

# DISTANČNÍ PŘÍSTUP K ANALÝZE KATEGORIZOVANÝCH DAT A JEHO APLIKACE NA PROBLÉM SHODY

Jan ŘEHÁK (Ústav pro filosofii a sociologii ČSAV, Praha)

Blanka ŘEHÁKOVÁ (Ústav pro výzkum veřejného mínění při FSV, Praha)

Problém shody zahrnuje v analytické praxi širší třídu úloh, než jde jen o tradičně uváděná.

## I. Obrázek motivace

Uvádeme příklad čtyř kategorií  $A = (A_1, A_2, A_3, A_4)$  s rovnoměrným rozdělením předpokládaných pravděpodobnosti výskytu

$A_1$	$A_2$	$A_3$	$A_4$	
.25	.25	.25	.25	teoretické rozdělení
.25	.25	.35	.15	první empirické rozdělení
.35	.25	.25	.15	druhé - - -

V případě, že jde o prostou klasifikaci (nominalní proměnnou), se první a druhé empirické rozdělení od teoretického liší ve zcela stejném stupni, pouze kvalita odchýlení (tj. kategorie, do nichž se přesouvají jednotky z  $A_4$ ) se mění. V případě, že jde o uspořádanou klasifikaci (v pořadí indexů), je už rozdíl velmi značný. Jestliže mezi  $A_k$  uvažujeme jinou relaci vzhledem ke kategorii shodu hodnotami, může být situace neshody ještě více diferencována. ( $A_k$  mohou být např. místa na mapě - Bratislava, Praha, Most, Litvinov tvorí názorný extrémní případ; kategorie mohou reprezentovat také určité typy, které se od sebe liší v různém stupni). Obecně složitější relace mezi  $A_k$  se vyskytuji často ve společenských, biologických a lékařských vědách, v ekologické, diagnostické, typologické, dialektologické a jiné problematice).

Z příkladu plynou tři hlavní problémy:

- Jak odlišit různé situace (relace mezi  $A_k$ ) při testování shody?
- Jak měřit neshodu?
- Jak specifikovat neshodu?

Poslední problém se řeší pomocí testování reziduí (případ prosté klasifikace a případy, kdy klasifikace vzniká jako kombinace dvou, přičemž marginální distribuce jedné nebo obou klasifikací je známa viz B. Řeháková [1979]). Měření neshody bylo pro nominalní proměnnou navrženo H. Weilerem [1966].

## II. Weilerův koefficient neshody a jeho diskuse

### Označení

- $A : A_1, A_2, \dots, A_k$  kategorie,  
 $\pi_i : \pi_1, \pi_2, \dots, \pi_k$  hypotetické pravděpodobnosti,  
 $f : f_1, f_2, \dots, f_k$  empirické relativní četnosti,  
 $p : p_1, p_2, \dots, p_k$  skutečné pravděpodobnosti.

Test hypotézy  $H_0$ :  $\pi_i = p$  za předpokladu multinomického rozdělení provádime např. pomocí

Pearsonova  $\chi^2$

$$(1) \quad \chi^2 = n \sum_{i=1}^k \frac{(p_i - \pi_i)^2}{\pi_i} \sim \chi^2_{k-1} \text{ za } H_0.$$

H. Weiler [1966] defineval koefficient neshody  $\bar{\varphi}$  jako normalizaci  $\sqrt{\chi^2}$  mezi 0 a 1

$$(2) \quad \bar{q} = \sqrt{\frac{x_{\min}}{1-x_{\min}} \sum_{i=1}^k \frac{(x_i - f_i)^2}{x_i}}$$

a podal jeho diskusi. Koefficient však má dvě základní nové hedy:

- a) Je vhodný pro prestatu klasifikaci a není zřejmě jeho rozšíření na decnější typy proměnné.
- b) Platí

$$(3) \quad q^2 = \frac{x_{\min}}{1-x_{\min}} \left[ \frac{(x_{\min} - f_m)^2}{x_{\min}} + \sum_{i \neq m} \frac{(x_i - f_i)^2}{x_i} \right]$$

kde  $m$  je index přišlušný k  $x_{\min}$  (je-li jediné). Z (3) plyně, že  $\lim_{x_{\min} \rightarrow 0} q^2 = f_m^2$  a tudíž příspěvek druhého člena v (3) je pro malé  $x_{\min}$  mizivý oproti příspěvku v kategorii  $f_m$ . (Obdobné výsledky platí i v případě, kdy je více kategorií s minimálním  $x_{\min}$ ). V tomto případě tedy  $\bar{q}$  neodráží rovnoměrnou neshodu ve všech kategoriích (obdobný nedostatek má i  $\chi^2$ ).

### III. Distanční model pro anglicku zebecněných kategorizovaných proměnných (D-model)

Výše uvedené aspekty se snažíme překonat pomocí distanční analýzy distribuci (J. Řehák, B. Řeháková [1979]). Označime  $A = \{A_1, \dots, A_k\}$  množinu hodnot kategorizace  $A$ ,  $f = \{f_1, \dots, f_k\}$  distribuci z  $K$ -rozměrného simplexu  $\Omega_k = \{f: \sum f_i = 1, f_i \geq 0\}$ . Dále označime  $D = \|d_{ij}\|$ , typu  $K \times K$  matice skóru vytvářících typ proměnné,  $d_{ij} = \text{skóř určující relaci } (A_i, A_j) \text{ a splňující podmínky } d_{jj}=d_{ii} \text{ a } d_{ii}=0$ . Zebecněnou proměnnou definujeme jako  $A = \{A_1, \dots, A_k; D\}$ .

Příklady:

- a)  $d_{ij}=1$  pro  $i \neq j$ , pak  $A$  se nazývá nesinglální (prestaté kategorizace),
- b)  $d_{ij} = |i-j|$ , pak  $A$  se nazývá ordinální (uspořádané kategorizace).
- c)  $d_{ij} = (x_i - x_j)^2$ , kde  $x_i$  jsou čísla přiřazená kategoriím ( $x_i = x(A_i)$ ), pak proměnnou nazýváme kardinální (čiselné kategorizace).
- d) Jestliže existuje  $K$  vektorů s  $M$  složkami  $x_k = (x_{k1}, \dots, x_{kM})$ ,  $k=1, \dots, K$  tak, že  $d_{ij} = \sum_{m=1}^M (x_{im} - x_{jm})^2$ , pak hovoříme o M-dimensionální metrické proměnné, pro  $M=2$  se tato proměnná nazývá grafikou.

Základní charakteristiky (definice) a vlastnosti

- a) Zebecněná míra rozptylu

$$(4) \quad \text{Genvar } f = f' D f$$

- b) Míra polohy

$$(5) \quad c = A_k \geq d_k^* = \min_j d_{ij}, \text{ kde } d_j = E d_{ij} = \sum_i f_i d_{ij}$$

- c) Věta (existence semimetriky)

fo  $f, g \in \Omega_k$  platí

$$(6) \quad D(f, g) = \sqrt{(f-g)' D(g-f)}$$

je semimetrika na  $\Omega_k$ , jestliže  $D^* = \|d_{ij}^*\|$ ,  $d_{ij}^* = d_{ik} + d_{jk} - d_{ij}$ , typu  $(K-1) \times (K-1)$  je pozitivně semidefinitní. Je-li  $D^*$  pozitivně definitní, pak  $D(f, g)$  je metrika na  $\Omega_k$ .  $D(f, g)$  nazýváme D-semimetriku, resp. D-metrikou na  $\Omega_k$ .

- d) Věta (rozklad zebecněné variance)

Bud  $f = \sum p_r f_{(r)}$ , kde  $p_r \in \Omega_R$ ,  $f_{(r)} \in \Omega_K$ , pak pro  $D$  tvorící semimetriku platí

$$(7) \quad \text{Genvar } f = \sum p_r \text{Genvar } f_{(r)} + \frac{1}{2} \sum_r \sum_s p_r p_s D^2(f_{(r)}, f_{(s)}) = \sum p_r \text{Genvar } f_{(r)} + \sum p_r D^2(f_{(r)}, f)$$

Příklady:

	nominální	ordinální	kardinální
Generál f	$1 - \sum f_i^2$	$2 \sum F_i(1-F_i)$	$\text{zvar } X$
c	modální kat.	mediánová kat.	kategorie průměru
$D(f, g)$	$\sqrt{\sum f_i(g_i)^2}$	$\sqrt{2 \sum (F_i - g_i)^2}$	$\sqrt{2(\bar{x}_f - \bar{x}_g)}$
	(metrika)	(metrika)	(semimetrika)

kde  $F_i, g_i$  jsou distribuční funkce,  $\bar{x}_f, \bar{x}_g$  jsou průměry.

Důsledky:

- a) Nominální analýza odpovídá např. metodě CANTHOVA (analýza rozptýlu pro kategorizované data) zavedené v práci Light, Margolin [1971], aplikujeme-li (7) na nominální proměnnou.
- b) Analýza kardinalních průměrných přechází k lineárnímu modelu s metodou nejmenších čtverců.
- c) Model poskytuje přístup k analýze ordinálních dat, která je analogická k přístupu Cramér-von Misesovy statistiky pro spojité data (viz J. Řehák [1976]).

#### IV. Aplikace D-modelu na testování dobré shody (asymptotická teorie)

U testů dobré shody tvoří D přirozenou ztrátovou funkcí odvozenou z typu kategorizace a tudíž poskytuje váhy pro odchyly od předpokladu. Testy dobré shody můžeme založit na statistice typu (8) :

$$(8) \quad d^2 = \theta^2(n, f)$$

pro hypotézu  $H_0 = p$ . Její významnost lze určit podle algoritmu AS 106 (viz Sheil, O'Muircheartaigh [1977]).

Příručou možnosti je převedení na  $\chi^2$  distribuci pomocí následujícího postupu. Poležme  $f^* = (f_1, \dots, f_{k-1})$ , obdobně  $\pi^*, g^*$ . Existuje a také, že  $\pi^* = \pi^T$ ,  $\pi^T \pi = I_N$ , kde  $I_N$  je jednotková matice typu  $N \times N$ ,  $N =$  hodnota  $D^*$ . Platí  $(f^* - \pi^*) = g^* \sim N(0, \Sigma)$  za platnosti  $H_0$ . Pro všechna  $\pi_{ij} > 0$  je rozložení regulérní  $(\sigma_{ij} = n^{-1} [\delta_{ij} \pi_{ij} - \pi_{ij} \pi_{ij}])$ . Odtud  $h = (h_1, \dots, h_N) = g^* \pi \sim N(0, \pi^T \Sigma \pi)$  a tudíž

$$(9) \quad x_D^2 = h(\pi^T \Sigma \pi)^{-1} h^T = (f^* - \pi^*) \pi (\pi^T \Sigma \pi)^{-1} \pi^T (f^* - \pi^*)^T$$

je za platnosti  $H_0$  rozděleno jako  $\chi_N^2$ .

Pro ordinální D je  $h = (F_1, \dots, F_{k-1})$ ,  $\Sigma_\pi = \pi^T \Sigma \pi$  je určena prvky  $\sigma_{0,ij} = \Pi_j(1 - \Pi_j)$  pro  $i \neq j$ , kde  $\Pi_j$  je distribuční funkce k  $\pi_{ij}$ .

Pro kardinální D je problém převeden na obvyklý z-test  $x_D^2 = z^2 = n(\bar{x}_f - \bar{x}_{\pi^*})^2 / \text{var}(X/n)$ . Nominální případ vede na  $x^2$  z (1).

#### V. Aplikace na měření neshody

Pro  $A = \{A_1, A_2, \dots, A_k\} \subset \mathcal{A}$ ,  $p, f \in \mathcal{A}_k$  zavedla Řeháková [1980] koeficient neshody

$$(10) \quad \rho = \frac{\theta(n, p)}{\max \theta(n, p)}$$

v praxi používáme výběrový analog (odhad metodu maximální věrohodnosti)

$$(11) \quad R = \frac{\theta(n, f)}{\max \theta(n, f)}$$

Maximum ve jmenovateli (11) pro běžné typy proměnných (nominalní, ordinální, kardinální) je

$$\frac{1 - 2 \pi_{\min} + \sum_{k=1}^K \pi_k^2}{2 \max \left( \sum_{k=1}^{K-1} \pi_k^2, \sum_{k=1}^{K-1} (1 - \pi_k)^2 \right)}, \quad \pi_k = \sum_{i=1}^k \pi_i,$$

$$\sqrt{2 \max (\bar{x}_{\text{av}} - x_{\min}, x_{\max} - \bar{x}_{\text{av}})},$$

kde  $x_{\min}, x_{\max}$  jsou minimální a maximální skóry přiřazené kategorii,  $\bar{x}_{\text{av}} = \sum_k \pi_k x_k$ .

Vlastnosti R :

- a)  $0 \leq R \leq 1$ ;  $R = 0 \Leftrightarrow \pi = 1$  pro D-metriku  
 $\pi = 1 \Rightarrow R = 0$  pro D-semimetriku
- b)  $R \sim N(\rho, \frac{\sigma^2(R)}{n})$ ,  $\sigma^2(R)$  jsou uvedeny v cítevané práci.

Asymptotická normalita umožňuje

- a) konstrukci intervalů spolehlivosti  $R \in [\bar{R} \pm \sqrt{\frac{\sigma^2(R)}{n}}, \bar{R}]$ ,
- b) test  $\rho = \rho_0$ ,
- c) testy  $\rho_1 = \rho_2 = \dots = \rho_n$  a párová porovnání  $\rho_i = \rho_j$  pro nezávislé výbory.

Poznámka : Koefficienty neshody i jejich testy mohly praktickou aplikaci při vyhodnocování reprezentativity výzkumu veřejného mínění a při porovnávání distribuci s nezávislým standardem (např. shoda reality s zámeru u působení časopisu, televize, rozhlasu ap.).

## VI. Řešení aplikace D-modelu

1. Koefficienty asociace - speciální případ je Walliseova  $\chi^2$  i korelační poměr  $\eta^2$  aplikovaný na kontingenční tabulku, též koefficient  $\beta$  pro ordinální proměnné (viz Řehák [1976]).
2. Koefficienty parcíální asociace.
3. Analýza kategorizovaných dat ve schématech ANOVA (včetně testů homogenity pro tabulku RxB).
4. Seskupování řádků tabulky (např. vážená centrádní metoda - viz Řehák, Řeháková [1982]).
5. Klasické multidimensionální škálování řádků tabulky.

Výhody D-modelu spočívají

- a) v překonání obtíží, které byly diskutovány v úvodních částech referátu, při řešení všech komparativních úloh spojených s obecnými typy kategorizací;
- b) v poskytnutí jednotného pohledu a jednotné interpretace odvozených měr a statistických testů;
- c) v možnosti práce s obecnými typy kategorizací, ale i v jednoduché metodice pro analýzu ordinálních dat;
- d) v jednoduchém heuristickém základu a v možnosti jednoduchých grafických reprezentací výsledků (euklidovská reprezentace simplexu  $\Delta_K$ ).

## LITERATURA

1. Light, R.J., Margolin, B.H. [1971] : An Analysis of Variance for Categorical Data. Journal of American Statistical Association 66, 534-544.
2. Rao, R.C. [1978] : Lineární metody statistické indukce a jejich aplikace. Academia, Praha.
3. Řehák, J. [1976] : Základní deskriptivní metry pro rozložení ordinálních dat. Sociologický časopis 4, 416-431.

4. Řehák,J., Řeháková B. [1979] : Základní charakteristiky proměnných s konečným počtem hodnot a distanční analýza jejich rozložení. *Sociologický časopis* 2, 214-233.
5. Řehák,J. Řeháková B. [1981] : Analýza kategorizovaných dat v sekvenci (nepublikováno).
6. Řeháková,B. [1979] : Statistické ověřování reprezentativity : testy dobré shedy. *Sociologický časopis* 6, 615-629.
7. Řeháková,B. [1980] : Statistické ověřování reprezentativity : koeficienty neshody. *Sociologický časopis* 6, 612-627.
8. Weiler,H. [1966] : A Coefficient Measuring the Goodness of Fit. *Technometrics* 2,327-334.
9. Sheil J., O'Muircheartaigh I. [1977] : Algorithm AS 106, The Distribution of Non-negative Quadratic Forms in Normal Variables. *Applied Statistics*, 92-98.