}_r	2.204

Závěr: Pro 95%ní statistickou jistotu byly nalezeny následující intervalové odhady: pro aritmetický průměr \bar{x} je interval $2.19 < \mu < 2.23$, pro medián $\tilde{x}_{0.5}$ pak $2.16 < \mu < 2.22$. Z uvedených intervalových odhadů vyplývá, že obsah vápníku 2.20 mmol/l leží v rozmezí zadané normy a naměřené výsledky jsou správné.

Vzorová úloha 3.4 Test shodnosti středních hodnot


Na vzorové úloze *Porovnání práce dvou laborantek* ukážeme aplikaci testu shodnosti. Dvě laborantky prováděly analýzu koncentrace mukoproteinů v kontrolním vzorku. Určete, zda obě dospěly ke stejným výsledkům. Test shodnosti proveďte na hladině významnosti $\alpha = 0.05$.

Data: Stanovení koncentrace mukoproteinů v g/l laborantkou A a laborantkou B:

A: 11.6 12.1 13.2 12.1 10.6 13.3 13.7 14.4 15.2 13.6 13.7 12.4 12.5

B: 12.4 12.8 12.3 12.7 12.4 12.5 11.9 13.1 12.7 12.5 11.8 11.6 12.3

Řešení: Z ověření základních předpokladů pro jednotlivé výběry vyplývá, že data v obou výběrech jsou nezávislá, homogenní bez odlehlých bodů, test normality u obou výběrů prokázal Gaussovo rozdělení.



Obr. 3.6 Krabicový graf porovnání dvou výběrů, NCSS2000

Porovnání dvou výběrů (ADSTAT)

(1) Klasické odhady parametrů:

Parametr	Výběr 1	Výběr 2	Celkově
Četnost	13	13	26
Průměr	12.954	12.385	12.669
Rozptyl	1.5160	0.1764	0.81243
Šikmost	-0.07	-0.34	-0.10
Špičatost	2.58	2.50	4.21

(2) Test homogenity rozptylu $H_0: s_1^2 = s_2^2$. Fisher-Snedecor F-test:

Počet stupňů volnosti $n_1 - 1$	12
Počet stupňů volnosti $n_2 - 1$	12
Tabulkový kvantil $F_{1-\alpha}(n_1 - 1, n_2 - 1)$	3.277
Experimentální F_{exp} statistika	8.594

Závěr: Rozptyly se považují za rozdílné, H_0 zamítnuta

(3) Test shody průměrů $H_0: \mu_1 = \mu_2$: Studentův t-test (pro různé rozptyly)

Tabulkový kvantil $t_{1-\alpha/2}(v)$	2.120
T_2 statistika	1.578

Závěr: Průměry se považují za shodné, H_0 přijata

Závěr: Na hladině významnosti $\alpha = 0.05$ potvrzuje oboustranný klasický test shody středních hodnot obou výběrů i při významné odlišnosti obou rozptylů. Obě laborantky dosáhly stejných výsledků, i když každá s jinou variabilitou.

Vzorová úloha 3.5 Párový test

Na úloze **H3.22** Zkoušení obsahu niklu v drátu a svarovém kovu u dat ukážeme párový test, $n = 45$.

Řešení: Párový test úlohy **H3.22** (ADSTAT): Průměrný rozdíl \bar{D} je 0.04356.

Rozptyl s_D^2	0.03004
Počet stupňů volnosti $n-1$	44
Tabulkový kvantil $t_{1-\alpha/2}(n-1)$	2.015
t_{exp} statistika	9.728

Závěr: Průměry se považují za rozdílné, H_0 zamítnuta na hladině významnosti 0.000.

Závěr: Párový test zamítl hypotézu o shodě obsahu niklu v drátu a svarovém kovu.