

Kontingenční tabule

Používají se k sledování vzájemnosti relací, které se nemají kvantitativní, ale mohou jít mimo jiné mnoho, malo hodnot a vztahy se řídí možností či nesplnitelností daných kódů.

Příklad: pacient: muž - žena

léčil a - nelíčil se

zemřel - nezemřel

Do tabulek se maxmálně ukládají nejvýznamnější čísla (tisk pro ty pacienty) a dále kombinaci analýz.

Nechť relace Y má jíž hodnoty 1, 2, ..., r a relace X hodnoty 1, ..., c.

Kontingenční tabulka vypadá takto:

Y	X		Σ			
		1	2	...	c	
1	m_{11}	m_{12}	\dots	m_{1c}	$m_{1\cdot} = \sum_j m_{1j}$	
2	m_{21}	m_{22}	\dots	m_{2c}	$m_{2\cdot}$	
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
r	m_{r1}	m_{r2}	\dots	m_{rc}	$m_{r\cdot}$	
Σ	$m_{\cdot 1}$	$m_{\cdot 2}$	\dots	$m_{\cdot c}$	$m = \sum_i \sum_j m_{ij}$	
	II					
	$\sum_i m_{i1}$					

m_{ij} je počet případů, kdy se ve sňatku vyskytla dojitec (i, j), tj:

platí, že $Y=i$ a současně $X=j$

komu odpovídají (vznikají) pravděpodobnosti $p_{ij} = P(Y=i, X=j)$

relaci m_{ij} pak mají obecně multinomické rozdělení s polni p_{ij}

a platí pro ně, že $\sum_{i,j} \frac{(m_{ij} - m p_{ij})^2}{m p_{ij}} \xrightarrow{\text{asympotický pro } n \rightarrow \infty} \chi^2_{(r-1)(c-1)}$

asympotický pro $n \rightarrow \infty$

Veličiny Y a Z budou nezávislé, když bude platit

$$p_{ij} = P(Y=i, Z=j) = P(Y=i)P(Z=j) = \left(\sum_j p_{ij}\right)\left(\sum_i p_{ij}\right) = p_i \cdot p_j$$

Hypotéza nezávislosti Y a Z se lze formulovat jako $H_0: p_{ij} = p_i \cdot p_j$

Nenámi parametry se pak mohou vztahovat relativními číslostmi

$$\hat{p}_{ii} = \frac{m_{ii}}{m}, \quad \hat{p}_{ij} = \frac{m_{ij}}{m}$$

Testovací kritérium lze uvažovat

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{\left(m_{ij} - \frac{m_{i \cdot} m_{\cdot j}}{m}\right)^2}{\frac{m_{i \cdot} m_{\cdot j}}{m}} = m \sum_{i=1}^r \sum_{j=1}^c \frac{\frac{m_{ij}}{m}^2}{\frac{m_{i \cdot} m_{\cdot j}}{m}} - m \geq \chi^2_{(r-1)(c-1)} (\alpha).$$

Pokud je asymptotický, da je pravdě, když $\frac{m_{i \cdot} m_{\cdot j}}{m} > 5$ pro vš. i, j

Speciálně se objevuje tabulkový test.

$$\chi^2 = m \frac{(m_{11}m_{22} - m_{12}m_{21})^2}{m_{11}m_{22}m_{12}m_{21}} \sim \chi^2_1$$

Příklad: Udaje o nemocnictví mužích

	perili	nemeli	celkovy
léčení	5	6	11
néléčení	3	4	7
celkovy	8	10	18

$$\chi^2 = 18 \cdot \frac{(5 \cdot 4 - 6 \cdot 3)^2}{11 \cdot 7 \cdot 8 \cdot 10} = \frac{18 \cdot 4}{11 \cdot 7 \cdot 8 \cdot 10} = \frac{9}{770} < 3,84 = \chi^2_1 (0,05)$$

Nesta' se tedy, že by léčení mělo významně vliv na perili a nemocnost pacienta. Tento fakt je může být dán, že málo číselnosti po χ^2 -testu. Co s tím?

Pacient má řečená množství tablet: bude-li se léčit, má sánce na pírku 5:6
nebude-li se léčit, má sánce 3:4
Která sánce je větší?

$$\frac{5:6}{3:4} = \frac{5 \cdot 4}{3 \cdot 6} = \frac{20}{18} > 1$$

Tedy lepší bude dát se léčit.

Podíl sánce obecně je relativa $\delta = \frac{m_{11}m_{22}}{m_{12}m_{21}}$ se nazývá interval
a je ohraničen teoretické intervaly $\beta = \frac{p_1p_{22}}{p_{12}p_{21}}$.

Hypotéza nerovnosti se pak formuluje jako $H_0: \beta = 1$.

V testuje používají logaritmické intervaly $d = \ln \delta$, $\sigma = \ln \beta$
a hypotéza pak má tvar $H_0: \sigma = 0$.

Pokud, že relativa

$$D = \frac{d}{\sqrt{\frac{1}{m_{11}} + \frac{1}{m_{12}} + \frac{1}{m_{21}} + \frac{1}{m_{22}}}} \quad \left(= \frac{0,10536}{0,974679} = 0,108 \right)$$

má možnost výroby soudění (asympotick) $N(0,1)$.

H_0 se zamítá, když $|D| \geq u(\frac{\alpha}{2})$. ($= 1,959$)

Další příklad: Udaje o nemocných násobkách

	perily	nemoci	celkov.
léčení	6	3	9
nalečení	9	5	14
celkov.	15	8	23

$$\text{interval } \delta = \frac{6:3}{9:5} = \frac{30}{24} > 1, \text{ tj: výhodnější je dát se léčit}$$

Údaje o nemocných lidech (muži a ženy celkem)

	písní	xemřeli	celkem
lečení	11	9	20
nelečení	12	9	21
celkem	23	18	41

$$\text{interval } b = \frac{11:9}{12:9} = \frac{99}{108} < 1$$

Kávér: Pro muže i ženy je výhodnější se lečit, ale pro člověka je výhodnější se nelečit.

Cím to je? Podobně jako u korelačních koeficientů často nastávají situace pouze korelace dvoujic faktorů, ale nich. Tady máme vlastně 3 veličiny: lečba, písní, podpora a měli bychom analyzovat trojparametrickou kontingenční tabulku.