

Statistická analýza kompozičních tabulek

Kamila Fačevicová, Karel Hron

Katedra matematické analýzy a aplikací matematiky,
Univerzita Palackého v Olomouci

Od kontingenčních ke kompozičních tabulkám

- **Kontingenční tabulky:** vztah dvou faktorů zachycený v tabulce s diskrétními vstupy. Test nezávislosti

$$\chi^2 = \sum_{i=1}^I \sum_{j=1}^J \frac{\left(n_{ij} - \frac{n_{i\cdot} \cdot n_{\cdot j}}{n} \right)^2}{\frac{n_{i\cdot} \cdot n_{\cdot j}}{n}}.$$

- **Kompoziční tabulky:** spojitá analogie kompozičních tabulek. Umožňují analýzu vztahu mezi faktory na základě výběru n tabulek.

$I \times J$ kompoziční tabulky

- Speciální případ $I \cdot J$ -složkových kompozičních dat

$\mathbf{x} = \mathcal{C}(x_{11}, \dots, x_{1J}, \dots, x_{I1}, \dots, x_{IJ})$, které jsou přeuspořádány do tabulky o rozměru $I \times J$

$$\mathbf{x} = \mathcal{C} \begin{pmatrix} x_{11} & \cdots & x_{1J} \\ \vdots & \ddots & \vdots \\ x_{I1} & \cdots & x_{IJ} \end{pmatrix}.$$

- Nesou informaci o vztahu mezi řádkovým a sloupcovým faktorem.
- Příklad:

věk \ BMI	podváha	normální v.	nadváha	obezita
25 – 44	0.0144	0.2196	0.1410	0.0554
45 – 64	0.0022	0.1014	0.1792	0.0988
65 – 84	0.0014	0.0473	0.0900	0.0493

Tabulka : Rozdělení populace České republiky v roce 2008 podle věku a hodnoty BMI indexu.

$I \times J$ kompoziční tabulky

- Operace uzávěru:

$$\mathcal{C}(\mathbf{x}) = \begin{pmatrix} \frac{\kappa \cdot x_{11}}{\sum_{i,j=1}^{I,J} x_{ij}} & \dots & \frac{\kappa \cdot x_{1J}}{\sum_{i,j=1}^{I,J} x_{ij}} \\ \vdots & \ddots & \vdots \\ \frac{\kappa \cdot x_{I1}}{\sum_{i,j=1}^{I,J} x_{ij}} & \dots & \frac{\kappa \cdot x_{IJ}}{\sum_{i,j=1}^{I,J} x_{ij}} \end{pmatrix}.$$

- Výběrovým prostorem je $I \cdot J$ -složkový **simplex** dimenze $I \cdot J - 1$

$$\mathcal{S}^{IJ} = \{ \mathbf{x} = (x_{11}, \dots, x_{1J}, \dots, x_{IJ}) | x_{ij} > 0,$$

$$i = 1, 2, \dots, I, j = 1, 2, \dots, J; \sum_{i,j=1}^{I,J} x_{ij} = \kappa \}.$$

Základní operace s kompozičními tabulkami - Aitchisonova geometrie

- Perturbace:**

$$\mathbf{x} \oplus \mathbf{y} = \mathcal{C} \begin{pmatrix} x_{11}y_{11} & \cdots & x_{1J}y_{1J} \\ \vdots & \ddots & \vdots \\ x_{I1}y_{I1} & \cdots & x_{IJ}y_{IJ} \end{pmatrix}.$$

- Mocninná transformace:**

$$\alpha \odot \mathbf{x} = \mathcal{C} \begin{pmatrix} x_{11}^\alpha & \cdots & x_{1J}^\alpha \\ \vdots & \ddots & \vdots \\ x_{I1}^\alpha & \cdots & x_{IJ}^\alpha \end{pmatrix}.$$

- Skalárni součin:**

$$\langle \mathbf{x}, \mathbf{y} \rangle_a = \frac{1}{2IJ} \sum_{i,j} \sum_{k,l} \ln \frac{x_{ij}}{x_{kl}} \ln \frac{y_{ij}}{y_{kl}}.$$

- Aitchisonova délka a vzdálenost:**

$$\|\mathbf{x}\|_a = \sqrt{\langle \mathbf{x}, \mathbf{x} \rangle_a}$$

$$d_a(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} \ominus \mathbf{y}\|_a$$

Rozklad kompozičních tabulek

- Pomocí projekcí mohou být kompoziční tabulky rozděleny na nezávislou a interakční část.

$$\mathbf{x} = \mathbf{x}_{ind} \oplus \mathbf{x}_{int}.$$

- Nezávislá tabulka:**

$$\mathbf{x}_{ind} = \left(x_{ij}^{ind} = \left(\prod_{k=1}^I \prod_{l=1}^J x_{kj} x_{il} \right)^{\frac{1}{IJ}} \right)_{i,j=1}^{I,J}.$$

Popisují jen vztah mezi řádky nebo sloupci. Analogie s případem nezávislosti v kontingenčních tabulkách.

- Interakční tabulka:**

$$\mathbf{x}_{int} = \left(x_{ij}^{int} = \left(\prod_{k=1}^I \prod_{l=1}^J \frac{x_{ij}}{x_{kj} x_{il}} \right)^{\frac{1}{IJ}} \right)_{i,j=1}^{I,J}.$$

Popisují vztah mezi různými řádky a sloupci.

Analýza vztahu mezi faktory

Pokud jsou řádkový a sloupcový faktor nezávislé, pak

- veškerá informace o tabulce x je obsažena v její nezávislé části ($x = x_{ind}$),
- interakční tabulka je neutrální prvek (všechny prvky jsou si rovny),
- všechny iLR souřadnice tabulky x_{int} jsou nulové.

Vyjádření kompoziční tabulky v souřadnicích

Souřadnice D -složkových kompozičních dat představují
 $D - 1$ -rozměrný reálný vektor

$$\mathbf{z} = h(\mathbf{x}) = (\langle \mathbf{x}, \mathbf{e}_1 \rangle_a, \dots, \langle \mathbf{x}, \mathbf{e}_{D-1} \rangle_a) = (z_1, z_2, \dots, z_{D-1}),$$

kde $\mathbf{e}_i = \mathcal{C}(e_{i1}, \dots, e_{i,D})$, $i = 1, \dots, D - 1$ tvoří ortonormální bázi
 D -složkového simplexu.

Pro tyto souřadnice platí, že

$$h(\alpha \odot \mathbf{x}_1 \oplus \beta \odot \mathbf{x}_2) = \alpha \cdot \mathbf{z}_1 + \beta \cdot \mathbf{z}_2, \quad \langle \mathbf{x}_1, \mathbf{x}_2 \rangle_a = \langle \mathbf{z}_1, \mathbf{z}_2 \rangle.$$

Mezi různými systémy souřadnic existuje ortogonální vztah.

Vyjádření kompoziční tabulky v souřadnicích

Interakční tabulku lze převést do souřadnic pomocí:

- Postupného binárního dělení $\Rightarrow I \cdot J - 1$ obecně nenulových souřadnic.
- Vztahu

$$\frac{1}{\sqrt{r \cdot s \cdot (r-1) \cdot (s-1)}} \ln \prod_{i=1}^{r-1} \prod_{j=1}^{s-1} \frac{x_{ij}x_{rs}}{x_{is}x_{rj}} \quad (1)$$

pro $r = 2, 3, \dots, I$ a $s = 2, 3, \dots, J \Rightarrow (I-1)(J-1)$ obecně nenulových souřadnic, zbývající nulové.

- Permutací řádků nebo sloupců tabulky a použitím vztahu (1) $\Rightarrow (I-1)(J-1)$ obecně nenulových souřadnic s novou interpretací.

Srovnání metod pro převod interakční tabulky do souřadnic

Postupné binární dělení	Nová metoda
+ Interpretace pomocí bilancí	+ Souvislost s poměry šancí v tabulce x .
- Zdlouhavý výpočet o několika krocích.	+ Rychlý výpočet přímo z tabulky x .
- Více nenulových souřadnic, než je dimenze prostoru $\mathcal{S}^{I \times J}(x_{int})$.	+ Počet nenulových souřadnic je roven dimenzi prostoru $\mathcal{S}^{I \times J}(x_{int})$.
- Vede k problémům se singularitou souřadnic.	+ Problém se singularitou je eliminován.

Tabulka : Srovnání metod pro vyjádření tabulky x_{int} v souřadnicích.

Příklad - vztah mezi věkem a indexem BMI

- Zabýváme se vztahem mezi věkem a BMI.
- K dispozici máme výběr kompozičních tabulek typu 3×4 popisujících rozdělení populace 18-ti evropských zemí podle věku a BMI v roce 2008.
- Faktor věk má 3 úrovně: 25 – 44, 45 – 64 a 65 – 84 let.
- Faktor BMI má 4 úrovně: podváha, normální váha, nadváha a obezita.

věk \ BMI	podváha	normální v.	nadváha	obezita
25 – 44	0.0144	0.2196	0.1410	0.0554
45 – 64	0.0022	0.1014	0.1792	0.0988
65 – 84	0.0014	0.0473	0.0900	0.0493

Příklad - rozklad na nezávislou a interakční tabulku

- Nezávislá tabulka pro Českou republiku:**

$$\mathbf{x}_{ind} = \begin{pmatrix} 0.0061 & 0.1716 & 0.2218 & 0.1090 \\ 0.0039 & 0.1090 & 0.1409 & 0.0692 \\ 0.0020 & 0.0569 & 0.0736 & 0.0361 \end{pmatrix}$$

- Interakční tabulka pro Českou republiku:**

$$\mathbf{x}_{int} = \begin{pmatrix} 0.1813 & 0.0973 & 0.0483 & 0.0387 \\ 0.0444 & 0.0707 & 0.0967 & 0.1085 \\ 0.0541 & 0.0632 & 0.0930 & 0.1037 \end{pmatrix}$$


- Průměrná tabulka** (ve smyslu Aitchisonovy geometrie):

$$\bar{\mathbf{x}}_{int} = \begin{pmatrix} 0.1472 & 0.0959 & 0.0585 & 0.0462 \\ 0.0550 & 0.0747 & 0.0907 & 0.1023 \\ 0.0599 & 0.0677 & 0.0915 & 0.1027 \end{pmatrix}$$



Prvky si nejsou rovny \Rightarrow svědčí proti nezávislosti faktorů.

Příklad - převod interakční tabulky do souřadnic



$$z_{22}^{int} = \frac{1}{2} \ln \frac{x_{11}x_{22}}{x_{12}x_{21}}$$





$$z_{23}^{int} = \frac{1}{\sqrt{12}} \ln \frac{x_{11}x_{12}x_{23}^2}{x_{21}x_{22}x_{13}^2}$$





$$z_{24}^{int} = \frac{1}{\sqrt{24}} \ln \frac{x_{11}x_{12}x_{13}x_{24}^3}{x_{21}x_{22}x_{23}x_{14}^3}$$





$$z_{32}^{int} = \frac{1}{\sqrt{12}} \ln \frac{x_{11}x_{21}x_{32}^2}{x_{31}^2x_{12}x_{22}}$$



$$z_{33}^{int} = \frac{1}{\sqrt{36}} \ln \frac{x_{11}x_{12}x_{21}x_{22}x_{33}^4}{x_{31}^2x_{32}^2x_{13}^2x_{23}^2}$$



$$z_{34}^{int} = \frac{1}{\sqrt{72}} \ln \frac{x_{11}x_{12}x_{13}x_{21}x_{22}x_{23}x_{34}^6}{x_{31}^2x_{32}^2x_{33}^2x_{14}^3x_{24}^3}$$




Příklad - výběrové charakteristiky

Z_{int}	Z_{22}	Z_{23}	Z_{24}	Z_{32}	Z_{33}	Z_{34}
V. průměr	0.3674	0.6096	0.6494	0.1057	0.3624	0.3783
V. s. odchylka.	0.1488	0.1357	0.1426	0.2412	0.2175	0.1945

- Opět svědčí proti nezávislosti věku a BMI.
- Nejvíce jsou od nuly vzdáleny souřadnice z_{23} a z_{24} (poměry šancí agregující podváhu a normální váhu, resp. podváhu, normální váhu a nadváhu).
- V případě náhodného výběru (nezávislosti kompozičních tabulek) lze nezávislost dál ověřit pomocí testování nulovosti souřadnic Z_{int} .

Příklad - grafická reprezentace souřadnic



Co najdete na posteru

- Definici kompozičních tabulek jako spojité analogie kontingenčních tabulek.
- Metodu analýzy vztahu mezi dvěma faktory s využitím výběru n tabulek.
- Rozklad tabulek na interakční a nezávislou část.
- Vztah pro výpočet souřadnic interakční tabulky.
- Interpretaci souřadnic ve smyslu poměru šancí.
- Příklad použití metody pro analýzu vztahu mezi věkem a BMI.

Reference

- J. Aitchison (1986) *The Statistical Analysis of Compositional Data*. Chapman and Hall, London.
- J.J. Egozcue, V. Pawlowsky-Glahn, G. Mateu-Figueras, C. Barceló-Vidal (2003) Isometric logratio transformations for compositional data analysis. *Mathematical Geology* 35(3), 279–300.
- J.J. Egozcue, J.L. Díaz-Barrero, V. Pawlowsky-Glahn (2008) Compositional analysis of bivariate discrete probabilities. In: J. Daunis-i-Estadella, J.A. Martín-Fernández, eds, *Proceedings of CODAWORK'08*, University of Girona, Spain.
- K. Fačevicová, K. Hron, V. Todorov, D. Guo, M. Templ (2013) Logratio approach to statistical analysis of 2×2 compositional tables. *Journal of Applied Statistics*, DOI: 10.1080/02664763.2013.856871.
- K. Fačevicová, K. Hron, V. Todorov (2014) Compositional tables analysis in coordinates. V přípravě.