

RYSZARD ZIELIŃSKI (Warszawa)

## O średniej arytmetycznej i medianie

**Streszczenie.** Mierząc pewną wielkość  $\mu$  (długość, ciężar, temperaturę...) otrzymujemy wynik  $X$ , zwykle różniący się od  $\mu$  o pewną wielkość losową (błąd losowy)  $\varepsilon$ . Rozkład  $F$  prawdopodobieństwa błędu losowego  $\varepsilon$  czasami jest znany, a czasami wiemy o nim tylko to, że jest jakimś rozkładem z ustalonej rodziny rozkładów  $\mathcal{F}$  (np. rozkładem normalnym o średniej zero i nieznanym odchyleniu standardowym  $\sigma$ , albo jakimś rozkładem o ciągłej dystrybucji). Jeżeli rozkład  $F$  ma duży rozrzut, dokładność pomiaru może być niezadowalająca. Dobrze znanym i powszechnie stosowanym lekarstwem jest wielokrotne powtórzenie pomiaru i uśrednienie otrzymanych wyników. Okazuje się, że powszechnie stosowana średnia arytmetyczna może okazać się wysoce zawodna. Chociaż w bardziej abstrakcyjnym ujęciu rozważany w artykule problem polega na estymacji parametru położenia  $\mu$  w modelu statystycznym z rodziną rozkładów  $\{F_\mu : F_\mu(x) = F(x-\mu)\}$ , w artykule trzymam się terminologii „pomiar-błąd pomiaru”. W ogólniejszym sformułowaniu mówi się o problemie estymacji średniej wartości cechy w danej populacji, ale przejście na tę terminologię nie następuje żadnych trudności.

**Słowa kluczowe.** Pomiar, średnia arytmetyczna, mediana, estymacja, parametr położenia, rozrzut.

**1. Wstęp.** Mierząc pewną wielkość  $\mu$  (długość, ciężar, temperaturę...) otrzymujemy wynik  $X$ , zwykle różniący się od  $\mu$  o pewną wielkość losową  $\varepsilon$  (błąd losowy). Rozkład prawdopodobieństwa  $F$  błędu losowego  $\varepsilon$  czasami jest znany, a czasami wiemy o nim tylko to, że jest jakimś rozkładem z ustalonej rodziny rozkładów  $\mathcal{F}$ . Jeżeli rozkład  $F$  ma duży rozrzut, dokładność pomiaru może być niezadowalająca. Dobrze znanym i powszechnie stosowanym lekarstwem jest wielokrotne powtórzenie pomiaru. Bardziej formalnie: rozważamy model statystyczny

$$(1) \quad X_i = \mu + \varepsilon_i, \quad i = 1, 2, \dots, n,$$

w którym  $\mu$  jest parametrem liczbowym oraz  $\varepsilon_i$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie  $F$  takim, że  $E_F(\varepsilon) = 0$  (pomiar nieobciążony).


Jeżeli rozkład  $F$  błędu jest jednoznacznie znany, będziemy mówili o *prostym modelu* (1), a jeżeli wiemy tylko tyle, że  $F \in \mathcal{F}$ , gdzie  $\mathcal{F}$  jest ustaloną rodziną rozkładów – będziemy mówili o *modelu złożonym*. Jeżeli błąd  $\varepsilon$  ma rozkład  $F$ , to rozkład obserwacji będzie oznaczany przez  $F_\mu$ . Przyjmujemy, że  $F_\mu(x) = F(x - \mu)$ .

Zadanie polega na oszacowaniu  $\mu$  na podstawie obserwacji  $X_1, X_2, \dots, X_n$ . Własności rozkładu  $F$  w modelu prostym lub własności rodziny  $\mathcal{F}$  w modelu złożonym decydują o tym, co jest a co nie jest „dobrym estymatorem” wielkości (parametru)  $\mu$ .

Chociaż przyjęta w artykule terminologia odwołuje się do intuicji związanej z dokonywaniem pomiarów różnych obiektów, to problem jest ogólniejszy i obejmuje na przykład estymację średniej wartości cechy w danej populacji, np. estymację średnich zarobków w populacji danego kraju, średnich zwrotów danych papierów na giełdzie papierów wartościowych, średniego stopnia zanieczyszczenia powietrza, itp. Nie precyzuję na razie, co rozumiem przez „średnią” w tych sformułowaniach. Jeżeli  $X$  jest interesującą nas cechą elementów populacji oraz  $\mu$  jest interesującym nas wskaźnikiem, uzyskujemy model (1) pisząc  $X = \mu + (X - \mu)$ ; tu  $\mu$  może być średnią arytmetyczną badanej cechy, medianą, kwantylem (np.  $V@R$ ), itp.

**2. Prosty model pomiaru z rozkładem normalnym.** Przypuśćmy, że rozkład błędu  $F$  jest rozkładem normalnym  $N(0, \sigma)$ , gdzie  $\sigma > 0$  jest ustalone i znane. W praktyce odpowiada to mierzeniu nieznannej wielkości  $\mu$  za pomocą przyrządu pomiarowego o znanej dokładności. Model jest tak powszechnie znany i stosowany (metrologia, geodezja, astronomia, fizyka, zastosowania przemysłowe i zastosowania przyrodnicze), że nie musimy tutaj poświęcać mu dużo miejsca. Celem tego paragrafu jest ustalenie terminologii i oznaczeń oraz przywołanie narzędzi, które będą istotne w dalszej części artykułu.

W rozważanym modelu istotne jest to, że duże błędy są mało prawdopodobne: prawdopodobieństwo zdarzenia polegającego na tym, że błąd przekroczy bezwzględnie  $x$ , jest dla dużych  $x$  wielkością rzędu  $\exp(-x^2)$ . Rozkładem obserwacji  $X$  jest wtedy rozkład normalny  $N(\mu, \sigma)$  i zagadnienie sprowadza się do znanego z elementarnego kursu statystyki problemu estymacji wartości oczekiwanej zmiennej losowej o rozkładzie normalny ze znaną wariancją. Istotą tego modelu jest możliwość dowolnego zmniejszenia błędu (dowolnego zwiększenia dokładności pomiaru) przez wybór odpowiednio dużej liczby  $n$  pomiarów: *średnia arytmetyczna*  $\bar{X} = \sum_{i=1}^n X_i/n$  ma rozkład normalny  $N(\mu, \sigma/\sqrt{n})$ . Redukcję błędu na skutek uśredniania coraz to większej liczby obserwacji ilustruje Rys. 1.

Rys. 1. Rozkład średniej  $\bar{X}_n$  w modelu (1) dla  $\mu = 2$  oraz  $\epsilon \sim N(0, 1)$ 

Ten mechanizm redukcji błędu przez powtarzanie pomiarów chyba najłatwiej jest spostrzec patrząc na odpowiednie funkcje charakterystyczne<sup>(\*)</sup>: jeżeli  $X_1, X_2, \dots, X_n$  jest ciągiem zmiennych losowych o jednakowym rozkładzie normalnym  $N(\mu, \sigma)$  z funkcją charakterystyczną

$$\varphi_X(t) = \exp \left\{ i\mu t - \frac{1}{2} \sigma^2 t^2 \right\},$$

to funkcja charakterystyczna średniej arytmetycznej  $\bar{X}_n = \sum_{j=1}^n X_j / n$  jest równa:

$$\varphi_{\bar{X}_n}(t) = \left( \varphi_X(t/n) \right)^n = \exp \left\{ i\mu t - \frac{1}{2} \left( \frac{\sigma^2}{n} \right) t^2 \right\}.$$

Zakończenie procesu estymacji polega na podaniu przedziału ufności dla estymowanego parametru; wyższa dokładność estymacji prowadzi do krótszego przedziału ufności. W rozważanym tu modelu gaussowskim przedział ufności wyznacza się w podręcznikowy sposób.

**3. Prosty model pomiaru z rozkładem  $\alpha$ -stabilnym.** Będziemy teraz rozważali rozkłady  $\alpha$ -stabilne  $S_\alpha(\mu, \lambda)$  z funkcją charakterystyczną

$$\varphi_X(t) = \exp \{ i\mu t - |\lambda t|^\alpha \},$$

gdzie  $\alpha$  jest parametrem kształtu (wykładnikiem charakterystycznym),  $\mu$  – parametrem położenia oraz  $\lambda$  – parametrem skali.

Rozszerzenie zastosowań statystyki na ekonomię, ubezpieczenia, rynki finansowe, itp. spowodowało, że standardowe metody związane z modelem gaussowskim stały się nieadekwatne: duże odchylenia poszczególnych obserwacji  $X_i$  od „wartości centralnej  $\mu$ ” stały się dużo bardziej prawdopodobne, niżby to wynikało z modelu gaussowskiego. Przykładem może służyć wysokość szkód pokrywanych przez towarzystwa ubezpieczeniowe: od czasu do


<sup>(\*)</sup> Termin funkcja charakterystyczna nie ma tutaj nic wspólnego ze znanym w teorii zbiorów (przyp. red.).

czasu, ale częściej niżby to sugerował rozkład normalny, pojawia się szkoda bardzo wysoka.

Jeżeli próba  $X_1, X_2, \dots, X_n$  jest ciągiem zmiennych losowych o jednakowym rozkładzie  $\alpha$ -stabilnym  $S_\alpha(\mu, \lambda)$ , to funkcja charakterystyczna średniej arytmetycznej  $\bar{X}_n$  jest równa

$$\varphi_{\bar{X}_n}(t) = \left( \exp\left\{i\mu\frac{t}{n} - \left|\lambda\frac{t}{n}\right|^\alpha\right\} \right)^n = \exp\{i\mu t - |n^{1/\alpha-1}\lambda t|^\alpha\}.$$

Wnioskujemy stąd natychmiast, że średnia z  $n$ -elementowej próby może mieć rozkład bardziej rozproszony niż rozkład pojedynczej obserwacji (Rys. 2).



Rys. 2. Rozkład obserwacji  $X \sim S_\alpha(2, 1)$ ,  $\alpha < 1$ , oraz średniej  $\bar{X}_n$


Co więcej, w takich przypadkach obserwacja  $X$ , a więc także średnia arytmetyczna obserwacji, może w ogóle nie mieć wartości oczekiwanej.

Typowym przedstawicielem rozkładów  $\alpha$ -stabilnych jest rozkład Cauchy'ego  $Ca(\mu, \sigma)$  o gęstości

$$\frac{1}{\pi\sigma} \cdot \frac{1}{1 + \left(\frac{x-\mu}{\sigma}\right)^2}.$$

Jest to rozkład  $\alpha$ -stabilny z parametrem  $\alpha = 1$ . W pobliżu zera błąd losowy  $\varepsilon$  o tym rozkładzie zachowuje się podobnie jak błąd losowy w modelu gaussowskim, ale bardziej tłuste ogony tego rozkładu (Rys. 3) wskazują na wyraźnie większe prawdopodobieństwo błędów dużych. W przypadku rozkładu Cauchy'ego rozkład średniej arytmetycznej z próby  $n$ -elementowej jest taki sam jak rozkład pojedynczej obserwacji. Wyróżniłem tutaj ten rozkład z powodu jego roli w zastosowaniach: nadaje się do modelowania różnych zjawisk (np. w fizyce znany jest jako rozkład Lorentza lub Breita-Wignera), a jednocześnie jest łatwy numerycznie i w symulacjach.

**4. Prosty model (1) pomiaru z medianą  $\mu$ .** Rozpatrzmy model pomiaru (1) z rozkładem  $F$  błędu  $\varepsilon$  o medianie równej zero. Wtedy obserwacja ma rozkład  $F_\mu$  o medianie równej  $\mu$ : mówimy, że pomiar jest medianowo-nieobciążony.



Rys. 3. Rozkład normalny i rozkład Cauchy'ego

Jeżeli  $T = T(X_1, X_2, \dots, X_n)$  jest statystyką z próby  $X_1, X_2, \dots, X_n$  i jeżeli  $F$  jest rozkładem obserwacji  $X$ , to medianę rozkładu tej statystyki będziemy oznaczali symbolem  $Med(F, T)$ . Problem estymacji  $\mu$  w modelu pomiaru (1) staje się teraz problemem estymacji mediany rozkładu obserwacji  $X$  na podstawie próby  $X_1, X_2, \dots, X_n$ .

Standardowym *estymatorem mediany rozkładu* jest mediana  $M_n$  z próby  $n$ -elementowej definiowana wzorem

$$(2) \quad M_n = \begin{cases} \frac{1}{2} (X_{\frac{n}{2}:n} + X_{\frac{n}{2}+1:n}), & \text{jeżeli } n \text{ jest parzyste,} \\ X_{\frac{n+1}{2}:n}, & \text{jeżeli } n \text{ jest nieparzyste.} \end{cases}$$


Tu, jak zwykle,  $X_{1:n}, X_{2:n}, \dots, X_{n:n}$  ( $X_{1:n} \leq X_{2:n} \leq \dots \leq X_{n:n}$ ) oznaczają statystyki pozycyjne z tej próby. Będę zajmował się przypadkiem nieparzystego  $n$ ; przypadek estymatora  $M_n$ , gdy  $n$  jest parzyste, jest bardziej złożony niż na pierwszy rzut oka można by się tego spodziewać i skomentuję ten przypadek oddzielnie później.

Jeżeli obserwacje mają rozkład  $F_\mu$  z gęstością  $f_\mu$ , to gęstość rozkładu mediany  $M_n$  ma postać

$$\frac{\Gamma(n+1)}{\Gamma^2\left(\frac{n+1}{2}\right)} \left(F_\mu(x) [1 - F_\mu(x)]\right)^{(n-1)/2} f_\mu(x).$$

Wykresy tej gęstości dla  $n = 1, 5, 25$  w przypadku, gdy  $\mu = 2$  i rozkład błędu  $\varepsilon$  jest rozkładem Cauchy'ego  $Ca(0, 1)$ , przedstawia Rys. 4.

Porównanie Rys. 1 i Rys. 4 wskazuje na to, że mediana w modelu z rozkładem Cauchy'ego spełnia taką samą rolę, jak średnia arytmetyczna w modelu gaussowskim. Mediana w modelu gaussowskim może oczywiście być także traktowana jako estymator parametru  $\mu$ , chociaż nie jest to w tym modelu estymator tak dobry, jak zwykła średnia arytmetyczna.

Rys. 4. Rozkład mediany  $M_n$  w modelu (1) z błędem  $\epsilon \sim Ca(0, 1)$ 

Wygodna forma dystrybuanty rozkładu mediany  $M_n$  ma postać

$$(3) \quad P_F\{M_n \leq x\} = B\left(F(x - \mu); \frac{n+1}{2}, \frac{n+1}{2}\right),$$

gdzie  $B(t; \alpha, \beta)$  jest dystrybuatą rozkładu beta:

$$B(t; \alpha, \beta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \int_0^t u^{\alpha-1}(1-u)^{\beta-1} du.$$

Kwantyl rzędu  $q \in (0, 1)$  tego rozkładu będziemy oznaczali przez  $B^{-1}(q; \alpha, \beta)$ . Obie te funkcje są łatwo dostępne w standardowych pakietach komputerowych (np. Mathematica, Excel, R, Statgraphics). *Kwantylem*  $x_q = x_q(F, M_n)$  rzędu  $q$  rozkładu mediany  $M_n$  jest wtedy


$$(4) \quad x_q = \mu + F^{-1}\left(B^{-1}\left(q; \frac{n+1}{2}, \frac{n+1}{2}\right)\right).$$

Ocena dokładności pomiaru i jej zależności od liczby  $n$  powtórzeń za pomocą odchylenia standardowego (jak to miało miejsce w modelu gaussowskim) nie jest teraz możliwa, bo odpowiednie momenty rozkładów w modelu  $\alpha$ -stabilnym nie istnieją. Odpowiednią miarą dokładności może być teraz rozstęp międzykwartyłowy rozkładu estymatora (używana jest również nazwa odległość międzykwartyłowa).

Jeżeli statystyka  $T_n = T(X_1, X_2, \dots, X_n)$  ma rozkład ciągły, to jej kwantyl rzędu  $q$  będziemy oznaczali przez  $x_q = x_q(F, T_n)$ . *Rozstępem międzykwartyłowym* rozkładu statystyki  $T_n$ , gdy obserwacja  $X$  ma rozkład  $F$ , nazywamy wielkość

$$\Delta(F, T_n) = x_{0.75}(F, T_n) - x_{0.25}(F, T_n).$$

Ilustrację graficzną tej wielkości przedstawia Rys. 5, a numeryczną Tab. 1.



Rys. 5. Rozstęp międzykwartyłowy rozkładu  $F$  zmiennej losowej  $X$

Tab. 1. Rozstęp międzykwartyłowy  $\Delta(F, T_n)$

$n$	Rozkład, statystyka		
	$Ca(0, 1), M_n$	$N(0, 1), M_n$	$N(0, 1), \bar{X}_n$
5	0.9455	0.7199	0.6033
15	0.5472	0.4294	0.3483
25	0.4239	0.3348	0.2698
51	0.2968	0.2356	0.1889
101	0.2108	0.1678	0.1342

Finał procesu estymacji wielkości (parametru)  $\mu$  polega oczywiście na podaniu przedziału ufności na zadanym poziomie ufności  $\gamma$ , co ma nam dać wyobrażenie o wielkości błędu estymatora. W celu zbudowania takiego przedziału wystarczy wyznaczyć kwantyle  $x_{\frac{1-\gamma}{2}}$  oraz  $x_{\frac{1+\gamma}{2}}$  takie, żeby

$$P_F\{x_{\frac{1-\gamma}{2}} \leq M_n \leq x_{\frac{1+\gamma}{2}}\} = \gamma.$$

Korzystając z (4) otrzymujemy przedział ufności

$$(5) \quad \left( M_n - F^{-1} \left( B^{-1} \left( \frac{1+\gamma}{2}; \frac{n+1}{2}, \frac{n+1}{2} \right), \right), \right. \\ \left. M_n - F^{-1} \left( B^{-1} \left( \frac{1-\gamma}{2}; \frac{n+1}{2}, \frac{n+1}{2} \right) \right) \right).$$

Gdy  $F$  jest rozkładem Cauchy'ego  $Ca(0, \sigma)$ , to  $F^{-1}(t) = \sigma \cdot tg[(t-0.5)\pi]$ . W przypadku innych, dowolnych ale ustalonych rozkładów  $F$ , sprawa może się

obliczeniowo komplikować, ale pojawiające się trudności są tylko techniczne. Jeżeli rozkład  $F$  błędu jest symetryczny względem zera, to otrzymany przedział ufności jest symetryczny względem zaobserwowanej wartości  $M_n$  estymatora mediany.

**5. Złożony model pomiaru z medianą  $\mu$ .** Rozpatrzmy model pomiaru (1) z nieznanym rozkładem  $F \in \mathcal{F}$  błędu  $\varepsilon$  o medianie równej zeru. Jeżeli próba  $X_1, X_2, \dots, X_n$  ma nieparzystą liczbę  $n$  elementów, to  $M_n$  jest medianowo-nieobciążonym estymatorem mediany  $\mu$  obserwacji: wynika to natychmiast z wzoru (3):

$$P_F\{M_n \leq \mu\} = B\left(F(0); \frac{n+1}{2}, \frac{n+1}{2}\right) = B\left(\frac{1}{2}; \frac{n+1}{2}, \frac{n+1}{2}\right) = \frac{1}{2}.$$

Jak już wspominałem, przypadkiem parzystej liczby  $n$  obserwacji zajmę się oddzielnie.

Przedział (5) jest oczywiście nadal przedziałem ufności dla mediany, ale problem polega na tym, że skoro nie znamy  $F$ , to z tego wzoru nie mamy wielkiego pożytku. Żeby wyobrazić sobie skalę pojawiających się trudności pomyślmy o  $F$  w modelu gaussowskim jako o rozkładzie normalnym  $N(0, \sigma)$  z nieznanym odchyleniem standardowym  $\sigma$ : przedział ufności dla  $\mu$  buduje się wtedy z wykorzystaniem rozkładu Studenta, a nie rozkładu normalnego. Trudności pojawiające się wtedy, gdy  $\mathcal{F}$  jest rodziną symetrycznych rozkładów  $\alpha$ -stabilnych, wydają się nie do pokonania na obecnym etapie wiedzy o estymacji parametrów takich rozkładów.

Chociaż może się to wydawać paradoksalne, pewnym wyjściem jest wtedy rozszerzenie rodziny  $\mathcal{F}$  nieznanymi rozkładami do wielkiej nieparametrycznej rodziny wszystkich rozkładów o ciągłych i ściśle rosnących dystrybuantach. Użyłem tutaj określenia „wielkiej”, bo jeżeli rozkład  $F$  pewnej zmiennej losowej  $X$  należy do tej rodziny i jeżeli  $g$  jest ściśle monotonicznym przekształceniem prostej, to rozkład zmiennej losowej  $g(X)$  również należy do  $\mathcal{F}$ . Konstrukcja przedziału ufności dla mediany  $\mu_F$  rozkładu  $F \in \mathcal{F}$  wymaga teraz jednak zupełnie innego podejścia: przedział ufności przyjmuje postać  $(X_{k:n}, X_{n-k+1:n})$ , gdzie dla danej liczby  $n$ , liczbę  $k$  wyznacza się jako największą (!) liczbę, dla której przy założonym poziomie ufności  $\gamma$

$$P_F\{X_{k:n} \leq \mu_F \leq X_{n-k+1:n}\} \geq \gamma, \quad \text{dla każdego } F \in \mathcal{F}.$$

Okazuje się to bardzo łatwe: wystarczy pamiętać, że jeżeli zmienna losowa  $X$  ma rozkład o dystrybuancie  $F \in \mathcal{F}$ , to zmienna losowa  $Y = F(X)$  ma rozkład jednostajny  $U(0, 1)$ , a zmienna losowa  $F(X_{k:n})$  ma taki sam rozkład jak  $k$ -ta statystyka pozycyjna z  $n$ -elementowej próby z rozkładu  $U(0, 1)$ .



Mamy więc

$$\begin{aligned} P_F\{X_{k:n} \leq \mu_F \leq X_{n-k+1:n}\} &= P\{U_{k:n} \leq \frac{1}{2} \leq U_{n-k+1:n}\} \\ &= \left(\frac{1}{2}\right)^n \sum_{s=k}^{n-k} \binom{n}{s}, \end{aligned}$$

gdzie  $P\{\}$  bez żadnego wskaźnika oznacza prawdopodobieństwo w rozkładzie jednostajnym  $U(0, 1)$ . Jest to wynik podręcznikowy, a wartości  $k$  odpowiednie dla danych  $n$  i  $\gamma$  można łatwo porachować lub znaleźć w tablicach lub pakietach komputerowych.

**6. Mediana  $M_n$  z próby o parzystej liczbie obserwacji  $n$ .** Rozważam medianę próbkową według definicji (2). Podam dwa wyniki mogące budzić niepokój.

**Pierwszy wynik.** Weźmy pod uwagę efektywność mediany w stosunku do średniej arytmetycznej (średnia arytmetyczna w modelu gaussowskim jest estymatorem nieobciążonym o jednostajnie minimalnej wariancji), zdefiniowaną wzorem

$$e(n) = \frac{\text{Var}(\bar{X}_n)}{\text{Var}(M_n)}.$$

Poniższa Tab. 2 pokazuje wartości  $e(n)$  dla przypadku rozkładu normalnego  $N(0, 1)$  i jednostajnego  $U(0, 1)$ :

Tab. 2. Efektywność  $e(n)$  mediany

$n$	$N(0, 1)$	$U(0, 1)$
1	1.000	1.000
2	1.000	1.000
3	0.743	0.556
4	0.838	0.625
5	0.697	0.467
6	0.776	0.519
7	0.679	0.429
8	0.743	0.469
9	0.669	0.407
10	0.723	0.440

Czyż nie wygląda na paradoks fakt, że zwiększenie liczności próby z  $2n$  do  $2n+1$  pogarsza efektywność estymatora?

**Drugi wynik.** Niech, jak wyżej,  $\mathcal{F}$  oznacza rodzinę wszystkich rozkładów o ciągłych i ściśle rosnących dystrybuatach i niech  $Med(F, T)$  oznacza

medianę rozkładu statystyki  $T$ , gdy próba pochodzi z rozkładu o dystrybucji  $F$ . Niech  $m_F = F^{-1}(\frac{1}{2})$  oznacza medianę rozkładu  $F \in \mathcal{F}$ . Okazuje się, że dla każdej liczby  $C > 0$  znajdzie się taki rozkład  $F \in \mathcal{F}$ , że

$$\text{Med}(F, M_{2n}) - m_F > C,$$

co oznacza, że mediana rozkładu estymatora może być dowolnie daleko od estymowanej mediany rozkładu. Praktyczny wniosek jest następujący: jeżeli trafi mi się próba z parzystą liczbą obserwacji, wyrzucam jedną z nich.

**7. Komentarz bibliograficzny.** W artykule nie ma nowych wyników naukowych: oryginalne (tak przypuszczam) jest ujęcie problemu dylematu „średnia arytmetyczna czy mediana” w modelu pomiaru  $X = \mu + \varepsilon$ . W dyskusji tego modelu przechodzę kolejno przez model gaussowski, model z rozkładami o tłustych ogonach i w końcu model nieparametryczny. Model gaussowski, gdy  $\varepsilon \sim N(0, \sigma)$ , jest klasyczny i szczegóły estymacji  $\mu$  można znaleźć we wszystkich podstawowych podręcznikach statystyki matematycznej. Jest ich dużo i są łatwo dostępne; ja sam najchętniej korzystam z monografii Bartoszewicza (1996), Krzyński (1996, 1998) oraz Magiery (2005, 2007). Model z rozkładami  $\alpha$ -stabilnymi jest naturalnym rozszerzeniem modelu gaussowskiego; więcej informacji o tych rozkładach można znaleźć u Magiery (2005), a w kontekście matematyki finansowej u Weron et al. (1998) i Čížeka et al. (2005). Rozkłady  $\alpha$ -stabilne mają ogony rzędu  $x^{-\alpha}$ , ale nie muszą być aż tak tłuste po to, żeby mediana dominowała średnią arytmetyczną. Mówi o tym Niemirow (1999); pojawia się to już w przypadku rozkładu Laplace’a z ogonami rzędu  $\exp(-x)$  (przypominam, że rozkład normalny ma ogony  $\exp(-x^2)$ ). Tab.2 pochodzi z pracy Hodges et al. (1967), a drugi wynik po raz pierwszy pojawił się w pracy Zieliński (1995), ale w dużo łatwiejszy sposób można go wydedukować z ogólniejszego twierdzenia z pracy Zieliński (2007). Bardziej szczegółowe informacje o kwestiach poruszonych w artykule każdy może sobie sam „wygooglować”.

#### Prace cytowane

- Bartoszewicz, J. (1996): *Wykłady ze statystyki matematycznej*, Wydawnictwo Naukowe PWN.
- Čížek, P., W. Híardle, R. Weron (2005): *Statistical Tools for Finance and Insurance*, Springer.
- Hodges, J.L., Jr., and E. L. Lehmann (1967): *On medians and quasi medians*, *JASA* September 1967, pp. 926–931.
- Krzyński, M. (1996, 1998): *Statystyka matematyczna*, Wydawnictwo Naukowe UAM, Tom I 1996, Tom II 1998.
- Magiera, R. (2005, 2007): *Modele i metody statystyki matematycznej*, Oficyna Wydawnicza GiS Wrocław. Część I 2005, Część II 2007.

- Niemiro, W. (1999): *Rachunek prawdopodobieństwa i statystyka matematyczna*, Biblioteka Szkoły Nauk Ścisłych.
- Weron, A., R. Weron (1998): *Inżynieria finansowa*, WNT.
- Zieliński, R. (1995): *Estimating median and other quantiles in nonparametric models*, *Applicationes Mathematicae* 23,3, pp. 363–370.
- Zieliński, R. (2007): *A sharp inequality for medians of L-statistics in a nonparametric statistical model*, *Journal of the Iranian Statistical Society*, Vol. 6, No. 2, pp. 173–177.

Ryszard Zieliński  
Instytut Matematyczny PAN  
Warszawa. Poland  
E-mail: R.Zielinski@impan.gov.pl

---

#### The arithmetic mean and the median

**Abstract.** Beginning with the statistical model  $X_i = \mu + \varepsilon_i, i = 1, 2, \dots, n$ ,  $\mu$  – an unknown constant to be estimated and  $\varepsilon_i$  independent identically distributed  $N(0, \sigma^2)$  random variables, models with heavy tails ( $\alpha$ -stable) distributions as well as nonparametric models are discussed. Confidence intervals for  $\mu$  are presented.

**Keywords:** measurement, arithmetic mean, median, estimating location, spread.

(wpłynęło 13 lutego 2010 r.)