

# Statystyka matematyczna

## Elementy statystyki opisowej

**Średnia arytmetyczna** – inaczej średnia lub przeciętna z  $n$  liczb  $x_1, x_2, \dots, x_n$ , dla  $n \geq 1$  jest to liczba  $x_{sr}$  określona wzorem:

$$x_s = (x_1 + x_2 + \dots + x_n) / n$$

Najczęściej oznacza się średnią arytmetyczną jako  $\bar{x}$  nadkreślone:

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$$

$\bar{x}$  - średnia arytmetyczna

$\sum_{i=1}^n x_i$  - suma liczb  $x$  dla  $i$  od 1 do  $n$ ,  $n \geq 1$

Przykład:

Średnia arytmetyczna liczba: -1, 0, 1, 4, 6:

$$x_s = (-1 + 0 + 1 + 4 + 6) : 5 = 10 : 5 = 2$$

Średnia arytmetyczna z ciągu złożonego z tej samej liczby jest równa tej liczbie.

Przykład:

Średnia z liczb: 12, 12, 12, 12 wynosi 12, bo:

$$(12 + 12 + 12 + 12) / 4 = 4 * 12 : 4 = 12$$

W przypadku podanych **liczebności** kolejnych danych  $x_i$ , średnia  $x_s$  wyraża się wzorem:

$$x_s = (n_1 * x_1 + n_2 * x_2 + \dots + n_k * x_k) / (n_1 + n_2 + \dots + n_k)$$

$$x_s = \frac{x_1 * n_1 + x_2 * n_2 + \dots + x_n * n_n}{n_1 + n_2 + \dots + n_k} = \frac{\sum_{i=1}^k x_i * n_i}{\sum_{i=1}^k n_i} \quad k \in \mathbb{N}$$

Liczebności można potraktować jak wagi i wzór jest analogiczny jak dla średniej ważonej

Przykład

Wartość $x_i$	0	1	2	3
Liczebność $n_i$	4	2	3	1

$$x_s = (n_1 * x_1 + n_2 * x_2 + n_3 * x_3 + n_4 * x_4) / (n_1 + n_2 + n_3 + n_4)$$

$$x_s = (0 * 4 + 1 * 2 + 2 * 3 + 3 * 1) / (4 + 2 + 3 + 1) = 1.1$$

W przypadku podanych **częstości** (gdzie suma częstości równa się 1)

$$x_s = x_1 * c_1 + x_2 * c_2 + \dots + x_n * c_n$$

Wartość $x_i$	1	2	3	4	5	6
Częstość $c_i$	0	0,09	0,41	0,35	0,10	0,05

$$x_s = 1 * 0 + 2 * 0,09 + 3 * 0,41 + 4 * 0,35 + 5 * 0,10 + 6 * 0,05 = 3,61$$

**Średnia ważona** liczba  $x_1, x_2, \dots, x_n$ , z wagami równymi odpowiednio  $p_1, p_2, \dots, p_n$

Jest to liczba  $x_p$  określona wzorem:

$$x_p = (x_1 * p_1 + x_2 * p_2 + \dots + x_n * p_n) / (p_1 + p_2 + \dots + p_n)$$

$p_i$  – waga (*power*) - liczba dodatnia

wagi - liczby dodatnie określające ważność poszczególnych składników sumy (znaczenie, ważność, częstość występowania).

$$x_p = \frac{x_1 * p_1 + x_2 * p_2 + \dots + x_n * p_n}{p_1 + p_2 + \dots + p_n} = \frac{\sum_{i=1}^n x_i * p_i}{\sum_{i=1}^n p_i} \quad k \in \mathbb{N}$$

Przykład 1:

Średnia ważona liczb -1, 0, 1, 4, 6 z wagami odpowiednio: 1, 2, 3, 4, 5

$$x_p = (-1*1 + 0*2 + 1*3 + 4*4 + 6*5) / (1 + 2 + 3 + 4 + 5) = 3,2$$

Przykład 2:

W pewnej klasie uzyskano następujące oceny ze sprawdzianu:

6 – 1 osoba, 5 - 2 osoby, 4 - 3 osoby, 3 - 5 osób, 2 – 6 osób, 1 - 4 osoby.

Oblicz średnią ocenę ze sprawdzianu.

$$x_p = (6*1 + 5*2 + 4*3 + 3*5 + 2*6 + 1*4) / (1 + 2 + 3 + 5 + 6 + 4) = (6 + 10 + 12 + 15 + 12 + 4) / 49 = 59 / 49 = 3,93$$

Odpowiedź: Średnia ocena ze sprawdzianu w klasie wynosi 3,93.

**Dominanta** (moda) - **wartość występująca najczęściej.**

W niektórych przypadkach istnieje kilka dominant.

[http://pl.wikipedia.org/wiki/Dominanta\\_\(statystyka\)](http://pl.wikipedia.org/wiki/Dominanta_(statystyka))

**Dominanta** (wartość modalna, moda, wartość najczęstsza) to jedna z miar tendencji centralnej, statystyka dla zmiennych o rozkładzie dyskretnym, wskazująca na wartość o największym prawdopodobieństwie wystąpienia, lub wartość najczęściej występująca w próbie.

Dla zmiennej losowej o rozkładzie ciągłym jest to wartość, dla której funkcja gęstości prawdopodobieństwa ma wartość największą.

Przykład 1

Podaj dominantę z liczb: 6, 2, 4, 6, 1, 6, 4

Częstość występowania: 6 – 3 razy, 4 – 2 razy, pozostałe liczby 1 raz

Rozwiązanie: Najczęściej występuje liczba 6, która jest dominantą zestawu liczb.

Przykład 2

Liczba	3	4	6	7	10
Częstość występowania	4	3	4	4	2

Trzy liczby powtarzają się tak samo często, zatem są trzy dominanty.

Są to: 3, 6, 7.

Odpowiedź: Są trzy dominanty: 3, 6 i 7.

Przykład 3

Wartość	Prawdopodobieństwo
1	0,3
2	0,25
<b>3</b>	<b>0,35</b>
4	0,15
5	0,30

Wartość modalna dla tego rozkładu wynosi **3**, bo tam jest największe prawdopodobieństwo.

### Zastosowanie dominanty

[http://pl.wikipedia.org/wiki/Dominanta\\_\(statystyka\)](http://pl.wikipedia.org/wiki/Dominanta_(statystyka))

*Dominanta może być szczególnie użyteczna, gdy wartości zmiennej obserwowanej nie są liczbowe a opisowe - co uniemożliwia (bez przypisania wartości liczbowych) zastosowania m.in. mediany czy średniej arytmetycznej.*

*W zbiorze {jabłko, gruszka, jabłko, pomarańcza, gruszka, banan, jabłko} dominantą jest jabłko; w klasie jest 5 brunetek, 3 blondynki i 4 szatynki - dominantą jest brunetka.*

*Dominanta jest niedoceniana w zagadnieniach społecznych czy ekonomicznych np. przy analizowaniu zagadnień płacowych gdyż lepiej od powszechnie stosowanego średniego wynagrodzenia*

*oddaje strukturę wynagrodzeń.*

*Np. w sklepie pracuje 5 osób: kierownik z wynagrodzeniem 10000 zł; zastępca 7000 zł i trzech sprzedawców po 1000 zł*

*- średnie wynagrodzenie to 4 tysiące a najczęstsze (dominanta) to 1000 złotych.*

**Mediana** – wartość środkowa n liczb  $x_1, x_2, \dots, x_n$  uporządkowanych niemalejąco to liczba dzieląca ten zestaw na 2 części o równej liczebności.

**Mediana  $m_e$**  dzieli zbiór danych wartości na dwie części tak, że liczba danych, których wartości zmiennej są mniejsze od mediany, jest równa liczbie danych, których wartości zmiennej są większe od mediany.

**Mediana** (zwana też wartością środkową, wartością przeciętną lub drugim kwartylem) – w statystyce wartość cechy w szeregu uporządkowanym, powyżej i poniżej której znajduje się jednakowa liczba obserwacji.

$$m_e = x_{\frac{n+1}{2}} \quad \text{gdy } n \text{ jest liczbą nieparzystą}$$

$$m_e = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2} + 1}}{2} \quad \text{gdy } n \text{ jest liczbą parzystą}$$

### Mediana $m_e$

$$m_e = x_{(n+1)/2} \quad \text{gdy } n \text{ jest liczbą nieparzystą}$$

$$m_e = (x_{n/2} + x_{(n/2+1)}) / 2 \quad \text{gdy } n \text{ jest liczbą parzystą}$$

Przykłady – liczby uporządkowane rosnąco

1)

n jest liczbą nieparzystą – mediana jest liczbą środkową

-3    0    **1**    5    9

$$n = 5, (n+1)/2 = (5+1)/2 = 6/2 = 3$$

$$m_e = x_3 = 1$$

2) n jest liczbą parzystą – mediana jest średnią arytmetyczną 2 liczb środkowych

-2      -1      **1**      **3**      5      10

$$n/2 = 6/2 = 3$$

$$n/2 + 1 = 3 + 1 = 4$$

$$m_e = (x_3 + x_4) / 2 = (1 + 3) / 2 = 2$$

### Przykłady – liczby nieuporządkowane

#### Przykład 1

Podaj medianę z liczb: 2, 7, 12, 3, 9.

Najpierw porządkujemy liczby: 2, 3, **7**, 9, 12

$$n = 5, (n+1)/2 = 6/2 = 3$$

$$m_e = x_3 = \mathbf{7}$$

#### Przykład 2

Oblicz medianę z liczb: 7, 4, 6, 4, 7, 1, 9.

Po uporządkowaniu rosnąco: 1, 4, 4, **6**, 7, 7, 9

$$m_e = 6.$$

#### Przykład 3

Oblicz medianę z liczb 12, 6, 24, 18, 40, 8

Po uporządkowaniu: 6, 8, **12**, **18**, 24, 40

$$m_e = (12 + 18) / 2 = 15$$

**Rozstęp R** - różnica między największą i najmniejszą z liczb w zbiorze (lub różnica między najwyższą i najniższą zaobserwowaną wartością zmiennej).

Jest to jedna z prostszych miar rozrzutu.

**Rozstęp** pokazuje zatem jedynie jaki jest zakres obserwacji nie informuje w żaden sposób co dzieje się "w środku" tego zakresu

np. jaka wartość występowała najczęściej, czy jaka jest średnia dla tego zbioru obserwacji.

<http://pl.wikipedia.org/wiki/Rozst%C4%99p>

*Rozstęp jest najprostszą z miar rozrzutu, mało precyzyjną, gdyż opiera się tylko na dwu zaobserwowanych wartościach zmiennej, a pozostałe wartości nie mają wpływu na jej wielkość.*

*Przykład zastosowania:*

*w pedagogice w analizie ilościowej wyników egzaminowania rozstęp bywa obliczany dla uzyskania wstępnej orientacji*

*co do rezultatów egzaminowania albo wtedy,*

*gdy chodzi wyłącznie o krańcowe wyniki.*

[http://www.naukowiec.org/wiedza/statystyka/rozstep\\_711.html](http://www.naukowiec.org/wiedza/statystyka/rozstep_711.html)

*Dwie grupy osób poproszono o ocenę na dziesięciostopniowej skali.*

*W jednej grupie najniższy wynik wynosił 3, najwyższy 9.*

*W drugiej grupie natomiast wynik najniższy to 1 a najwyższy 9.*

$$R1 = X1 \max - X1 \min = 9 - 3 = 6$$

$$R2 = X2 \max - X2 \min = 9 - 1 = 8$$

*Widzimy zatem, że w grupie 2 zakres odpowiedzi był większy niż w grupie 1.*

*Oznacza to, że w grupie 2 udzielano bardziej skrajnych odpowiedzi niż w grupie 1.*

Miarę tą często stosuje się dla takich zmiennych jak wiek osób badanych czy uzyskiwany dochód. **Rozstęp** informuje nas wtedy, jak duża była dysproporcja pomiędzy osobą najmłodszą a najstarszą, pomiędzy osobą o najniższych dochodach a najwyższych. Określa jak duża jest ta różnica.

### Odchylenie wartości $x$ od średniej arytmetycznej

$$d = x_i - x_s$$

Przykład

$$x_1 = 4, x_2 = -3, x_3 = 2$$

$$x_s = x = (4 - 3 + 2) / 3 = 1$$

$$x_1 - x = 4 - 1 = 3$$

$$x_2 - x = -3 - 1 = -4$$

$$x_3 - x = 2 - 1 = 1$$

**Odchylenie bezwzględne** elementu zbioru danych statystycznych to wartość bezwzględna różnicy wartości

dla tego elementu  $x_i$  i pewnego ustalonego punktu  $x$ .

$$d = |x_i - x|$$

Za ustalony punkt, od którego liczone jest odchylenie bezwzględne, przyjmuje się zazwyczaj medianę lub średnią arytmetyczną.

Dla przykładu wyżej:

$$d_1 = |x_1 - x| = |4 - 1| = 3$$

$$d_2 = |x_2 - x| = |-3 - 1| = 4$$

$$d_3 = |x_3 - x| = |2 - 1| = 1$$

Odchylenia bezwzględne są wykorzystywane przy obliczaniu średniego odchylenia bezwzględnego.

**Odchylenie średnie** jest to średnia arytmetyczna odchyłeń od wartości średniej.

**Średnie odchylenie bezwzględne** (inaczej: odchylenie **przeciętne**)

to średnia arytmetyczna z odchyłeń bezwzględnych dla wszystkich elementów zbioru danych statystycznych.

$$D = \sum(x_i - x) / n, \quad i = 1 \dots n \quad n - \text{liczebność zbioru danych}$$

Dla przykładu wyżej

$$D = (3 + |-4| + 1) / 3 = 8/3 = 2,7$$

**Wariancja** to w statystyce klasyczna miara zmienności.

Intuicyjnie utożsamiana ze zróżnicowaniem zbiorowości;

Wariancja jest średnią arytmetyczną kwadratów odchyłeń (różnic) poszczególnych wartości cechy od wartości oczekiwanej.

**Wariancja** liczb  $x_1, x_2, \dots, x_n$  jest to średnia arytmetyczna z kwadratów odchyłeń liczb od ich wartości średniej

$$\sigma^2 = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

$$\sigma^2 = \sum (x_i - \bar{x})^2 / n = (x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 / n \quad \text{dla } i = 1 \text{ do } n$$

gdzie  $\bar{x}$  = średnia arytmetyczna wartości  $x_i$

$$\bar{x} = \sum x_i / n = (x_1 + x_2 + \dots + x_n) / n$$

$$\sigma^2 = \sum x_i^2 / n - \bar{x}^2 = (x_1^2 + x_2^2 + \dots + x_n^2) / n - \bar{x}^2$$

Inna postać wzoru:

$$\sigma^2 = \sum x_i^2 / n - \bar{x}^2, \quad \text{gdzie } \bar{x} = x_s \text{ - średnia arytmetyczna}$$

$$\sigma^2 = \frac{\sum_{i=1}^k x_i^2}{\sum_{i=1}^k n_i} - \bar{x}^2$$

**Odchylenie standardowe** liczb od średnie arytmetycznej – pierwiastek kwadratowy z wariancji

$$\sigma = \sqrt{\sigma^2} = \sqrt{\sum (x_i - \bar{x})^2 / n} = \sqrt{(\sum x_i^2 / n - \bar{x}^2)} \quad \text{gdzie } \bar{x} \text{ - średnia arytmetyczna wartości } x_i$$

W przypadku występowania **liczebności** danych wzory uwzględniające **liczebność**:

$$\sigma^2 = \sum (n_i * x_i - \bar{x})^2 / n = (n_1 * (x_1 - \bar{x})^2 + n_2 * (x_2 - \bar{x})^2 + \dots + n_k * (x_n - \bar{x})^2) / (n_1 + n_2 + \dots + n_k)$$

$$\sigma^2 = \frac{n_1 (x_1 - \bar{x})^2 + n_2 (x_2 - \bar{x})^2 + \dots + n_k (x_n - \bar{x})^2}{n_1 + n_2 + \dots + n_k} = \frac{\sum_{i=1}^k (x_i - \bar{x})^2}{\sum_{i=1}^k n_i}$$

$$\sigma = \sqrt{\sigma^2}$$

## Analiza dokładności

**Odchylenie wartości od średniej arytmetycznej**

$$v_i = x_i - x_s \text{ - odchylenie wartości } x_i \text{ od średniej arytmetycznej } x_s$$

**Odchylenie przeciętne**

$$d = (|x_1 - x_s| + |x_2 - x_s| + \dots + |x_n - x_s|) / n = (|v_1| + |v_2| + \dots + |v_n|) / n = (\sum |x_i - x_s|) / n$$

**Wariancja**

Wariancja to w statystyce klasyczna miara zmienności.

Wariancja informuje o tym, jak duże jest zróżnicowanie wyników w danym zbiorze wyników

$$\sigma^2 = [(x_1 - x_s)^2 + (x_2 - x_s)^2 + \dots + (x_n - x_s)^2] / n = (\sum (x_i - x_s)^2) / n$$

## Odchylenie standardowe

**Odchylenie standardowe** – klasyczna miara zmienności, obok średniej arytmetycznej najczęściej stosowane pojęcie statystyczne.

**Odchylenie standardowe jest pierwiastkiem kwadratowym z wariancji.**

$$\sigma = \sqrt{[(x_1 - x_s)^2 + (x_2 - x_s)^2 + \dots + (x_n - x_s)^2] / n} = \sqrt{(\sum(x_i - x_s)^2) / n}$$

$$\sigma = \sqrt{\sigma^2}$$

## Współczynnik zmienności v – odchylenie względne

$$v = \sigma / x_s * 100\%$$

**Współczynnik zmienności** to klasyczna miara zróżnicowania rozkładu cechy.

W odróżnieniu od [odchylenia standardowego](#), które określa bezwzględne zróżnicowanie cechy, współczynnik zmienności jest miarą *względną*, czyli zależną od wielkości średniej arytmetycznej.

### Przykład

Obliczenie średniej ocen z analizą dokładności

<b>Obliczenie średniej ocen, odchylenia przeciętnego, wariancji i odchylenia standardowego</b>				
Lp	x(i)	v(i) = x(i) - x	x(i) - x	v(i)^2
1	5	2	2	4
2	4	1	1	1
3	3	0	0	0
4	3	0	0	0
5	3	0	0	0
6	2	-1	1	1
7	1	-2	2	4
Suma	21	0	6	10
średnia	<b>3</b>		0,86	
<b>Srednia</b>	=21/7		<b>3</b>	
<b>Odchylenie przeciętne d</b>	= 2/7		<b>0,86</b>	
<b>Wariancja sigma^2</b>	= 2/7		<b>1,43</b>	
<b>Odchylenie stand. sigma</b>	Pierwiastek(2/7)		<b>1,20</b>	
<b>Współczynnik zmienności v</b>	=1,20 / 3 * 100%		<b>17,07%</b>	

