

## SMÍŠENÉ INTERAKČNÍ MODELY

Marta Horáková, ÚSEB ČSAV Brno

Předpokládejme, že máme analyzovat data zapsaná ve tvaru tabulky objekt-znak, která jsou realizací náhodného výběru obecně ze smíšeného rozložení pravděpodobnosti, a předpokládejme, že nás zajímá vzájemná struktura závislosti pozorovaných znaků - náhodných veličin.

Problematiku vhodné definice struktury závislosti takových dat a její ověření s použitím smíšených interakčních modelů budeme sledovat na příkladu souboru dat z literatury, která analyzoval např. Morrison a s použitím námi sledovaných postupů pak znova Edwards (1987). Jedná se o data, která jsou výsledkem měření váhových ztrát po jednom a dvou týdnech od aplikace tří různých látek, z nichž každá byla podána čtyřem náhodně vybraným samcům a čtyřem samicím krys. Počet objektů je v tomto příkladě 24, sledované náhodné veličiny jsou: A = pohlaví, B = aplikovaná látka, X = váhová stráta po 1 týdnu, Y = váhová ztráta po 2 týdnech.

Obecně budeme předpokládat, že máme výsledek pozorování p diskrétních a q spojitych náhodných veličin a že objekt je popsán p+q vektorem  $(i, y)$ , kde  $i = (i_1, \dots, i_p)$  jsou hodnoty diskrétních proměnných,  $y = (y_1, \dots, y_q)$  jsou hodnoty spojitych proměnných. Množinu diskrétních náhodných veličin označíme D, množinu spojitych S.

Předpokládejme, že smíšené rozložení pravděpodobnosti, z něhož je proveden náhodný výběr rozsahu N, je tzv. CG-rozložení ( Conditional Gaussian ) s hustotou

$$\log f(i, y) = \alpha_i + \beta_i^T \cdot y - \frac{1}{2} \cdot y^T \cdot \Delta_i \cdot y ,$$

kde skalár  $\alpha_i$ , qx1 vektor  $\beta_i = (\beta_i^1, \dots, \beta_i^q)^T$  a qxq symetrická pozitivně definovaná matice koncentrace  $\Delta_i = (\delta_{ij}^{jk})_{j=1, \dots, q; k=1, \dots, q}$  jsou po řadě diskrétní, lineární

a kvadratické kanonické parametry rozložení CG.

Název CG-rozložení vystihuje skutečnost, že podmíněné rozložení spojitych náhodných veličin při pevných hodnotách diskrétních veličin je q-rozměrné normální  $N_q(\mu_i, \Sigma_i)$ , kde  $\mu_i = \Delta_i^{-1} \cdot \beta_i$ ,  $\Sigma_i = \Delta_i^{-1}$ . Marginální rozdělení diskrétních náhodných veličin má pravděpodobnostní funkci

$$p_i = (2\pi)^{q/2} \cdot \det(\Delta_i)^{-1/2} \cdot \exp\{\alpha_i + \frac{1}{2} \cdot \beta_i^T \cdot \Delta_i^{-1} \cdot \beta_i\} .$$

Parametry  $p_i$ ,  $\mu_i$ ,  $\Sigma_i$  se nazývají přirozené,  $m_i = p_i \cdot N$  je očekávaná četnost třídy i odpovídající kontingenční tabulky z diskrétních náhodných veličin,  $\mu_i$  je qx1 vektor průměru spojitych náhodných veličin a  $\Sigma_i$  je jejich qxq kovarianční matici.

CG-rozložení pravděpodobnosti pak popisuje smíšený interakční model. Zadat smíšený interakční model tedy po stránce pravděpodobnosti znamená zadat diskrétní, lineární a kvadratické kanonické, resp. přirozené, parametry odpovídajícího CG-rozložení. V praxi se přitom obvykle omezují úvahy na hierarchické a zejména pak grafové smíšené interakční modely ( Edwards 1986 ). Situace je analogická s problematikou analýzy vícerozměrných kontingenčních tabulek pro výlučně diskrétní proměnné, kterou popisuje ve stornicích ROEUSTu 82, 84, T. Havránek z SVT ČSAV, z jehož podnětu tento příspěvek vznikl.

Popis struktury závislosti je názornější, vyjádříme-li z kanonických parametrů. Zadat hierarchický interakční model znamená zadat generující třídu

hierarchického rozkladu pro diskrétní kanonické parametry  $\alpha_i$  pro všechna i; pro každou složku  $\beta_i^Y$ ,  $Y \in S$ , lineárních kanonických parametrů  $\beta_i$  generující třídu pro všechna i; pro každý prvek  $\delta_i^{XY}$ ,  $X, Y \in S$ , matice koncentrace  $\Delta_i$  generující třídu hierarchického rozkladu pro všechna i. (Hierarchickým rozkladem přitom rozumíme situaci podobnou analýze rozptylu.)

V příkladě s krysmi je  $S = \{A, B\}$ ,  $S = \{X, Y\}$  a lze specifikovat například následující modely:

$M_1$ : parametr	hierarchický rozklad	generátor	generující třída
$\alpha_i$	$\lambda + \lambda_i^A + \lambda_i^B$	A,B	A,B
$\beta_i^X$	$\xi + \xi_i^A + \xi_i^B$	A,B	AX,BX,AY
$\beta_i^Y$	$\gamma + \gamma_i^A$	A	
$\delta_i^{XX}$	$\tau$	1	
$\delta_i^{YY}$	$\gamma$	1	X,Y
$\delta_i^{XY}$	0	0	
$M_2$ : parametr	hierarchický rozklad	generátor	generující třída
$\alpha_i$	$\lambda + \lambda_i^A + \lambda_i^B + \lambda_i^{AB}$	AB	AB
$\beta_i^X$	$\xi + \xi_i^A$	A	
$\beta_i^Y$	$\gamma + \gamma_i^A$	A	AX,AY
$\delta_i^{XX}$	$\tau + \tau_i^A$	A	
$\delta_i^{YY}$	$\gamma + \gamma_i^A$	A	AXX,AYY,AXY stručně: AXY
$\delta_i^{XY}$	$\tau + \tau_i^A$	A	
$M_3$ : parametr	hierarchický rozklad	generátor	generující třída
$\alpha_i$	$\lambda + \lambda_i^A + \lambda_i^B + \lambda_i^{AB}$	AB	AB
$\beta_i^X$	$\xi + \xi_i^B$	B	
$\beta_i^Y$	$\gamma + \gamma_i^B$	B	BX,BY
$\delta_i^{XX}$	$\tau + \tau_i^B$	B	
$\delta_i^{YY}$	$\gamma$	1	BXX,YY,XY stručně: BX,XY
$\delta_i^{XY}$	$\tau$	1	
$M_4$ : parametr	hierarchický rozklad	generátor	generující třída
$\alpha_i$	$\lambda + \lambda_i^A + \lambda_i^B + \lambda_i^{AB}$	AB	AB
$\beta_i^X$	$\xi + \xi_i^B$	B	
$\beta_i^Y$	$\gamma + \gamma_i^B$	B	BX,BY
$\delta_i^{XX}$	$\tau$	1	
$\delta_i^{YY}$	$\gamma$	1	XX,YY,XY stručně: XY
$\delta_i^{XY}$	$\tau$	1	

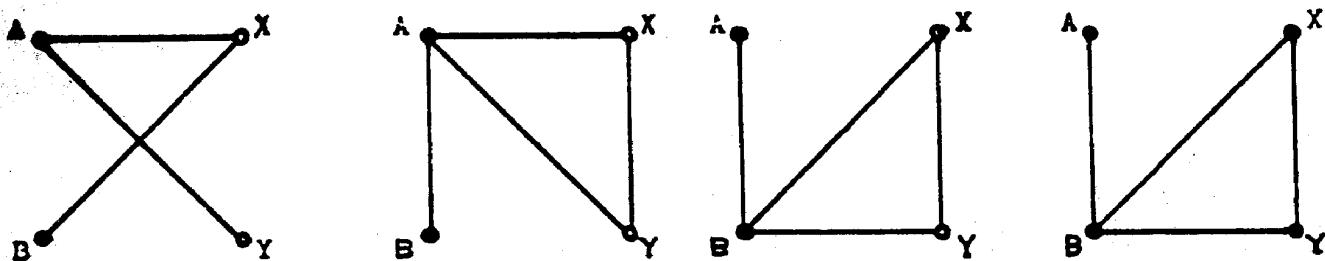
Pro stručný zápis modelu Edwards (1986) definuje generující sentenci hierarchického smíšeného modelu jako zápis diskrétních, lineárních a kvadratických generujících tříd oddělených lomítkem. Generující sentence modelů  $M_1$ ,  $M_2$ ,  $M_3$  a  $M_4$  tedy jsou:  $M_1$ : A, $\tau$ /AX,BX,AY/X,Y       $M_3$ : AB/BX,BY/BX,XY  
 $M_2$ : AB/AX,AY/AXY       $M_4$ : AB/BX,BY/XY

Edwards (1986) také uvádí požadavky, které musí parametrizace modelu splňovat:  
 1. Pouze nediagonální prvky matic  $\Delta_i$  mohou být nulové a zbyvající musí být alespoň konstantní.

2. Každý průnik lineárního generátoru s množinou diskrétních náhodných veličin D musí být obsažen v některém diskrétním generátoru.
3. Každý průnik kvadratického generátoru s množinou diskrétních náhodných veličin D musí být při sjednocení s každou spojitou náhodnou veličinou obsažen v lineárním generátoru.

Generující sentenci smíšeného interakčního modelu lze přiřadit její graf. Grafem generující sentence hierarchického smíšeného interakčního modelu rozumíme obyčejný graf s dvěma typy uzelů. Diskrétním náhodným veličinám odpovídají „diskrétní“ uzly (značené obvykle • podle anglického dot - discrete), spojitym náhodným veličinám „spojitě“ uzly (značené obvykle ○ podle anglického circle - continuous). Dva uzly jsou pak spojeny hranou právě tehdy, když existuje generátor, který obě jim odpovídající náhodné veličiny obsahuje.

Grafy generujících sentencí modelů uvedených dříve jsou například:  
 $M_1: A, B/AX, BX, AY/X, Y \quad M_2: AB/AX, AY/AXY \quad M_3: AB/BX, BY/BX, XY \quad M_4: AB/BY, BY/XY$



Nechť  $G = (V, E)$  je graf generující sentence hierarchického smíšeného modelu. Grafový (smíšený) model je pak právě takový model, jehož diskrétní generátory jsou právě kliky (= maximální úplné množiny uzelů) grafu  $G(D) = (V(D), E(D))$ , kde  $V(D)$  je množina všech diskrétních uzelů, množina hran  $E(D) = \{e \in E: e \subseteq V(D)\}$ ; lineární generátory jsou právě kliky grafu  $G(D \cup \{Y\}) = (V(D \cup \{Y\}), E(D \cup \{Y\}))$  pro každou spojitu veličinu  $Y \in S$ , kde  $V(D \cup \{Y\}) = D \cup \{Y\}$ ,  $E(D \cup \{Y\}) = \{e \in E: e \subseteq V(D \cup \{Y\})\}$ ; kvadratické generátory jsou právě ty kliky grafu  $G$ , které obsahují alespoň jeden spojitý uzel.

Z modelů uvedených v příkladu s kryjsami jsou tedy grafové modely  $M_1$ ,  $M_2$ , modely  $M_3$  a  $M_4$  grafové nejsou.

Z pravděpodobnostního hlediska jsou grafové právě ty smíšené modely, jejichž hustota pravděpodobnosti je markovská vzhledem ke grafu  $G$ ; tj. dvě náhodné veličiny odpovídající nesousedním uzelům v grafu generující sentence jsou podmíněně nezávislé při daných hodnotách zbyvajících proměnných. Interpretaci grafových modelů lze vyčíst přímo z grafu generující sentence: Jestliže  $a, b$  jsou množiny náhodných veličin, které jsou v grafu  $G$  odděleny množinou  $c$ , pak náhodné veličiny v  $a$  jsou podmíněně nezávislé s náhodnými veličinami v  $b$  při pevné hodnotě náhodných veličin v  $c$ .

Interpretace modelu  $M_2$  například je:  $a = \{B\}$ ,  $b = \{X, Y\}$ ,  $c = \{A\}$ , tedy při daném pohlaví jsou aplikovaná látka a váhové ztráty po jednom týdnu spolu s váhovými ztrátami po dvou týdnech nezávislé náhodné veličiny.

Ucelený systém programů pro hierarchické smíšené interakční modely MIM (Mixed Interaction Models) nabízí Edwards (1987).

V systému MIM jsou náhodné veličiny označovány jedním písmenem A až Z. Diskrétní náhodné veličiny jsou spolu s počtem úrovní specifikovány příkazem jazy-

ka MIMu      MIM → FACTOR A 2 B 2 C 3 D 2 ,

spojité proměnné jsou specifikovány příkazem

    MIM → CONTINUOUS X Y Z W ,

model je zadáván generující sentencí modelu příkazem

    MIM → MODEL A,B/AX,AY/AXY ,

    MIM → MODEL ABC,BCD// :

    MIM → MODEL // WXY,XYZ :

Užitím příkazů PLOT, DESCRIBE, PRINT je možno zobrazit graf generující sentence, vypsat určité vlastnosti běžného modelu a jeho generující sentenci.

Ověření adekvátnosti hierarchického smíšeného modelu v systému MIM provádí příkazy FIT, PRINT, TEST, BASE. Příkazem FIT se provede odhad parametrů pro daný model s data, spočte se odpovídající hodnota věrohodnostní funkce  $L_M$  pro daný model M a pro saturovaný model I a určí se hodnota testové statistiky

$$-2 \cdot \log Q((i,y)^{(1)}, \dots, (i,y)^{(N)}) = -2 \cdot (\log L_M - \log L_I).$$

Příkaz PRINT umožní vypsat podle volby odhadu parametrů. Příkaz TEST je určen pro test daného modelu proti saturovanému modelu založený na poměru věrohodnosti a asymptotickém rozložení  $\chi^2$  s počtem stupňů volnosti rovnému rozdílu počtu volných parametrů v těchto modelech. Příkazem BASE lze určit jiný model něž saturovaný, proti němuž má být model testován. Odhad parametrů je prováděn iteračním procesem, který může být řízen příkazy MAXCYCLES a CONVERGENCE jazyka MIMu se stejným významem specifikovaní maximálního počtu cyklů a udáním požadované přesnosti konvergence.

Vážení vstupních dat v systému MIM je možné buď ve tvaru tabulky objekt-znak, nebo ve tvaru četnosti, průměrů a kovariančních matic ( s koeficientem  $1/n$  místo obvyklého  $1/(n-1)$  ). V prvním případě jsou po příkazu READ s udáním jmen načítaných proměnných zadávány jejich hodnoty postupně na jednotlivých objektech. Ve druhém případě se při výlučně diskrétních náhodných veličinách zadávají četnosti jednotlivých tříd kontingenční tabulky pro p diskrétních proměnných, při výlučně spojitych náhodných veličinách se zadává celkový počet objektů N, q výběrových průměrů pro q spojitych náhodných proměnných a  $q(q+1)/2$  odpovídajících kovariancí ( s délitelem n nikoli n-1 ), ve smíšeném případě se postupně pro každou třídu p-rozměrné kontingenční tabulky zadává četnost třídy a q výběrových průměrů spojitych náhodných veličin pro objekty z dané třídy a  $q(q+1)/2$  výběrových kovariancí spojitych znaků pro objekty z dané třídy. Užitím příkazu STATREAD se načítají údaje ve standardním uspořádání tříd (1,...,1),(1,...,1,2),..., (rozsah prvního diskrétního znaku,..., rozsah p-tého diskrétního znaku), užitím příkazu CELLREAD je nutno zadat třídu explicitně, a uspořádání se tedy nevyžaduje.

V příkladu s kryssami Edwards (1987) postupně ověřoval následující modely s cílem najít model co nejjednodušší:

MIM → MODEL AB/ABX,ABY/AXY

MIM → FIT

DEVIANCE: 24.4014 DF: 12

CYCLE: 6

MIM → TEST

TEST OF H0: AB/ABX,ABY/AXY

AGAINST THE FULL MODEL.

LR: 24.4014 DF: 12 P: 0.0178

MIM → MODEL AB/ABX,ABY/BXY

MIM → FIT

DEVIANCE: 15.7173 DF: 9

CYCLE: 6

MIM → TEST

TEST OF H0: AB/ABX,ABY/BXY

AGAINST THE FULL MODEL.

LR: 15.7173 DF: 9 P: 0.0725

MIM → BASE

MIM → MODEL AB/ABX,ABY/BX,XY

MIM → FIT

DEVIANCE: 21.4050 DF: 13

CYCLE: 5

MIM → TEST

TEST OF H0: AB/ABX,ABY/BX,XY

AGAINST H: AB/ABX,ABY/BXY

LR: 5.6877 DF: 4 P: 0.2225

MIM → BASE

MIM → MODEL AB/BX,BY/BX,XY

MIM → FIT

DEVIANCE: 26.7960 DF: 19

CYCLE: 5

MIM → TEST

TEST OF H0: AB/BX,BY/BX,XY

AGAINST H: AB/ABX,ABY/BX,XY

LR: 5.3911 DF: 6 P: 0.5041

MIM - BASE  
MIM - MODEL AB/BX,Y/BX,XY  
MIM - FIT  
DEVIANC: 51.4148 DF: 21  
CYCLE: 3  
MIM - TEST  
TEST OF H0: AB/BX,Y/BX,XY  
AGAINST H: AB/BX,BY/BX,XY  
LR: 24.6188 DF: 2 P: 0.0000

Výsledkem Edwardsovy analýzy dat o krysách je tedy model s generující sentencí  $AB/BX, BY/BX, XY$  ( zde označovaný jako model  $M_3$  ). V Morrisonovi (1967) jsou tato data analyzována s použitím exaktních testů vícerozměrné analýzy s výsledkem, který se zde užívanou symbolikou odpovídá modelu  $M_4$ :  $AB/BX, BY/XY$  .

Systém MIM je psán v jazyce Pascal Turbo na IBM PC, vyžaduje alespoň 320 KB RAM a numericky koprocessor.

#### Literatura:

- Edwards, D. (1986): Mixed interaction models.  
Stat. Research Unit Univ. Copenhagen, Research Report.  
Edwards, D. (1987): A guide to MIM.  
Stat. Research Unit Univ. Copenhagen, Research Report.  
Morrison, D.F. (1967): Multivariate Statistical Methods.  
McGraw-Hill.  
Havránek, T. (1982): O analýze mnohorozměrných kontingenčních tabulek.  
ROBUST 82, JČSMF, Praha, str. 11-18.  
Havránek, T. (1984): O logaritmicko-lineárních modelech pro mnohorozměrná kategoriální data. ROBUST 84, JČSMF, Praha, str. 31-41.