

12 12-Kontingenční tabulky

12.1 Testování nezávislosti v kontingenčních tabulkách

- dvourozměrný náhodný výběr rozsahu n , dva nominální znaky X a Y
- znak $X \dots r$ variant; znak $Y \dots s$ variant
- absolutní simultánní četnosti
- marginální absolutní četnosti
- simultánní pst π_{jk} ; odhad $p_{jk} = \frac{n_{jk}}{n}$
- marginální pst $\pi_{j\cdot}, \pi_{\cdot k}$; odhad $p_{j\cdot} = \frac{n_{j\cdot}}{n}, p_{\cdot k} = \frac{n_{\cdot k}}{n}$
- grafické znázornění dat: scatterplot

Testování hypotézy o nezávislosti

- $H_0 : X, Y$ jsou nezávislé
- $H_1 : X, Y$ nejsou nezávislé
- porovnáváme pozorované četnosti n_{jk} s očekávanými četnostmi $\frac{n_{j\cdot}n_{\cdot k}}{n}$
- podmínka dobré aproximace: očekávané četnosti musí v 80 % být ≥ 5 a ve zbylých dvaceti % ≥ 2 ; `chisq.test(data)$expected`
- Testová statistika má tvar:

$$K = \sum_{j=1}^r \sum_{k=1}^s \frac{(n_{jk} - \frac{n_{j\cdot}n_{\cdot k}}{n})^2}{\frac{n_{j\cdot}n_{\cdot k}}{n}} \sim as.\chi^2((r-1)(s-1))$$

- `chisq.test(data)`
- H_0 zamítáme na hl. význ. α , pokud $K \in W = \langle \chi^2_{1-\alpha}((r-1)(s-1)), \infty \rangle$

Měření závislosti, Cramérův koeficient

- Cramérův koeficient

$$V = \sqrt{\frac{K}{n(m-1)}},$$

kde $m = \min\{r, s\}$.

- `cramersV` (knihovna `lsr`)

12.2 Čtyřpolní kontingenční tabulky

- náhodné veličiny X, Y mají pouze 2 varianty \rightarrow čtyřpolní kontingenční tabulka
- Fisherův faktoriállový (přesný) test
 - $H_0 : X, Y$ jsou nezávislé
 - $H_1 : X, Y$ nejsou nezávislé
 - `fisher.test(data)` $\rightarrow p$ -hodnota
- Podíl šancí ve čtyřpolní KT
 - pokus \rightarrow 2 okolnosti \rightarrow úspěch nebo neúspěch
 - 1.okolnost: podíl počtu úspěchů ku počtu neúspěchů: $\frac{a}{c}$
 - 2.okolnost: podíl počtu úspěchů ku počtu neúspěchů: $\frac{b}{d}$
 - podíl šancí
$$OR = \frac{\frac{a}{c}}{\frac{b}{d}} = \frac{ad}{bc}$$
 - $OR \in (0; \infty)$... nesymetrický interval $\rightarrow \ln OR \in (-\infty; \infty)$... symetrický okolo nuly
 - Závislost X, Y je tím silnější, čím více se OR liší od jedné, nebo čím více se $\ln OR$ liší od nuly

Testování nezávislosti ve čtyřpolních KT pomocí podílu šancí

- $H_0 : X, Y$ jsou nezávislé ... $\ln o\rho = 0$
- $H_1 : X, Y$ nejsou nezávislé ... $\ln o\rho \neq 0$.
- ověřit podmínky dobré approximace
- Testovací statistika

$$T_0 = \frac{\ln OR}{\sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}}} \sim \text{as.}N(0, 1)$$

- kritický obor $W = (-\infty; -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}; \infty)$
- $T_0 \in W \rightarrow H_0$ zamítáme na ASYMPTOTICKÉ hladině významnosti α ,
- $100(1 - \alpha)\%$ asymptotický interval spolehlivosti

$$(d, h) = \left(\ln OR - \sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}} u_{1-\alpha/2}; \ln OR - \sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}} u_{\alpha/2} \right).$$

- $0 \notin IS \rightarrow H_0$ zamítáme na asymptotické hl. význ. $\alpha = 0.05$.