

J. ODERFELD (Warszawa)

## O SKUPIENIU ROZKŁADU

**§ 1. Skupienie a wartość użytkowa.** Niechaj  $X$  będzie zmienną losową ciągłą, jednowymiarową, określoną w zbiorze  $S$ , który jest sumą przedziałów  $\langle d_{i-1}, d_i \rangle$ ,  $i = 1, 2, \dots, N$ . Oznaczmy gęstość prawdopodobieństwa zmiennej losowej  $X$  przez  $\varphi(x)$ .

Utwórzmy wyrażenia


$$(1) \quad w = \left( \int_{(S)} \varphi^2(x) dx \right)^{1/2}$$

$$(2) \quad v_i = \left( \int_{d_{i-1}}^{d_i} \varphi^2(x) dx \right)^{1/2}.$$

Wyrażenie  $w$  będziemy nazywali *skupieniem względnym*, a wyrażenie  $v_i$  *skupieniem częściowym*.

Przedmiotem artykułu są własności wyrażeń  $w$  i  $v_i$ . Przed ich omówieniem damy pewną interpretację, która w gruncie rzeczy stała się punktem wyjścia do badania ścisłego.

Na rysunku 1 pokazano trzy warianty a, b i c rozkładów  $X$  i przy każdym napisano, ile wynosi skupienie względne wyrażone w umownych jednostkach tak dobranych, żeby  $w_a = 100$ . Mamy  $w_b = 70$ ,  $w_c = 100$ .



Rys. 1

Liczby te pokazują, że  $w$  jest tym większe, im — *caeteris paribus* — rozkład jest bardziej skupiony wokół wartości modalnej, lub wartości modalnych, jeśli jest ich kilka.

Przypuśćmy<sup>(1)</sup> teraz, że rysunek 1 przedstawia rozkład ciężaru ziarn zboża przeznaczonego do siewu. Otóż jednym z kryteriów kwalifikujących ziarno do siewu jest mała dyspersja ciężaru. A więc ziarno o rozkładzie 1b ma mniejszą wartość użytkową niż ziarno o rozkładzie 1a.

Wiadomo również, że ziarno o rozkładzie 1c łatwiej można rozsortować niż 1b, a więc znowu ziarno 1b ma mniejszą wartość użytkową niż 1c.

Jest więc — przynajmniej w rozważanym przykładzie — dość wyraźna jednokierunkowa zależność między skupieniem względnym a wartością użytkową.

Na te związki zwrócił uwagę już w 1954 r. H. Steinhaus [1]. Ponadto w grudniu 1955 r. podał on (bez dowodu) tezę twierdzenia 1, które dowodzę w niniejszej pracy i postawił jako temat (w postaci szczególnej) zadanie, którego ogólnym rozwiązaniem jest twierdzenie 2.

**§ 2. Skupienie względne a odchylenie średnie.** Wzrokowe porównanie rysunków 1a i 1b nasuwa przypuszczenie, że istnieje jakaś relacja między skupieniem względnym  $w$  a odchyleniem średnim  $\sigma$ . Oczywiście nie ma żadnej zależności ogólnej, istnieje bowiem nieskończenie wiele rozkładów o różnych  $\sigma$  i tym samym  $w$ . Jednakże są pewne zależności, prawdziwe w przypadkach szczególnych, ale często spotykanych w praktyce.

Jeśli zmienna losowa  $X$  ma gęstość prawdopodobieństwa  $\varphi(x)$ , to zmienna losowa  $Y = ax + b$  ma gęstość

$$\psi(y) = \frac{1}{|a|} \varphi\left(\frac{y-b}{a}\right).$$

Wstawiając gęstość  $\varphi(x)$  i  $\psi(y)$  po prawej stronie (1) znajdujemy, że między skupieniami  $w_x$  a  $w_y$  jest zależność

$$w_y = \frac{1}{\sqrt{|a|}} w_x.$$

Jak wiadomo,  $\sigma_y = |a| \sigma_x$ , więc

$$(3) \quad w_y \sqrt{\sigma_y} = w_x \sqrt{\sigma_x} = K.$$

A więc w przekształceniu liniowym zmiennej losowej wyrażenie  $w\sqrt{\sigma}$  pozostaje stałe.

<sup>(1)</sup> Aby uniknąć ewentualnego nieporozumienia, zastrzegamy się, że we wszystkich przykładach podanych w tej pracy staraliśmy się o poprawność techniczną tylko w takim zakresie, jaki był każdorazowo potrzebny do zilustrowania pewnej koncepcji matematycznej.

Łatwy rachunek daje następujące wartości stałej  $K$ :

w rozkładzie prostokątnym  $K_1 = 2^{-1/2} 3^{-1/4} \sim 0,537$ ,

„ trójkątnym  $K_2 = \frac{1}{3} \cdot 2^{3/4} \sim 0,561$ ,

„ normalnym  $K_3 = 2^{-1/2} \pi^{-1/4} \sim 0,531$ .

Weźmy jeszcze pod uwagę symetryczny rozkład beta o gęstości

$$\varphi(x) = \frac{\Gamma(2p)}{\Gamma^2(p)} [x(1-x)]^{p-1} \quad (0 < x < 1).$$

Rozkład ten gra dość dużą rolę w badaniu automatycznej produkcji metalowej. Znajdujemy zależność

$$(4) \quad w\sqrt{\sigma} = \frac{\Gamma(2p)}{\Gamma^2(p)} \cdot \frac{\Gamma(2p-1)}{\sqrt{\Gamma(4p-2)}} \cdot \frac{1}{\sqrt{2} \sqrt[4]{2p+1}} = K_4(p).$$

W poniższej tabliczce spisano kilka wartości (z dokładnością do trzeciego znaku) funkcji  $K_4(p)$ :

$p$	2	3	5	10	20	50	$\infty$
$K_4(p)$	0,518	0,520	0,523	0,527	0,529	0,530	0,531

### § 3. Wpływ podziału na skupienie względne.

**Twierdzenie 1.** Niechaj  $\varphi(x)$ ,  $\varphi_1(x)$  i  $\varphi_2(x)$  będą gęstościami prawdopodobieństwa i niechaj

$$(5) \quad \varphi(x) = c\varphi_1(x) + (1-c)\varphi_2(x),$$

gdzie  $c$  jest ustalone i spełnia podwójną nierówność  $0 \leq c \leq 1$ . Niechaj skupienie względne  $w$  będzie określone wzorem (1).

Wtedy

$$(6) \quad w \leq \max(w_1, w_2).$$

Znak równości w (6) zachodzi tylko wtedy, gdy

$$(7) \quad \varphi(x) = \varphi_1(x) = \varphi_2(x).$$

Dowód<sup>(\*)</sup>.

$$(8) \quad \int_{(S)} \varphi^2(x) dx = \int_{(S)} [c\varphi_1(x) + (1-c)\varphi_2(x)]^2 dx = \\ = c^2 \int_{(S)} \varphi_1^2(x) dx + (1-c)^2 \int_{(S)} \varphi_2^2(x) dx + 2c(1-c) \int_{(S)} \varphi_1(x)\varphi_2(x) dx.$$

(\*) Mój dowód w pierwszej wersji tej pracy opierał się, jak obecnie, na nierówności Schwarza, ale był dłuższy; skrócenie zawdzięczę S. Zubrzyckiemu, który ponadto zauważył, że twierdzenie 1 stosuje się również do rozkładów skokowych, ze stosownymi zmianami formalnymi.

Ale z nierówności Schwarza [2] wynika, że

$$\int_{(S)} \varphi_1(x) \varphi_2(x) dx \leq \left( \int_{(S)} \varphi_1^2(x) dx \right)^{1/2} \left( \int_{(S)} \varphi_2^2(x) dx \right)^{1/2}$$

Wskutek tego

$$\begin{aligned} \int_{(S)} \varphi^2(x) dx &\leq c^2 \int_{(S)} \varphi_1^2(x) dx + (1-c)^2 \int_{(S)} \varphi_2^2(x) dx + \\ &+ 2c(1-c) \left( \int_{(S)} \varphi_1^2(x) dx \right)^{1/2} \left( \int_{(S)} \varphi_2^2(x) dx \right)^{1/2}, \end{aligned}$$

czyli

$$\left( \int_{(S)} \varphi^2(x) dx \right)^{1/2} \leq c \left( \int_{(S)} \varphi_1^2(x) dx \right)^{1/2} + (1-c) \left( \int_{(S)} \varphi_2^2(x) dx \right)^{1/2},$$

a więc — wobec (1) —

$$(9) \quad w \leq cw_1 + (1-c)w_2.$$

Przy założeniach przyjętych co do  $c$  prawa strona (9) jest nie większa niż  $\max(w_1, w_2)$ , co stanowi dowód pierwszej części twierdzenia 1.

Ponieważ w nierówności Schwarza równość zachodzi wtedy i tylko wtedy, gdy  $w_1 = w_2 = w$ , więc prawdziwa jest druga część twierdzenia 1.

Uwaga. Z warunków, w których zachodzi nierówność Schwarza, wynika, że twierdzenie 1 jest prawdziwe nie tylko dla rozkładów ciągłych, ale również skokowych, ze stosownymi zmianami formalnymi.

Twierdzenie 1 ma następującą interpretację:

Przypuśćmy, że każdemu przedmiotowi pewnej partii można przyporządkować pewną realizację cechy  $X$ . Jeśli tę partię podzielimy w dowolny sposób, to na ogół otrzymamy, przynajmniej w jednej z części, skupienie względne *większe* niż przed podziałem. W szczególnym przypadku ( $w_1 = w_2$ ) może ono być *niemniejsze* niż przed podziałem; taki przypadek może zajść wtedy, gdy partię podzielono przez losowanie i gdy zarówno partia, jak jej obie części, są duże.

Nasuwa się pytanie, jakie warunki należałoby dołączyć do (5), aby otrzymać tezę mocniejszą od (6), mianowicie tezę, że

$$(10) \quad w < \min(w_1, w_2).$$

Przypuśćmy, że obszar  $S$  całkowania jest przedziałem  $\langle d_0, d_2 \rangle$  zawierającym punkt  $d_1$  i że

$$(11) \quad \begin{aligned} \varphi_1(x) &= \begin{cases} \varphi(x)/c & \text{dla } d_0 < x < d_1, \\ 0 & \text{dla } x < d_0 \text{ oraz } x \geq d_1; \end{cases} \\ \varphi_2(x) &= \begin{cases} \varphi(x)/(1-c) & \text{dla } d_1 < x < d_2, \\ 0 & \text{dla } x < d_1 \text{ oraz } x \geq d_2. \end{cases} \end{aligned}$$

W naszej interpretacji posługującej się partią przedmiotów znaczy to, że podzielono partię na dwie części rozłączne według cechy  $X$ .

Wobec (11) jest

$$(12) \quad \int_{(S)} \varphi_1(x) \varphi_2(x) dx = 0$$

i wzór (8) przyjmuje postać

$$\int_{(S)} \varphi^2(x) dx = c^2 \int_{(S)} \varphi_1^2(x) dx + (1-c)^2 \int_{(S)} \varphi_2^2(x) dx,$$

czyli

$$(13) \quad w^2 = c^2 w_1^2 + (1-c)^2 w_2^2.$$

Jeśli zaś  $w$  jest określone przez (13), to nierówność (10) jest spełniona, gdy

$$(14) \quad \frac{1-c}{1+c} < \left( \frac{w_1}{w_2} \right)^2 < \frac{2-c}{c}.$$

Ostatecznie więc, warunkami *dostatecznymi* mocniejszej tezy (10) są łącznie warunki (11) i (14).

Nie zająłem się poszukiwaniem warunków koniecznych i dostatecznych, w których zachodzi (10), pragnę jednak zwrócić uwagę, że już sama klasa przypadków spełniających warunki (11) i (14) jest obszerna i ważna dla praktyki. Mianowicie dzieląc partię o rozkładzie cechy  $X$  prostokątnym, trójkątnym lub normalnym na dwie podpartie rozłączne według cechy  $X$ , mamy  $w_1 > w$  oraz  $w_2 > w$ . Ponieważ dowody tych własności są elementarne, poprzestane na zanotowaniu, że dzieląc partię o rozkładzie normalnym i gęstości prawdopodobieństwa

$$\varphi(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{1}{2\sigma^2} (x-\mu)^2 \right\} \quad (-\infty < X < \infty),$$

na część I, taką że  $X \leq d$ , i część II, taką że  $X > d$ , mamy

$$\frac{w_1}{w} = \sqrt{\frac{1}{2} + \Theta\left(\frac{d-\mu}{\sigma/\sqrt{2}}\right)} : \left[ \frac{1}{2} + \Theta\left(\frac{d-\mu}{\sigma}\right) \right],$$

$$\frac{w_2}{w} = \sqrt{\frac{1}{2} - \Theta\left(\frac{d-\mu}{\sigma/\sqrt{2}}\right)} : \left[ \frac{1}{2} - \Theta\left(\frac{d-\mu}{\sigma}\right) \right],$$

gdzie  $\Theta(\dots)$  oznacza funkcję Laplace'a.

Łatwo zauważyć, że wtedy zawsze  $w_1/w > 1$  oraz  $w_2/w > 1$ . Gdy  $d$  rośnie od  $\mu$  do  $\infty$ , to  $w_1/w$  maleje monotonicznie od  $\sqrt{2}$  do 1, a  $w_2/w$  rośnie

monotonicznie od  $\sqrt{2}$  do  $\infty$ . Dla  $d \rightarrow \infty$ , asymptotyczna wartość  $w_2/w$  jest równa  $\sqrt{\pi} \sqrt{(d-\mu)/\sigma}$ .

Pospolitość przykładów, w których zachodzi mocniejsze twierdzenie (10), może nasunąć przypuszczenie, że zachodzi ono zawsze. Tak jednak nie jest, a nawet bywa tak, że prawdziwość twierdzenia (10) zależy nie tylko od typu rozkładu i sposobu podziału, ale również od relacji metrycznych.

Dla ilustracji rozważmy następujący przykład.

Niechaj zmienna losowa  $X$  w partii ma gęstość jak na rysunku 2. Podzielmy partię na dwie części, tak żeby

w części I  $X \in (0, d_1)$ ,

w części II  $X \in (d_1, d_2)$ .

Mamy

$$w = \frac{\sqrt{d_1 \varphi_1^2 + (d_2 - d_1) \varphi_2^2}}{d_1 \varphi_1 + (d_2 - d_1) \varphi_2}, \quad w_1 = \frac{1}{\sqrt{d_1}}, \quad w_2 = \frac{1}{\sqrt{d_2 - d_1}}.$$

Żeby zachodziły jednocześnie nierówności  $w < w_1$  i  $w < w_2$ , potrzeba i wystarcza, żeby

$$\frac{d_2 - d_1}{d_1} + 2 \frac{\varphi_1}{\varphi_2} > 1 \quad \text{oraz} \quad \frac{d_1}{d_2 - d_1} + 2 \frac{\varphi_2}{\varphi_1} > 1.$$

A więc na przykład, jeśli  $d_2 = 2d_1$ , to twierdzenie (10) jest prawdziwe dla wszelkich wartości  $\varphi_1$  i  $\varphi_2$ . Jeśli natomiast  $(d_2 - d_1)/d_1 = \varphi_1/\varphi_2 = 0,1$ , to twierdzenie (10) nie jest prawdziwe.


Twierdzenie 1 można łatwo uogólnić na podział partii na  $N$  części. Dzieląc najpierw partię na 2 części stwierdzamy, że zgodnie z (6),  $w \leq \max(w_1, w_2)$ . Dzieląc teraz część I na części I' i I'', mamy  $w_1 \leq \max(w_1', w_1'')$ , a więc  $w \leq \max(w_1', w_1'', w_2)$  itd. Ogólnie:

$$w \leq \max(w_i) \quad (i = 1, 2, \dots, N).$$

A więc dzieląc partię w dowolny sposób na  $N$  części, mamy przynajmniej w jednej z części skupienie względne nie mniejsze niż przed podziałem.

#### § 4. Podział według największej sumy skupień częściowych.

Niechaj zmienna losowa  $X$  określona w obszarze  $S$  ma gęstość prawdopodobieństwa  $\varphi(x)$  i niechaj obszar  $S$  będzie sumą przedziałów  $\langle d_{i-1}, d_i \rangle$ ,  $i = 1, 2, \dots, N$ .



Rys. 2

TWIERDZENIE 2. *Jeśli  $v_i$  jest określone przez (2), to  $\sum_1^N v_i = \max$ ,  
gdy*

$$(15) \quad v_1 = v_2 = \dots = v_N.$$

Dowód. Z warunku koniecznego

$$\frac{\partial}{\partial d_i} \sum_1^N v_i = 0 \quad (i = 1, 2, \dots, N-1)$$

wynika, że

$$\frac{1}{2v_i^2} \varphi^2(d_i) - \frac{1}{2v_{i+1}^2} \varphi^2(d_i) = 0 \quad (i = 1, 2, \dots, N-1),$$

czyli

$$v_i^2 = v_{i+1}^2 \quad (i = 1, 2, \dots, N-1),$$

co jest równoznaczne z (16).

Pomijamy banalny dowód, że ekstremum tak znalezione jest maksimum.

WNIOSEK. *Wielkości  $d_i$  są kwantylami rzędu  $N$  w rozkładzie o gęstości prawdopodobieństwa  $\propto \varphi^2(x)$ . W przypadku szczególnym, gdy  $N = 2$ ,  $d_i$  jest medianą.*

Twierdzenie 2 ma następującą interpretację:

Jeśli partię należy podzielić na  $N-1$  części i jeśli wartość  $i$ -tej części jest proporcjonalna do  $i$ -tego skupienia częściowego, to największą wartość łączną uzyskuje się przy podziale według warunków (15).

Dla ilustracji przypuśćmy, że dana jest partia złożona z 1000 klocków; rozkład ich ciężarów jest normalny ze średnią  $m$  gramów i odchyleniem średnim  $\sigma = 10$  gramów. Klocki są przeznaczone do montażu sprzęgieł odśrodkowych. Z warunków pracy wynika, że komplety 5-cio sztukowe przeznaczone do jednego sprzęgła powinny mieć możliwie zbliżone ciężary. Z warunków technicznych wynika, że nie opłaca się dobierać indywidualnie klocków do takich kompletów, ale że wystarczy całą partię podzielić na 4 części i wybierać na chybił trafił po 5 klocków z jednej części. Jak należy podzielić partię?

Przyjmujemy, że wartość części partii jest proporcjonalna do skupień częściowych. Ma więc zastosowanie twierdzenie 2. Z wniosku z tego twierdzenia wynika, że punkty podziału powinny być kwantylami w rozkładzie normalnym  $N(m, \sigma/\sqrt{2})$ , czyli że

$$a_1 = m - \frac{0,674}{\sqrt{2}} \sigma, \quad a_2 = m, \quad a_3 = m + \frac{0,674}{\sqrt{2}} \sigma.$$

A więc powinno być:

w części I około 315 klocków o ciężarach do  $m-4,8$  g,  
 w części II „ 185 klocków o ciężarach od  $m-4,8$  do  $m$  g,  
 w części III „ 185 klocków o ciężarach od  $m$  do  $m+4,8$  g,  
 w części IV „ 315 klocków o ciężarach powyżej  $m+4,8$  g.

Twierdzenie 2 pozostaje w mocy, jeśli zamiast (15) rozważymy wyrażenie  $(\int_{a_{i-1}}^{a_i} \varphi^k(x) dx)^{1/k}$ . Okazuje się, że optymalne punkty podziału są kwartylami w rozkładzie o gęstości prawdopodobieństwa  $\propto \varphi^k(x)$ . Może to być użyteczne w praktyce, gdyż swoboda w doborze wykładnika  $k$  pozwala na dobre powiązanie wartości ze skupieniem.

Można pójść jeszcze dalej w uogólnieniach, ale nie jest to ani ciekawe matematycznie, ani nie wydaje się użyteczne w praktyce.

#### Prace cytowane

- [1] H. Steinhaus, *Über einige prinzipielle Fragen...*, Berlin, 1956, Deutscher Verlag d. Wissenschaften.  
 [2] H. Cramér, *Mathematical methods of statistics*, Princeton, 1946, str. 88.

INSTYTUT MATEMATYCZNY POLSKIEJ AKADEMII NAUK

Praca wpłynęła 21. 2. 1956

Я. ОДЕРФВЛД (Варшава)

#### О СОСРЕДОТОЧЕНИИ РАСПРЕДЕЛЕНИЯ

##### РЕЗЮМЕ

Пусть случайная переменная величина  $X$  непрерывная, одномерна и определена в области  $S$ , которая является суммой интервалов  $\langle d_{i-1}, d_i \rangle$  ( $i = 1, 2, \dots, N$ ). Обозначим плотность вероятности через  $\varphi(x)$ . Составим формулы

$$w = \left( \int_{(S)} \varphi^2(x) dx \right)^{1/2}, \quad v_i = \left( \int_{d_{i-1}}^{d_i} \varphi^2(x) dx \right)^{1/2}.$$

Первая формула называется *сосредоточением относительным*, вторая — *сосредоточением частичным*.

Показано связь между  $w$  и средним отклонением. Доказано две теоремы.

I. *Разделяя произвольно совокупность получаем по крайней мере в одной её части относительное сосредоточение не меньшее чем до разделения.*

Рассмотрено несколько примеров разделения, среди которых одно такое, что в каждой части сосредоточение относительное больше чем до разделения.



II. Разделяя партию на части не пересекающиеся относительно признака  $X$  получаем наибольшую сумму частичных сосредоточений, когда точки разделения являются квантилями в распределении  $\propto f^2(x)$ .

Приводятся некоторые обобщения этих теорем.

Выяснено связь между параметрами  $w$  и  $v$  и значением партии товара и приведено несколько примеров применения.

---

J. ODERFELD (Warszawa)

# ON THE CONCENTRATION OF DISTRIBUTION

## SUMMARY

Let  $X$  be a continuous one-dimensional random variable, defined in region  $S$  which is the sum of the intervals  $\langle d_{i-1}, d_i \rangle$ ,  $i = 1, 2, \dots, N$ . Let us denote the density of probability by  $\varphi(x)$ . Let us form the expressions

$$w = \left( \int_{(S)} \varphi^2(x) dx \right)^{1/2} \quad \text{and} \quad v_i = \left( \int_{d_{i-1}}^{d_i} \varphi^2(x) dx \right)^{1/2}.$$

The first of them will be called relative concentration, and the second partial concentration.

The relation between  $w$  and the standard deviation is shown.

Two theorems are proved. Theorem 1 states that by an arbitrary division of a population we obtain in at least one part of the population a relative concentration that is not smaller than before the division. Several particular cases of division are considered, among them a case in which the relative concentration in each part is greater than before the division.

Theorem 2 states that by dividing a lot into parts that are disjoint with respect to the characteristic  $X$  we obtain the greatest sum of partial concentrations when the points of division are quantiles in the distribution  $\propto f^2(x)$ .

Some generalizations of both theorems are given.

In the part containing applications the author explains the relation between parameters  $w$  and  $v$  and the value of a lot of the product and gives a few examples of application.

---