

## Interval spolehlivosti pro rozdíl středních hodnot

Nechť náhodné výběry  $X_1$  a  $X_2$  jsou nezávislé a necht' rozptyly  $\sigma_1$  a  $\sigma_2$  jsou neznámé, přičemž platí  $\sigma_1 \neq \sigma_2$ . Přibližným  $100(1 - \alpha)$  procentním intervalem spolehlivosti pro rozdíl  $\mu_1 - \mu_2$  je interval

$$\bar{x}_1 - \bar{x}_2 - t_{1-\alpha/2}(v) \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}} < \mu_1 - \mu_2 < \bar{x}_1 - \bar{x}_2 + t_{1-\alpha/2}(v) \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}},$$

přičemž

$$v = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{1}{n_1-1} \left(\frac{S_1^2}{n_1}\right)^2 + \frac{1}{n_2-1} \left(\frac{S_2^2}{n_2}\right)^2}$$

## Testování korelace

### Příklad 1

Jsou známy výsledky testů ze dvou předmětů zjištěné u 8 náhodně vybraných studentů určitého oboru.

č.	1	2	3	4	5	6	7	8
1. test	80	50	36	58	42	60	56	68
2. test	65	60	35	39	48	64	48	61

Za předpokladu, že uvedené výsledky jsou číselné realizace náhodného výběru z dvourozměrného normálního rozdělení, testujte na hladině významnosti 0,05 hypotézu o nezávislosti výsledků obou testů.

$$T = \frac{R}{\sqrt{1-R^2}} \sqrt{n-2} \sim t(n-2) \quad H_0 : \rho = 0 \quad H_1 : \rho \neq 0$$

$$R_{12} \doteq 0.6264 \quad T_0 \doteq 1.18 \quad t_{0.975}(6) \doteq 2.45$$

Hypotézu  $H_0$  nezamítáme (způsobeno malým rozsahem výběru).

### Příklad 2

U 600 vzorků rudy byl stanoven obsah železa dvěma metodami. Výběrový korelační koeficient výsledků těchto metod je 0,85. V literatuře se uvádí, že tento koeficient má být 0,9. Za předpokladu dvourozměrné normality naměřených dat testujte na hladině významnosti 0,05 hypotézu, že rozdíl mezi těmito koeficienty je náhodný.

$$Z = \frac{1}{2} \ln \frac{1+R}{1-R} \quad U = (Z - Z_\rho) \sqrt{n-3} \sim N(0, 1) \quad H_0 : \rho = 0.9 \quad H_1 : \rho \neq 0.9$$

$$Z \doteq 1.2562 \quad Z_\rho \doteq 1.4722 \quad U_0 \doteq -5.2777 \quad u_{0.975} \doteq 1.9600$$

Hypotézu  $H_0$  zamítáme.

### Příklad 3

Lékařský výzkum se zabýval sledováním koncentrací látek A a B v moči pacientů trpících určitou ledvinovou chorobou. U 100 zdravých osob byl výběrový koeficient korelace 0,65 a u 142 osob trpících zmíněnou chorobou byl 0,37. Na hladině významnosti 0,05 testujte hypotézu, že se korelační koeficienty neliší. Předpokládejte dvourozměrnou normalitu.

$$Z = \frac{1}{2} \ln \frac{1+R}{1-R} \quad U = \frac{(Z - Z_*)}{\sqrt{\frac{1}{n-3} + \frac{1}{n^*-3}}} \sim N(0, 1) \quad H_0 : \rho = \rho_* \quad H_1 : \rho \neq \rho_*$$

$$Z \doteq 0.7753 \quad Z_* \doteq 0.3884 \quad U_0 \doteq 2.9249 \quad u_{0.975} \doteq 1.9600$$

Hypotézu  $H_0$  zamítáme.

### Test dobré shody pro normální rozdělení

Příklad 1. Zo základného súboru sme náhodne vybrali výberový súbor s rozsahom  $n = 100$  a s výsledkami, ktoré sú uvedené v tab. 9.2.

Tab. 9.2

$x$	$n_i$	$n_i x_i$	$(x_i - \bar{x})^2$	$n_i(x_i - \bar{x})^2$	$p_i$	$n_i^2/p_i n$
< 5	8	20	176,89	1 415,12	0,0537	11,92
5–10	10	75	68,89	688,90	0,1412	7,08
10–15	25	312,5	10,89	272,25	0,2573	24,29
15–20	32	560	2,89	92,48	0,2835	36,12
20–25	15	337,5	44,89	673,35	0,19215	11,71
> 30	10	275	136,89	1 368,90	0,07215	13,86
Spolu	$n = 100$	1 580,0		4 511,00	1,0000	104,98

Máme otestovať hypotézu, že základný súbor má normálne rozdelenie. Aby bolo možné určiť pravdepodobnosti  $p_i$  zo vzorca (9.51), resp. (9.53), musíme poznať strednú hodnotu  $m$  a štandardnú odchýlku  $\sigma$ , ktorými je definované normálne rozdelenie. Pretože tieto hodnoty neboli udané, odhadneme ich z výberového súboru metódou maximálnej vierohodnosti. Ako vieme z kapitoly 7, odhadmi parametrov  $m$  a  $\sigma$ , získanými metódou maximálnej vierohodnosti, sú výberový priemer  $\bar{X}$ , resp. výberová štandardná odchýlka  $S$ , kde

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$$

Pretože tu disponujeme výberovými súbormi zoskupenými do intervalov, na výpočet  $\bar{x}$  a  $s$  použijeme približné vzorce:

$$\bar{x} = \frac{\sum_{l=1}^r n_l x'_l}{n}$$

$$s = \sqrt{\frac{1}{n} \sum_{l=1}^r n_l (x'_l - \bar{x})^2}$$

kde  $x'_l$  je stredom intervalu  $(x_l, x_{l+1})$  pre  $l = 1, 2, \dots, r$ . Tab. 9.2 udáva hodnoty, ktoré umožňujú vypočítať  $\bar{x}$  a  $s$ . Podľa toho

$$\bar{x} = 15,8$$

$$s = 6,72$$

Keď sme určili hodnoty  $\bar{x}$  a  $s$ , môžeme vypočítať  $p_l$  za predpokladu, že hypotéza je správna, a že súbor má normálne rozdelenie. Tieto pravdepodobnosti môžeme vypočítať dvojakým spôsobom: Buď použijeme distribučnú funkciu normálneho rozdelenia

$$p_1 = F_0(x_{l+1}) - F_0(x_l) \quad (9.54)$$

buď tak, že za východisko zvolíme hodnotu normálneho rozdelenia

$$p_l \doteq f_0(x'_l) \frac{(x_{l+1} - x_l)}{s} \quad (9.55)$$

Je zrejmé, že ak použijeme vzorec (9.55), dostaneme len približné hodnoty pravdepodobností  $p_l$ . Použijeme preto presnejší vzorec (9.54). Aby bolo možné v tabuľkách odčítať požadované hodnoty normálnej distribučnej funkcie  $F_0(x_l)$ , musíme od každého  $x_l$  odpočítať strednú hodnotu 15,8 a výsledok vydeliť štandardnou odchýlkou 6,72.

Z tabuliek distribučnej funkcie normálneho rozdelenia

pre	$\frac{5 - 15,8}{6,72} = -1,61$	dostaneme	0,0537
pre	$\frac{10 - 15,8}{6,72} = -0,86$	dostaneme	0,1949

$$\begin{array}{llll} \text{pre} & \frac{15 - 15,8}{6,72} = -0,12 & \text{dostaneme} & 0,4522 \\ \text{pre} & \frac{20 - 15,8}{6,72} = 0,63 & \text{dostaneme} & 0,7357 \\ \text{pre} & \frac{25 - 15,8}{6,72} = 1,46 & \text{dostaneme} & 0,92785 \end{array}$$

Pre prvý interval platí:

$$p_1 = F(-1,61) - F(-\infty) = 0,0537 - 0 = 0,0537$$

Za dolnú hranicu prvého intervalu berieme  $-\infty$ , lebo predpokladáme, že premenná má normálne rozdelenie. Pre druhý interval platí:

$$p_2 = F(-0,86) - F(-1,61) = 0,1949 - 0,0537 = 0,1412$$

Podobne dostaneme:

$$p_3 = F(-0,12) - F(-0,86) = 0,4522 - 0,1949 = 0,2573$$

$$p_4 = F(0,63) - F(-0,12) = 0,7357 - 0,4522 = 0,2835$$

$$p_5 = F(1,46) - F(0,63) = 0,92785 - 0,7357 = 0,19215$$

$$p_6 = F(+\infty) - F(1,46) = 1 - 0,92785 = 0,07215$$

Ak sme našli hodnoty  $p_i$ , môžeme vypočítať štatistiku  $\chi^2$  podľa vzorca (9.53). Pre tento cieľ v prípade každého intervalu vypočítame  $\frac{n_i^2}{p_i n}$ . Tieto hodnoty sú uvedené v tab. 9.2. Po sčítaní dostaneme:

$$\sum_{i=1}^r \frac{n_i^2}{p_i n} = 104,98$$

Podľa vzorca (9.53) napokon dostaneme hodnotu štatistiky  $\chi^2$

$$\chi^2 = \sum_{i=1}^r \frac{n_i^2}{p_i n} - n = 104,98 - 100 = 4,98$$

Ako vieme, premenná  $\chi^2$  bude mať  $r - m - 1$  stupňov voľnosti. Keďže  $r = 6$  (toľko máme intervalov) a  $m = 2$  (toľko bolo odhadovaných parametrov), preto

$$r - m - 1 = 6 - 2 - 1 = 3$$

Zvolíme hladinu významnosti  $\alpha = 0,05$  a v tabuľkách rozdelenia  $\chi^2$  nájdeme hodnotu  $\chi_{\alpha}^2$ , ktorá spĺňa podmienku (9.52). Dostaneme  $\chi_{\alpha}^2 = 7,815$ . Pretože pozorované  $\chi^2 = 4,98$  neprevyšuje kritickú hodnotu  $\chi_{\alpha}^2$ , nie je dôvod na zamietnutie postavenej hypotézy s normálnym rozdelením základného súboru.

## Použitá literatúra

- Budíková M., Lerch T., Mikoláš Š.: Základní statistické metody. MU Brno 2006
- Hátle J., Likeš J.: Základy počtu pravděpodobnosti a matematické statistiky. SNTL/ALFA 1974
- Sadowski W.: Matematická statistika. ALFA 1975