

Pravděpodobnost a statistika

12. cvičení

(vytvořeno 12. prosince 2020)

Úloha 1 (χ^2 -test dobré shody se známým rozdělením). Hodili jsme stokrát mincí. Tabulka udává, kolikrát padl rub než padl první líc. Otestujte na hladině významnosti 5% hypotézu, že naměřené hodnoty pochází z geometrického rozdělení k koeficientem (pravděpodobnost rubu) $q = 0,5$.

| | | | | | | | |
|------------------|----|----|----|---|---|---|---|
| hodnota | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
| naměřená četnost | 57 | 24 | 10 | 6 | 2 | 0 | 1 |

Úloha 2 (χ^2 -test dobré shody se známým rozdělením). Máme podezření že hrací kostka je falešná a padá na ní šestka častěji, než by měla. Otestujte na hladině významnosti 5% hypotézu, že naměřené hodnoty pochází z roznorměného rozdělení.

| | | | | | | |
|------------------|---|---|---|----|---|----|
| hodnota | 1 | 2 | 3 | 4 | 5 | 6 |
| naměřená četnost | 7 | 5 | 5 | 12 | 6 | 15 |

Úloha 3 (χ^2 -test dobré shody dvou neznámých rozdělení). Dvě skupiny studentů psaly test, ze kterého bylo možné získat maximálně 4 body. Následující tabulka uvádí počty studentů, kteří dosáhli daného bodového ohodnocení. Na hladině významnosti 5% otestujte hypotézu, že obě skupiny mají stejné rozdělení pravděpodobnosti (tj., že není statisticky významný rozdíl mezi tím, jak dopadl test v první a ve druhé skupině).

| | | | | | |
|---------------|----|---|---|----|----|
| počet bodů | 0 | 1 | 2 | 3 | 4 |
| první skupina | 12 | 8 | 4 | 16 | 20 |
| druhá skupina | 8 | 7 | 1 | 9 | 15 |

Úloha 4 (Test nezávislosti). Následující tabulka udává naměřené četnosti lidí podle barvy očí a světlosti vlasů. Otestujte na hladině významnosti 5% hypotézu, že barva očí nezávisí na světlosti vlasů.

| | | | |
|-------------|-------|------|-------|
| vlasý \ oči | modré | šedé | hnědé |
| tmavé | 10 | 10 | 40 |
| světlé | 20 | 10 | 10 |

Úloha 5 (Test korelace). Změřili jsme výšku a váhu čtyř mužů. Otestujte na hladině významnosti 5% hypotézu, že výška a váha nejsou korelovány.

| | | | | |
|-------|-----|-----|-----|-----|
| výška | 205 | 155 | 185 | 155 |
| váha | 95 | 55 | 65 | 85 |

Řešení

Řešení 1:

- nulová hypotéza H_0 : naměřené hodnoty pochází z geometrického rozdělení k koeficientem $q = 0,5$
- alternativní hypotéza H_1 : naměřené hodnoty nepochází z geometrického rozdělení k koeficientem $q = 0,5$
- testovací statistika:

$$T = \sum_{i=1}^k \frac{(n_i - n p_i)^2}{n p_i} \dots \chi^2(k-1) \quad (\text{pro } n \rightarrow \infty)$$

- realizace testovací statistiky: $t = 2.5$

| hodnota | i | 0 | 1 | 2 | 3 a více | Σ |
|----------------------------|---------------------------------|---------------|---------------|---------------|---------------|----------|
| naměřená četnost | n_i | 57 | 24 | 10 | 9 | |
| teoretická pravděpodobnost | p_i | $\frac{1}{2}$ | $\frac{1}{4}$ | $\frac{1}{8}$ | $\frac{1}{8}$ | |
| teoretická četnost | $n \cdot p_i$ | 50 | 25 | 12.5 | 12.5 | |
| | $n_i - n p_i$ | 7 | -1 | -2.5 | -3.5 | |
| | $(n_i - n p_i)^2$ | 49 | 1 | 6.25 | 12.25 | |
| | $\frac{(n_i - n p_i)^2}{n p_i}$ | 0.98 | 0.04 | 0.5 | 0.98 | 2.5 |

- kvantily: $q_{\chi^2(3)}(0.025) \doteq 0.216$, $q_{\chi^2(3)}(0.975) \doteq 9.35$
- Nulovou hypotézu H_0 nezamítáme.

Řešení 2:

- nulová hypotéza H_0 : naměřené hodnoty pochází z roznoměrného rozdělení
- alternativní hypotéza H_1 : naměřené hodnoty nepochází z roznoměrného rozdělení (kostka je falešná)
- realizace testovací statistiky: $t = 6.4$

| hodnota | i | 1 až 5 | 6 | Σ |
|----------------------------|---------------------------------|---------------------------------|-------------------------------|---|
| naměřená četnost | n_i | 35 | 15 | |
| teoretická pravděpodobnost | p_i | $\frac{5}{6}$ | $\frac{1}{6}$ | |
| teoretická četnost | $n \cdot p_i$ | $\frac{250}{6} = \frac{125}{3}$ | $\frac{50}{6} = \frac{25}{3}$ | |
| | $n_i - n p_i$ | $-\frac{20}{6}$ | $\frac{20}{6}$ | |
| | $(n_i - n p_i)^2$ | $\frac{400}{9}$ | $\frac{400}{9}$ | |
| | $\frac{(n_i - n p_i)^2}{n p_i}$ | $\frac{400}{375}$ | $\frac{400}{75}$ | $\frac{400+2000}{375} = \frac{32}{5} = 6.4$ |

- kvantily: $q_{\chi^2(1)}(0.025) \doteq 0.001$, $q_{\chi^2(1)}(0.975) \doteq 5.02$

| α | 0.025 | 0.5 | 0.95 | 0.975 |
|-------------------------|-------|--------|------|-------|
| $q_{\chi^2(1)}(\alpha)$ | 0.001 | 0.0039 | 3.84 | 5.02 |

- Nulovou hypotézu H_0 zamítáme, kostka je falešná.

Řešení 3:

- nulová hypotéza H_0 : naměřené hodnoty pochází ze stejného rozdělení
- alternativní hypotéza H_1 : naměřené hodnoty nepochází ze stejného rozdělení
- testovací statistika:

$$T = \sum_{i=1}^k \frac{(m_i - m p_i)^2}{m p_i} + \sum_{i=1}^k \frac{(n_i - n p_i)^2}{n p_i}$$

$$p_i = \frac{m_i + n_i}{m + n}$$

- realizaci t testujeme na $\chi^2(k - 1)$

- realizace testovací statistiky:

| | | | | | |
|---------------------------------|--------|--------|--------|--------|---------------|
| i | 1 | 2,3 | 4 | 5 | |
| m_i | 14 | 12 | 16 | 18 | $m = 60$ |
| n_i | 10 | 6 | 10 | 14 | $n = 40$ |
| $m_i + n_i$ | 24 | 18 | 26 | 32 | $m + n = 100$ |
| $p_i = \frac{m_i + n_i}{m + n}$ | 0.24 | 0.18 | 0.26 | 0.32 | |
| $m p_i$ | 14.4 | 10.8 | 15.6 | 19.2 | |
| $m_i - m p_i$ | -0.4 | 1.2 | 0.4 | -1.2 | |
| $(m_i - m p_i)^2$ | 0.16 | 1.44 | 0.16 | 1.44 | |
| $\frac{(m_i - m p_i)^2}{m p_i}$ | 0.1111 | 0.1333 | 0.0103 | 0.075 | 0.3297 |
| $n p_i$ | 9.6 | 7.2 | 10.4 | 12.8 | |
| $n_i - n p_i$ | 0.4 | -1.2 | -0.4 | 1.2 | |
| $(n_i - n p_i)^2$ | 0.16 | 1.44 | 0.16 | 1.44 | |
| $\frac{(n_i - n p_i)^2}{n p_i}$ | 0.1667 | 0.2 | 0.0154 | 0.1125 | 0.4946 |

$$t = 0.3297 + 0.4946 = 0.8243$$

- kvantil: $q_{\chi^2(3)}(0.95) \doteq 7.81$
- Nulovou hypotézu H_0 nezamítáme.

Řešení 4:

- nulová hypotéza H_0 : jevy jsou nezávislé
- alternativní hypotéza H_1 : jevy nejsou nezávislé
- testovací statistika:

$$T = \sum_{i=1}^k \sum_{j=1}^m \frac{(n_{ij} - n p_i q_j)^2}{n p_i q_j} \dots \chi^2(km - 1) \quad (\text{pro } k \rightarrow \infty, m \rightarrow \infty)$$

$$p_i = \frac{1}{n} \sum_{j=1}^m n_{ij}$$

$$q_j = \frac{1}{n} \sum_{i=1}^k n_{ij}$$

- realizaci t ale testujeme na $\chi^2((k-1)(m-1))$
- realizace testovací statistiky:

| | | | | | |
|------------|-----------------|----|----|----|----------|
| n_{ij} : | $i \setminus j$ | 1 | 2 | 3 | Σ |
| | 1 | 10 | 10 | 40 | 60 |
| | 2 | 20 | 10 | 10 | 40 |
| | Σ | 30 | 20 | 50 | 100 |

| | | | | | |
|-------------|-----------------|------|------|-----|-------|
| $p_i q_j$: | $i \setminus j$ | 1 | 2 | 3 | p_i |
| | 1 | 0.18 | 0.12 | 0.3 | 0.6 |
| | 2 | 0.12 | 0.08 | 0.2 | 0.4 |
| | q_j | 0.3 | 0.2 | 0.5 | 1 |

| | | | | |
|---------------|-----------------|----|----|----|
| $n p_i q_j$: | $i \setminus j$ | 1 | 2 | 3 |
| | 1 | 18 | 12 | 30 |
| | 2 | 12 | 8 | 20 |

| | | | | |
|------------------------|-----------------|----|----|-----|
| $n_{ij} - n p_i q_j$: | $i \setminus j$ | 1 | 2 | 3 |
| | 1 | -8 | -2 | 10 |
| | 2 | -8 | 2 | -10 |

| | | | | |
|----------------------------|-----------------|----|---|-----|
| $(n_{ij} - n p_i q_j)^2$: | $i \setminus j$ | 1 | 2 | 3 |
| | 1 | 64 | 4 | 100 |
| | 2 | 64 | 4 | 100 |

| | | | | |
|--|-----------------|-------|------|--------|
| $\frac{(n_{ij} - n p_i q_j)^2}{n p_i q_j}$: | $i \setminus j$ | 1 | 2 | 3 |
| | 1 | 64/18 | 4/12 | 100/30 |
| | 2 | 64/12 | 4/8 | 100/20 |

$$t = 1 + \frac{1}{18} \doteq 18.056$$

- kvantil: $q_{\chi^2(2)}(0.95) \doteq 5.992$
- Nulovou hypotézu H_0 zamítáme.

Řešení 5:

- nulová hypotéza H_0 : naměřené hodnoty nejsou korelovány (korelace je nulová)
- alternativní hypotéza H_1 : naměřené hodnoty jsou korelovány
- testovací statistika:

$$T = \frac{R_{(X,Y)} \sqrt{n-2}}{\sqrt{1-R_{(X,Y)}^2}} \dots t(n-2)$$

$$R_{(X,Y)} = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \cdot \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

- realizace testovací statistiky:

| | i | 1 | 2 | 3 | 4 | |
|-------|---|-----|-----|------|------|-----------------|
| výška | x_i | 205 | 155 | 185 | 155 | $\bar{x} = 175$ |
| váha | y_i | 95 | 55 | 65 | 85 | $\bar{y} = 75$ |
| | $x_i - \bar{x}$ | 30 | -20 | 10 | -20 | |
| | $y_i - \bar{y}$ | 20 | -20 | -10 | 10 | |
| | $(x_i - \bar{x}) \cdot (y_i - \bar{y})$ | 600 | 400 | -100 | -200 | $\Sigma = 700$ |
| | $(x_i - \bar{x})^2$ | 900 | 400 | 100 | 400 | $\Sigma = 1800$ |
| | $(y_i - \bar{y})^2$ | 400 | 400 | 100 | 100 | $\Sigma = 1000$ |

$$r_{(X,Y)} = \frac{700}{\sqrt{1800 \cdot 1000}} \doteq 0.5217$$

$$t = \frac{0.5217 \cdot \sqrt{2}}{\sqrt{1-0.5217^2}} \doteq 0.8649$$

- kvantily: $q_{t(2)}(0.025) \doteq -4.3$, $q_{t(2)}(0.975) \doteq 4.3$
- Nulovou hypotézu H_0 nezamítáme.