

O ANALÝZE MNOHORozMĚRNÝCH KONTINGENČNÍCH TABULEK

Tomáš Havránek

Podívejme se na následující frekvenční tabulku:

E	D	C	B	A		s
				0	1	
3.0	140	0	0	95	1	1.04
			1	201	8	3.83
		1	0	295	5	1.67
			1	38	2	5.00
	140	0	0	49	5	11.36
			1	117	15	11.36
		1	0	192	15	7.25
			1	20	3	13.04
3.0	140	0	0	58	7	12.73
			1	158	6	3.89
		1	0	145	10	6.45
			1	22	3	12.00
	140	0	0	47	6	12.77
			1	137	17	9.06
		1	0	117	16	6.25
			1	22	9	29.30

kde A je výskyt ischemické choroby srdeční v průběhu pěti let po vyšetření (0 ne, 1 ano), B psychická náročnost práce (subjektivně, 0 ne, 1 ano), C fyzická náročnost práce (subjektivně, 0 ne, 1 ano), D systolický krevní tlak (pod 140, nad 140 včetně), E index alfa a beta lipoproteinů. Hodnoty B až E jsou zjišťovány při vstupním vyšetření. Hodnoty veličin D a E nejsou ve zdrojových datech kategorizovány, ale kategorizace se provádí zejména pro tabulační účely. Data pocházejí z výzkumu prováděného Angiologickou laboratoří fakulty všeobecného lékařství UK pod vedením prof. MUDr. Z. Reiniše, DrSc.

Čeho si na tabulce všimneme? Především neobsahuje žádné nulové frekvence. To nám při zpracování ušetří mnohé starosti. Dále je pravděpodobně zřejmé, že A závisí na čtveřici B, C, D, E. Otázkou je však struktura této závislosti i závislosti B, C, D a E mezi sebou. Dále je asi vhodné konstatovat, že žádná z veličin není veličinou řízenou.

1. Stojíme nejprve před otázkou, jak vyjadřovat hypotézy o nezávislosti resp. závislosti náhodných veličin, jejichž pozorováním (nezávislým homogenním náhodným výběrem) vznikne tabulka tohoto typu. Jedna z možností, která se v posledních letech čím dál tím více používá je logaritmicko-lineární vyjádření. O co jde si nejprve ukážeme na případě tří náhodných veličin. Pro jednoduchoost budeme předpokládat, že všechny nabývají pouze hodnot 0 a 1.

Veličiny si označíme A, B, C . Necht' nyní p_{ijk}^{ABC} je pravděpodobnost, že trojice $\langle A, B, C \rangle$ nabývá hodnoty $\langle i, j, k \rangle \in \{0, 1\}^3$. Tyto pravděpodobnosti můžeme rozepsat jako

$$\log p_{ijk}^{ABC} = \theta + \lambda_i^A + \lambda_j^B + \lambda_k^C + \lambda_{ij}^{AB} + \lambda_{ik}^{AC} + \lambda_{jk}^{BC} + \lambda_{ijk}^{ABC}, \quad (1)$$

kde požadujeme, aby $\sum_i \lambda_i^A = \sum_j \lambda_j^B = \sum_k \lambda_k^C = \sum_{ij} \lambda_{ij}^{AB} = \sum_{ik} \lambda_{ik}^{AC} = \sum_{jk} \lambda_{jk}^{BC} = \sum_{ijk} \lambda_{ijk}^{ABC} = 0$

Tento pohled je podobný pohledu při obvyklém modelu analýzy rozptylu s více faktory. Čísla $\lambda_i^A, \lambda_j^B, \lambda_k^C$ nazýváme hlavními efekty (nebo efekty prvního řádu), $\lambda_{ij}^{AB}, \lambda_{ik}^{AC}, \lambda_{jk}^{BC}$ efekty druhého řádu a λ_{ijk}^{ABC} efektem třetího řádu (často se též říká dvoufaktorový efekt) atd. Zpravidla, mluvíme-li o efektech, pak efektem myslíme vždy např. λ_{ij}^{AB} pro každé $i \in \{0, 1\}$ a $j \in \{0, 1\}$.

Model (1), resp. struktura závislosti jemu odpovídající, "vysvětluje" jakoukoliv trojrozměrnou tabulku. Problém je, zda tabulku nelze "vysvětlit" jednodušším způsobem, jednodušší strukturou závislosti vzniklou vynecháním některých efektů, např. zda nestačí předpokládat, že

$$\log(p_{ijk}^{ABC}) = \theta + \lambda_i^A + \lambda_j^B + \lambda_k^C + \lambda_{jk}^{BC}, \quad (2)$$

což odpovídá nezávislosti páru C, B na A .

Jednodušší struktury závislosti dostáváme vynecháváním efektů; budeme předpokládat, že vynecháme-li některý efekt druhého řádu, vynecháme i efekt třetího řádu, t.j. λ_{ijk}^{ABC} . Takto získané modely nazýváme hierarchické logaritmicko-lineární modely a můžeme je zapisovat zkráceným zápisem. Zapisujeme vždy jen horní indexy nejvyšších obsažených efektů (efekt druhého řádu je vyšší než efekt prvního řádu atd.). Tedy pravděpodobnostní model (1) má zápis (ABC) , model (2) má zápis (A, BC) a model úplné nezávislosti $\log(p_{ijk}^{ABC}) = \theta + \lambda_i^A + \lambda_j^B + \lambda_k^C$

má zápis (A, B, C) . Tento způsob zápisu je dostatečně přehledný a mnohdy snadno interpretovatelný: (A, B, C) znamená, že A, B a C jsou navzájem nezávislé atd. Model ABC se nazývá saturovaný model, nebo úplný model třetího řádu, model (AB, AC, BC) , který obsahuje všechny efekty prvního a druhého řádu, se nazývá úplný model druhého řádu, podobně (A, B, C) je úplný model prvního řádu.

Důležité je si uvědomit, že o modelech můžeme mluvit pouze na základě jejich velmi stručného zápisu, který je tvořen vlastně výrazy slovy určitého velmi jednoduchého formálního jazyka. S těmito výrazy lze provádět určité operace, které mohou být popsány syntaktickými pravidly a které mohou mít určitý sémantický význam v prostoru odpovídajících pravděpodobností (pravděpodobnostních modelů). Jednoduchý formální zápis modelů je zároveň velice důležitý pro jejich interpretaci a komunikování nestatistikům. Zároveň je vhodný i po stránce počítačové.

Podívejme se nyní na seznam logaritmicko-lineárních hierarchických modelů, které připadají rozumně v úvahu u trojrozměrné tabulky (pomíjíme modely nižší dimenze a modely vzniklé vynecháním efektů prvního řádu):

model	vyjádření v pravděpodobnostech (horní indexy vynecháváme)	stupně volnosti
(A, B, C)	$p_{ijk} = p_{i..} \cdot p_{.j.} \cdot p_{..k}$	4
(AB, C)	$p_{ijk} = p_{ij.} \cdot p_{..k}$	3
(AC, B)	$p_{ijk} = p_{i.k} \cdot p_{.j.}$	3
(A, BC)	$p_{ijk} = p_{i..} \cdot p_{.jk}$	3
(AB, AC)	$p_{ijk} = p_{ij.} \cdot p_{i.k} / p_{i..}$	2
(AB, BC)	$p_{ijk} = p_{ij.} \cdot p_{.jk} / p_{.j.}$	2
(AC, BC)	$p_{ijk} = p_{ij.} \cdot p_{.jk} / p_{..k}$	2
(AB, AC, BC)	$(p_{111} p_{001}) / (p_{101} p_{011}) = (p_{110} p_{000}) / (p_{100} p_{010})$	1

Všimněme si, že prvních 7 modelů lze snadno vyjádřit v řeči nezávislosti a podmíněné nezávislosti. Navíc, maximálně věrohodné odhady pravděpodobností p_{ijk} při platnosti každého z těchto modelů dostaneme snadno součinem (či podílem) přímých odhadů marginálních pravděpodobností. Tyto modely se nazývají přímé nebo multiplikační. Poslední model (AB,AC,BC) má jiný charakter: jednak jeho interpretace je jiná a jednak odhady metodou maximální věrohodnosti musíme získávat iteračním postupem (např. "iterative proportional fitting, viz BISHOP(ová), FIENBERG, HOLLAND (1975)).

2. Logaritmicko-lineární modely lze použít i pro tabulky vyšší dimenze, kdy vyjadřování v pravděpodobnostech je velmi složité a nepřehledné. Ve vyšších dimenzích je zřetelné vidět jednoduchost formálního zápisu modelů. Logaritmicko-lineární model odpovídající (A,BCDE) si jistě již každý umí sestavit. Uvažujme nyní obecně tabulky dimenze n a nechť veličiny jsou očíslovány $1, \dots, n$. Pak každý zápis (A_1, \dots, A_k) , kde $A_i \subseteq \{1, \dots, n\}$ a pro každé $i \neq j$ není ani $A_i \subseteq A_j$, ani $A_i \supseteq A_j$ definuje jednoznačně logaritmicko-lineární hierarchický model. (A_1, \dots, A_k) se pak nazývá generující sentencí (množinou) modelu. Obvykle se ovšem prakticky používají místo čísel písmena, neboť konkrétně zatím nikdo pravděpodobně nepracuje s tabulkou dimenze větší než $n = 22$. Navíc místo pedantického zápisu $\{(A,B), (B,C,D,E)\}$ atp. se používá zjednodušený zápis (AB,BCDE), který jsme také používali výše.

Ve vyšších dimenzích již drtivě převažují hierarchické logaritmicko-lineární modely, které nejsou multiplikační. Viz následující tabulku:

dimenze: n	2	3	4	5	výraz
hierarchické	5	19	167	7580	$2^{2^n} - 1$
z toho					$\sum_{i=0}^n \binom{n}{i} 2^{\binom{i}{2}}$
ZPA, grafové	5	18	113	1450	
multiplikační	5	18	110	1233	není znám

S třídou ZPA logaritmicko-lineárních hierarchických modelů se seznámíme později.

Jak rozlišíme multiplikační a nemultiplikační modely? Jednoduchý algoritmus využívající generující sentence lze nalézt v knize BISHOP, FIENBERG a HOLLAND (1975). Zde ho uvádíme v nepatrně pozměněné formulaci:

§ Měj (A_1, \dots, A_k) . Je-li $k = 2$ zastav.

(1) Vyhoď písmeno, které se vyskytuje ve všech A_i .

(2) Vyhoď písmeno, které se vyskytuje v jediném A_i . Nebylo-li možné použít ani (1) ani (2), zastav. Tím vznikne (A'_1, \dots, A'_k) (některé A'_i může být prázdné).

(3) Vyhoď každé A'_i , které je vlastní částí jiného. Je-li $A'_i = A'_j$ $i < j$, vyhoď A'_j (pro všechna i, j) Tím vznikne (A''_1, \dots, A''_k) , $k \leq k$.

Polož $k = k - 1$ a $(A_1, \dots, A_k) = (A''_1, \dots, A''_k)$ a jdi na §.

(A_1, \dots, A_k) vstupující do prvního cyklu je multiplikační právě když je výpočet zastaven v některém cyklu pro podmínku $k = 2$.

Uveďme si příklady pro $n = 5$:

(ABC, ACDE) je triviálně multiplikační.

(ABE, BCE, ADE, CDE) $\xrightarrow{(4)}$ (AB, BC, AD, CD) a již nelze aplikovat (1) a (2); model není multiplikační.

(ABE, ADE, BC) $\xrightarrow{(1)}$ (ABE, ADE, B) $\xrightarrow{(3)}$ (ABE, ADE) - model je multiplikační.

Pro $n = 7$: (ABD, BCE, ACF, EG, ABC) $\xrightarrow{(2)}$ (ABD, BCE, AC, EG, ABC) $\xrightarrow{(3)}$ (ABD, BCE, EG, ABC) $\xrightarrow{(2)}$ (ABD, BCE, E, ABC) $\xrightarrow{(3)}$ (ABD, BCE, ABC) $\xrightarrow{(4)}$ (AD, CE, AC) $\xrightarrow{(2)}$ (A, CE, AC) $\xrightarrow{(3)}$ (CE, AC) - model je multiplikační.

Zde je opět na místě zdůraznit, že jde o čistě syntaktický postup, používající pouze formální

vyjádření modelů.

3. Máme-li dva logaritmicko-lineární hierarchické modely, můžeme uvažovat jejich konjunkci, t.j. model spočívající v platnosti omezení daných oběma modely současně. Píšeme formálně pro tento případ např. $(ABC, ACDE) \& (ABE, ADE, BC)$. Platí, že výsledný model je opět hierarchický logaritmicko-lineární model a že existuje konstruktivní postup, jak nalézt jeho generující sentenci ze sentencí modelů vstupujících do konjunkce:

Budiž (A_1, \dots, A_k) , (B_1, \dots, B_ℓ) dvě generující sentence. Definujme jejich spojení \cap jako $(A_1, \dots, A_k) \cap (B_1, \dots, B_\ell) = (A_1 \cap B_1, A_1 \cap B_2, \dots, A_k \cap B_\ell)$ (přitom každé $A_i \cap B_j$, které bude vlastní částí jiného průniku, vynecháme a v případě rovnosti dvou průníků ponecháme ve výrazu vpravo jen jeden z nich).

Platí, že model, který je konjunkcí dvou hierarchických logaritmicko-lineárních modelů definovaných generujícími sentencemi (A_1, \dots, A_k) a (B_1, \dots, B_ℓ) je definován generující sentencí $(A_1, \dots, A_k) \cap (B_1, \dots, B_\ell)$.

Tedy například $(ABC, ACDE) \& (ABE, ADE, BC)$ vyjádříme jako $(ABC, ACDE) \cap (ABE, ADE, BC) = (AB, A, BC, AE, ADE, C) = (AB, BC, ADE)$.

4. Z hlediska interpretačního rozumná třída modelů by měla být uzavřena vzhledem ke konjunkci. Naneštěstí třída multiplikativních modelů uzavřená na konjunkci není. Viz následující příklad:

$$(ABC, BCD) \& (ABD, ACD) = (AB, AC, BD, CD) \quad (\text{ENKE, 1980})$$

Je tedy vhodné hledat nejmenší třídu modelů, uzavřenou na konjunkci a obsahující třídu multiplikativních modelů (samozřejmě jako podtřídu hierarchických logaritmicko-lineárních modelů). Cesta k hledání takové třídy vede přes standardní reprezentaci hierarchických logaritmicko-lineárních modelů.

Uvažujme modely dané pevné dimenze n . Generující sentence sestávající se z množin kardinality právě $n-1$ nazveme elementární. Příklad pro $n = 5$: $(ABCD, ACDE, ABCE)$. Počet množin v generující sentence nazveme velikostí sentence.

Platí, že každou generující sentence lze jednoznačně vyjádřit konjunkcí $\varphi_1 \& \dots \& \varphi_r$ kde $\varphi_1, \dots, \varphi_r$ jsou elementární sentence. Tuto konjunkci nazýváme standardní reprezentací.

Maximální velikostí sentence v $\varphi_1 \& \dots \& \varphi_r$ můžeme měřit složitost původní sentence jejmž standardním vyjádřením daná konjunkce je. Modely, jejichž standardní vyjádření obsahuje sentence velikosti maximálně 2, nazýváme ZPA modely. Z praktických důvodů se většinou omezujeme na případ, kdy standardní vyjádření obsahuje právě sentence velikosti dvě (jinak by chyběl některý efekt prvního řádu).

Příklady standardních vyjádření: $n = 4$

$(A, B, C, D) = (ABC, ACD) \& (ABC, BCD) \& (ABC, ABD) \& (ABD, ACD) \& (ABD, BCD) \& (ACD, BCD)$ je ZPA i multiplikativní.

$(AB, AC, AD, BC) = (ABC, ACD) \& (ABC, ABD) \& (ABD, ACD, BCD)$ není ZPA ani multiplikativní.

$(AB, AC, BD, CD) = (ABC, BCD) \& (ABD, ACD)$ je ZPA a není multiplikativní.

$(AC, AD, BD) = (ABC, ABD) \& (ABD, ACD) \& (ACD, BCD)$ je ZPA i multiplikativní.

Co znamená ZPA? "Zero partial association". Model ABC, ACD odpovídá nulové parciální asociaci mezi B a C , t.j. podmíněné nezávislosti B a C podmíněno AD (jde o parciální asociaci v Birchově smyslu).

Platí následující skutečnosti:

- 1) Třída ZPA modelů je uzavřena vzhledem ke konjunkci,
- 2) třída ZPA modelů obsahuje třídu multiplikatívních modelů a
- 3) třída ZPA modelů je nejmenší třída hierarchických logaritmicko-lineárních modelů obsahující třídu multiplikatívních modelů.

Vidíme, že třída ZPA modelů má vlastnosti naší hledané třídy. ZPA modely, které nejsou multiplikatívni, neumožňují ovšem přímé odhady pravděpodobností a mají obtížnější interpretaci. Rozdíl v počtu ZPA modelů a multiplikatívních modelů je vidět z tabulky (3). Třída ZPA modelů odpovídá třídě grafových modelů definovaných v práci DARROCH, LAURITZEN a SPEED, (1980). V této práci je také navržen grafický způsob reprezentace těchto modelů, který může být vhodný pro komunikaci modelů zadavatelům a zákazníkům.

5. Máme-li klasickou úlohu testovat danou hypotézu popsanou generující sentencí $(\varphi = (A_1, \dots, A_k))$, víme jak postupovat (za určitých podmínek např. na frekvence v tabulce apod.). Můžeme například použít χ^2 test poměrem věrohodnosti. Ukažme si jej opět pro speciální případ dimenze tabulky, abychom se vyhnuli obtížným formálním zápisům. Nechť tedy $n = 4$. Jsou-li f_{ijkl} pozorované frekvence v tabulce, označíme $m = \sum_{i,j,k,l} f_{ijkl}$ a očekávané frekvence můžeme vyjádřit jako $F_{ijkl}(\varphi) = m p_{ijkl}(\varphi)$, kde $p_{ijkl}(\varphi)$ jsou pravděpodobnosti odhadnuté metodou maximální věrohodnosti za předpokladu platnosti hypotézy popsané pomocí φ . K testování pak použijeme statistiku

$$\chi^2(\varphi) = 2 \sum_{ijkl} f_{ijkl} \log (f_{ijkl} / F_{ijkl}(\varphi))$$

s příslušným počtem stupňů volnosti ($7 - \text{počet odhadovaných parametrů}$).

Někdy je vhodné zkoumat vztahy mezi hypotézami. Řekneme, že $\varphi \models \psi$ (φ logicky vyplývá z ψ) plyne-li z pravdivosti modelu definovaného φ pravdivost modelu definovaného ψ (je-li φ splněno, je splněno i ψ). Tuto relaci opět snadno rozpoznáme na syntaktické úrovni:

platí totiž, že $(A_1, \dots, A_k) \models (B_1, \dots, B_l)$ právě když $(A_1, \dots, A_k) \leq (B_1, \dots, B_l)$,

kde relace \leq je definována takto: $(A_1, \dots, A_k) \leq (B_1, \dots, B_l)$, jestliže pro každé A_i existuje B_j tak, že $A_i \subseteq B_j$.

Chceme-li nyní testovat "významnost rozdílu" mezi φ a ψ , $\varphi \not\models \psi$, použijeme statistiky

$$\chi^2(\varphi/\psi) = \chi^2(\varphi) - \chi^2(\psi)$$

stupně volnosti dostaneme rovněž odečtením. Je dobré si všimnout, že φ může být považována za jednodušší hypotézu.

6. Velmi často se ocitáme v situaci popsané na začátku tohoto článku: nemáme žádnou specifikovanou hypotézu, nebo několik málo specifikovaných hypotéz, ale musíme naopak nějaké hypotézy "podporované daty" nalézt. To pak znamená zkoušet celou řadu hypotéz, které by mohly připadat v úvahu a pozorovat jejich shodu s daty. Úmyslně zde je použito slovo "zkoušet" místo testovat, aby bylo jasné odlišení této situace od klasické situace testování. V našem případě, i když používáme testových statistik, dosazených hladin významnosti atd., chápeme tyto spíše jako míry shody a neshody hypotéz s daty, než jako testy v klasickém smyslu (neuvažujeme zde metody simultánní inference). Metody vyhledávání hypotéz by měly být z teoretického hlediska vlastně hodnoceny jinak, než klasické metody testování. Obrana proti chybě prvního druhu (resp. globální chybě prvního druhu) zde možná není vůbec tou nejdůležitější věcí. Spíše zde záleží na něčem, co by mohlo být nazváno silou - například na tom, s jakou pravděpodobností metoda odhalí danou (známou) strukturu závislosti. Zde je tedy mnoho otevřených otázek a my zatím používáme řekněme empiricko-intuitivní přístup.

Vraťme se nyní k frekvenčním tabulkám. Víme, že hierarchických logaritmicko-lineárních hypotéz, které by mohly teoreticky připadat v úvahu je velmi velké množství. Musíme se tedy omezit na nějakou rozumnou podtřídu. Z řady výše uvedených důvodů je prvním kandidátem na takovou třídu právě třída ZPA modelů:

(1) je uzavřená vůči konjunkci, (2) obsahuje třídu multiplikativních modelů a je to nejmenší taková třída a (3) všechny ZPA modely jsou popsateľné konjunkcemi elementárních sentencí, které popisují jednoduché ZPA modely vyjadřující nulovou parciální asociaci párů veličin.

Na druhé straně je vidět, že i ZPA hypotéz může být poměrně mnoho. Je proto nutné využít vztahy mezi hypotézami k tomu, abychom nemuseli zkoumat celou třídu ZPA hypotéz. Zvolíme si pevnou hladinu významnosti; hypotézy s dosaženou hladinou významnosti nižší než zvolená zamítáme, ostatní "akceptujeme".

Zdá se vhodné využít toto pravidlo:

Je-li $\varphi \models \psi$ (a tedy $\varphi \leq \psi$) pak při zamítnutí ψ v daných datech zamítneme i φ (aniž bychom ho testovali).

Mohlo by se zdát, že je vhodné použít i opačného vztahu: při "akceptování" φ "akceptovat" i ψ . Tedy například, kdybychom akceptovali některé elementární ZPA modely, akceptovali bychom i jejich konjunkci. Víme však, že role zamítnutí a nezamítnutí není v tomto smyslu symetrická a že zamítnutí můžeme považovat za "jistější".

(Předběhneme nyní k dokončení našeho příkladu. Nezamítnutí hypotéz označených 2,3,5,6,0 při dané hladině významnosti by tedy znamenalo akceptování hypotézy $23560 = (AB, BC, ADE)$, která má však hodnotu $\chi^2 = 41.56$ při 20 stupních volnosti a tedy dosaženou hladinu významnosti 0.0032!)

Samozřejmě, že při použití testu χ^2 poměrem věrohodnosti (i Pearsonova χ^2) se nám může stát, že sice ψ zamítneme, ale φ při testování nikoliv. Při použití výše zmíněného pravidla dojde tedy k chybnému rozhodnutí (jde ovšem o něco jiného než chyba I a II. druhu) vzhledem k daným datům. Praxe však ukazuje, že tyto případy nejsou příliš časté a takto zamítnuté hypotézy bez testování nemívají dosaženou hladinu významnosti příliš vyšší než je zvolená mez a nepatřily by k "nejlepším" hypotézám podle kriterií naznačených v bodě 7. Celá věc by si však zasloužila ještě hlubší zkoumání. Jde o zjištění jak časté či pravděpodobné jsou chyby zmíněné výše a nebo o konstrukci testu, který by neměl tuto nepříjemnou (i z teoretického hlediska) vlastnost χ^2 testů.

Celý postup vyhledávání "akceptovatelných" hypotéz vypadá s použitím námi navrženého pravidla takto:

ZPA hypotézy generujeme a testujeme v pořadí opačném k uspořádání \leq . To znamená, že v prvním kroce testujeme elementární ZPA hypotézy o parciální asociaci. V dalším kroce testujeme hypotézy odpovídající dvoučlenným konjunkcím elementárních sentencí, v třetím kroce hypotézy odpovídající trojčlenným konjunkcím atd. Tak máme zajištěno, že pro dané $\varphi (= \varphi_1 \wedge \dots \wedge \varphi_k)$ budou všechny hypotézy ψ takové, že $\psi \models \varphi$ (a tedy takové, které v případě zamítnutí už nemusíme generovat a testovat) uvažovány později než φ a můžeme tedy informaci o zamítnutí φ využít. Výsledkem je množina "akceptovaných" hypotéz, t.j. takových hypotéz, které byly testovány a nezamítnuty (hypotézy, které jsou zamítnuty na základě našeho pravidla nejsou testovány).

Takto získaná množina kandidátů může být ještě dosti velká. Je proto vhodné z ní vybírat "nesilnější", "nejzajímavější", "nejlepší" apod. hypotézy. Výše uvedená slova je nutné nějakým způsobem specifikovat. Jednou z čistě logických možností je hledat minimální prvky množiny akceptovaných hypotéz vzhledem k uspořádání \leq . Tím dostáváme vlastně i nejjednodušší akceptované hypotézy pokud měříme složitost počtem obsažených logaritmicko-lineárních parametrů (efektů). To je ve shodě se strategií propagovanou BENEDETTI ovou a BROWNEM.

7. Dokončíme nyní náš příklad:

Testováno:	zamítnuto (0.1)	parciální a marginální asociace dle Browna:
1. ABCD, ABCE	+	+ +
2. ABCD, ABDE		+ +
3. ABCD, ACDE		+ +
4. ABCD, BCDE	+	+ +
5. ABCE, ABDE		
6. ABCE, ACDE		
7. ABCE, BCDE	+	+ +
8. ABDE, ACDE	+	+(nejméně silnější vazba)
9. ABDE, BCDE	+	+
10. ABDE, BCDE		
23 ABCD, ADE	+ multiplikativní	
25 ABC, ABDE	multiplikativní	
26 ABC, ACD, ABE, ADE	ne	
20 BCD, ABDE	multiplikativní	
35 ABC, ABD, ACE, ADE	ne	
36 ABC, ACDE	multiplikativní	
30 ABD, BCD, ADE, CDE	+ ne	
56 ABCE, ADE	multiplikativní	
60 ABE, BCE, ADE, CDE	ne	
256 ABC, ABE, ADE	multiplikativní	
250 BC, ABDE	multiplikativní	
260 BC, CD, ABE, ADE	ne	
356 ABC, ACE, ADE	multiplikativní	
560 ABE, BCE, ADE	multiplikativní	
2560 ABE, ADE, BC	multiplikativní	

23 znamená konjunkci elementárních sentencí 2 a 3. Testovány jsou pouze dvoučlenné konjunkce elementárních sentencí nezamítnutých v prvním kroce.

Je tedy testováno pouze 10 hypotéz místo $\binom{10}{2} = 45$ možných.

V třetím kroce jsou testovány pouze ty konjunkce, které nejsou zamítnuty již na základě zamítnutí konjunkcí v předchozích krocích. Tedy netestujeme např. 125, nebo 350.

Testované 5 hypotéz místo 105 možných.

Ve čtvrtém kroce máme již pouze jedinou konjunkci, které není zamítnuta na základě předchozích výsledků.

Množina "akceptovatelných" hypotéz je tedy tvořena všemi hypotézami (modely), sentencemi které byly testovány a nezamítnuty. Zkráceně jde tedy o modely zapsané výše kódy 2, 3, 5, 6, 0, 25, 26, 35, 30, 60, 256, 250, 260, 356, 560, 2560.

Které z uvedených hypotéz jsou ty "nejlepší" a měly by být prezentovány jako možné hypotézy pro další zkoumání? Jeden z možných přístupů je hledat minimální prvky množiny "akceptovaných" sentencí vzhledem k uspořádání \leq . Platí totiž, že na teoretické úrovni jsou všechny ostatní sentence v množině "akceptovaných" sentencí jejich logickými důsledky. Zde jsou dva takové prvky a to 356 a 2560, naštěstí obě multiplikativní.

Pro vyhledávání těchto prvků je vhodné si všimnout vztahu mezi relací \leq mezi sentencemi a inkluzí jejich kódů. $\varphi \geq \psi$ je ekvivalentní $\text{kód}(\varphi) \subseteq \text{kód}(\psi)$. Např.: $(\text{ABE, BCE, ADE}) \geq (\text{ABE, ADE, BC})$ a $560 \subseteq 2560$. Hledání minimálních prvků v \leq se tedy převádí na hledání maximálních kódů vzhledem k inkluzi.

Někdy může být užitečná i celá množina "akceptovaných" hypotéz. Navržené kritérium pro výběr "nejzajímavějších" hypotéz není jediné možné. Při výběru mohou hrát roli i apriorní znalosti zadavatele o tom, co s čím může souviset, nebo jiná kritéria výběru "nejlepších" hypotéz, například podle nevyšší dosažené hladiny významnosti chápané jako kritérium shody modelu s dat, či podle různých modifikací χ^2 jako míry shody, např. AIC (Akaike information criterion), viz SAKAMOTO a AKAIKE, (1978); $AIC = \chi^2 - 2 \text{ d.f.}$. V našem příkladě jsou dvě hypotézy s nižším AIC (a tedy lepším) než hypotézy vybrané a to 256 a 56.

Při větších příkladech to znamená skladovat množinu "akceptovaných" hypotéz spolu s některými numerickými údaji a pomocí dalších programů z ní pak vybírat podle různých návrhů a kritérií výše zmíněných i podle dalších kritérií, která mohou být z různých důvodů uplatněna.

Příklad byl spočítán pomocí programu BMDP3F ze systému BMDP (viz DIXON and BROWN, 1977). Tento program umožňuje snadno testovat zadaný model. Pro každý testovaný model bylo nutné napsat příkaz MODEL+ ABC, ABE, ADE. atp., což je při větších příkladech, kdy by bylo testováno větší množství hypotéz již dosti pracné. Napsání programu, který by prováděl celý výše popsáný postup automaticky máme v plánu.

8. Kromě přímo citovaných prací se text opírá o dosud nepublikované preprinty DARROCH a SPEED (1979) a HAVRÁNEK (1981a, b). Seznam literatury obsahuje další související práce.

LITERATURA:

- AITKIN M. (1980). A note on the selection of log-linear models, *Biometrics* 36, 173-178.
- BENEDETTI J.K., BROWN M.B. (1978). Strategies for the selection of log-linear models. *Biometrics* 34, 680-686.
- BISHOP Y.M.M., FIENBERG S.E., HOLLAND P.W. (1975). *Discrete multivariate analysis: Theory and practice*, MIT Press, Cambridge, Mass.
- DARROCH J.N., LAURITZEN S.L., SPEED T.P. (1980). Markov fields and log-linear interaction models for contingency tables. *The Annals of Statistics* 8, 522-539.
- DARROCH J.N., SPEED T.P. (1979). *Multiplicative and additive models and interactions*. Dept. of theoretical statistics, res. rep. 49, University of Aarhus.
- DIXON W.J., BROWN M.B. (1977). *Biomedical computer programs, BMDP*. University of California Press, Los Angeles.
- ENKE H. (1980) To some reasonable test procedures in multiple contingency tables to investigate certain epidemiological or medicin-sociological relationships. *Biometrical Journal* 22, 779-793.
- GOODMAN L.A. (1970) The multivariate analysis of qualitative data: interactions among classifications. *JASA* 65, 226-256.
- GOODMAN L.A. (1971) Partitioning of chi-square, analysis of contingency tables, and estimation of expected frequencies in multidimensional contingency tables. *JASA* 66, 339-344.
- HAVRÁNEK, T. (1981a) On some possibilities of logical analysis of the dependency structure in multidimensional contingency tables, EMS Wroclaw.
- HAVRÁNEK, T. (1981b) A procedure for model search in multidimensional contingency tables, *Statistical semetster of the Banach Center, Warszawa*.
- WERMUTH, N. (1976). Model search among multiplicative models, *Biometrics* 32, 253-263.
- WERMUTH, N. (1980). Linear recursive equations, covariance selection and path analysis, *JASA* 75, 963-972.