

RYSZARD ZIELIŃSKI (Warszawa)

O średniej arytmetycznej i medianie

Streszczenie. Mierząc pewną wielkość μ (długość, ciężar, temperaturę...) otrzymujemy wynik X , zwykle różniący się od μ o pewną wielkość losową (błąd losowy) ε . Rozkład F prawdopodobieństwa błędu losowego ε 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 σ , 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 μ 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 μ (długość, ciężar, temperaturę...) otrzymujemy wynik X , zwykle różniący się od μ o pewną wielkość losową ε (błąd losowy). Rozkład prawdopodobieństwa F błędu losowego ε 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 μ jest parametrem liczbowym oraz ε_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 ε ma rozkład F , to rozkład obserwacji będzie oznaczany przez F_μ . Przyjmujemy, że $F_\mu(x) = F(x - \mu)$.

Zadanie polega na oszacowaniu μ 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) μ .

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 μ jest interesującym nas wskaźnikiem, uzyskujemy model (1) pisząc $X = \mu + (X - \mu)$; tu μ 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 μ 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^(*): 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 α -stabilnym. Będziemy teraz rozważali rozkłady α -stabilne $S_\alpha(\mu, \lambda)$ z funkcją charakterystyczną

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

gdzie α jest parametrem kształtu (wykładnikiem charakterystycznym), μ – parametrem położenia oraz λ – 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 μ ” stały się dużo bardziej prawdopodobne, niżby to wynikało z modelu gaussowskiego. Przykładem może służyć wysokość szkód pokrywanych przez towarzystwa ubezpieczeniowe: od czasu do


^(*) 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 α -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 α -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 α -stabilny z parametrem $\alpha = 1$. W pobliżu zera błąd losowy ε 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 μ . Rozpatrzmy model pomiaru (1) z rozkładem F błędu ε o medianie równej zero. Wtedy obserwacja ma rozkład F_μ o medianie równej μ : 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 μ 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_μ z gęstością f_μ , 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 ε 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 μ , 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 α -stabilnym nie istnieją. Odpowiednią miarą dokładności może być teraz rozstęp międzykwartylowy rozkładu estymatora (używana jest również nazwa odległość międzykwartylowa).

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 międzykwartylowym* 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

Final procesu estymacji wielkości (parametru) μ polega oczywiście na podaniu przedziału ufności na zadanym poziomie ufności γ , 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 μ . Rozpatrzmy model pomiaru (1) z nieznanym rozkładem $F \in \mathcal{F}$ błędu ε 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 μ 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 σ : przedział ufności dla μ buduje się wtedy z wykorzystaniem rozkładu Studenta, a nie rozkładu normalnego. Trudności pojawiające się wtedy, gdy \mathcal{F} jest rodziną symetrycznych rozkładów α -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 μ_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 γ

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

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

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

(wpłynęło 13 lutego 2010 r.)