

M. BIENKIEWICZ (Łódź)

## O metodzie „jackknife”

(Praca wpłynęła do Redakcji 14.04.1980)

**0. Wstęp.** Jackknife to w dosłownym tłumaczeniu scyzoryk, a więc ostre i praktyczne narzędzie. W statystyce nazwa jackknife określa metodę redukcji obciążenia estymatorów, zaproponowaną przez M. H. Quenouille'a w 1956 r. [6]. Zagadnieniami związanymi z jackknifem od szeregu już lat zajmują się liczni matematycy, m.in. A. F. Bissel, R. A. Ferguson, H. L. Gray, L. A. Jaeckel, R. G. Miller, W. R. Schucany i T. A. Watkins, ale sprawa możliwości zastosowań tej techniki jest nadal otwarta. Ponieważ w polskiej literaturze matematycznej brak jest omówień tej problematyki, poniższa praca ma charakter informacyjny, stanowiąc zarazem pewną próbę przedstawienia teorii dotyczącej jackknife'u.

Nazwę jackknife wprowadził J. W. Tukey, chociaż — jak wyżej wspomniano — nie on był twórcą metody. Zaproponowana przez Tukey'a nazwa sugeruje, że narzędzie to ma być „ostre i szybkie w użyciu”. Mam pewne opory z przeniesieniem na nasz grunt dokładnego tłumaczenia tej nazwy, gdyż żadne z określeń: nóż, scyzoryk, czy po prostu ostrze nie brzmi dobrze ani jako nazwa estymatora, ani jako nazwa metody (nóż? nożowanie? estymator nożowy?). Poczekam więc chętnie w tej kwestii na sugestie innych, a sama, na użytek chociażby tej pracy, posługiwać się będę nazwami: jackknife i jackknifing.

Jackknife jest metodą lub techniką — aby nie użyć często spotykanego w literaturze określenia — matematyczną sztuczką, która pozwala zredukować obciążenie większości estymatorów i estymować ich wariancję (bez względu na rozkład próby). Uwalnia ona więc statystyków od często kwestionowanych założeń o rozkładzie, a przez to ma bezpośredni związek z zagadnieniem odporności. Oczywiście nieobciążoność estymatorów jest tylko jednym z aspektów dobrej estymacji i dlatego jackknife nie zawsze będzie dawał najlepsze rozwiązania, ale i w swoim założeniu nie ma to być narzędzie uniwersalne.

**1. Jackknife — definicja ogólna.** Niech  $\{\mathcal{X}, \mathcal{A}, (P_\theta; \theta \in \Theta)\}$  będzie modelem statystycznym i niech zadanie polega na estymacji parametru  $\theta$  indeksującego rodzinę rozkładów prawdopodobieństwa na  $\mathcal{A}$ . Interesować nas przy tym będą estymatory nieobciążone, a więc takie estymatory  $T$ , że  $E_\theta T = \theta$ . Estymatory parametru  $\theta$  oznaczать będziemy przez  $\hat{\theta}$  lub ewentualnie  $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_i, \dots$

**DEFINICJA 1.** Niech  $\hat{\theta}_1, \hat{\theta}_2$  będą ustalonymi estymatorami parametru  $\theta$ . Uogólnionym jackknife'm estymatorów  $\hat{\theta}_1, \hat{\theta}_2$  nazywamy estymator  $G(\hat{\theta}_1, \hat{\theta}_2)$  określony wzorem:

$$(1) \quad G(\hat{\theta}_1, \hat{\theta}_2) = \frac{\hat{\theta}_1 - R\hat{\theta}_2}{1 - R},$$

gdzie  $R \neq 1$  jest dowolną, ale ustaloną liczbą rzeczywistą.

Zauważmy, że jeżeli wartości oczekiwane estymatorów  $\hat{\theta}_1, \hat{\theta}_2$  wynoszą odpowiednio:

$$\begin{aligned} E\hat{\theta}_1 &= \theta + b_1(n, \theta), \\ E\hat{\theta}_2 &= \theta + b_2(n, \theta), \quad b_2(n, \theta) \neq 0, \end{aligned}$$

to dla  $R = b_1(n, \theta)/b_2(n, \theta)$  estymator  $G(\hat{\theta}_1, \hat{\theta}_2)$  jest nieobciążony.

Często obciążenia rozważanych estymatorów mają pewną szczególną postać, np

$$(2) \quad E\hat{\theta} - \theta = \frac{1}{n} g_1(\theta) + \frac{1}{n} g_2(\theta) + \dots$$

Ogólniej, załóżmy, że

$$\begin{aligned} E\hat{\theta}_1 &= \theta + \sum_{i=1}^{\infty} b_{1i}(n, \theta), \\ E\hat{\theta}_2 &= \theta + \sum_{i=1}^{\infty} b_{2i}(n, \theta). \end{aligned}$$

Jeżeli teraz  $b_{11}(n, \theta)/b_{12}(n, \theta) \neq 1$ , a we wzorze (1) przyjmiemy  $R = b_{11}(n, \theta)/b_{12}(n, \theta)$ , to

$$EG(\hat{\theta}_1, \hat{\theta}_2) = \theta + \left( \sum_{i=2}^{\infty} b_{1i}(n, \theta) - R \sum_{i=2}^{\infty} b_{2i}(n, \theta) \right) / (1 - R),$$

a więc obciążenie  $G(\hat{\theta}_1, \hat{\theta}_2)$  jest mniejszego rzędu niż obciążenia każdego z estymatorów  $\hat{\theta}_1, \hat{\theta}_2$ .

**2. Opis metody Quenouille'a.** Definiując uogólniony jackknife  $G(\hat{\theta}_1, \hat{\theta}_2)$  zakładaliśmy, że dane są estymatory (obciążone)  $\hat{\theta}_1$  oraz  $\hat{\theta}_2$ . Obecnie zajmiemy się zagadnieniem wyboru tych dwóch estymatorów, przedstawiając pewną konstrukcję podaną przez Quenouille'a [6].

Niech  $X_1, \dots, X_n$  będzie ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie („próbą losową”) i niech  $\hat{\theta} = \hat{\theta}_n = \hat{\theta}_n(X_1, \dots, X_n)$  będzie estymatorem parametru  $\theta$ , opartym na tej próbie losowej. Załóżmy przy tym, że estymator  $\hat{\theta}_n$  jest określony dla każdego  $n = 1, 2, \dots$

Daną próbę dzielimy w sposób losowy na  $N$  rozłącznych podzbiorów o rozmiarze  $M$  każdy. Oczywiście,  $n = N \cdot M$ . Bez zmniejszania ogólności rozważań można

przyjąć, że dokonany podział ma postać:

$$(X_1, \dots, X_M), (X_{M+1}, \dots, X_{2M}), \dots, (X_{(N-1)M+1}, \dots, X_{NM}).$$

Tworzymy nową  $(N-1)M$ -elementową próbę losową pomijając  $i$ -ty podzbiór i określamy estymator:

$$(3) \quad \hat{\theta}^i = \hat{\theta}_{n-M} = \hat{\theta}(X_1, \dots, X_{(i-1)M}, X_{iM+1}, \dots, X_n); \quad i = 1, \dots, N.$$

DEFINICJA 2. *Pseudowartościami jackknife* nazywamy estymatory

$$(4) \quad J_i(\hat{\theta}) = N\hat{\theta} - (N-1)\hat{\theta}^i$$

a *jackknife'm*  $J(\hat{\theta})$  ich średnią arytmetyczną, tzn.

$$(5) \quad J(\hat{\theta}) = \frac{1}{N} \sum_{i=1}^N J_i(\hat{\theta}) = N\hat{\theta} - (N-1)\hat{\theta},$$

gdzie

$$\hat{\theta} = \frac{1}{N} \sum_{i=1}^N \hat{\theta}^i.$$

Zauważmy, że tak skonstruowany estymator  $J(\hat{\theta})$  jest szczególnym przypadkiem uogólnionego jackknife'u postaci (1). Istotnie, przyjmując  $\hat{\theta}_1 = \hat{\theta}$ ,  $\hat{\theta}_2 = \hat{\theta}$  oraz  $R = R(N) = (N-1)/N$ , mamy  $G(\hat{\theta}_1, \hat{\theta}_2) = J(\hat{\theta})$ . W dalszym ciągu rozważań wygodnie będzie utożsamiać estymator  $G(\hat{\theta}_1, \hat{\theta}_2)$  o parametrze  $R = (N-1)/N$  z estymatorem  $J(\hat{\theta})$ .

Aby wyznaczyć obciążenie tak określonego jackknife'u załóżmy, że estymator  $\hat{\theta}$  jest obciążony i że wartość oczekiwana tego estymatora ma postać

$$E\hat{\theta} = \theta + \sum_{i=1}^{\infty} \frac{a_i}{n^i} = \theta + \sum_{i=1}^{\infty} \frac{a_i}{N^i M^i},$$

gdzie  $a_i$  mogą być funkcjami parametru  $\hat{\theta}$ , ale nie liczności próby  $n$ . Okazuje się, że sytuacja taka ma miejsce w przypadku większości praktycznie używanych estymatorów. Otrzymujemy

$$E\hat{\theta} = \theta + \sum_{i=1}^{\infty} \frac{a_i}{(n-M)^i} = \theta + \sum_{i=1}^{\infty} \frac{a_i}{(N-1)^i M^i},$$

a stąd

$$\begin{aligned} EJ(\hat{\theta}) &= \theta - \frac{a_2}{M^2 N(N-1)} - \frac{a_3}{M^3 N^2(N-1)^2} - \dots = \\ &= \theta - \frac{a_2}{n(n-M)} - \frac{a_3}{n^2(n-M)^2} - \dots \end{aligned}$$

Obciążenie estymatora  $J(\hat{\theta})$  jest więc rzędu  $n^{-2}$ , podczas gdy obciążenie  $\hat{\theta}$ , przy  $a_1 \neq 0$ , było rzędu  $n^{-1}$ . Ponadto, gdy  $a_2 = a_3 = \dots = 0$ , jackknife  $J(\hat{\theta})$  jest nieobciążony.

### 3. Przykłady.

**PRZYKŁAD 1. Schemat Bernoullie'go.** Wykonujemy  $n$  niezależnych prób, z których każda z prawdopodobieństwem  $p$  kończy się sukcesem lub z prawdopodobieństwem  $1-p$  — porażką. Niech  $X_i$  będzie zmienną losową przyjmującą wartość 1, gdy  $i$ -ta próba kończy się sukcesem i wartość 0, gdy  $i$ -ta próba kończy się porażką. Łączna liczba sukcesów

$$X = \sum_{i=1}^n X_i$$

określa zmienną losową, która ma rozkład dwumianowy:

$$f(x) = \binom{n}{x} p^x (1-p)^{n-x}, \quad x = 0, 1, \dots, n.$$

Niech zadanie polega na estymacji  $p^2$ . Ponieważ  $X/n$  jest nieobciążonym estymatorem parametru  $p$ , to rozważmy

$$\hat{\theta} = (X/n)^2.$$

Jest to estymator obciążony, gdyż

$$E\hat{\theta} = p^2 + \frac{1}{n}(p-p^2).$$

Dla estymatorów  $\hat{\theta}^i$  (wzór (3)) otrzymujemy wartości:

$$((X-1)/(n-1))^2 \quad \text{lub} \quad (X/(n-1))^2,$$

w zależności od tego czy pominięta próba była sukcesem czy porażką. Średnia  $\hat{\theta}$  jest równa:

$$\hat{\theta} = \frac{1}{n} \left[ X \left( \frac{X-1}{n-1} \right)^2 + (n-X) \left( \frac{X}{n-1} \right)^2 \right] = \frac{(n-2)X^2 + X}{n(n-1)^2},$$

a stąd, na mocy wzoru (5)

$$J(\hat{\theta}) = \frac{X(X-1)}{n(n-1)}.$$

Otrzymana modyfikacja  $J(\hat{\theta})$  estymatora  $\hat{\theta}$  jest estymatorem nieobciążonym, gdyż  $EJ(\hat{\theta}) = p^2$ .

**PRZYKŁAD 2. Rozkład równomierny.** Niech  $X_1, \dots, X_n$  będzie próbą losową z rozkładu równomiernego na przedziale  $(0, \theta)$  i niech  $X_{(1)}, \dots, X_{(n)}$  będą statystykami pozycyjnymi z tej próby. Rozpatrzmy następujący estymator parametru  $\theta$ :

$$\hat{\theta} = \max(X_1, \dots, X_n) = X_{(n)}.$$

Jest to estymator obciążony, gdyż  $E\hat{\theta} = \theta - \theta/(n+1)$ . Jest oczywiste, że  $(n+1)/n\hat{\theta}$  byłoby estymatorem nieobciążonym, ale warto również i w tym przypadku prześledzić konstrukcję jackknife’u opisaną w punkcie 2.

Zauważmy, że

$$\hat{\theta}^i = \begin{cases} X_{(n)}, & \text{gdy } X_i \neq X_{(n)}, \\ X_{(n-1)}, & \text{gdy } X_i = X_{(n)}, \end{cases}$$

a stąd

$$\hat{\theta} = \frac{1}{n} ((n-1)X_{(n)} + X_{(n-1)}).$$

Zgodnie z konstrukcją Quenouille’a mamy:

$$J(\hat{\theta}) = X_{(n)} + \frac{n-1}{n} (X_{(n)} - X_{(n-1)}).$$

Jest to wprawdzie estymator obciążony, ale obciążenie jego jest mniejsze od obciążenia estymatora  $\hat{\theta}$ , gdyż

$$EJ(\hat{\theta}) = \theta - \theta/(n(n+1)).$$

Skonstruujmy z kolei uogólniony estymator  $G(\hat{\theta}_1, \hat{\theta}_2)$ , który jak wiemy będzie nieobciążony, jeżeli tylko właściwie wybierzemy parametr  $R$ . Przyjmijmy

$$R = \frac{E(\hat{\theta} - \theta)}{E(\hat{\theta} - \theta)} = \frac{n}{n+1}.$$

Wtedy

$$G(\hat{\theta}_1, \hat{\theta}_2) = (\hat{\theta} - R\hat{\theta})/(1-R) = 2X_{(n)} - X_{(n-1)}$$

i istotnie  $G(\hat{\theta}_1, \hat{\theta}_2)$  jest estymatorem nieobciążonym, gdyż  $EG(\hat{\theta}_1, \hat{\theta}_2) = 2EX_{(n)} - EX_{(n-1)} = \theta$ .

Pokażemy teraz, że redukcja obciążenia estymatora nie musi prowadzić do pogorszenia innych jego własności, np. błędu średniokwadratowego (MSE). W rozważanym przypadku mamy:

$$\text{MSE}(\hat{\theta}) = 2\theta^2/((n+1)(n+2)),$$

$$\text{MSE}G(\hat{\theta}_1, \hat{\theta}_2) = 2\theta^2/((n+1)(n+2)),$$

oraz

$$\text{MSE}J(\hat{\theta}) = 2\theta^2(n^2 - n + 1)/(n^2(n+1)(n+2)).$$

Okazuje się więc, że obciążenia estymatorów  $J(\hat{\theta})$  oraz  $G(\hat{\theta}_1, \hat{\theta}_2)$  są mniejsze niż obciążenie estymatora  $\hat{\theta}$ , przy czym  $\text{MSE}J(\hat{\theta}) < \text{MSE}\hat{\theta}$  dla  $n \geq 2$  oraz  $\text{MSE}G(\hat{\theta}_1, \hat{\theta}_2) = \text{MSE}\hat{\theta}$ .

4. Własności estymatorów typu jackknife. Niech  $\hat{\theta}_1, \hat{\theta}_2$  będą estymatorami parametru  $\theta$  określonymi na próbie o liczności  $n$  i niech

$$b_1(n, \theta) = E(\hat{\theta}_1 - \theta) \neq 0,$$

$$b_2(n, \theta) = E(\hat{\theta}_2 - \theta) \neq 0.$$

Jeżeli  $|\lim_{n \rightarrow \infty} b_1(n, \theta)/b_2(n, \theta)| = 1$ , to mówimy, że  $\hat{\theta}_1$  jest estymatorem o tym samym rzędzie obciążenia co  $\hat{\theta}_2$  i piszemy  $\hat{\theta}_1 \sim \hat{\theta}_2$ .

Jeżeli  $0 < |\lim_{n \rightarrow \infty} b_1(n, \theta)/b_2(n, \theta)| < 1$ , to mówimy, że  $\hat{\theta}_1$  jest lepszym estymatorem o tym samym rzędzie obciążenia co  $\hat{\theta}_2$ , i piszemy  $\hat{\theta}_1 \lesssim \hat{\theta}_2$ .

Jeżeli  $\lim_{n \rightarrow \infty} b_1(n, \theta)/b_2(n, \theta) = 0$  (bez założenia, że  $b_1(n, \theta) \neq 0$ ), to mówimy, że  $\hat{\theta}_1$  jest estymatorem o niższym rzędzie obciążenia niż  $\hat{\theta}_2$  i piszemy  $\hat{\theta}_1 \prec \hat{\theta}_2$ .

LEMAT 1. Jeżeli  $\hat{\theta}$  jest estymatorem parametru  $\theta$ , określonym na próbie losowej  $X_1, \dots, X_n$ , oraz

$$E(\hat{\theta} - \theta) = b(n, \theta),$$

to

$$(6) \quad EJ(\hat{\theta}) = \theta + b(n, \theta) + (n-1)\Delta b(n, \theta),$$

gdzie

$$\Delta b(n, \theta) = b(n, \theta) - b(n-1, \theta).$$

Dla dowodu wystarczy zauważyć, że

$$J(\hat{\theta}) = \hat{\theta} + (n-1)((\hat{\theta} - \theta) - (\hat{\theta} - \theta))$$

oraz

$$E(\hat{\theta} - \theta) = b(n-1, \theta),$$

co wynika bezpośrednio z założenia i definicji estymatora  $\hat{\theta}$ .

TWIERDZENIE 1. Jeżeli istnieje taka liczba  $p > 0$ , że spełnione są warunki

$$\lim_{n \rightarrow \infty} n^p b(n, \theta) = C(\theta), \text{ przy czym } C(\theta) \text{ jest skończone i różne od zera,}$$

$$\lim_{n \rightarrow \infty} n^{p+1} \Delta b(n, \theta) \text{ istnieje,}$$

to

$$(i) \quad p = 1 \Rightarrow J(\hat{\theta}) \prec \hat{\theta},$$

$$(ii) \quad p < 2, p \neq 1 \Rightarrow J(\hat{\theta}) \lesssim \hat{\theta},$$

$$(iii) \quad p = 2 \Rightarrow J(\hat{\theta}) \sim \hat{\theta},$$

$$(iv) \quad p > 2 \Rightarrow \hat{\theta} \lesssim J(\hat{\theta}).$$

Podobne twierdzenie można sformułować dla uogólnionego jackknife'u  $G(\hat{\theta}) = G(\hat{\theta}_1, \hat{\theta}_2)$ .

**TWIERDZENIE 2.** Niech  $b(n, \theta) \neq 0$  i niech  $p > 0$  będzie liczbą spełniającą założenia twierdzenia 1. Jeżeli

$$R(n) = [(n-1)/n]^m, \quad m > 0,$$

to

- (i)  $p = m \Rightarrow G(\hat{\theta}) < \hat{\theta}$ ,
- (ii)  $0 < p < 2m, p \neq m \Rightarrow G(\hat{\theta}) \lesssim \hat{\theta}$ ,
- (iii)  $p = 2m \Rightarrow G(\hat{\theta}) \sim \theta$ ,
- (iv)  $p > 2m \Rightarrow \hat{\theta} \lesssim G(\hat{\theta})$ ,
- (v)  $p = m \neq 1 \Rightarrow G(\hat{\theta}) < J(\hat{\theta})$ ,
- (vi)  $\left. \begin{array}{l} p > 1, 1 < m < p/(2-p) \\ p < 1, p/(2-p) < m < 1 \end{array} \right\} \Rightarrow G(\hat{\theta}) \lesssim J(\hat{\theta})$ ,
- (vii)  $p = m = 1 \Rightarrow G(\hat{\theta}) \sim J(\hat{\theta})$ ,
- (viii)  $\left. \begin{array}{l} p > 1, m < 1 \\ p < 1, m > 1 \end{array} \right\} \Rightarrow J(\hat{\theta}) \lesssim G(\hat{\theta})$ ,
- (ix)  $p = 1, m \neq 1 \Rightarrow J(\hat{\theta}) < G(\hat{\theta})$ .

Aby udowodnić twierdzenie 1, wystarczy posłużyć się lematem 1 i pewnymi własnościami ciągów monotonicznych. Otrzymuje się wtedy

$$\left| \lim_{n \rightarrow \infty} \frac{E(J(\hat{\theta}) - \theta)}{E(\hat{\theta} - \theta)} \right| = \left| 1 + \lim_{n \rightarrow \infty} \frac{(n-1) \Delta b(n, \theta)}{b(n, \theta)} \right| = |1 - p|,$$

skąd już w sposób oczywisty wynikają kolejne tezy twierdzenia 1.

Dla dowodu twierdzenia 2 zauważmy, że dla  $R(n) = ((n-1)/n)^m$  mamy

$$\lim_{n \rightarrow \infty} \frac{1}{n-1} \frac{R(n)}{1-R(n)} = \frac{1}{m}$$

a z dowodu twierdzenia 1

$$\lim_{n \rightarrow \infty} (n-1) \frac{\Delta b(n, \theta)}{b(n, \theta)} = -p.$$

Stąd

$$\begin{aligned} \left| \lim_{n \rightarrow \infty} \frac{E(G(\hat{\theta}) - \theta)}{E(\hat{\theta} - \theta)} \right| &= \left| \lim_{n \rightarrow \infty} \frac{(b(n, \theta) - R(n)b(n-1, \theta))/(1-R(n))}{b(n, \theta)} \right| = \\ &= \left| \lim_{n \rightarrow \infty} \left( 1 + \frac{R(n)}{1-R(n)} \frac{\Delta b(n, \theta)}{b(n, \theta)} \right) \right| = \\ &= \left| \lim_{n \rightarrow \infty} \left( 1 + \frac{R(n)}{1-R(n)} \frac{1}{1-n} \cdot (n-1) \frac{\Delta b(n, \theta)}{b(n, \theta)} \right) \right| = \\ &= \left| 1 - \frac{p}{m} \right|; \end{aligned}$$

więc tezy (i)–(iv) są natychmiastowe. Aby wykazać (vii) zauważmy, że dla  $p = m = 1$   $J(\hat{\theta}) = G(\hat{\theta})$  więc  $J(\hat{\theta}) \sim G(\hat{\theta})$ . Ponieważ

$$\left| \lim_{n \rightarrow \infty} \frac{E(G(\hat{\theta}) - \theta)}{E(J(\hat{\theta}) - \theta)} \right| = \left| \lim_{n \rightarrow \infty} \frac{E(G(\hat{\theta}) - \theta)/E(\hat{\theta} - \theta)}{E(J(\hat{\theta}) - \theta)/E(\hat{\theta} - \theta)} \right| = \left| \frac{1 - p/m}{1 - p} \right|,$$

to na mocy przyjętych określeń mamy (v)–(ix), co kończy dowód.

Aby zilustrować przedstawione twierdzenia zauważmy, że w omawianym wcześniej przykładzie 2 mieliśmy

$$\hat{\theta} = X_{(n)} \quad \text{i} \quad b(n, \theta) = -\theta/(n+1).$$

Stąd dla  $p = 1$

$$\lim_{n \rightarrow \infty} n^p b(n, \theta) = -\theta = C(\theta)$$

i

$$\lim_{n \rightarrow \infty} n^{p+1} \Delta b(n, \theta) = \lim_{n \rightarrow \infty} n\theta/(n+1) = \theta,$$

więc zgodnie z tezą (i) twierdzenia 1 mamy  $J(\hat{\theta}) < \hat{\theta}$ , co rzeczywiście miało miejsce, gdyż

$$\lim_{n \rightarrow \infty} \frac{E(J(\hat{\theta}) - \theta)}{E(\hat{\theta} - \theta)} = \lim_{n \rightarrow \infty} \frac{-\theta/(n(n+1))}{-\theta/(n+1)} = 0.$$

**5. Jackknife wyższego rzędu.** Rozważmy ponownie estymator  $G(\hat{\theta}_1, \hat{\theta}_2)$ , który dla  $R = a_{11}/a_{12}$  można zapisać w postaci:

$$(7) \quad G(\hat{\theta}_1, \hat{\theta}_2) = \frac{\begin{vmatrix} \hat{\theta}_1 & \hat{\theta}_2 \\ a_{11} & a_{12} \end{vmatrix}}{\begin{vmatrix} 1 & 1 \\ a_{11} & a_{12} \end{vmatrix}}.$$

Wzór ten sugeruje następujące uogólnienie:

**DEFINICJA 3.** Niech  $\hat{\theta}_1, \dots, \hat{\theta}_{k+1}$  będą estymatorami parametru  $\theta$ , określonymi na próbie losowej  $X_1, \dots, X_n$  i niech  $a_{ij}$ ,  $i = 1, \dots, k$ ,  $j = 1, \dots, k+1$  będą takimi liczbami rzeczywistymi, że wyznacznik

$$(8) \quad \begin{vmatrix} 1 & 1 & \dots & 1 \\ a_{11} & a_{12} & \dots & a_{1k+1} \\ \dots & \dots & \dots & \dots \\ a_{k1} & a_{k2} & \dots & a_{kk+1} \end{vmatrix}$$

jest różny od zera. Uogólnionym jackknife'm  $k$ -tego rzędu nazywać będziemy esty-



mator  $G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1})$ , określony wzorem

$$(9) \quad G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}) = \frac{\begin{vmatrix} \hat{\theta}_1 & \hat{\theta}_2 & \dots & \hat{\theta}_{k+1} \\ a_{11} & a_{12} & \dots & a_{1k+1} \\ \dots & \dots & \dots & \dots \\ a_{k1} & a_{k2} & \dots & a_{kk+1} \end{vmatrix}}{\begin{vmatrix} 1 & 1 & \dots & 1 \\ a_{11} & a_{12} & \dots & a_{1k+1} \\ \dots & \dots & \dots & \dots \\ a_{k1} & a_{k2} & \dots & a_{kk+1} \end{vmatrix}}.$$

Jeżeli obciążenia estymatorów  $\hat{\theta}_1, \dots, \hat{\theta}_{k+1}$  dadzą się zapisać jako iloczyny pewnej funkcji liczności próby  $n$  i funkcji parametru  $\theta$ , to prawdziwe jest następujące twierdzenie:

**TWIERDZENIE 3.** *Jeżeli*

$$E\hat{\theta}_j - \theta = \sum_{i=1}^{\infty} f_{ij}(n)b_i(\theta), \quad j = 1, \dots, k+1$$

oraz wyznacznik (8) dla  $a_{ij} = f_{ij}(n)$  jest różny od zera, to

$$EG(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}) = \theta + b_G(n, \theta),$$

gdzie

$$b_G(n, \theta) = \frac{\begin{vmatrix} b_1^* & b_2^* & \dots & b_{k+1}^* \\ f_{11} & f_{12} & \dots & f_{1k+1} \\ \dots & \dots & \dots & \dots \\ f_{k1} & f_{k2} & \dots & f_{kk+1} \end{vmatrix}}{\begin{vmatrix} 1 & 1 & \dots & 1 \\ f_{11} & f_{12} & \dots & f_{1k+1} \\ \dots & \dots & \dots & \dots \\ f_{k1} & f_{k2} & \dots & f_{kk+1} \end{vmatrix}}$$

oraz

$$b_j^* = \sum_{i=k+1}^{\infty} f_{ij}(n)b_i(\theta), \quad j = 1, \dots, k+1,$$

Dowód wynika wprost z definicji 3 i własności wyznacznika.

Natychmiastowym wnioskiem jest stwierdzenie, że jeżeli

$$E\hat{\theta}_j - \theta = \sum_{i=1}^k f_{ij}(n)b_i(\theta), \quad j = 1, \dots, k+1,$$

to

$$EG(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}) = 0,$$

a więc jackknife  $k$ -tego rzędu jest wtedy nieobciążony.

Ograniczmy teraz nasze rozważania do szczególnej postaci uogólnionego jackknife'u, a mianowicie do przypadku, kiedy funkcje  $f_{ij}$  mają postać:

$$f_{ij}(n) = (n-j-1)^{-i}.$$

Zachodzi wtedy następujące twierdzenie:

**TWIERDZENIE 4. Jeżeli**

$$E\hat{\theta}_j - \theta = \sum_{i=1}^{\infty} f_{ij}(n) b_i(\theta), \quad j = 1, \dots, k+1$$

oraz

$$f_{ij}(n) = (n-j+1)^{-i},$$

to

$$EG(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}) - \theta = O(n^{-k-1}).$$

Z twierdzenia tego wynika, że gdy estymatory  $\hat{\theta}_1, \dots, \hat{\theta}_{k+1}$  mają obciążenia rzędu  $n^{-1}$ , estymator  $G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1})$  ma obciążenie rzędu tylko  $n^{-k-1}$ . Ponadto, jeżeli

$$E\hat{\theta}_j - \theta = \sum_{i=1}^k \frac{b_i(\theta)}{(bn-j+1)^i},$$

to estymator  $G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1})$  jest nieobciążony.

Dowód powyższego twierdzenia znaleźć można np. w [2].

**6. Rozszerzona metoda Quenouille'a.** Jak widać z definicji 3, konstrukcja jackknife'u wyższego rzędu dla estymatora  $\hat{\theta}_1$  wymaga utworzenia  $k$  nowych estymatorów  $\hat{\theta}_2, \dots, \hat{\theta}_{k+1}$ . Podobnie jak poprzednio, i tutaj można się posłużyć odpowiednio rozszerzoną metodą Quenouille'a.

Niech  $\hat{\theta}_1 = \hat{\theta}_1(X_1, \dots, X_n)$  będzie estymatorem określonym dla każdego  $n = 1, 2, \dots$ , a  $\hat{\theta}_1^{i_1, \dots, i_j}$  — estymatorem  $\hat{\theta}_1$  na próbie  $(X_1, \dots, X_n)$ , z której odrzucano obserwacje  $X_{i_1}, \dots, X_{i_j}$ , przy czym wskaźniki  $i_1, \dots, i_j$  wybiera się losowo. Niech  $k < n$ . Weźmy pod uwagę ciąg estymatorów  $\hat{\theta}_1^{i_2}, \dots, \hat{\theta}_1^{i_2, \dots, i_{k+1}}$  i zdefiniujmy estymatory  $\hat{\theta}_j$  wzorem

$$(10) \quad \hat{\theta}_j = \hat{\theta}_1^{i_2, \dots, i_j} = \frac{1}{\binom{n}{j-1}} \sum \hat{\theta}_1^{i_2, \dots, i_j}$$

dla  $j = 2, \dots, k+1$ , przy czym sumowanie rozciąga się na wszystkie permutacje liczb  $i_2, \dots, i_j$ .

Na przykład, w rozważanym już wcześniej przykładzie 2 mieliśmy

$$\hat{\theta}_1 = \hat{\theta} = X_{(n)},$$

$$\hat{\theta}_2 = \hat{\theta} = \frac{1}{n} [(n-1)X_{(n)} + X_{(n-1)}].$$

Aby wyznaczyć  $\hat{\theta}_3$  wyznaczmy estymatory  $\hat{\theta}^{ij}$ , które mogą przyjmować następujące wartości:

$$\begin{aligned} X_{(n)} & \text{ gdy } X_i, X_j \neq X_{(n)}, \\ X_{(n-1)} & \text{ gdy } (X_i = X_{(n)}, X_j \neq X_{(n-1)}) \text{ lub } (X_j = X_{(n)}, X_i \neq X_{(n-1)}), \\ X_{(n-2)} & \text{ gdy } (X_i = X_{(n)}, X_j = X_{(n-1)}) \text{ lub } (X_j = X_{(n)}, X_i = X_{(n-1)}). \end{aligned}$$

Stąd średnia  $\binom{n}{2}$  możliwych wartości  $\hat{\theta}^{ij}$ , przy uwzględnieniu częstości pojawiania się każdej z wartości  $X_{(n)}, X_{(n-1)}, X_{(n-2)}$ , wynosić będzie

$$\hat{\theta}_3 = \frac{2}{n(n-1)} \left[ \frac{(n-1)(n-2)}{2} X_{(n)} + (n-2)X_{(n-1)} + X_{(n-2)} \right].$$

Zauważmy, że jeżeli  $E\hat{\theta}_1 - \theta = b(n, \theta)$ , to przy omawianym sposobie konstrukcji  $\hat{\theta}_j$  mamy  $E\hat{\theta}_j - \theta = b(n-j+1, \theta)$  a stąd, jeżeli tylko obciążenie estymatora  $\hat{\theta}_1$  można rozwinąć względem potęg wyrażenia  $1/n$ , w postaci

$$E\hat{\theta}_1 - \theta = \frac{a_1}{n} + \frac{a_2}{n^2} + \dots,$$

to

$$E\hat{\theta}_j - \theta = \frac{a_1}{n-j+1} + \frac{a_2}{(n-j+1)^2} + \dots$$

i, zgodnie z definicją,

$$(11) \quad G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}) = \frac{\begin{vmatrix} \hat{\theta}_1 & \hat{\theta}_2 & \dots & \hat{\theta}_{k+1} \\ \frac{1}{n} & \frac{1}{n-1} & \dots & \frac{1}{n-k} \\ \dots & \dots & \dots & \dots \\ \frac{1}{n^k} & \frac{1}{(n-1)^k} & \dots & \frac{1}{(n-k)^k} \end{vmatrix}}{\begin{vmatrix} 1 & 1 & \dots & 1 \\ \frac{1}{n} & \frac{1}{n-1} & \dots & \frac{1}{n-k} \\ \dots & \dots & \dots & \dots \\ \frac{1}{n^k} & \frac{1}{(n-1)^k} & \dots & \frac{1}{(n-k)^k} \end{vmatrix}}$$

Na mocy twierdzenia 4 mamy teraz, że

$$EG(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}) - \theta = O(n^{-k-1}),$$

a dla  $a_{k+1} = a_{k+2} = \dots = 0$  estymator  $G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1})$  jest nieobciążony.

Skonstruowany estymator postaci (11) nazywać też będziemy *zwykłym jackknife'm k-tego rzędu* i oznaczać będziemy symbolem  $J^{(k)}(\hat{\theta})$ . Ponadto, wygodnie będzie stosować uproszczony zapis:

$$G^{(k)}(\hat{\theta}) = G(\hat{\theta}_1, \dots, \hat{\theta}_{k+1}).$$

**PRZYKŁAD 3.** Wyznaczmy postać estymatora  $J^{(2)}(\hat{\theta})$ . Na mocy przyjętych określeń mamy

$$J^{(2)}(\hat{\theta}) = G^{(2)}(\hat{\theta})$$

dla  $f_{ij}(n) = 1/(n-j+1)^i$ ,  $j = 1, 2, 3$ ;  $i = 1, 2$ ; czyli

$$J^{(2)}(\hat{\theta}) = \frac{\begin{vmatrix} \hat{\theta}_1 & \hat{\theta}_2 & \hat{\theta}_3 \\ \frac{1}{n} & \frac{1}{n-1} & \frac{1}{n-2} \\ \frac{1}{n^2} & \frac{1}{(n-1)^2} & \frac{1}{(n-2)^2} \end{vmatrix}}{\begin{vmatrix} 1 & 1 & 1 \\ \frac{1}{n} & \frac{1}{n-1} & \frac{1}{n-2} \\ \frac{1}{n^2} & \frac{1}{(n-1)^2} & \frac{1}{(n-2)^2} \end{vmatrix}} = \frac{1}{2} (n^2 \hat{\theta}_1 - 2(n-1)^2 \hat{\theta}_2 + (n-2)^2 \hat{\theta}_3).$$

Istnieje wiele możliwości zarówno modyfikacji samej metody jak i wykorzystania estymatorów  $J(\hat{\theta})$ . Jedną z takich propozycji jest pomysł T. Sharota [7] „wyostrenia” jackknife’u (sharpening the jackknife). Sugeruje on mianowicie utworzenie nowej rodziny estymatorów typu jackknife, składającej się z liniowych kombinacji estymatorów  $\hat{\theta}$ ,  $\hat{\theta}^j$ ,  $\hat{\theta}^{ij}$ ;

$$J(p) = pn\hat{\theta} + (1-2p)(n-1)\hat{\theta}^j + (p-1)(n-2)\hat{\theta}^{ij},$$

przy czym za  $p$  wybieramy taką wartość, która minimalizuje wariancję  $J(p)$ . Oczywiście  $J(1) = J(\hat{\theta})$ , a  $J(n/2) = J^{(2)}(\hat{\theta})$ .

**7. Pewne zastosowania metody jackknife.** Początkowo jedyną motywacją dla jackknife’u była redukcja obciążenia estymatorów lub wręcz konstruowanie estymatorów nieobciążonych. Dopiero późniejsze badania asymptotycznych własności uczyniły z jackknife’u szczególnie użyteczne narzędzie w analizie danych.

Już w 1958 r. J. W. Tukey [8] wskazał, że pseudowartości  $J_i(\hat{\theta})$  mogą być w przybliżeniu traktowane jako niezależne zmienne losowe o jednakowym rozkładzie — a stąd jackknifing może być użyteczny przy konstrukcji przybliżonych przedziałów

ufności. Procedura ta, stosowana z zadawalającymi rezultatami, ma obecnie szeroką podbudowę teoretyczną w postaci twierdzeń asymptotycznych, z których wiele znaleźć można w pracy [1]. Pozwalają one traktować pseudowartości

$$J_i(\hat{\theta}) = n\hat{\theta} - (n-1)\hat{\theta}^i$$

jako zmienne losowe, asymptotycznie niezależne i o jednakowym rozkładzie. Zmienne te w pewnym sensie reprezentują wpływ każdej pojedynczej obserwacji na  $\hat{\theta}$ , więc estymatorem wariancji  $\hat{\theta}$  może być wyrażenie

$$\text{var}(\hat{\theta}) = \frac{1}{n(n-1)} \sum_{i=1}^n (J_i(\hat{\theta}) - J(\hat{\theta}))^2.$$

Statystyka

$$\frac{(J(\hat{\theta}) - \theta) \sqrt{n(n-1)}}{\sqrt{\sum (J_i(\hat{\theta}) - J(\hat{\theta}))^2}}$$

ma wtedy asymptotycznie rozkład  $t$ -Studenta z  $(n-1)$  stopniami swobody.

Najcenniejszym zastosowaniem techniki jackknife'u, zwłaszcza z punktu widzenia odporności metod statystycznych, jest testowanie hipotez o wariancji. Wiadomo, że w tym problemie niewygodnie jest opierać test na rozkładzie  $\chi^2$  lub  $F$ , gdyż taki test jest bardzo czuły na odchylenia od normalności. Z drugiej strony, niektóre z wersji klasycznych metod przewidywały podział próby losowej na grupy, co sugerowało możliwość zastosowania jackknife'u. Wiele miejsca temu zagadnieniu poświęcił w swoich pracach R. G. Miller [3].

Na przykład, niech zadanie polega na testowaniu hipotezy  $H_0: \sigma_y^2 = \sigma_x^2$ , gdzie

$$X_1, \dots, X_n \text{ — próba losowa z populacji } \sim F\left(\frac{x - \mu_x}{\sigma_x}\right),$$

$$Y_1, \dots, Y_m \text{ — próba losowa z populacji } \sim F\left(\frac{y - \mu_y}{\sigma_y}\right).$$

Parametry  $(\mu_x, \mu_y, \sigma_x, \sigma_y)$  są nieznanne, tak jak i postać rozkładu  $F$  (poza założeniem, że  $F$  ma skończone momenty do czwartego rzędu włącznie). Do konstrukcji testu może służyć statystyka

$$t = \frac{(J(\hat{\theta}_x) - \theta_x) - (J(\hat{\theta}_y) - \theta_y)}{\sqrt{\frac{1}{n(n-1)} \sum_{i=1}^n (J_i(\hat{\theta}_x) - J(\hat{\theta}_x))^2 + \frac{1}{m(m-1)} \sum_{i=1}^m (J_i(\hat{\theta}_y) - J(\hat{\theta}_y))^2}},$$

gdzie

$$\theta_x = \log \sigma_x^2, \quad \theta_y = \log \sigma_y^2.$$

Statystyka ta ma rozkład  $t$ -Studenta z  $(n+m-2)$  stopniami swobody.

Niektórzy autorzy zwracają jednak uwagę na fakt, że niekiedy natura estymatora  $\hat{\theta}$  jest taka, że jego pseudowartości nie tworzą  $n$  różnych wartości. Sugerują oni, aby w takiej sytuacji ilość stopni swobody rozważanej statystyki obniżyć do liczby

równej ilości tych różnych wartości, pomniejszonej o jeden. Na przykład, w omawianym przykładzie 2 mieliśmy tylko dwie różne wartości, ponieważ  $\hat{\theta}^i$  było równe  $X_{(n)}$  lub  $X_{(n-1)}$  — więc zgodnie z tym rozkład  $t$  należałoby traktować jako rozkład z jednym stopniem swobody.

**8. Uwagi końcowe.** Jak już wcześniej zauważono „jackknife — to dostosowanie podstaw teoretycznych do tego, co każdy dobry i doświadczony statystyk już dawno robił w sposób nieformalny”. Jest jeszcze wprawdzie wiele niejasności przy formułowaniu zagadnień związanych z samą metodą, jak i wiele trudności natury technicznej przy licznosci podgrup  $M > 1$ , ale z drugiej strony jackknife jest jeszcze jedną, jeżeli nie jedyną, możliwością rozwiązania postawionego problemu.

Jak podkreśla R. G. Miller [4], [5] wynik zastosowania jackknife'u w dużym stopniu zależy od „rozsądnego” podziału danych na grupy; występują bowiem sytuacje, gdy przyjęte założenia o asymptotycznej niezależności  $J_i(\hat{\theta})$  nie są spełnione. Nie umniejsza to jednak znaczenia samej techniki, która w wielu przypadkach daje szybkie i proste rozwiązania — jak przy cięciu nożem — czyli jackknifing.

#### Prace cytowane

- [1] H. L. Grey, W. L. Schucany, *The generalized jackknife statistic*, Marcel Dekker, New York 1972.
- [2] —, —, *On bias reduction in estimation*, J. Amer. Statist. Assoc. 66 (1971), str. 524–533.
- [3] R. G. Miller, *Jackknifing variances*, Ann. of Math. Statist. 39 (1968), str. 567–582.
- [4] —, *Jackknifing — a review*, Biometrika 61 (1974a), str. 1–15.
- [5] —, *A trustworthy jackknife*, Ann. of Math. Statist. 35 (1964), str. 1594–1605.
- [6] M. H. Quenouille, *Notes on bias in estimation*, Biometrika 43 (1956), str. 353–360.
- [7] T. Sharot, *Sharpening the jackknife*, ibid. 63 (1976), str. 315–321.
- [8] J. W. Tukey, *Bias and confidence in not-quite large samples*, Ann. of Math. Statist. 29 (1958) (Abstract), str. 614.