

JACK-KNIFEOVÁNÍ KOEFICIENTŮ ASOCIACE II

Jaromír Běláček, GGÚ ČSAV

Stejnojmenný příspěvek ze sborníku ROBUST 86 poukázal na možnost aplikace nej-jednodušších transformací typu jackknife na koeficientech asociace (matematicky hlad-kých funkcích frekvenčního multinomického vektoru), které poskytuje méně vychýlené od-hady empirických koeficientů a alternativní (neparametrické) odhady rozptylu. Smyslem tohoto příspěvku je poskytnout informaci o univerzálních zákonitostech těchto metod kon-struovaných pro eliminaci vychylujících členů vysších řádů nežli $O(n^{-1})$, a to i pro situaci několika nezávislých náhodných výběrů. Na příkladech vybraných koeficientů aso-ciace jsou referovány některé zákonitosti praktické závěry.

V návaznosti na terminologickou diskusi odebírávající se po oznámení prvotního příspěvku na ZŠ ROBUST 86 si dovoluji upozornit, že termín "jackknife" znamená podle doslovného překladu (viz. [5], str. 1174) "velký kapesní zavírací nůž, zavírák". V tomto smyslu interpretoval "jackknife" i profesor P.K.Sen na své loňské předvánoční přednášce na KPMS přiřazuje jednotlivým čepelím svého "nože" rozličné speciální interpretace. Jak mne ovšem upozornil můj pozorný kolega dr.P.Hrala ([6]), lze na základě věrných his-toriických pramenů přisuzovat anglické terminologické přiřazení dané metodě pracovním aktivitám českých národnostních menšin před druhou světovou válkou. Jak známo Valaši (jinak též profesionální klestiči dobytka) se proslavili právě výrobou a aktivním pou-žíváním kapesních nožů, jejichž prostřednictvím účinně potlačovali nežádoucí aktivity domácího skotu po celé Evropě. Ilužno podotknout, že kategorická informace o tom, že adekvátní český ekvivalent anglického "jackknife" je tudíž "okleštování", způsobila po-zitivní nezájem mého nejbližšího nadřízeného dr.J.Řeháka o další terminologické nuance.

1. JEDNOVÝBĚROVÁ JACKKNIFEOVÁ TRANSFORMACE K-TÉHO ŘÁDU

Pro libovolný odhad $\hat{\theta}_n$ pořízený na základě náhodného výběru o rozsahu n a $k < n$ zavedme veličiny

$$(1) \quad \begin{aligned} \bar{\theta}_{n-v} &\leftarrow \sum_{1 \leq i_1 < \dots < i_v \leq n}^{\binom{n}{v}^{-1}} \hat{\theta}_{-i_1, \dots, -i_v} && \text{pro } v=1, \dots, k \\ &\quad \hat{\theta}_n && \text{pro } v=0 \end{aligned}$$

jako průměry všech $\binom{n}{v}$ odhadů získaných z původního výběru při postupném vynechávání v -tic pozorování. Jednovýběrový jackknifeový odhad k-tého řádu byl definován v [10] předpisem

$$(2) \quad J_k(\hat{\theta}_n) := \frac{\begin{vmatrix} \bar{\theta}_{n-0} & \bar{\theta}_{n-1} & \cdot & \cdot & \cdot & \bar{\theta}_{n-k} \\ n^{-1} & (n-1)^{-1} & \cdot & \cdot & \cdot & (n-k)^{-1} \\ \cdot & \cdot & & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ n^{-k} & (n-1)^{-k} & \cdot & \cdot & \cdot & (n-k)^{-k} \end{vmatrix}}{\begin{vmatrix} 1 & 1 & \cdot & \cdot & \cdot & 1 \\ n^{-1} & (n-1)^{-1} & \cdot & \cdot & \cdot & (n-k)^{-1} \\ \cdot & \cdot & & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ n^{-k} & (n-1)^{-k} & \cdot & \cdot & \cdot & (n-k)^{-k} \end{vmatrix}}$$

jakožto řešení pro $\hat{\Theta}$ soustavy lineárních rovnic

$$(3) \quad \hat{\Theta}_{n-\hat{v}} = \hat{\Theta} + \sum_{v=1}^k \hat{\alpha}_v \cdot (n-\hat{v})^{-v}, \quad \hat{v}=0,1,\dots,k$$

v proměnných $\hat{\Theta}, \hat{\alpha}_1, \dots, \hat{\alpha}_k$. Vzhledem k tomu, že Vandermondův determinant matic soustavy (3) -tj. jmenovatel zlomku v (2)- je různý od nuly, je $J_k(\hat{\Theta}_n)$ definován jednoznačně jako lineární kombinace $\hat{\Theta}_{n-0}, \dots, \hat{\Theta}_{n-k}$ s pevně určenými koeficienty. Rozvojem čitatele v (2) podle prvního řádku lze získat explicitní vyjádření

$$(4) \quad J_k(\hat{\Theta}_n) = \frac{1}{k!} \left[\sum_{v=0}^k (-1)^v \binom{k}{v} (n-v)^k \hat{\Theta}_{n-v} \right]$$

snad poprvé uvedené v [12].

Základní vlastnost transformace $J_k(\cdot)$ vyplývá z níže uvedeného tvrzení - Lemma 1: Necht' odhad $\hat{\Theta}_n$ má konečný rozvoj střední hodnoty typu

$$(5) \quad E \hat{\Theta}_n = \hat{\Theta} + \sum_{v=1}^{\infty} \alpha_v \cdot n^{-v},$$

kde parametry $\hat{\Theta}, \alpha_1, \alpha_2, \dots$ nezávisí na n . Pak platí

$$(6) \quad E J_k(\hat{\Theta}_n) = \hat{\Theta} + O(n^{-k-1}), \quad n \rightarrow \infty.$$

Důkaz viz [10], str.527 nebo v [3] na str.54-5.

Je důležité poznamenat, že význam předpokladu (5) nespočívá v explicitní znalosti parametrů $\hat{\Theta}, \alpha_1, \alpha_2, \dots$, nýbrž v pouhé specifikaci struktury vychylujícího rozvoje odhadu $\hat{\Theta}_n$. Platnost (5) se zbytkem řady nahrazeným symbolem $O(n^{-v})$ pro některé $v > k$ lze ověřit pro většinu standardních odhadů $\hat{\Theta}_n$ založených na posloupnosti nezávislých stejně rozdělených náhodných veličin (viz také [11], §6).

Zajímavá je interpretace vlastnosti (6) z hlediska explicitního vyjádření (4). Koeficienty $(-1)^v \binom{k}{v}$ pro $v=0,1,\dots,k$ charakterizují k-tou zpětnou differenci běžně zaváděnou pro libovolnou posloupnost $\{x_n\}$ reálných čísel rekurentními vztahy

$$(7) \quad \begin{aligned} \nabla x_n &:= x_n - x_{n-1} \\ \nabla^2 x_n &:= \nabla x_n - \nabla x_{n-1} = x_n - 2x_{n-1} + x_{n-2} \\ &\vdots \qquad \vdots \\ \nabla^k x_n &:= \nabla^{k-1} x_n - \nabla^{k-1} x_{n-1} = \sum_{v=0}^k (-1)^v \binom{k}{v} x_{n-v}. \end{aligned}$$

Mohlo by být těžké ukázat, že je-li x_n nezáporná mocnina n řádu $j \geq 0$, pak $\nabla^k x_n$ je polynom stupně $j-k$ při $j < k$ identicky rovný nule; dokonce každý pól v nule typu n^{-j} pro kladné j převádí k -tou differenci na pól typu $O(n^{-j-k})$. V situaci odpovídající splnění (5) definujeme

$$(8) \quad x_n := n^k \cdot \hat{\Theta}_n = \hat{\Theta} \cdot n^k + \sum_{v=1}^{\infty} \alpha_v \cdot n^{k-v}, \quad n > k,$$

takže k -tá differenční aplikovaná na x_n (tj. $\nabla^k x_n = (k!)^{-1} J_k(\hat{\Theta}_n)$) musí být nutně výraz typu (6).

Explicitní znalost transformačního vzorce (4) umožňuje vysetřovat otázkou asymptotického rozdělení $J_k(\hat{\Theta}_n)$ ve vztahu k původnímu rozdělení odhadu $\hat{\Theta}_n$. Platí-li asymptotická normalita pro n.v. $n^{1/2}(\hat{\Theta}_n - \Theta)$, lze stejně normální approximace použít obvykle i v případě n.v. $n^{1/2}(J_k(\hat{\Theta}_n) - \Theta)$. Odhadem společného asymptotického rozptylu je statistika

$$(9) \quad S_1^2(\hat{\Theta}_n) := (n-1) \sum_{i=1}^n (\hat{\Theta}_{i-1} - \hat{\Theta}_{n-1})^2$$

2. S-VÝBĚROVÁ JACKKNIFEOVÁ TRANSFORMACE K-TÉHO RÁLU

Definici odhadu ($\hat{\theta}$) lze analogicky rozšířit na situace, kdy parametr Θ je odhadován na základě $S(s)$ nezávislých náhodných výběrů s rozsahy n_1, \dots, n_s ($n_1 + \dots + n_s = n$). Pokud zanedbáme členy rádu $O(n^{s-k})$, lze typickou strukturu vychylujícího rovna odpovídajícího odhadu $\hat{\Theta}_n^s$ charakterizovat vyjádřením

$$(10) \quad E \hat{\Theta}_n^s = \hat{\theta} + \sum_{r=1}^{s+k} \sum_{\substack{1 \leq a_1 < \dots < a_r \leq s \\ r \leq v_1 + \dots + v_r \leq k}} \alpha_{v_1 \dots v_r}^{a_1 \dots a_r} \hat{\theta}_{v_1 \dots v_r}^{a_1 \dots a_r},$$

kde $\hat{\theta}$ a všechna $\alpha_{v_1 \dots v_r}^{a_1 \dots a_r}$ jsou parametry nezávislé na n_1, \dots, n_s a poslední sumace sčítá přes systém $\{[v_1, \dots, v_r] : 1 \leq v_1, \dots, v_r \leq k \text{ a } v_1 + \dots + v_r \leq k\}$. V nejjednodušším případě $k=1$ lze jackknifeovou transformaci vyjádřit jako řešení soustavy lineárních rovnic definované vzorcem (viz [7], str. 131)

$$(11) \quad J_1^s(\hat{\Theta}_n^s) := \frac{\begin{vmatrix} \hat{\Theta}_n^s & \hat{\theta}_1^1 & \dots & \dots & \dots & \hat{\theta}_1^s \\ n_1^{-1} & (n_1-1)^{-1} & \dots & \dots & \dots & n_1^{-1} \\ \vdots & \vdots & \ddots & & & \vdots \\ \vdots & \vdots & & \ddots & & \vdots \\ \vdots & \vdots & & & \ddots & \vdots \\ n_s^{-1} & n_s^{-1} & \dots & \dots & \dots & (n_s-1)^{-1} \end{vmatrix}}{\begin{vmatrix} 1 & 1 & \dots & \dots & \dots & 1 \\ n_1^{-1} & (n_1-1)^{-1} & \dots & \dots & \dots & n_1^{-1} \\ \vdots & \vdots & \ddots & & & \vdots \\ \vdots & \vdots & & \ddots & & \vdots \\ \vdots & \vdots & & & \ddots & \vdots \\ n_s^{-1} & n_s^{-1} & \dots & \dots & \dots & (n_s-1)^{-1} \end{vmatrix}} = (n-s+1)\hat{\Theta}_n^s - \sum_{s=1}^s (n_s-1)\hat{\theta}_1^s,$$

kde $\hat{\theta}_1^s$ pro $s=1, \dots, s$ je průměr všech n_s odhadů získaných z $\hat{\Theta}_n^s$ vynocháním právě jednoho pozorování v rámci stratifikační proměnné a .

Pro obecné $k < \min\{n_1, \dots, n_s\}$ máme k dispozici systém pomocných odhadů

$$(12) \quad \hat{\Theta}_{v_1 \dots v_r}^{a_1 \dots a_r} := \binom{n_a}{v_1}^{-1} \dots \binom{n_a}{v_r}^{-1} \sum_{\substack{1 \leq i_1^{a_1} < \dots < i_s^{a_s} \leq n_a \\ \vdots \\ 1 \leq i_1^{a_r} < \dots < i_s^{a_r} \leq n_a}} \hat{\theta}_{-i_1^{a_1}, \dots, -i_s^{a_s}}^{a_1 \dots a_r} \hat{\theta}_{v_1 \dots v_r}^{a_1 \dots a_r}$$

při

$$(13) \quad 1 \leq v_r \leq k, \quad 1 \leq a_1 < \dots < a_r \leq s, \quad r \leq v_1 + \dots + v_r \leq k.$$

Pro libovolnou sestavu indexů z (13) zřejmě platí

$$(14) \quad E \hat{\Theta}_{v_1 \dots v_r}^{a_1 \dots a_r} = \hat{\theta} + \sum_{r=1}^{s+k} \sum_{\substack{1 \leq a_1 < \dots < a_r \leq s \\ r \leq v_1 + \dots + v_r \leq k}} \sum_{\substack{s+k \\ v_1 \dots v_r}} \alpha_{v_1 \dots v_r}^{a_1 \dots a_r} \hat{\theta}_{v_1 \dots v_r}^{a_1 \dots a_r},$$

když

$$(15) \quad \begin{array}{ll} \tilde{n}_a < \begin{cases} n_a & \text{pro } a \notin \{a_1, \dots, a_r\} \\ (n_a - \tilde{n}_a) & \text{kdykoli } a \text{ je rovno některému indexu } \tilde{a}_0 \\ a_0 & \text{z množiny } \{a_1, \dots, a_r\}. \end{cases} \end{array}$$

Mahradíme-li střední hodnoty na levých stranách rovnic (10) a (14) jejich přirozenými odhady $\hat{\Theta}_n^s$ a $\hat{\Theta}_{v_1 \dots v_r}^{a_1 \dots a_r}$ a všechny teoretické parametry doplníme symbolem $\hat{\cdot}$, definuje řešení pro $\hat{\theta}$ takto vzniklé soustavy $\binom{s+k}{s+k}$ lineárních rovnic o $\binom{s+k}{s+k}$ neznámých

odhad $J_k^S(\zeta_n^S)$ zobecňující jednovýběrový odhad ze statí 1 (speciálně $J_k^1(\zeta_n^1) = J_k^1(\zeta_n^1)$).

Jednoznačnost definice i přesnějsí představu o struktuře odhadu $J_k^S(\zeta_n^S)$ poskytuje následující technické tvrzení -

-Lemma 2: Zavedme symbol $\tilde{\nabla}_{v_1 \dots v_r}^{a_1 \dots a_r}$ pro r -složkový vektor sestavený z prvků

$$(16) \quad \tilde{\nabla}_{v_1 \dots v_r}^{a_1 \dots a_r} := \tilde{\zeta}_{v_1 \dots v_r}^{a_1 \dots a_r} - [\tilde{\zeta}_{v_1 \dots v_{r-1}}^{a_1 \dots a_{r-1} \dots a_r} + \dots + (-1)^{r-1} [\tilde{\zeta}_{v_1 \dots v_{r-1}}^{a_1 \dots a_{r-1}} + \dots + \tilde{\zeta}_{v_r}^{a_r}] + (-1)^r \tilde{\zeta}_n^S$$

pro systém indexů korespondující s (13).

$$(17) \quad \text{Platí } J_k^S(\theta_n^S) = \theta_n^S + \sum_{r=1}^{s-k} (-1)^r \left\{ \sum_{1 \leq a_1 < \dots < a_r \leq s} \hat{\alpha}_{(r)}^*(\tilde{\nabla}_{v_1 \dots v_r}^{a_1 \dots a_r}) \right\}.$$

kde $\hat{\alpha}_{(r)}^*(\tilde{\nabla}_{v_1 \dots v_r}^{a_1 \dots a_r})$ je jediné řešení pro $\hat{\alpha}_{1 \dots 1}^{a_1 \dots a_r}$ soustavy lineárních rovnic

$$(18) \quad \frac{\nabla_{v_1 \dots v_r}^{a_1 \dots a_r}}{\hat{v}_1 \dots \hat{v}_r} = \sum_{r \leq v_1 + \dots + v_r \leq k} \hat{\chi}_{v_1 \dots v_r}^{a_1 \dots a_r} \cdot (n_1 - \hat{v}_1) \dots (n_r - \hat{v}_r), \quad r \leq v_1 + \dots + v_r \leq k.$$

Důkaz je podrobně rozepsán v [3].

Při $k < \min\{n_1, \dots, n_s\}$ lze ověřit jednoznačnost řešení každé soustavy typu (18) a za předpokladu (10) i požadovanou vlastnost

$$(19) \quad E J_k^S(\theta_n^S) = \theta.$$

Explicitní vyjádření (17) pro $k=1, 2, 3$ udávají vzorce (11) a

$$(20) \quad J_2^S(\theta_n^S) = \theta_n^S - \left\{ \sum_{a=1}^s [(n_a - 1)^2 \nabla_{11}^{a1} - \frac{1}{2}(n_a - 2)^2 \nabla_{21}^{a2}] \right\} + \left\{ \sum_{1 \leq a_1 < a_2 \leq s} [(n_{a_1} - 1)(n_{a_2} - 2) \nabla_{1112}^{a1a2}] \right\},$$

$$(21) \quad J_3^S(\theta_n^S) = \theta_n^S - \left\{ \frac{1}{6} \sum_{a=1}^s [3(n_a - 1)^3 \nabla_{111}^{a1} - 3(n_a - 2)^3 \nabla_{211}^{a2} + (n_a - 3)^3 \nabla_{311}^{a3}] \right\} + \\ + \left\{ \frac{1}{2} \sum_{1 \leq a_1 < a_2 < a_3 \leq s} [(n_{a_1} - 2)^2 (n_{a_2} - 1) \nabla_{112}^{a1a2} - 2(n_{a_1} - 1)(n_{a_2} - 1) \begin{vmatrix} (n_{a_1} - 1) & (n_{a_2} - 2) \\ (n_{a_1} - 1) & (n_{a_2} - 1) \end{vmatrix} \nabla_{111}^{a1a2}] \right. + \\ \left. + (n_{a_1} - 1)(n_{a_2} - 2)^2 \nabla_{122}^{a1a2} \right\} - \left\{ \sum_{1 \leq a_1 < a_2 < a_3 \leq s} (n_{a_1} - 1)(n_{a_2} - 1)(n_{a_3} - 1) \nabla_{1111}^{a1a2a3} \right\},$$

kde každá sumace přes systém $1 \leq a_1 < \dots < a_r \leq s$ pro $r > s$ je definována jako nula.

3. APLIKACE NA KOEFICIENTY ASOCIACE

Uvažujme koeficienty asociace typu $\delta(\zeta_n^S)$, kde $\delta(\cdot): \mathbb{R}^m \rightarrow \mathbb{R}$ je funkce a proměnných omezená na svém definičním oboru a $\zeta_n^S := (\zeta_{n_1}^S, \dots, \zeta_{n_s}^S)$ sestává z s nezávislých vektorů odpovídajících po řadě c-rozměrným multinomickým rozdělením $M(n_1, p^1), \dots, M(n_s, p^s)$. Případ s=1 pokrývá jednovýběrovou situaci z příspěvku [2], při s>1 odpovídají nezávislé výběry přirozené stratifikaci vzhledem k hodnotám některé proměnné kontingenční tabulky. Korektní aplikace jackknifeové transformace $J_k^S(\cdot)$ ze statí 2 požaduje pro $\theta_n^S = \delta(\zeta_n^S)$ strukturu vychylujícího rozvoje typu (10). Za předpokladu dostatečné hladkosti funkce $\delta(\cdot)$ na okolí teoretického bodu $p := (p^1, \dots, p^s)$ lze tuto vlastnost odvodit ze standardní approximace Taylorovým rozvojem vyjádřené ve tvaru

$$(22) \quad [E \delta(\zeta_n^S) - \delta(p)] = \sum_{j=1}^{2k} \frac{1}{j!} D_j \cdot [E(d\zeta_n^S)^j] + o(n^{-k}), \quad n \rightarrow \infty,$$

kde D_j je matici j-tých parciálních derivací $\delta(\cdot)$ v bodě p blokově strukturovaná jakožto $D_j := [\zeta_j^{a_1 \dots a_j}]_{1 \leq a_1, \dots, a_j \leq s}$, $[E(d\zeta_n^S)^j]$ symbolizuje matici j-tých centrálních momentů m-(s.c)-složkového vektoru $(d\zeta_n^S) := (\zeta_n^S - p)$ a tečka značí skalární součin.

Elementární rozpis každého součinu z (22) pro matice \tilde{L}_j symetrické vzhledem k permutacím indexů

$$(23) \quad D_j \cdot [E(\tilde{df}_n^s)^j] = \sum_{r=1}^s \sum_{\substack{l \leq a_1 < \dots < a_r \leq s \\ l \leq j_1, \dots, j_r \leq j}} \sum_{\substack{j_1! \dots j_r! \\ j_1 + \dots + j_r = j}} D_j^{a_1 \dots a_r} [E(\tilde{df}_n^{a_1})^{j_1} \dots E(\tilde{df}_n^{a_r})^{j_r}]$$

umožnuje využít explicitních vyjádření (7) resp. (8) z článku [2] pro výpočet každého dílčího součinu z (23) typu $D_j^{a_1 \dots a_r} \cdot [E(\tilde{df}_n^{a_1})^{j_1} \dots E(\tilde{df}_n^{a_r})^{j_r}]$. S ohledem na (22) a (23) lze snadno nahlédnout explicitní závislost každého koeficientu $\alpha_{v_1 \dots v_r}^{a_1 \dots a_r}$ z (10) pouze na parametrech p_1, \dots, p_r a dané sestavě v_1, \dots, v_r . Speciálně při vyneschání všech nulových sčítanců v (23) -odpovídajících situaci $j_a = 1$ pro některé $a=1, \dots, r$ - dostaneme vyjádření koeficientů u řádů n_a^{-1}, n_a^{-2} a $n_a^{-1} n_b^{-1}$ tvaru

$$(24) \quad \begin{aligned} \alpha_1^a &= \frac{1}{2} D_2^a \cdot [E(\tilde{df}_n^a)^2], & a=1, \dots, s \\ \alpha_2^a &= \frac{1}{6} D_3^a \cdot [E(\tilde{df}_n^a)^3] + \frac{1}{8} D_4^a \cdot [E(\tilde{df}_n^a)^2 \times E(\tilde{df}_n^a)^2], \\ \alpha_{11}^{a_1 a_2} &= \frac{1}{4} D_4^{a_1 a_2} \cdot [E(\tilde{df}_n^{a_1})^2 \times E(\tilde{df}_n^{a_2})^2], & l \leq a_1 < a_2 \leq s \end{aligned}$$

kde $\tilde{df}_n^{a_1}, \tilde{df}_n^{a_2}, \tilde{df}_n^{a_1 a_2}$ jsou nezávislé multinomické vektory s rozdelením $M(l, p^a), M(l, p^{a_1})$ a $M(l, p^{a_2})$. Analogické výpočtové vzorce se komplikují s přechodem k vyšším řádům $O(n^{-k})$ a k nesymetrickým maticím \tilde{L}_j .

Naznačené možnosti teoretického výpočtu vychylujících parametrů pro každý zvolený koeficient $\delta(\tilde{f}_n^s)$ a jejich následné využití pro účely eliminace vychýlení jsou ovšem nivelirovány při aplikaci transformací jackknife, které mají univerzální schopnost eliminace těchto členů bez ohledu na analytický předpis $\delta(\tilde{f}_n^s)$. Výpočtové vzorce (12) pro $\tilde{\theta}_{v_1 \dots v_r}^{a_1 \dots a_r} := \delta(\tilde{f}_n^{a_1 \dots a_r})_{v_1 \dots v_r}$ budou mít sice složitější strukturu typu

$$(25) \quad \delta(\tilde{f}_n^{a_1 \dots a_r})_{v_1 \dots v_r} = - \left(\frac{n_1}{v_1} \right)^{-1} \dots \left(\frac{n_r}{v_r} \right)^{-1} \sum_{\substack{0 \leq m_1^1, \dots, m_c^1 \leq v_1 \\ \vdots \\ 0 \leq m_1^r, \dots, m_c^r \leq v_r \\ m_1^1 + \dots + m_c^1 = v_1 \\ \vdots \\ m_1^r + \dots + m_c^r = v_r}} \left\{ \binom{n_1^1}{m_1^1} \dots \binom{n_c^1}{m_c^1} \dots \binom{n_1^r}{m_1^r} \dots \binom{n_c^r}{m_c^r} \delta(\tilde{f}_n^{a_1 \dots a_r})_{-(m_1^1 \dots m_c^1), \dots, -(m_1^r \dots m_c^r)} \right\} .$$

kde sumace v (25) sčítá přes počty $m_1^1, \dots, m_c^1, \dots, m_1^r, \dots, m_c^r$ všech sestav indexů vyhodnocených po řadě z 1. až c-té třídy 1. až r-té stratifikační proměnné a $n_1^1, \dots, n_c^1, \dots, n_1^r, \dots, n_c^r$ jsou odpovídající absolutní četnosti (pokud $n_b^a < n_b^b$ pro některou dvojici $[a, b] \in \{1, \dots, r\} \times \{1, \dots, c\}$, je celý výraz ve složené závorce definován jako nula), ale jsou formálně stejné pro libovolný koeficient $\delta(\tilde{f}_n^s)$.

4. ZÁVĚRY ZE SIMULAČNÍHO EXPERIMENTU

Statistické chování jackknifeových transformací bylo zkoumáno na jednovýběrové $J_k(\cdot)$ pro $k=1, \dots, 10$ aplikované na korelačním poměru η^2 (viz [9], str. 251) počítaném z kontingenční tabulky 4×5 a na logaritmické součinového poměru v tabulce 2×2 , který lze chápat jako speciální případ logaritmické interakce z [4]. V obou případech lze teoreticky zdůvodnit volou řádu k jackknifeové transformace odpovídající faktické numerické významnosti několika prvních členů v (5) pro dostatečně velké n (kupř. $n \geq 100$).

V případě korelačního poměru γ^2 je možno ověřit nárušt významnosti teoretických koeficientů z (24) při snižující se hodnotě některé z marginálních řádkových (resp. stratifikačních) pravděpodobností - z teoretických i simulačních výsledků však vyplývá pro všechny běžné volby teoretických parametrů (a rozsahu n) potřeba použití $J_k(\cdot)$ (resp. $J_k^*(\cdot)$) pro k nejvyšší rovné dvěma. Méně jednoznačná je volba "správného řádu k " v situaci logaritmické interakce, jejíž teoretickou hodnotu pro jednovýběrový případ lze definovat vztahem (viz [1], str.101)

$$(26) \quad \hat{\delta}_k(p) := \sum_{m=1}^c \gamma_m \log p_m ,$$

kde $p := (p_1, \dots, p_c)$ je pravděpodobnostní rozdělení obecně vícerozměrné kontingenční tabulky s nenulovými složkami a $\gamma := (\gamma_1, \dots, \gamma_c)$ nenulový vektor konstant vyhovující podmínce $\gamma_1 + \dots + \gamma_c = 0$. Problémy s definicí (26) na hranici jednotkového simplexu se v případě výběrového koeficientu $\hat{\delta}_k(f_n^1)$ kompenzují připočtením jisté korekční konstanty ke všem absolutním četnostem analyzované taule. Dá se ukázat, že tato úprava nic nezmění na platnosti asymptotického vztahu

$$\begin{aligned} \hat{\delta}_k(f_n^1) &= \hat{\delta}_k(p) - n^{-1} \left\{ \frac{1}{2} \Gamma_{-1} \right\} + n^{-2} \left\{ \frac{1}{2} \Gamma_{-1} - \frac{5}{12} \Gamma_{-2} \right\} - n^{-3} \left\{ \frac{1}{2} \Gamma_{-1} - 1\frac{1}{4} \Gamma_{-2} + \frac{3}{4} \Gamma_{-3} \right\} + \\ &\quad + n^{-4} \left\{ \frac{1}{2} \Gamma_{-1} - 2\frac{11}{12} \Gamma_{-2} + 4\frac{1}{2} \Gamma_{-3} - 2\frac{11}{120} \Gamma_{-4} \right\} - \\ (27) \quad &\quad - n^{-5} \left\{ \frac{1}{2} \Gamma_{-1} - 6\frac{1}{4} \Gamma_{-2} + 18\frac{3}{4} \Gamma_{-3} - 20\frac{11}{12} \Gamma_{-4} + 7\frac{11}{12} \Gamma_{-5} \right\} + \\ &\quad + n^{-6} \left\{ \frac{1}{2} \Gamma_{-1} - 12\frac{11}{12} \Gamma_{-2} + 67\frac{1}{2} \Gamma_{-3} - 135\frac{23}{24} \Gamma_{-4} + 118\frac{3}{4} \Gamma_{-5} - 37\frac{439}{504} \Gamma_{-6} \right\} + o(n^{-6}), \quad n \rightarrow \infty , \end{aligned}$$

pro

$$(28) \quad \Gamma_{-v} := \sum_{m=1}^c (\gamma_m) (p_m)^{-v} , \quad v=1, \dots, 6 ,$$

který lze odvodit z approximace typu (2c) při $k=6$ s ohledem na jednoduchou (diagonální) strukturu všech matic parciálních derivací a na znalost centrálních momentů elementárního multinomického rozdělení (viz [3], str.35-7). Faktická významnost koeficientů stojících v (27) u jednotlivých řad n^{-v} tedy bezprostředně závisí na rychlosti konvergence hodnoty $1/(n \cdot \min\{p_1, \dots, p_c\})$ k nule. Pro dosti malá n ($n=50$) a konkrétní volby vektoru γ a p je tudíž oprávněno použití jackknifeových transformací vyššího řádu k .

Formální simulační aplikace $J_k(\cdot)$ na oba uvažované koeficienty přinesla tyto závěry:

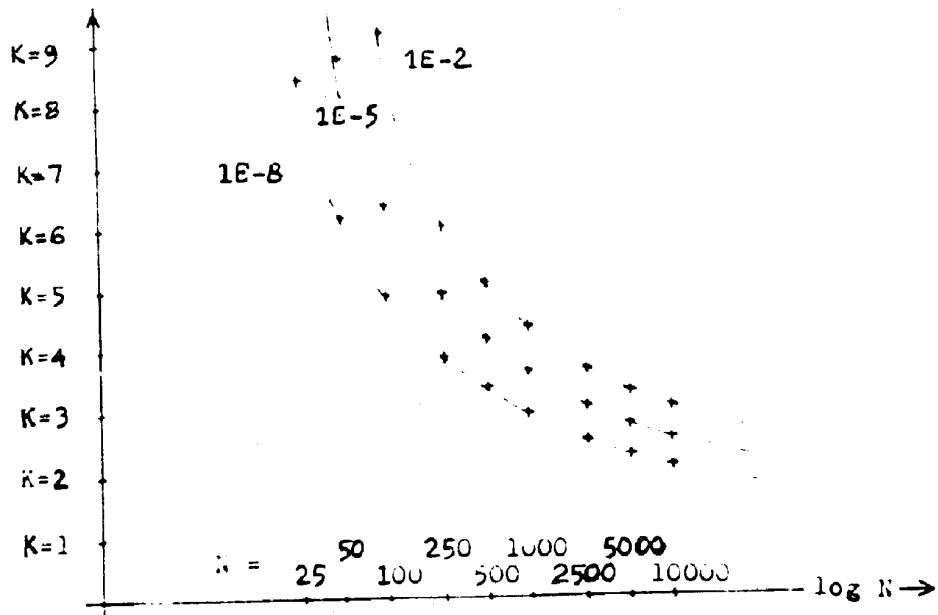
i/ Obecný vzorec (4) nelze použít pro neomezeně velká n a k , nebot' sčítání a odčítání příslušných členů typu $O(n^k)$ klade zvýšené nároky na numerickou přesnost použité výpočetní techniky. Z tohoto důvodu je nutné počítat hodnoty koeficientů asociace, na něž se aplikuje transformace $J_k(\cdot)$ při $k>2$, s vysokou přesností (double precision). Volba maximálního řádu k v závislosti na rozsahu n a zvolené přesnosti zaokrouhlovací coby vyplývá z empirického grafu na obr.1.

ii/ Počet $\binom{n}{k}$ vynechávaných pozorování pro účely následného přeypočítávání hodnot původního odhadu podle (1) lze v případě koeficientů asociace úspěšně redukovat na počet $\binom{c+k-1}{k}$ pro c kategoriálních tříd. Jak ovšem vyplývá z grafu na obr.2, vzrůstá při zvýšujícím se c a k i tento počet nad časově zvládnutelnou hranici.

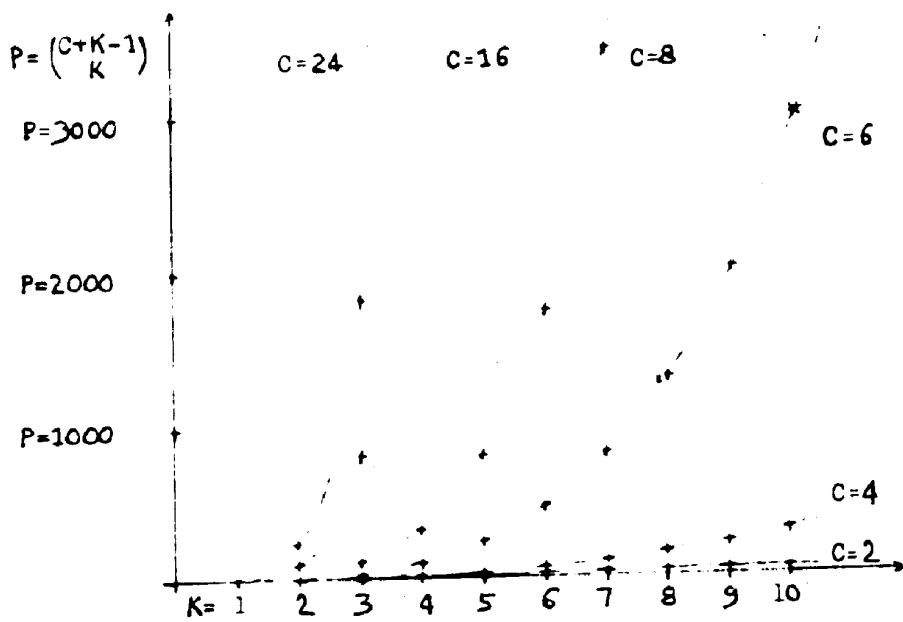
iii/ Pokud zvolený koeficient $\hat{\delta}(p)$ není definován na celém jednotkovém simplexu, může dojít k situaci, že od jistého k není (na rozdíl od empirické hodnoty $\hat{\delta}(f_n^1)$) definován odhad $J_k(\hat{\delta}(f_n^1))$. Bodové vlastnosti jackknifeových odhadů jsou potom při malých n velmi citlivé na případná předefinování-korekce jako za vzorcem (26).

iv/ Respektujeme-li omezení vyplývající z i-iii/, vykazují všechny numericky dostupné odhady značnou stabilitu projevující se vysokou párovou korelací mezi odhady $J_1(\hat{\delta}(f_n^1)), \dots, J_k(\hat{\delta}(f_n^1))$, z nichž všechny se statisticky významně liší od původní-vychýlené hodnoty $\hat{\delta}(f_n^1)$. Pro malé rozsahy n je ovšem třeba mít na paměti, že rozptyl jackknifeových odhadů je obvykle téhož řádu jako původní odhad, takže jednotlivé pozorované hodnoty -přestože jsou fakticky nevychýlené- mohou být značně variabilní!!

Obr.1: Závislost maximálního výpočetního řádu K Jackknifeové transformace JK(.) na rozsahu N a zvolené hodnoty E zaokrouhlené chyby.



Obr.2: Závislost počtu P znova pře-
pocítávaných hodnot koeficientu aso-
ciace na řádu K Jackknifeové trans-
formace JK(.) a počtu C kategori-
álních tříd.



LITERATURA:

- [1] Anděl J.(1973): Interaction in contingency tables. Aplikace matematiky 18, str.99-109
- [2] Běláček J.(1986): Jackknifeování koeficientů asociace. Sborník ROBUST 86, str.21-6
- [3] Běláček J.(1988): Eliminace vychýlení obecných měr asociace. Kand.práce KFF UK, Praha
- [4] Goodman L.(1964): Interactions in multidimensional contingency tables. Ann.Math.Statist.35, str.632-46
- [5] Heis K.-Hodek B.(1984): Velký anglicko-český slovník. Academia, Praha
- [6] Hrala P.(1987) - osobní sdělení
- [7] Krewski L.-Rao J.N.(1981): Inference from stratified samples - properties of the linearization, jackknife and balanced repeated replication methods. Ann.Statist.5, str.1010-19
- [8] Parr W.C.-Tolley H.D.(1982): Jackknifing in categorial data analysis. Austral.J.Statist.24, str.67-79
- [9] Rebák J.-Rebáková B.(1986): Analýza kategorizovaných dat v sociologii. Academia, Praha
- [10] Schucany W.R.-Gray H.L.-Owen L.B.(1971): On bias reduction in estimation. JASA 66, str.524-33
- [11] Serfling R.J.(1980): Approximation theorems of mathematical statistics. J.Wiley and sons, New York-Chichester-Brisbane-Toronto, str.210-42
- [12] Smith E.P.-van Belle G.(1984): Nonparametric estimation of species richness. Biometrics 40, str.119-29