

Miroslav Hartmann, Josef Bukač

Výpočetní středisko lékařské fakulty UK  
v Hradci Králové, Šimkova 870

## 1. ÚVOD

Tento postup byl vyvinut pro případy, kdy  $\chi^2$ -test dobré shody, používaný při testování nezávislosti v kontingenčních tabulkách, nevyhovuje pro velmi malé pozorované četnosti v některých políčkách. Metodu přesného výpočtu hladiny významnosti vyvinuli Freeman a Halton [1]. V této práci z roku 1951 se ještě nepředpokládá použití počítače a není ani zaměřena na jednoznačné stanovení algoritmu výpočtu. První program s přesným popisem postupu výpočtu publikoval March [2]. Při podrobném rozboru se ukazuje, že postup nevyužívá speciálních vztahů v kontingenčních tabulkách, které lze odvodit elementárními úvahami. Program je velmi jednoduchý a krátký, ale ne dostatečně účinný pro praktické použití. Některých speciálních vztahů pro tabulky typu 2xc využívají Stucky a Vollmar [3]. Jímí sestrojený program pro tento typ tabulek je podstatně efektivnější, než Marchův.

Naše práce je zaměřena na obecné tabulky typu RxC. Vycházíme z Marchovy myšlenky, postup jsme podstatně upravili a tím urychlili několikanásobně vlastní výpočet.

## 2. STANOVENÍ PROBLÉMU

Kontingenční tabulkou typu RxC rozumíme matici celých nezáporných čísel

$$X = \begin{pmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,c} \\ \vdots & \vdots & \ddots & \vdots \\ x_{R,1} & x_{R,2} & \dots & x_{R,c} \end{pmatrix} \quad (1)$$

Marginální součet i-tého řádku tabulky je definován vztahem

$$r_i = \sum_{j=1}^c x_{i,j} \quad (2)$$

obdobně marginální součet j-tého sloupce je definován vztahem

$$c_j = \sum_{i=1}^R x_{i,j} \quad (3)$$

Celkový počet pozorování v tabulce je dán výrazem

$$N = \sum_{i=1}^R \sum_{j=1}^c x_{i,j} = \sum_{i=1}^R r_i = \sum_{j=1}^c c_j \quad (4)$$

Pravděpodobnost výskytu tabulky  $X$  pro předem dané marginální součty  $r_i$  a  $c_j$  je při platnosti hypotézy nezávislosti dána výrazem

$$P(X) = \frac{\prod_{i=1}^R (r_i!) \prod_{j=1}^c (c_j!)}{N! \prod_{i=1}^R \prod_{j=1}^c (x_{i,j}!)} \quad (5)$$

Hladinu významnosti  $P_0(X_0)$  testu nezávislosti v dané tabulce definujeme součtem

$$P_0(X_0) = \sum_{P(X) \leq P(X_0)} P(X) \quad (6)$$

Tuto definici vyjádříme slovně takto:

- zadaná tabulka  $X_0$  určuje konkrétní hodnoty marginálních součtů  $r_i$  a  $c_j$  a hodnotu  $N$ .
- stanovíme pravděpodobnost  $P(X_0)$  zadané tabulky.

c. vytvoříme všechny možné tabulky  $X$ , které vyhovují daným marginálním součtům a pro každou z nich vypočteme její pravděpodobnost  $P(X)$ .

d. hladina významnosti je pak dána jako součet všech pravděpodobností  $P(X)$ , pro které platí  $P(X) \leq P(X_0)$ .

Vzhledem k tomu, že hodnoty  $r_i, c_j, N$  jsou ve všech vytvářených tabulkách totožné, je vhodné přepsat vzorec (5) do tvaru

$$P(X) = a(X_0) / R(X), \quad (7)$$

$$a(X_0) = \prod_{i=1}^R (r_i!) \prod_{j=1}^C (c_j!) / (N!) \quad (8)$$

$$R(X) = \prod_{i=1}^R \prod_{j=1}^C (x_{i,j}!) \quad (9)$$

### 3. GENEROVÁNÍ TABULEK

#### 3.1 Marchova metoda

Jelikož jednotlivé hodnoty  $x_{i,j}$  musí vyhovovat rovnicím (2) a (3), je tabulka typu  $R \times C$  dána  $(R-1) \times (C-1)$  prvky, přičemž zbývající prvky jsou z těchto rovnic dopočítány. Přípustnou tabulkou nazveme takovou tabulku, která splňuje rovnice (2), (3) a jejíž všechny prvky jsou nezáporné. První tabulku vytváří March tak, že pro  $(R-1) \times (C-1)$  prvků vpravo dole, tj. s vynecháním prvního sloupce a prvního řádku, dosadí minimum z příslušných sloupcových a řádkových marginálních součtů. Po vypočtení prvků v prvním sloupci a řádku podle rovnic (2) a (3) zjistí, zda tabulka je přípustná. Generování další tabulky vychází vždy z vygenerované tabulky předchozí. V této tabulce hledá postupně v prvcích  $x_{2,2}, \dots, x_{2,C}, x_{3,2}, \dots, x_{3,C}, \dots, x_{R,C}$  první kladný prvek. Od tohoto prvního odečte jedničku a do všech předcházejících, které byly nulové, dosadí minimum z příslušných marginálních součtů. Opět vypočítá prvky v prvním sloupci a řádku a zjistí, zda vzniklá tabulka je přípustná. Následuje opakovaný návrat do vyhledávání kladného prvku. Celý postup je ukončen, jestliže není nalezen žádný další prvek.

V podstatě tento postup představuje  $(R-1) \times (C-1)$  násobný cyklus s pevnými mezemi a ukazuje se, že obecně je při něm generován velký počet nepřípustných tabulek.

#### 3.2 Nová metoda

Jde o způsob, podobný metodě severozápadního rohu, používané pro nalezení základního řešení lineárního dopravního problému. Z hlediska dopravního problému lze hodnoty marginálních součtů  $r_i$ , resp.  $c_j$  zadané tabulky  $X_0$  považovat za kapacity řádků, resp. sloupců tabulky. Toho využijeme následujícím způsobem:

Před započítím generování naplníme první řádek tabulky hodnotami  $c_j$  z tabulky  $X_0$ , tj. na prvním řádku jsou umístěny kapacity sloupců ( $x_{1,j} = c_j$ ). Obdobně do prvního sloupce, počínaje druhým řádkem, umístíme hodnoty  $r_i$  z tabulky  $X_0$ , tj. kapacity řádků ( $x_{i,1} = r_i$  pro  $i=2,3,\dots,R$ ). Ostatní prvky tabulky nechť jsou nulové. Takto vzniklá tabulka splňuje rovnice (2) pro všechny řádky s výjimkou prvního a rovnice (3) pro všechny sloupce s výjimkou prvního.

Při generování jakéhokoliv prvku  $x_{i,j}$  ( $i > 1, j > 1$ ) v tabulce dbáme vždy této zásady: Jestliže prvek zvětšíme, resp. zmenšíme o určitou hodnotu, pak o tutéž hodnotu zmenšíme, resp. zvětšíme i prvky  $x_{i,1}$  a  $x_{1,j}$ . Tím je tedy neustále zachována platnost rovnic (2) a (3) kromě prvního řádku a prvního sloupce.

První tabulku generujeme tak, že do  $x_{R,C}$  dosadíme minimum z  $x_{R,1}$  a  $x_{1,C}$ . Po dosažení okamžité hodnoty  $x_{R,1}$  a  $x_{1,C}$  upravíme. Obdobně do prvku  $x_{R,j}$  ( $j=C-1, C-2, \dots, 2$ ) dosadíme minimum z hodnot  $x_{R,1}$  a  $x_{1,j}$ . Po tomto procesu již nebudeme považovat hodnotu  $x_{R,1}$  za volnou kapacitu  $R$ -tého řádku, ale za hodnotu, která byla

v tomto prvku vygenerována. O tuto hodnotu  $x_{R,1}$  snížíme prvek  $x_{1,1}$  /tj. kapacitu prvního sloupce/. Stejně jako v  $R$ -tém řádku postupujeme i v řádcích vyšších /tj.  $i=R-1, R-2, \dots, 2$ /. Po vygenerování celého druhého řádku budeme také hodnoty, které zůstaly v prvním řádku, považovat za vygenerované. Tato první vygenerovaná tabulka je vždy přípustná /analogie metody severozápadního rohu u dopravního problému/ a navíc je totožná s první přípustnou tabulkou, generovanou Marchovou metodou.

Při generování dalších tabulek vycházíme podobně jako March vždy z předcházející vygenerované tabulky. V prvcích  $x_{2,2}, \dots, x_{2,c}, x_{3,2}, \dots, x_{3,c}, \dots, x_{R,2}, \dots, x_{R,c}$  hledáme první kladný prvek. Navíc před započítím prohledávání  $i$ -tého řádku přičteme hodnotu  $x_{1,1}$  k hodnotě  $x_{1,j}$ . Od prvního kladného prvku, řekněme  $x_{1,j}$ , odečteme jedničku a navíc tuto jedničku přičteme k prvkům  $x_{1,1}$  a  $x_{1,j}$ . V pořadí opačném k pořadí prohledávání znovu generujeme již popsáním způsobem /jako u první tabulky/ hodnoty prvků, předcházejících prvku  $x_{1,j}$ .

Ze způsobu generování plyne, že přípustnost vygenerované tabulky je závislá pouze na hodnotě prvku  $x_{1,1}$ . Tabulka je přípustná právě tehdy, když  $x_{1,1} \geq 0$ .

Vzhledem k tomu, že hodnota  $x_{1,1}$  během generování tabulky představuje volnou kapacitu prvního sloupce, potom jestliže po vygenerování  $i$ -tého řádku ( $i \geq 2$ ) je hodnota  $x_{1,1}$  větší než hodnota  $x_{1,1}$  a tedy po odečtení by hodnota  $x_{1,1}$  byla záporná, pak ať je ve vyšších řádcích tímto postupem generováno cokoli, výsledná tabulka nebude nikdy přípustná. V takovém případě není tedy třeba zbytek tabulky generovat a hodnotu  $x_{1,1}$  od hodnoty  $x_{1,1}$  neodečteme. Můžeme vyhledat první kladný prvek, počínaje prvkem  $x_{1,2}$  a od něj odečíst jedničku. Jestliže však odečteme jedničku od prvku  $x_{1,2}$  /je-li to možné/, zvýšíme tím hodnotu  $x_{1,1}$  a po odečtení této hodnoty od  $x_{1,1}$  /kapacity 1. sloupce/ získáme ještě menší hodnotu  $x_{1,1}$  a tudíž ani tato tabulka nebude přípustná. Analogicky můžeme uvážit:

Byla-li po vygenerování  $i$ -tého řádku přečerpána kapacita 1. sloupce a byly-li vyčerpány kapacity 2. až  $j$ -tého sloupce, pak jakékoli snížení hodnot v 2. až  $(j+1)$ . prvku  $i$ -tého řádku nevede k přípustné tabulce. V důsledku toho můžeme před vyhledáváním prvního kladného prvku vrátit hodnoty prvků  $x_{1,2}$  až  $x_{1,j+1}$  do jim příslušných kapacit a tyto prvky vynulovat. Po odečtení jedničky v prvním kladném prvku a úpravách patřičných kapacit opět začneme generovat předcházející prvky dříve popsáním způsobem.

Efektivnost těchto úvah vyplývá z následujícího tvrzení: Jestliže po vygenerování  $i$ -tého řádku nebyla přečerpána kapacita 1. sloupce, pak jistě existuje alespoň jedna tabulka, která je přípustná a prvky v řádcích  $i$ -tém až  $R$ -tém má totožné s dosud vygenerovanými. Toto tvrzení plyne z analogie s dopravním problémem.

Vytváření všech tabulek je ukončeno tehdy, když všechny prvky  $x_{i,j}$  ( $i > 1, j > 1$ ) jsou nulové a nelze tedy nikde provést odečtení jedničky.

### 3.3 Postupy užitečné při programování nové metody

#### 3.3.1 Odlísné generování u prvku $x_{2,2}$

Mějme vygenerovanou přípustnou tabulku a nechť  $x_{2,2} > 0$ . Při generování další tabulky bychom tedy odečetli jedničku od prvku  $x_{2,2}$ . Musíme pak přičíst jedničku k prvkům  $x_{1,2}$  a  $x_{2,1}$  a odečíst jedničku od prvku  $x_{1,1}$ . Opakované použití tohoto postupu neneruší přípustnost tabulky v tom případě, kdy  $x_{1,1} \geq x_{2,2}$ . Toho lze využít k naprogramování těchto změn v jednoduchém cyklu. Hodnoty v prvcích o indexech  $(1,1)$ ,  $(1,2)$ ,  $(2,1)$  a  $(2,2)$  budou dány výrazy

$$x_{1,1} - K, x_{1,2} + K, x_{2,1} + K, x_{2,2} - K \quad (10)$$

kde  $K = 0, 1, \dots, \min(x_{1,1}, x_{2,2})$ .

Po tomto cyklu přičteme hodnotu  $x_{2,2}$  k  $x_{1,1}$  a hodnotu  $x_{1,1}$  očíste k  $x_{2,2}$ .

a  $x_{2,1}$ . Prvek  $x_{2,2}$  vynulujeme a teprve nyní začneme hledat kladný prvek.

### 3.3.2 Uspořádání marginálních součtů

Ze vzorců (5) a (7) vyplývá, že jsou invariantní k záměně řádků a sloupců zadané tabulky. Tím tedy ani výpočet hladiny významnosti (6) nezávisí na uspořádání marginálních součtů, přesto, že přípustné tabulky mohou být generovány v jiném pořadí. Vzhledem k algoritmu generování tabulek a vzhledem k odstavci 3.3.1 se jeví nejvýhodnější uspořádání marginálních součtů sestupně podle velikosti. To je výhodné zejména proto, že algoritmus zajišťuje rychlejší změny v prvcích o nižších řádkových a v řádku o nižších sloupcových indexech.

### 3.4 Zhodnocení nové metody

Nová metoda zaručuje generování všech přípustných tabulek, navíc jsou generovány tyto přípustné tabulky ve stejném pořadí, v jakém jsou generovány Marchovou metodou. Proti Marchově metodě zde vzniká podstatně menší počet nepřípustných tabulek, navíc nepřípustnost generované tabulky můžeme zjistit dříve, než March a proces generování zastavit.

Není třeba vypočítávat prvky v 1. řádku, resp. 1. sloupci pomocí rovnic (2), resp. (3) a během jejich výpočtu kontrolovat přípustnost, jako to dělá March. Zde se stačí omezit na prvek  $x_{1,1}$  a to v libovolné fázi výpočtu.

Sestupné uspořádání marginálních součtů snižuje podstatně dobu výpočtu a při praktických výpočtech se ukázalo, že vede i ke snížení počtu nepřípustných tabulek. Toto uspořádání by mohlo urychlit i Marchovu metodu.

## 4. VÝPOČET HLADINY VÝZNAMNOSTI

### 4.1 Výpočet pravděpodobnosti tabulky

Pravděpodobnost vygenerované tabulky se počítá podle vzorců (7), (8) a (9). Při praktickém využití je vhodné používat logaritmy, což zabrání přetečení. V Marchově metodě je výraz  $\ln(R(X))$  počítán po každé vygenerované přípustné tabulce celý znovu. Ukazuje se, že je účelné zavést tabulku  $S$  součtu logaritmů faktoriálů, jejíž využití urychlí výpočet  $\ln(R(X))$ . Tabulka  $S$  má také rozměr  $R \times C$  a je svázána s tabulkou  $X$  tak, že prvek  $s_{i,j}$  obsahuje součet logaritmů faktoriálů všech prvků, lexicograficky následujících za prvkem  $x_{i,j}$ . Např. prvek  $s_{3,C}$  obsahuje součet logaritmů faktoriálů všech prvků tabulky  $X$  od čtvrtého řádku počínaje.

Výpočet prvků tabulky  $S$  se provádí současně s generováním tabulky  $X$ . Jestliže před generováním další tabulky  $X$  byla odečtena jednička na prvku  $x_{i,j}$ , potom tabulka  $S$  bude přepočítána jen v prvcích lexicograficky předcházejících prvku  $s_{i,j}$ .

### 4.2 Výpočet hladiny významnosti pomocí doplňku

Pravděpodobnosti  $P(X)$  přípustných tabulek, které byly vypočteny v průběhu generování, jsou vždy porovnány s pravděpodobností  $P(X_0)$  zadané tabulky  $X_0$  a jestliže platí  $P(X) \leq P(X_0)$ , jsou přičteny do proměnné, která po skončení generování dává  $P_s(X_0)$ .

Tímto způsobem počítá hladinu významnosti March. Rovněž počítá doplněk k hladině významnosti podle vzorce

$$P_s^D(X_0) = \sum_{P(X) > P(X_0)} P(X) \quad (11)$$

Součet  $P_s(X_0) + P_s^D(X_0)$  by se měl, až na zaokrouhlovací chyby rovnat jedné. Tohoto vztahu používá pro kontrolu přesnosti výpočtu. Praktické výpočty na ODŘE 1204 ukázaly, že přesnost je dostatečně vysoká a tato kontrola je zbytečná. Lze tedy bez

podstatné chyby počítat hladinu významnosti  $\alpha$  ze vztahu

$$P_s(X_0) = 1 - P_0^D(X_0) \quad (12)$$

V nové metodě nepočítáme  $P_s(X_0)$  podle vztahu (6) jako March, ale podle vztahu (12). Omezili jsme se tedy jen na ty tabulky  $X$ , pro které  $P(X) > P(X_0)$ . Ze vztahu (7) vyplývá, že u těchto tabulek platí  $R(X) < R(X_0)$ .

## 5. PRAVDĚPODOBNOSTNÍ OMEZENÍ PŘI GENEROVÁNÍ

### 5.1 Pravděpodobnostní omezení

Jestliže se při výpočtu hladiny významnosti řídíme vztahem (12), omezíme se jen na tabulky  $X$ , pro které  $R(X) < R(X_0)$ .  $R(X_0)$  je tedy horní mezí hodnot  $R(X)$  pro všechny tabulky  $X$ , které je nutné generovat. Ostatní tabulky, které mají  $R(X) \geq R(X_0)$ , nejsou k výpočtu hladiny významnosti potřebné. Je tedy možno je z generování vypustit.

Vzhledem k tomu, že  $\ln(R(X))$  je v nové metodě načítán průběžně v tabulce  $S$ , je možné po vygenerování jakéhokoliv prvku  $x_{i,j}$  zjistit, zda  $s_{i,j} + \ln(x_{i,j}!)$  je větší než  $\ln(R(X_0))$ . Jestliže ano, potom již není nutné takovou tabulku dále generovat, neboť pro ni bude jistě platit  $R(X) > R(X_0)$ , ať do zbývajících prvků vygenerujeme cokoliv.

### 5.2 Funkce MSF

Pro potřeby dalšího výkladu udělejme tuto úvahu. Máme-li rozdělit  $K$  jednotek do  $N$  políček tak, aby součin faktoriálů / resp. součet logaritmů faktoriálů / počtu jednotek v těchto políčkách byl minimální, lze jednoduše ukázat, že to bude v tom případě, když budou rozděleny co nejrovnoměrněji / tj. počty v libovolných dvou políčkách se budou lišit nejvýše o jednotku /. K tomu si definujeme funkci  $MSF(K, N)$ , jejíž hodnotou bude minimální součet logaritmů faktoriálů při  $K$  jednotkách, rozdělených do  $N$  políček.

### 5.3 Řádková a sloupcová pravděpodobnostní omezení

Podle úvahy v předchozím odstavci 5.2 můžeme pro jednotlivé řádky tabulek určit předem dolní mez součtů logaritmů faktoriálů prvků v těchto řádcích. Tato dolní mez je pro  $i$ -tý řádek dána hodnotou funkce  $MSF(r_i, C)$ . Můžeme tedy pro  $i$ -tý řádek určit horní mez  $RB_i$  součtů logaritmů faktoriálů prvků v tomto řádku a v řádcích s indexem vyšším pomocí vztahu

$$RB_i = \ln(R(X_0)) - \sum_{k=1}^{i-1} MSF(r_k, C) \quad (13)$$

Hodnoty  $RB_i$  je možno vypočítat před započatím generování, neboť závisí pouze na  $R(X_0)$ ,  $r_i$  a  $C$ . Omezení stanovené v bodě 5.1 je možné ještě ztřídit tímto způsobem:

Jestliže po vygenerování prvku  $x_{i,j}$  zjistíme, že

$$s_{i,j} + \ln(x_{i,j}!) > RB_i, \quad (14)$$

není nutné tabulku dále generovat. Ať je do zbytku tabulky dogenerováno cokoliv, bude vždy  $R(X) > R(X_0)$  pro každou přípustnou tabulku  $X$ , která má v prvku  $x_{i,j}$  a v prvcích lexikograficky následujících hodnoty dosud vygenerované.

Obdobně jako pro řádky je možno uplatňovat během výpočtu i omezení pro sloupce, neboť zbývající sloupcové kapacity je nutno určitým způsobem do dosud nevygenerovaných prvků rozdělit. Je zřejmé, že pokud

$$x_{1,j} + \ln(x_{1,j}!) > \ln(R(X_0)) - \sum_{k=1}^{l-1} \text{MSF}(x_{1,k}, i) - \sum_{k=0}^c \text{MSF}(x_{1,k}, i-1), \quad (15)$$

je zbytečně tabulku degenerovat.

Toto omezení však již závisí na volných kapacitách a na indexech  $i, j$  a není proto možné je vypočítat předem.

Průběžná kontrola podle nerovnosti (15) by časově příliš zatěžovala proces generování a proto jsou předchozí úvahy prakticky realizovány tak, že nerovnost (14) je kontrolována při generování každého prvku. Teprve když je splněna, jsou prováděny kontroly jak pro sloupcové omezení (15), tak i pro zůstavné řádkové omezení, dané nerovností

$$x_{1,j} + \ln(x_{1,j}!) > \alpha_{1,j} - \text{MSF}(x_{1,1}, j-1). \quad (16)$$

Pokud je pro prvek  $x_{1,j}$  splněna alespoň jedna z nerovností (15) a (16) a  $x_{1,j} > 0$ , odečteme od  $x_{1,j}$  jedničku a provedeme příslušné úpravy kapacit  $x_{1,1}$  a  $x_{1,j}$ . Opět kontroujeme splnění nerovností (15) a (16). Jestliže již  $x_{1,j} = 0$  a dosud alespoň jedna z nerovností (15) a (16) platí, pokračujeme v obdobném testování prvku lexicograficky následujícího. Tento zpětný proces je ukončen, jestliže obě nerovnosti nejsou splněny /pak se pokračuje v generování/, případně tehdy, když jsme v tomto procesu dospěli k poslednímu prvku tabulky  $x_{R,C}$  a tento je již nulový, přičemž alespoň jedna z nerovností (15) a (16) platí /pak je generování tabulek u konce/. Při přechodu na nižší řádek je v tomto procesu samozřejmě nutné upravit i kapacitu 1. sloupce /k hodnotě  $x_{1,1}$  přičíst hodnotu  $x_{1,j}$  /.

Tato strategie generování vyžaduje složitější program, ale nezatěžká zbytečnými časovými ztrátami výpočty pro tabulky s nízkou hladinou významnosti.

#### 5.4. Úprava generování u prvku $x_{2,2}$

Postup uvedený v bodě 3.3.1 můžeme při využívání pravděpodobnostních omezení v generování upravit následujícími způsoby:

Množinu těch  $K$ , které vystupují v (10) můžeme rozdělit na dvě podmnožiny, pro které se  $R(X)$  chová monotónně.

$$M_1 = \{K; K \leq L\},$$

$$M_2 = \{K; K > L\},$$

kde

$$L = \frac{x_{1,1} \cdot x_{2,2} - (x_{1,2} + 1) \cdot (x_{2,1} + 1)}{x_{1,1} + x_{1,2} + x_{2,1} + x_{2,2} + 2} \quad (17)$$

v množině  $M_1$  se pro rostoucí  $K$   $R(X)$  snižuje, v  $M_2$  naopak zvyšuje. Je možné, že jedna z množin je prázdná.

Výsledek pak budeme provádět raději ve dvou cyklech, odpovídajících množinám  $M_1$  a  $M_2$ . v  $M_1$  postupně pro klesající  $K$ , v  $M_2$  pro rostoucí. Nemusíme pak zbytečně počítat s tabulkami s  $R(X) > R(X)$ .

V případě, že nebyla v obou cyklech nalezena ani jedna tabulka  $X$ , pro kterou  $R(X) < R(X)$ , nepokračujeme přímo v generování dalších tabulek, ale počínáme prvkem  $x_{2,2}$  provádíme testování vzhledem k pravděpodobnostním omezením podle bodu 5.3.

## 5.5 Zhodnocení metody generování při pravděpodobnostních omezeních

Metoda popsaná v kapitole 5 má proti metodě generování všech přípustných tabulek z kapitoly 3 tu přednost, že z procesu generování vynechává tabulky pravděpodobnostně nevhodné, tj. tabulky, pro které  $P(X) \leq P(X_0)$ . Z toho plyne, že efektivnost této metody se projeví podstatně především v těch případech, kdy  $P(X_0)$  bude co největší vzhledem k pravděpodobnostem ostatních přípustných tabulek. Algoritmus je ovšem navržen tak, aby nezdržoval výpočet hladiny významnosti u tabulek, pro které  $P(X_0)$  je malé.

Vezmeme-li v úvahu výsledky kapitoly 3 a této kapitoly, je zřejmé, že požadovanou hladinu významnosti  $P_s(X_0)$  získáme v podstatně kratším čase, než March.

## 6. PROCEDURA CONP

### 6.1 Popis procedury

Nová metoda, jejíž popis byl uveden v předcházejících kapitolách 3 až 5, byla zpracována do algolské procedury. Hlavička procedury má tento tvar:

```
PROCEDURE CONP (MATRIX, R, C, PT, PS);
```

```
VALUE MATRIX, R, C;
```

```
INTEGER R, C;
```

```
REAL PT, PS;
```

```
INTEGER ARRAY MATRIX;
```

Parametry mají tento význam:

MATRIX	Dvourozměrné celočíselné pole s mezemi [1:R, 1:C], které obsahuje zadanou kontingenční tabulku $X_0$ .
R	Počet řádků tabulky $X_0$ .
C	Počet sloupců tabulky $X_0$ .
PT	Výstupní parametr; při návratu z procedury obsahuje pravděpodobnost $P(X_0)$ .
PS	Výstupní parametr, při návratu z procedury obsahuje hladinu významnosti $P_s(X_0)$ .

Procedura pracuje s nelokálními proměnnými typu ARRAY. Je to jednorozměrné pole FL [0: $\alpha$ ], jehož prvky obsahují logaritmy faktoriálů, tedy FL [I] =  $\ln(I!)$  a dvourozměrné pole MSFL [0: $\beta$ , 1: $\gamma$ ], kde jednotlivé prvky tohoto pole obsahují minimální součet logaritmů faktoriálů, tedy MSFL [K,N] = MSF (K,N), viz fce MSF, definovaná v bodě 5.2. Horní meze  $\alpha, \beta, \gamma$  v deklaracích těchto polí je nutno volit s ohledem na rozměry tabulky a počty pozorování v tabulce. Hodnota  $\alpha$  musí být větší nebo rovna celkovému počtu pozorování v tabulce  $X_0$ , hodnota  $\beta$  větší nebo rovna největšímu z řádkových a sloupcových marginálních součtů, hodnota  $\gamma$  větší nebo rovna maximu z hodnot R a C. Pokud tyto podmínky nejsou dodrženy, může dojít k chybě při práci procedury /SUBSCRIPT/. Hodnoty do polí FL a MSFL je nutno pochopitelně dosadit před vyvolání procedury CONP. Prvky nelokálních polí FL a MSFL je možno samozřejmě nahradit funkčními procedurami, které poskytnou požadované hodnoty, to ale podstatně prodlouží dobu výpočtu.

### 6.2 Doba výpočtu

Odhad doby výpočtu nelze v jednotlivých případech stanovit. Lze jen uvést určitá fakta, ze kterých je možné usuzovat na složitost a tedy i délku výpočtu příkladu. Délka výpočtu závisí obecně na počtu přípustných tabulek, u kterých  $P(X) > P(X_0)$ . Obtížnost je zde dána především neznalostí celkového počtu přípustných tabulek pro dané marginální součty a neznalostí rozvrstvení jejich pravděpodobnosti. Vzorec pro výpočet počtu přípustných tabulek nám není znám, ze zkušenos-

ti však víme, že tento počet závisí především na velikosti tabulky /jejich rozměrech/ a dále na velikosti a rozdělení marginálních součtů v řádcích a sloupcích. Čím rovnoměrněji jsou marginální součty v řádcích, resp. sloupcích rozděleny, tím větší počet přípustných tabulek můžeme očekávat. Také se vzrůstajícím počtem pozorování v tabulce počet přípustných tabulek narůstá.

Z praktického hlediska, jak ukázaly výpočty zkušebních příkladů, je vhodné zadávat tabulku  $X_0$  vždy tak, aby  $R \geq C$ . V tomto případě dochází k lepšímu využití pravděpodobnostních omezení  $RB_1$  v jednotlivých řádcích, proces generování pravděpodobnostně nevhodných tabulek ( $P(X) \in P(X_0)$ ) je zastavován dříve.

## 7. APLIKACE METODY

### 7.1 Náhrada $\chi^2$ -testu dobrou shodou

Je známo, že není vhodné používat  $\chi^2$ -testu, jestliže napozorované četnosti jsou nízké. Při srovnání s přesným testem se ukazuje, že testové kritérium  $\chi^2$  není vhodné užívat ani jako přibližnou míru závislosti v tabulce. Proti jeho použití svědčí dvě skutečnosti. Jednak to, že výsledky získané  $\chi^2$ -testem se mohou značně lišit od výsledků získaných přesným testem a to tím více, čím menší jsou napozorované četnosti. Druhá skutečnost je ta, že výsledek přesného testu závisí jen na pravděpodobnosti a marginálních součtech zadané tabulky, zatímco  $\chi^2$  je závislý ne na pravděpodobnosti  $P(X_0)$ , ale konkrétních napozorovaných četnostech. Pro dvě různé tabulky se stejnou pravděpodobností a se stejnými marginálními součty dává přesný test tutéž hladinu významnosti, zatímco  $\chi^2$ -test může dát hodnoty  $P_g(X_0)$  značně odlišné. To se projevuje podstatně u tabulek s nízkými četnostmi.

S ohledem na to, že doba výpočtu hladiny významnosti  $P_g(X_0)$  při použití přesného testu rychle roste s rostoucími rozměry tabulky a s rostoucími četnostmi pozorování, nelze očekávat počítat s jeho hromadným použitím jako náhradou za běžně používaný  $\chi^2$ -test. Přesného testu lze však použít v těch případech, kdy podmínky pro aplikaci  $\chi^2$ -testu nejsou dobře splněny.

### 7.2 Dopravní problém

Generování všech přípustných tabulek, které je součástí metody popsané v kapitole 3, je z hlediska matematického programování výčet všech přípustných řešení celočíselného dopravního problému. Toho lze využít při minimalizaci nákladů v dopravních problémech, jejichž účelová funkce není lineární. Je-li účelová funkce dopravního problému taková, že její předpis je shodný pro všechna přípustná řešení a příspěvek každého prvku matice přepravovaných množství je nezávislý na hodnotách jiných prvků této matice a přitom je nezáporný, můžeme při minimalizaci použít uvedených úvah, jako v bodě 4.1 a kapitole 5 této práce. Navíc omezení, analogické pravděpodobnostnímu omezení uvedenému v bodě 5.1 lze upravovat během výpočtu podle dosud zjištěného minima účelové funkce.

## 8. PŘÍKLADY

Pro ilustraci uvádíme dva příklady, na nichž bude demonstrováno srovnání uvedených metod výpočtu hladiny významnosti. Jednotlivé metody označme takto:

1. Výpočet pomocí  $\chi^2$ -testu.
2. Výpočet Warchovou metodou.
3. Jako 2, ale pro transponovanou tabulku.
4. Výpočet novou metodou generování tabulek bez pravděpodobnostních omezení /generovány všechny přípustné tabulky/.
5. Jako 4, ale pro transponovanou tabulku.
6. Výpočet novou metodou generování tabulek s pravděpodobnostními omezeními.
7. Jako 6, ale pro transponovanou tabulku.



**Příklad 1.**

Tabulka typu 3 x 3	metoda	hladina významnosti	počet generovaných přípust. tabulek	doba výpočtu s
2 3 1	1	0.53831	-	-
0 1 2	2	0.71218	278	37
6 5 5	3	0.71218	278	39
	4	0.71218	278	8
	5	0.71218	278	9
	6	0.71218	13	1
	7	0.71218	13	2

**Příklad 2.**

Tabulka typu 3 x 4	metoda	hladina významnosti	počet generovaných přípust. tabulek	doba výpočtu s
3 7 4 8	1	0.46631	-	-
5 2 3 3	2	?	?	3600
2 1 0 3	3	?	?	3600
	4	0.50790	31892	762
	5	0.50790	31892	768
	6	0.50790	818	70
	7	0.50790	818	53

Výpočet metodou 2 a 3 byl zastaven po jedné hodině bez získání výsledků.

**LITERATURA:**

- Freeman, G. H., Halton, J. H.:  
Note on an exact treatment of contingency, goodness of fit, and other problems of significance.  
Biometrika, 38(1951), 141-149.
- March, D. L.:  
Exact probabilities for R x C contingency tables. Algorithm 434. Communications of the Association for Computing Machinery 15 (1972) 11, 991-992.
- Stucky, W., Vollmar, J.:  
Ein Verfahren zur exakten Auswertung von 2 x C - Häufigkeitstafeln.  
Biometrische Zeitschrift 17(1975) 3, 147-162.