

JACK-KNIFEOVÁNÍ KOEFICIENTŮ ASOCIACE

Jaromír Růláček, MFF UK

Výsledky prezentované v tomto příspěvku jsou aplikovatelné ve všech situacích, kde může co činit s omezenými dostatečně hladkými funkcemi (normovaného) multinomického vektoru, pořízeného nezávislým výborem reprezentantů populace klasifikované do m -tříd. Takovými funkcemi jsou například rozličné koeficienty asociace vyjadřující míru jisté specifické statistické závislosti mezi zkoumanými znaky kontingenční tabulky, četné míry vnitřní variability (diversity) souboru apod. Příspěvek pojednává o teoretickém srovnání základních statistických vlastností výše zmíněných empirických veličin s odhady, které lze z těchto získat užitím elementárních metod typu jack-knife, zejména s ohledem na redukci vychýlení původního odhadu a na jack-knifeový odhad asymptotického rozptylu. V závěru je zdůrazněna především jednoduchost a praktická aplikovatelnost obou základních jack-knifeových odhadů představených v textu.

1. MATEMATICKÝ APARÁT

V celém článku budeme vycházet z multinomického rozdělení $M(n, p)$ m -složkového vektoru \tilde{f}_n ($p = (p_1, \dots, p_m)^T$ pro $p_1, \dots, p_m \geq 0$, $\sum p_j = 1$ a $\tilde{f}_n = (\tilde{f}_{n1}, \dots, \tilde{f}_{nm})^T$ je vektor relativních četností - frekvenční vektor). Předmětem našeho zkoumání je náhodná veličina $\delta(\tilde{f}_n)$, kde $\delta(\cdot): \mathbb{R}^m \rightarrow \mathbb{R}$ je funkce m -proměnných omezená na svém definičním oboru.

Je-li $\delta(\cdot)$ spojitá v bodě p , je $\delta(\tilde{f}_n)$ zřejmě konzistentním odhadem (při $n \rightarrow \infty$) parametru $\delta(p)$ ($\delta(p)$ je teoretická hodnota koeficientu na celé populaci). Za silnějších předpokladů na diferencovatelnost funkce $\delta(\cdot)$ lze hlubší statistické vlastnosti koeficientu $\delta(\tilde{f}_n)$ indikovat z Taylorova rozvoje funkce $\delta(\cdot)$ v blízkosti bodu p . Z hlediska výpočtu i teoretických tvrzení je výhodné vyjádření v tvaru (viz. [10], str. 173):

$$(1) \quad \delta(\tilde{t}) = \delta(p) + \sum_{k=1}^s \frac{1}{k!} D_k \cdot (\tilde{t} - p)^k + Z_s(\tilde{t}) (\tilde{t} - p)^s, \quad \tilde{t} \in \mathbb{R}^m, \quad \tilde{t} \rightarrow p,$$

kde D_k je k -indexová matice všech k -tých parciálních derivací funkce $\delta(\cdot)$ v bodě p (každý z k indexů probíhá od 1 do m), $(y)^k \equiv (y \times y \times \dots \times y)$ pro $y \in \mathbb{R}^m$ označuje tenzorový součin k vektoru y (což je opět k -indexová matice obsahující všechny smíšené součiny délky k všech m součadin vektoru y), $\tilde{t} - p$ zastupuje rozdíl (diferenci) $(\tilde{t} - p)$ a symbol $D_k \cdot (\tilde{t} - p)^k$ je skalární součin dvou k -indexových matic (definovaný jako součet součinu všech navzájem si odpovídajících indexových složek). Zbytkový člen v (1) je vyjádřen jako skalární součin dvou s -indexových matic, $Z_s(\tilde{t})$ a $(\tilde{t} - p)^s$, kde $Z_s(\cdot): \mathbb{R}^m \rightarrow \mathbb{R}^{m \times \dots \times m}$ je m -složková vektorová funkce mající na okolí bodu p vlastnost

$$(2) \quad \lim_{\tilde{t} \rightarrow p} Z_s(\tilde{t}) = Z_s(p) = 0_s$$

(0_s symbolisuje s -indexovou matici sestavenou ze samých nul).

Spojitost zbytkového člena v bodě p umožňuje využít rozvoje (1) pro stanovení (n-degenerovaného) asymptotického rozdělení n.v. $n^{s/2}(\delta(\tilde{f}_n) - \delta(p))$ (pro vhodně volené $s \in \mathbb{N}$) bez zbytečně silných předpokladů na stupeň diferencovatelnosti funkce $\delta(\cdot)$.

Obdobně lze vlastnost (2) využít při approximaci centrových momentů veličiny $\hat{\delta}(\tilde{f}_n)$ se zbytkem ve tvaru $o(\cdot)$. Na úrovni tohoto článku se omezíme na asymptotická rozdělení při $s = 1$ a approximace vychýlení s středních čtvercových odchylek veličiny $\hat{\delta}(\tilde{f}_n)$ a některých dalších odvozených statistik.

2. ASYMPTOTICKÁ NORMALITA A APPROXIMACE ZÁKLADNÍCH MOMENTOVÝCH CHARAKTERISTIK KLASICKÝCH ODHADŮ

Za předpokladu existence 1. totálního diferenciálu funkce $\hat{\delta}(\cdot)$ v bodě \tilde{p} vyplývá asymptotické rozdělení veličiny $n^{1/2}(\hat{\delta}(\tilde{f}_n) - \hat{\delta}(\tilde{p}))$ z asymptotické normality rozdělení $N(n, p)$. Platí (viz např. [9], str. 430 v kombinaci s [1], str. 198), že

$$(3) \quad n^{1/2}(\hat{\delta}(\tilde{f}_n) - \hat{\delta}(\tilde{p})) \xrightarrow{D} N(0, \sigma^2(\tilde{p})),$$

kde

$$(4) \quad \sigma^2(\tilde{p}) = D_1^T [\text{diag}(\tilde{p}) - \tilde{p}\tilde{p}^T] D_1$$

pro diagonální matici $\text{diag}(\tilde{p})$ s diagonálními prvky p_1, \dots, p_m . (Asymptotické rozdělení je nedegenerované, pokud $\sigma^2(\tilde{p}) \neq 0$.) Předpokládáme-li existenci vyšších diferenciálů funkce $\hat{\delta}(\cdot)$, vzniká možnost explicitních approximací prvních dvou centrových momentů n.v. $\hat{\delta}(\tilde{f}_n)$ prostřednictvím vzorců (viz [5], str. 233-238, resp. [4], str. 452-4):

$$(5) \quad [\mathbb{E} \hat{\delta}(\tilde{f}_n) - \hat{\delta}(\tilde{p})] = \sum_{k=1}^s \frac{1}{k!} D_k \cdot [\mathbb{E} (\tilde{df}_n)^k] + o(n^{-s/2}), \quad n \rightarrow \infty$$

$$(6) \quad \mathbb{E} [\hat{\delta}(\tilde{f}_n) - \hat{\delta}(\tilde{p})]^2 = \sum_{j=1}^{s-1} \sum_{\substack{k=1 \\ j+k=s}}^{s-1} \frac{1}{j!} \frac{1}{k!} D_{j+k} \cdot [\mathbb{E} (\tilde{df}_n)^{j+k}] + o(n^{-s/2}), \quad n \rightarrow \infty,$$

kde $\mathbb{E} (\tilde{df}_n)^k$ snadí k-indexové matici sestavené ze středních hodnot prvků matic $(\tilde{df}_n)^k$ a D_{j+k} jsou $(j+k)$ -indexové tensorové součiny matic $(\tilde{D}_j \times \tilde{D}_k)$ (obsahující všechny vzájemné součiny prvků matic \tilde{D}_j a \tilde{D}_k).

Pro frekvenční (multinomický) vektor \tilde{f}_n lze explicitně vyjádřit libovolný člen stojící na pravé straně v (5) a (6). Zavedeme-li označení D_2^2 pro jednoindexovou matici diagonálních prvků matic D_2 , D_3^3 pro jednoindexovou matici sestavenou z prvků matic D_3 , ježíž všechny tři indexy jsou si rovny, D_3^{21} pro dvojindexovou matici sestavenou z prvků matic D_3 , ježíž první dva indexy jsou si rovny atd., pak pro approximaci od (5) do rádu $O(n^{-2})$ můžeme využít vzorce

$$(7) \quad \begin{aligned} i) \quad & D_1 \cdot [\mathbb{E} (\tilde{df}_n)] = 0 \\ ii) \quad & D_2 \cdot [\mathbb{E} (\tilde{df}_n)^2] = n^{-1} (D_2^2 \cdot (\tilde{p}) - D_2 \cdot (\tilde{p})^2) \\ iii) \quad & D_3 \cdot [\mathbb{E} (\tilde{df}_n)^3] = n^{-2} (D_3^3 \cdot (\tilde{p}) - 3D_3^{21} \cdot (\tilde{p})^2 + 2D_3 \cdot (\tilde{p})^3) \\ iv) \quad & D_4 \cdot [\mathbb{E} (\tilde{df}_n)^4] = 3[(n-1)/n^3] (D_4^{22} \cdot (\tilde{p})^2 - 2D_4^{211} \cdot (\tilde{p})^3 + D_4 \cdot (\tilde{p})^4) + \\ & + n^{-3} (D_4^4 \cdot (\tilde{p}) - 4D_4^{31} \cdot (\tilde{p})^2 + 6D_4^{211} \cdot (\tilde{p})^3 - 3D_4 \cdot (\tilde{p})^4) \end{aligned}$$

které lze odvodit například na základě znalosti smíšených momentů multinomického rozdělení $M(n, p)$. Obdobně lze ověřit platnost identit

$$(8) \quad \begin{aligned} i) \quad & D_{1 \times 1} \cdot [E(\tilde{df}_n)^2] = n^{-1} (D_{1 \times 1}^2(p) - D_{1 \times 1}(p)^2) = n^{-1} \sigma^2(p) \\ ii) \quad & D_{1 \times 2} \cdot [E(\tilde{df}_n)^3] = n^{-2} (D_{1 \times 2}^3(p) - D_{1 \times 2}^2(p)^2 - 2D_{1 \times 2}^2(p)^2 + 2D_{1 \times 2}(p)^3) \\ iii) \quad & D_{1 \times 3} \cdot [E(\tilde{df}_n)^4] = 3[(n-1)/n^3] (D_{1 \times 3}^{22}(p)^2 - D_{1 \times 3}^{211}(p)^3 - D_{1 \times 3}^{112}(p)^3 + D_{1 \times 3}(p)^4) + \\ & + n^{-3} (D_{1 \times 3}^4(p) - 3D_{1 \times 3}^{31}(p)^2 - D_{1 \times 3}^{13}(p)^2 + 3D_{1 \times 3}^{211}(p)^3 + \\ & + 3D_{1 \times 3}^{121}(p)^3 - 3D_{1 \times 3}(p)^4) \end{aligned}$$

použitelných v approximacích ad(6). (Za předpokladu existence s-tého diferenciálu $\delta(\cdot)$ na otevřeném okolí bodu p jsou matice D_k , $k=1, \dots, s$, symetrické vzhledem k záměně svých indexů. Vzorce 7iii)-iv) jsou speciální případy 8ii)-iii) pro symetrické matice.)

V praktických případech bývá vzorec (4) využíván pro odhad $\sigma^2(f_n)$ as. rozptylu $\sigma^2(p)$ (co předpisu (4) dosazujeme f_n na místo p), na němž jsou často založeny intervaly spolehlivosti pro parametr $\delta(p)$ využívající kritických hodnot normovaného normálního rozdělení. Užití approximace ad(3) pro testy hypotéz o skutečné hodnotě parametru $\delta(p)$ však nebere na zážetek skutečnost, že empirické koeficienty $\delta(f_n)$ mohou být často odhady vychýlené. V takové situaci můžeme původní koeficient $\delta(f_n)$ opravit tak, že od něj odečteme odhad vychýlení, získaný dosazením f_n na místo p v předpisu (5) (upraveném podle (7)).

Nejjednodušším odhadem konstruovaným takto pro redukci vychýlení rádu $O(n^{-1})$ bude zřejmě statistika

$$(9) \quad \bar{\delta}_{\tilde{f}_n} \text{ je } \delta_{\tilde{f}_n} - (2n^{-1})(\bar{D}_2 \cdot (\tilde{f}_n) - \bar{D}_2 \cdot (\tilde{f}_n)^2),$$

kde \bar{D}_2 je matice parciálních derivací funkce $\delta(\cdot)$ v bodě \tilde{f}_n . S použitím vzorců (5) a (6) aplikovaných na koeficient $\delta_{\tilde{f}_n}$ lze ověřit platnost vztahů

$$(10) \quad [E \bar{\delta}_{\tilde{f}_n} - \delta(p)] = (2n)^{-1} \bar{D}_2 \cdot [E(\tilde{df}_n)^2] - \frac{1}{3} \bar{D}_3 \cdot [E(\tilde{df}_n)^3] - \frac{1}{24} \bar{D}_4 \cdot [E(\tilde{df}_n)^4] + o(n^{-2}), \quad n \rightarrow \infty.$$

$$(11) \quad E[\bar{\delta}_{\tilde{f}_n} - \delta(p)]^2 = \bar{D}_{1 \times 1} \cdot [E(\tilde{df}_n)^2] + \frac{1}{4} \bar{D}_{2 \times 2} \cdot [E(\tilde{df}_n)^4] - \frac{1}{4} \bar{D}_{2 \times 2} \cdot [E(\tilde{df}_n)^2]^2 + o(n^{-2}) = \\ n^{-1} \sigma^2(p) + \text{Var} \left[\frac{1}{2} \bar{D}_2 \cdot (\tilde{df}_n)^2 \right] + o(n^{-2}), \quad n \rightarrow \infty.$$

Protože vychýlení koeficientu (9) je zřejmě rádu $O(n^{-2})$, je approximace (11) vhodná také pro approximaci rozptylu $\text{Var}[\bar{\delta}_{\tilde{f}_n} - \delta(p)] = \text{Var}[\bar{\delta}_{\tilde{f}_n}]$. Pro účely statistické inference však obvykle vystačíme s členem $n^{-1} \sigma^2(p)$ (resp. s jeho konzistentním odhadem), neboť vzhledem k předpisu (9) je asymptotické rozdělení veličiny $n^{1/2}(\bar{\delta}_{\tilde{f}_n} - \delta(p))$ zřejmě opět $N(0, \sigma^2(p))$.

Teoretických approximací (5), (6), (10) a (11) lze s výhodou použít pro srovnání s koeficienty typu jack-knife, u nichž je docíleno analogických efektů jako u koeficientu $\delta_{\tilde{f}_n}$ a $\sigma^2_{\tilde{f}_n}$ při použití zcela odlišných výpočtových prostředků.

3. ODHADY TYPU JACK-KNIFE A JEJICH ZÁKLADNÍ STATISTICKÉ VLASTNOSTI

O metodách jack-knife je přehledně pojednáno např. v článku [8], kde lze nalézt i značné množství odkazů na literaturu. Z hlediska našeho použití jsou nejvýznamnější reference na [6], [7] a [2].

Za základní jack-knifeový odhad $\hat{\delta}(\tilde{f}_n)$ založený na konzistentním koeficientu $\delta(\tilde{f}_n)$ lze považovat odhad $\hat{\delta}(\tilde{f}_{\tilde{n}})$ definovaný předpisem (viz [8], str. 3)

$$(12) \quad \hat{\delta}(\tilde{f}_{\tilde{n}}) = n \cdot \delta(\tilde{f}_n) - [(n-1)/n] \sum_{i=1}^n \delta(\tilde{f}_{-i}),$$

kde $\delta(\tilde{f}_{-i})$ je odhad koeficientu $\delta(p)$ počítaný z vektoru relativních četností $\tilde{f}_{-i} = \frac{1}{n-1} (n \cdot \tilde{f}_n)_{-i}$ pro vektor $(n \cdot \tilde{f}_n)_{-i}$ vzniklý z $(n \cdot \tilde{f}_n)$ vyřazením (vynecháním, vyškrtnutím) i -tého pozorování. (Je-li $n \cdot \tilde{f}_n = \sum_{i=1}^n e_i$ pro nezávislé n.v. e_i rozdělené multinomický $M(1, p)$, pak $\tilde{f}_{-i} = \frac{1}{n-1} (n \cdot \tilde{f}_n - e_i)$. Za vhodných předpokladů na hladkost funkce $\delta(\cdot)$ lze dokázat asymptotickou normalitu statistiky $n^{1/2}(\hat{\delta}(\tilde{f}_n) - \delta(p))$. K témuž výsledku je možno dojít buď přímočarým souběžněm výsledků článku [6] na hladké funkce výběrového průměru mnohorozměrných statistik nebo správnou aplikací mnohem obecnějšího výsledku pro funkce několika U-statistik: Za předpokladu omezenosti 2. parciálních derivací $\delta(\cdot)$ na okolí bodu p dostáváme (viz [2], str. 2084), že

$$(13) \quad n^{1/2}(\hat{\delta}(\tilde{f}_n) - \delta(p)) \xrightarrow{D} N(0, \sigma^2(p)),$$

kde $\sigma^2(p)$ bylo definováno vzorcem (4). Lze tedy s pomocí koeficientu $\hat{\delta}(\tilde{f}_n)$ provádět analogické testy hypotéz jako s $\delta(\tilde{f}_n)$, resp. $\tilde{\delta}(\tilde{f}_n)$.

Teoreticky je konstrukce odhadu (12) (pořízeného na základě nezávislého náhodného výběru) motivována možností redukce vychýlení řádu $O(n^{-1})$ původního odhadu $\delta(\tilde{f}_n)$ (jak se snadno formálně ověří aplikací symbolu E na předpisu (12)). Přesnější sproximaci vychýlení (řádu $O(n^{-2})$) je možné získat za pomocí rozvoje funkce $\tilde{\delta}(\cdot)$ jakožto lineární kombinace Taylorových rozvojů veličin $\delta(\tilde{f}_n), \delta(\tilde{f}_{-1}), \dots, \delta(\tilde{f}_{-n})$ s následnou aplikací symbolu E .

Výsledek

$$(14) \quad [E \hat{\delta}(\tilde{f}_n) - \delta(p)] = -\frac{1}{6} D_3 \cdot [E(\delta \tilde{f}_n)^3] - \frac{1}{24} D_4 \cdot [E(\delta \tilde{f}_n)^4] + O(n^{-3}), \quad n \rightarrow \infty$$

se nepatrň liší od srovnání sproximace (10) pro $[E \tilde{\delta}(\tilde{f}_n) - \delta(p)]$. Je zajímavé, že obdobně získaná sproximace střední odchylky

$$(15) \quad E[\hat{\delta}(\tilde{f}_n) - \delta(p)]^2 = n^{-1} \sigma^2(p) + \text{Var} \left[\frac{1}{2} D_2 \cdot (\delta \tilde{f}_n)^2 \right] + O(n^{-3}), \quad n \rightarrow \infty$$

do řádu $O(n^{-2})$ vede k témuž vyjádření jako pro $E[\tilde{\delta}(\tilde{f}_n) - \delta(p)]^2$ ve vzoreci (11). Tento výsledek evokuje možnost vzájemné zaměnitelnosti koeficientů $\hat{\delta}(\tilde{f}_n)$ a $\tilde{\delta}(\tilde{f}_n)$. (Poznámka: Zatímco shoda asymptotických rozdělení od (3) a (13) je dána skutečností, že 1. členy Taylorových rozvojů koeficientů $\hat{\delta}(\tilde{f}_n)$ - resp. $\tilde{\delta}(\tilde{f}_n)$ - a $\hat{\delta}(\tilde{f}_n)$ jsou stejné, je eliminace vychýlení řádu $O(n^{-1})$ u $\tilde{\delta}(\tilde{f}_n)$ a $\hat{\delta}(\tilde{f}_n)$ dána specifickou konstrukcí těchto koeficientů. Shoda členů řádu $O(n^{-2})$ v sproximacích středních čtvercových chyb - resp. rozptylů - je však již netriviální vlastností ovlivněnou (skrze $\tilde{\delta}(\cdot)$) speciálním tvarem varianční matice multinomického rozdělení.)

Jack-knifeovému odhadu (12) přísluší dále odhad

$$(16) \quad \widehat{\sigma^2}(\tilde{f}_n) = (n-1) \sum_{i=1}^n (\delta(\tilde{f}_{n-i}) - n^{-1} \sum_{j=1}^n \delta(\tilde{f}_{n-j}))^2,$$

který je analogií výběrové statistiky S^2 pro odhad rozptylu v nezávislém náhodném výběru. Za předpokladu existence 1. totálního diferenciálu funkce $\delta(\cdot)$ na otevřeném okolí bodu p je statistika $\widehat{\sigma^2}(\tilde{f}_n)$ konzistentním odhadem asymptotického rozptylu $\sigma^2(p)$. (Uvedené tvrzení opět vyplývá jako speciální případ z článku [2], str. 2085). Jelikož vyslovený předpoklad zaručuje konzistence i klasickému odhadu $\widehat{\sigma^2}(\tilde{f}_n)$, je zajímavé teoreticky srovnávat i momentové charakteristiky obou těchto odhadů. Aproximace vychýlení a středních čtvercových odchylek lze pro oba koeficienty explicitně vyjádřit do členů řádu $O(n^{-1})$ jakožto funkce tensorových součinů prvních až třetích diferenciálů funkce $\delta(\cdot)$:

$$(17) \quad E \sigma^2(\tilde{f}_n) = \frac{n-1}{n} \sigma^2(p) + n^{-1} \left\{ 2D_{1 \times 2} [E(\tilde{d}\tilde{e})^3] + D_{1 \times 3} [E(\tilde{d}\tilde{e})^2 \times E(\tilde{d}\tilde{e})^2] + D_{2 \times 2} [E((\tilde{d}\tilde{e}_I) \times (\tilde{d}\tilde{e}_{II})^2 \times (\tilde{d}\tilde{e}_I))] \right\} + o(n^{-1}), \quad n \rightarrow \infty,$$

$$(18) \quad E[\sigma^2(\tilde{f}_n) - \sigma^2(p)]^2 = n^{-1} \left\{ D_{1 \times 1 \times 1 \times 1} [E(\tilde{d}\tilde{e})^4 - E(\tilde{d}\tilde{e})^2 \times E(\tilde{d}\tilde{e})^2] \right\} + 4n^{-1} \left\{ D_{1 \times 2 \times 1 \times 1} [E(\tilde{d}\tilde{e})^2 \times E(\tilde{d}\tilde{e})^3] + D_{1 \times 2 \times 2 \times 1} [E(\tilde{d}\tilde{e})^2 \times E(\tilde{d}\tilde{e})^2 \times E(\tilde{d}\tilde{e})^2] \right\} + o(n^{-1}), \quad n \rightarrow \infty;$$

$$(19) \quad E \widehat{\sigma^2}(\tilde{f}_n) = \sigma^2(p) + n^{-1} \left\{ D_{1 \times 2} [E(\tilde{d}\tilde{e})^3] + D_{1 \times 3} [E(\tilde{d}\tilde{e})^2 \times E(\tilde{d}\tilde{e})^2] + D_{2 \times 2} [E((\tilde{d}\tilde{e}_I) \times (\tilde{d}\tilde{e}_{II})^2 \times (\tilde{d}\tilde{e}_I))] \right\} + o(n^{-1}), \quad n \rightarrow \infty,$$

$$(20) \quad E[\widehat{\sigma^2}(\tilde{f}_n) - \sigma^2(p)]^2 = E[\sigma^2(\tilde{f}_n) - \sigma^2(p)]^2 + o(n^{-1}), \quad n \rightarrow \infty;$$

kde \tilde{d}, \tilde{d}_I a \tilde{d}_{II} jsou nezávislé multinomické vektory s rozdělením $M(1, p)$. (Hodnoty $E(\tilde{d}\tilde{e})^2$, $E(\tilde{d}\tilde{e})^3$ a $E(\tilde{d}\tilde{e})^4$ lze spočítat dosazením do vzorců (7) a (8) pro $\xi = \tilde{f}_1$ a $n=1$.)

Shodu sproximací (18) a (20) (která vzniká z analogických příčin jako při sproximaci středních čtvercových chyb koeficientů $\delta(\tilde{f}_n)$ a $\widehat{\delta}(\tilde{f}_n)$) lze interpretovat jako shodu asymptotických rozptylů n.v. $n^{1/2}[\sigma^2(\tilde{f}_n) - \sigma^2(p)]$ a $n^{1/2}[\widehat{\sigma^2}(\tilde{f}_n) - \sigma^2(p)]$ nazývaných opět jako hladké funkce normovaného multinomického rozdělení. Z hlediska této shody poskytuje sproximace (17) a (19) snadné kriterium, na jehož základě je možné rozhodovat, který z obou koeficientů má (jakožto bodový odhad parametru $\sigma^2(p)$) menší (resp. větší) vychýlení: Pokud pro konkrétní koeficient $\delta(\cdot)$ platí nerovnost

$$(21) \quad D_{1 \times 2} [E(\tilde{d}\tilde{e})^3] - \sigma^2(p) > 0,$$

je výhodnější užití jack-knifeového odhadu $\widehat{\sigma^2}(\tilde{f}_n)$, v případě opačné nerovnosti může menší vychýlení (řádu $O(n^{-1})$) koeficient $\sigma^2(\tilde{f}_n)$.

4. ZÍVĚRY PRO PRAKTICKÉ APLIKACE

Praktická použitelnost prezentovaných jack-knifeových odhadů (a s ní spojených teoretických sproximací předchozí státi) pro funkce frekvenčního (normovaného multinomického) vektoru \tilde{f}_n vyplývá z povšimnutí, že výpočetní vzorce předpisů (12) a (16) lze ve skutečnosti přepsat jako

$$(*) \quad \hat{\delta}(\tilde{f}_n) = n \cdot \delta(\tilde{f}_n) - [(n-1)/n] \sum_{j=1}^n n_j \cdot \delta(\tilde{f}_{-j})$$

$$(**) \quad \widehat{\sigma^2}(\tilde{f}_n) = (n-1) \left[\sum_{j=1}^n n_j (\delta(\tilde{f}_{-j}))^2 - n^{-1} \left(\sum_{j=1}^n n_j \cdot \delta(\tilde{f}_{-j}) \right)^2 \right]$$

n_j značí absolutní četnost v j -té třídě multinomického vektoru $n \cdot \tilde{f}_n$, neboť vynechání i -tého pozorování (respondenta) se v každé j -té třídě opakuje n_j -krát s týmž výsledkem $\delta(\tilde{f}_{-j})$. To znamená, že stačí počítat "navíc" (proti původnímu odhadu $\delta(\tilde{f}_n)$) pouze hodnot $\delta(\tilde{f}_{-j})$, což je při operační rychlosti současné výpočetní techniky záležitost zcela zanedbatelná.

Druhou výhodu metody jack-knife lze spatřovat v tom, že její užití není závislé na explicitním výpočtu diferenciálů funkce $\delta(\cdot)$, přestože výsledný efekt (v případě $\widehat{\delta}(\tilde{f}_n)$ -redukce vychýlení řádu $O(n^{-1})$ a vliv na střední čtvercovou odchylku do řádu $O(n^{-2})$; v případě $\widehat{\sigma^2}(\tilde{f}_n)$ ovlivnění asymptotického rozptylu) odpovídá použití klasických metod s diferenciály. Tato vlastnost přímo vybízí k tomu, aby "jack-knifeování" bylo zavedeno jako univerzální podprogram do prakticky užívaných statistických procedur, kde např. pro danou kontingenční tabulku (ziškanou multinomickým způsobem výběru) bývá počítáno několik různých koeficientů asociace současně.

Nevýhodou výše popsané metody jackknife při užití na konkrétních koeficientech asociace je vlastnost, že odhad $\widehat{\delta}(\tilde{f}_n)$ ze vzorce (12) (resp. (**)) nemusí padnout do oboru hodnot původního (omezeného) koeficientu $\delta(\tilde{f}_n)$ (resp. $\delta(p)$), což by vedlo ke sporu s jeho interpretací. Podobně jako u koeficientu $\widehat{\delta}(\tilde{f}_n)$ k tomuto dochází, když n je malé, že vychýlení odhadu $\widehat{\delta}(\tilde{f}_n)$ podstatným způsobem ovlivňuje i členy vyšších řádů ($O(n^{-2})$). V těchto situacích bývají ovšem problémy i s použitím normální approximace (3), takže odhady $\widehat{\delta}(\tilde{f}_n)$, $\widehat{\delta}(\tilde{f}_n)$ i $\widehat{\sigma^2}(\tilde{f}_n)$ a $\widehat{\sigma^2}(\tilde{f}_n)$ jsou příliš hrubé. Odstranit tuto nevýhodu by bylo možné přechodem k analogickým odhadům akceptujícím i členy řádu $O(n^{-2})$, což (v případě klasických odhadů) umožnuje jemnější užití approximací ad (5) a (6) nebo (v případě jack-knifeových metod) použití tzv. jack-knifeování 2. řádu (viz [8], str. 2).

Pozn.: Při formulaci approximačních vzorců pro vychýlení a střední čtvercové odchylky v textu uvažovaných koeficientů nebyly z úsporných důvodů stanoveny předpoklady na stupeň diferencovatelnosti funkce $\delta(\cdot)$, jejíž diferenciály se v těchto approximacích vyskytují. Obecně lze říci, že ve vzorcích s vyjádřením zbytku ve tvaru $o(\cdot)$ vystačíme s předpokladem existence nejvyššího diferenciálu D_s v daném vzorci se vyskytujícím. Podobně jako v případě approximace (13) lze však ověřit nutnost nepatrné silnějších předpokladů (typu existence omezených $(s+1)$ -ních parciálních derivací funkce $\delta(\cdot)$ v bodě p) při ověření platnosti srovnatelných vyjádření pro koeficient $\widehat{\delta}(\tilde{f}_n)$. Tento zesílený předpoklad (v approximacích (14) a (15) se indikuje řádem zbytku $O(\cdot)$) však jistě nebude bránit možnostem praktického používání tohoto koeficientu.

LITERATURA:

- [1] Anděl J. (1978): Matematická statistika, SNTL, Praha
- [2] Arvesen J.N. (1969): Jack-knifing U-statistics, AMS 40, 2076-100
- [3] Běláček J. (1981): Asymptotické vlastnosti korelačního poměru χ^2 odvozeného z kontingenční tabulky, Diplomová práce, MFF UK
- [4] Hurt J. (1976): Asymptotický rozvoj funkcí statistik, Aplikace matematiky 6, 21/1986
- [5] Hurt J. (1978): Asymptotic expansions for moments of functions of statistics, Proceedings of the 2-nd Prague Symp. on As. Statistics, 21-25 August, 233-238
- [6] Miller R. (1964): A trustworthy jack-knife, AMS 35, 1594-605
- [7] Miller R. (1968): Jackknifing variances, AMS 39, 567-82
- [8] Miller R. (1974): The jackknife-review, Biometrika 61
- [9] Rao C.R. (1978): Lineární metody statistické indukce a jejich aplikace, Academia, Praha
- [10] Sikorski R. (1973): Diferenciální a integrální počet, 52-59, 163-174