

# Charakterystyki liczbowe rozkładów cech statystycznych

## Miary położenia, zmienności, asymetrii i koncentracji

(literatura: Ostasiewicz, Rusnak, Siedlecka. Statystyka elementy teorii i zadania.  
Wydawnictwo AE we Wrocławiu, Wrocław 1999 (2006 – wydanie 6)

### Przykład 1. Szereg rozdzielczy szczegółowy

Na podstawie danych statystycznych (szereg rozdzielczy statystyczny szczegółowy  $n=20$ ) wyznaczyć charakterystyki liczbowe rozkładu dla  $X$  – oceny infrastruktury drogowej na Podkarpaciu.

$X = \{1 - \text{niedostateczna}, 2 - \text{mierna}, 3 - \text{dostateczna}, 4 - \text{dobra}, 5 - \text{bardzo dobra}, 6 - \text{celująca}\}.$

Obliczyć podstawowe miary klasyczne i pozycyjne: położenia, zmienności, asymetrii i koncentracji – wyniki zinterpretować w praktyce.

Ocena infrastruktury drogowej - $X_i$	Dane posortowane $X_i$	$(X_i - \bar{x})^2$	$(X_i - \bar{x})^3$	$(X_i - \bar{x})^4$
4	1	$(4-4,1)^2 = 0,01$	$(4-4,1)^3 = -0,001$	$(4-4,1)^4 = 0,00$
5	2	$(5-4,1)^2 = 0,81$	$(5-4,1)^3 = 0,73$	$(5-4,1)^4 = 0,66$
5	2	$(5-4,1)^2 = 0,81$	$(5-4,1)^3 = 0,73$	$(5-4,1)^4 = 0,66$
3	3	$(3-4,1)^2 = 1,21$	$(3-4,1)^3 = -1,33$	$(3-4,1)^4 = 1,46$
6	3	$(6-4,1)^2 = 3,61$	$(6-4,1)^3 = 6,86$	$(6-4,1)^4 = 13,03$
4	3	$(4-4,1)^2 = 0,01$	$(4-4,1)^3 = -0,001$	$(4-4,1)^4 = 0,00$
6	3	$(6-4,1)^2 = 3,61$	$(6-4,1)^3 = 6,86$	$(6-4,1)^4 = 13,03$
5	3	$(5-4,1)^2 = 0,81$	$(5-4,1)^3 = 0,73$	$(5-4,1)^4 = 0,66$
6	4	$(6-4,1)^2 = 3,61$	$(6-4,1)^3 = 6,86$	$(6-4,1)^4 = 13,03$
3	4	$(3-4,1)^2 = 1,21$	$(3-4,1)^3 = -1,33$	$(3-4,1)^4 = 1,46$
3	5	$(3-4,1)^2 = 1,21$	$(3-4,1)^3 = -1,33$	$(3-4,1)^4 = 1,46$
2	5	$(2-4,1)^2 = 4,41$	$(2-4,1)^3 = -9,26$	$(2-4,1)^4 = 19,45$
5	5	$(5-4,1)^2 = 0,81$	$(5-4,1)^3 = 0,73$	$(5-4,1)^4 = 0,66$
1	5	$(1-4,1)^2 = 9,61$	$(1-4,1)^3 = -29,79$	$(1-4,1)^4 = 92,35$
5	5	$(5-4,1)^2 = 0,81$	$(5-4,1)^3 = 0,73$	$(5-4,1)^4 = 0,66$
5	5	$(5-4,1)^2 = 0,81$	$(5-4,1)^3 = 0,73$	$(5-4,1)^4 = 0,66$
6	6	$(6-4,1)^2 = 3,61$	$(6-4,1)^3 = 6,86$	$(6-4,1)^4 = 13,03$
3	6	$(3-4,1)^2 = 1,21$	$(3-4,1)^3 = -1,33$	$(3-4,1)^4 = 1,46$
2	6	$(2-4,1)^2 = 4,41$	$(2-4,1)^3 = -9,26$	$(2-4,1)^4 = 19,45$
3	6	$(3-4,1)^2 = 1,21$	$(3-4,1)^3 = -1,33$	$(3-4,1)^4 = 1,46$
<b>suma</b>	<b>82</b>	<b>= 43,8</b>	<b>= -23,16</b>	<b>= 194,63</b>

- Miary położenia (klasyczne):

Średnia  $\bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{82}{20} = 4,1$  – średnio infrastruktura drogowa na Podkarpaciu była oceniana przez ankietowanych na ocenę 4,1 (4,0 - dobrze).

- Miary położenia (pozycyjne):

Modalna (Dominanta) – wartość najczęstsza statystyki pojawiająca się w rozkładzie  $D = M_o = 5$ , liczność mody = 6. Najczęściej ankietowani oceniali infrastrukturę drogową na ocenę 5 – bardzo dobrze (6 – ankietowanych na 20 – 30%)

Kwartyle (Mediana, Kwartył dolny, Kwartył górny)

Mediana ( $M_e = Q_2$ ) – wartość środkowa w rozkładzie cechy. W przypadku szeregu szczegółowego wyznaczamy pozycję mediany dla danych uporządkowanych. W przypadku parzystej liczby wyników są dwa takie wyniki  $\frac{n}{2} = \frac{20}{2} = 10$  oraz  $\frac{n}{2} + 1 = 11$ . Medianę obliczamy jako  $Me = \frac{x_{10} + x_{11}}{2} = \frac{4 + 5}{2} = 4,5$ . Połowa ankietowanych (50%) oceniła infrastrukturę drogową na ocenę 4,5 lub gorzej (co najwyżej 4,5: 1,2,3 lub 4), tym samym połowa ankietowanych oceniła infrastrukturę nie gorzej niż 4,5 (5 i 6).

Podobnie wyznaczamy:

Kwartył dolny  $Q_1$ . W przypadku parzystej liczby wyników są dwa takie wyniki odpowiadające kwartyłowi dolnemu  $\frac{n}{4} = \frac{20}{4} = 5$  oraz  $\frac{n}{4} + 1 = 6$ .  $Q_1$  obliczamy zatem jako  $Q_1 = \frac{x_5 + x_6}{2} = \frac{3 + 3}{2} = 3$ . Co czwarty ankietowany (25% ankietowanych) ocenił infrastrukturę drogową na ocenę 3 lub gorzej (co najwyżej 3: 1,2,3), tym samym  $\frac{3}{4}$  (75%) ankietowanych oceniało infrastrukturę nie gorzej niż 3 (co najmniej 3: 3, 4, 5 i 6).

Kwartył górny  $Q_3$ . W przypadku parzystej liczby wyników są dwa takie wyniki odpowiadające kwartyłowi górnemu  $\frac{3n}{4} = \frac{3 \cdot 20}{4} = 15$  oraz  $\frac{3n}{4} + 1 = 16$ .  $Q_3$  obliczamy zatem jako  $Q_3 = \frac{x_{15} + x_{16}}{2} = \frac{5 + 5}{2} = 5$ .  $\frac{3}{4}$  ankietowanych (75% ankietowanych) oceniało infrastrukturę drogową na ocenę 5 lub gorzej (co najwyżej 5: 1,2,3,4,5), tym samym co czwarty ankietowany (25%) ankietowanych oceniało infrastrukturę nie gorzej niż 5 (co najmniej 5: 5, 6).

- Miary zmienności (klasyczne):

Wariancja i odchylenie standardowe. Wariancję obciążoną wyznaczamy ze wzoru  $S^2 = \frac{\sum_{i=1}^n (X_i - \bar{x})^2}{n} = \frac{43,8}{20} = 2,19$  (2,2). Wariancję nieobciążoną  $S_1^2$  (wyznaczaną przez program Statistica), która daje lepsze oszacowanie dla nieznannej wartości wariancji w populacji w przypadku małych prób obliczamy ze wzoru:  $S_1^2 = \frac{\sum_{i=1}^n (X_i - \bar{x})^2}{n-1} = \frac{43,8}{20-1} = 2,31$  (2,3). Aby wyrazić zmienność w tych samych jednostkach co wartości statystyki obliczamy wartości odchylenia standardowego:  $S = \sqrt{2,19} = 1,48$  ( $S_1 = \sqrt{2,31} = 1,52$ ).

Zmienność ocen infrastruktury drogowej wyrażona odchyleniem standardowym wynosi +/- 1,5.

Zatem typowy przedział zmienności wartości tej statystyki jest postaci:  $(\bar{x} - S, \bar{x} + S) = (2,62 - 5,58)$ . Jest to typowy przedział zmienności, w którym znajduje się  $\frac{2}{3}$  (67%)

wszystkich wyników. Typowy przedział zmienności dla ocen infrastruktury to przedział zmienności ocen (2,6 – 5,6), w którym znajduje się zmienność (rozrzut) ocen dla ok. 2/3 (67%) wszystkich badanych ankietowanych. Jest to dość duża zmienność. Aby ocenić jak jest to duża procentowo zmienność należy wyznaczyć klasyczny procentowy współczynnik zmienności (procentowe zróżnicowanie wartości statystyki)  $V_s = \frac{S}{\bar{x}} * 100\% = \frac{1,48}{4,1} * 100 = 36,1\%$ . Zmienność ocen infrastruktury drogowej jest na poziomie 36% (dość duża zmienność – znaczne istotne zróżnicowanie wartości badanej statystyki > 10%).

- Miary zmienności (pozycyjne):

Rozstęp jest pozycyjnym parametrem charakteryzującym zmienność rozkładu wartości badanych statystyk. Rozstęp obliczamy ze wzoru:  $R = x_{max} - x_{min} = 6 - 1 = 5$ . Maksymalna zmienność – rozrzut (rozstęp) dla ocen infrastruktury drogowej wynosi 5. Podobnie możemy policzyć rozstęp kwartylowy  $R_{Q_1, Q_3} = Q_3 - Q_1 = 5 - 3 = 2$ . Rozstęp kwartylowy charakteryzuje zmienność wyników po odrzuceniu 25% najmniejszych wyników (poniżej  $Q_1=3$  dostatecznie) oraz 25% największych wyników (powyżej  $Q_3=5$  bardzo dobrze). Tak charakteryzowana zmienność wyników dla ocen infrastruktury wynosi 2. Pozycyjnym współczynnikiem zmienności jest odchylenie ćwiartkowe (podobnie jak w przypadku miar klasycznych odchylenie standardowe). Wyznamy go ze wzoru:  $Q = \frac{(Q_3 - M_e) + (M_e - Q_1)}{2} = \frac{Q_3 - Q_1}{2} = \frac{5 - 3}{2} = 1$ . Procentowy współczynnik zmienności pozycyjny można wyznaczyć ze wzoru  $V_Q = \frac{Q}{M_e} * 100\% = \frac{1}{4,5} * 100 = 22,2\%$ .

- Miary asymetrii – skośności rozkładu:

Rozkłady różnią się między sobą zarówno kierunkiem jak i siłą asymetrii. Do oceny asymetrii stosuje się porównanie  $\bar{x}$ ,  $M_e$  i  $M_o$ . Jeżeli  $\bar{x} = M_e = M_o$  mamy do czynienia z rozkładem w pełni symetrycznym. Jeżeli  $\bar{x} > M_e > M_o$  mamy do czynienia z rozkładem o asymetrii prawostronnej. Natomiast jeżeli  $\bar{x} < M_e < M_o$  mamy do czynienia z rozkładem o asymetrii lewostronnej. W naszym przypadku:  $\bar{x} = 4,1$ ;  $M_e = 4,5$ ;  $M_o = 5$ , zatem mamy do czynienia z asymetrią lewostronną rozkładu ocen infrastruktury. Do określania siły i kierunku asymetrii można stosować współczynniki skośności oparte zarówno na parametrach klasycznych jak i pozycyjnych. W przypadku parametrów klasycznych można wyznaczyć np. współczynnik skośności wyrażony wzorem  $A_s = \frac{\bar{x} - M_o}{S} = \frac{4,1 - 5}{1,48} = -0,61$  (asymetria lewostronna – dość duża). W przypadku parametrów pozycyjnych wyznacza się współczynnik skośności wyrażony wzorem  $A_Q = \frac{Q_3 + Q_1 - 2M_e}{2Q} = \frac{5 + 3 - 2 * 4,5}{2 * 1} = -0,5$  (asymetria lewostronna). Można również wyznaczyć (podobnie jak w pakiecie Statistica) klasyczny współczynnik asymetrii (skośności) oparty na tzw. momencie centralnym rozkładu rzędu 3 ze wzoru:  $A = \frac{m_3}{S^3} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{S^3} = \frac{-23,16 * \frac{1}{20}}{1,48^3} = -0,36$  (również świadczy to znaczącej asymetrii lewostronnej rozkładu ocen infrastruktury drogowej).

- Miary koncentracji rozkładu:

Miarą skupienia (koncentracji) poszczególnych wartości wokół średniej jest współczynnik skupienia Kurtoza  $K = \frac{m_4}{s^4} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{s^4} = \frac{194,63 \cdot \frac{1}{20}}{1,48^4} = 2,03$ . Porównanie koncentracji badanego rozkładu z rozkładem Normalnym (Gaussa), który jest symetrycznym rozkładem o koncentracji wyrażonej Kurtozą  $K=3$  odbywa się za pomocą analizy współczynnika koncentracji  $K' = K - 3 = 2,03 - 3 = -0,97$ . Zatem rozkład naszej badanej statystyki ma mniejszą koncentrację (jest bardziej spłaszczony) w porównaniu do analogicznego (o tych samych parametrach) rozkładu normalnego (jest rozkładem tzw. platokurtycznym). Gdy  $K > 3$  mamy do czynienia z rozkładami bardziej wysmukłymi (tzw. leptokurtycznymi).

## Przykład 2. Szereg rozdzielczy punktowy – dane uporządkowane (dane statystyczne z przykładu 1)

Na podstawie danych z przykładu 1 utworzono szereg rozdzielczy punktowy:

Klasa (i) k=6 liczba klas	$X_i$	$n_i$	Liczność sk. $n_{i,sk}$	Procent t $w_i$	Procent sk. $w_{i,sk}$	$x_i * n_i$	$(x_i - \bar{x})^2$ $* n_i$	$(x_i - \bar{x})^3$ $* n_i$	$(x_i - \bar{x})^4$ $* n_i$
ocena 1	1	1	1	0,05	0,05	1*1=1	9,61	-29,791	92,3521
ocena 2	2	2	3	0,1	0,15	2*2=4	8,82	-18,522	38,8962
ocena 3	3	5	8	0,25	0,4	3*5=15	6,05	-6,655	7,3205
ocena 4	4	2	10	0,1	0,5	4*2=8	0,02	-0,002	0,0002
ocena 5	5	6	16	0,3	0,8	5*6=30	4,86	4,374	3,9366
ocena 6	6	4	20	0,2	1	6*4=24	14,44	27,436	52,1284
<b>suma</b>		<b>20</b>		<b>1</b>		<b>82</b>	<b>43,8</b>	<b>-23,16</b>	<b>194,634</b>

Wyznaczyć dla tak zgrupowanych danych jeszcze raz: średnią, wariancję i odchylenie standardowe oraz współczynnik skośności ( $A$  oparty o moment centralny  $m_3$ ) oraz współczynnik koncentracji ( $K' = K - 3$ ) – zauważmy, że otrzymamy te same wyniki co w przykładzie 1.

Średnia:  $\bar{x} = \frac{\sum_{i=1}^k x_i * n_i}{n} = \frac{82}{20} = 4,1$ . Wariancja  $S^2 = \frac{\sum_{i=1}^k (x_i - \bar{x})^2 * n_i}{n} = \frac{43,8}{20} = 2,19$  (2,2),  
odchylenie standardowe  $S = \sqrt{2,19} = 1,48$ . Współczynnik asymetrii (skośności)  $A = \frac{m_3}{s^3} = \frac{\frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^3 * n_i}{s^3} = \frac{-23,16 \cdot \frac{1}{20}}{1,48^3} = -0,36$ . Współczynnik koncentracji  $K' = K - 3 = \frac{m_4}{s^4} - 3 = \frac{\frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^4 * n_i}{s^4} - 3 = \frac{194,63 \cdot \frac{1}{20}}{1,48^4} - 3 = 2,03 - 3 = -0,97$ .

### Przykład 3. Szereg rozdzielczy przedziałowy – dane uporządkowane

Na podstawie danych zgrupowanych w postaci szeregu rozdzielczego przedziałowego dla czasów dojazdu na uczelnię 15 studentów (min):

Przedziały klasowe $k=4$	Środek i $\dot{x}_i$	$n_i$	Liczność sk. $n_{i,sk}$	Procent $w_i$	Procent sk. $w_{i,sk}$	$\dot{x}_i * n_i$	$(\dot{x}_i - \bar{x})^2 * n_i$	$(\dot{x}_i - \bar{x})^3 * n_i$	$(\dot{x}_i - \bar{x})^4 * n_i$
[5-13]	9	3	3	0,2	0,2	27	522,72	-6899,904	91078,7328
[14-22]	18	5	8	0,33333 3	0,53	90	88,2	-370,44	1555,848
[23-31]	27	4	12	0,26666 7	0,8	108	92,16	442,368	2123,3664
[32-40]	36	3	15	0,2	1	108	571,32	7884,216	108802,1808
<b>suma</b>		<b>15</b>		<b>1</b>		<b>333</b>	<b>1274,4</b>	<b>1056,24</b>	<b>203560,128</b>

Wyznaczyć statystyki opisowe parametrów rozkładu badanej statystyki (**Interpretację praktyczną podać samodzielnie !!!**), takie jak:

$$\text{Średnia} = \bar{x} = \frac{\sum_{i=1}^k \dot{x}_i * n_i}{n} = \frac{333}{15} = 22,2 \text{ (min)}$$

Modalna - dla danych zgrupowanych wartość modalnej można oszacować następująco. Określić przedział zawierający modalną (klasa druga [14-22] – licznosc 5). Wyliczyć jej oszacowanie ze wzoru (3.12 – podręcznik Ostasiewicz):  $M_o = 14 + \frac{5-3}{(5-3)+(5-4)} * 9 = 20$  (min).

Mediana - dla danych zgrupowanych wartość kwartyli (w tym wypadku wartości środkowej mediany można oszacować następująco. Określić przedział zmienności, w którym znajduje się mediana (klasa druga – procent skumulowany powyżej 0,5: [14-22] – licznosc 5). Wyliczyć jej oszacowanie ze wzoru (3.14 – podręcznik Ostasiewicz):  $M_e = 14 + \frac{7,5-3}{5} * 9 = 22,1$  (min).

Podobnie mamy dla kwartyli dolnego. Przedział zmienności, w którym znajduje się  $Q_1$  (to dalej klasa druga – procent skumulowany powyżej 0,25: [14-22] – licznosc 5). Zatem  $Q_1 = 14 + \frac{3,75-3}{5} * 9 = 15,35$  (min).

Oraz dla kwartyli górnego. Przedział zmienności, w którym znajduje się  $Q_3$  (to klasa trzecia – procent skumulowany powyżej 0,75: [23-31] – licznosc 4). Zatem  $Q_3 = 23 + \frac{11,25-8}{4} * 9 = 30,31$  (min).

$$\text{Wariancja i odchylenie standardowe: } S^2 = \frac{\sum_{i=1}^k (\dot{x}_i - \bar{x})^2 * n_i}{n} = \frac{1274,4}{15} = 84,96, S = \sqrt{84,96} = 9,2.$$

Skośność i Kurtoza: Współczynnik asymetrii (skośności)  $A = \frac{m_3}{s^3} = \frac{\frac{1}{n} \sum_{i=1}^k (\dot{x}_i - \bar{x})^3 * n_i}{s^3} = \frac{1056,24 * \frac{1}{15}}{9,2^3} = 0,09$ . Współczynnik koncentracji  $K' = K - 3 = \frac{m_4}{s^4} - 3 = \frac{\frac{1}{n} \sum_{i=1}^k (\dot{x}_i - \bar{x})^4 * n_i}{s^4} - 3 = \frac{203560,13 * \frac{1}{15}}{9,2^4} - 3 = 1,9 - 3 = -1,1$ .

- **Zadania do samodzielnego rozwiązania (z książki: Ostasiewicz, Rusnak, Siedlecka. Statystyka elementy teorii i zadania. Wydawnictwo AE we Wrocławiu, Wrocław 1999 (2006)).**

- przeanalizować przykłady dla średniej geometrycznej i harmonicznej – str. 51 – 53. Interpretacja i zastosowanie tego typu średnich.

- Zad. 3.3, Zad. 3.10, Zad. 3.12, Zad. 3.14, Zad. 3.30, Zad. 3.31, Zad. 3.34.