

Statystyka  
w pracy badawczej nauczyciela  
Wykład 3: Analiza struktury zbiorowości statystycznej

dr inż. Walery Susłow  
walery.suslow@ie.tu.koszalin.pl

---

---

# Zadania analityczne (1)

- Analiza przewiduje badanie podobieństw i różnic, jakie występują między elementami danej zbiorowości ze względu na wyróżnioną cechę statystyczną.
  - Podobieństwa badamy określając *przeciętny poziom* (tendencję centralną) cechy w danej zbiorowości.
  - Różnice badamy, określając *dyspersję, asymetrię i koncentrację* wariantów cechy.
- 
-

## *Zadania analityczne (2)*

- *Dyspersja* (zmiennność, rozproszenie) – różnicowanie wariantów cechy w stosunku do przeciętnego poziomu tej cechy.
  - *Asymetria* (skośność) – wewnętrzne rozmieszczenie jednostek w ramach danej zbiorowości z punktem widzenia cechy badanej.
  - *Koncentracja* – stopień nierównomierności rozkładu wariantów cechy pomiędzy poszczególne jednostki danej zbiorowości oraz stopień skupienia wariantów cechy wokół przeciętnego poziomu tej cechy.
- 
-

# Parametry opisujące zbiorowość

Klasyczne	Pozycyjne
<i>Przeciętny poziom</i>	
$\bar{x}$ – średnia arytmetyczna	<b>D</b> – dominanta, <b>Me</b> – mediana
<b>G</b> – średnia geometryczna	<b>Q<sub>1</sub>, Q<sub>3</sub></b> – kwartyle
<b>H</b> – średnia harmoniczna	<b>Dci</b> – decyle
<i>Ocena dyspersji</i>	
<b>d</b> – odchylenie przeciętne	<b>O<sub>2</sub></b> – obszar zmienności
<b>s</b> – odchylenie standardowe, <b>s<sup>2</sup></b> - wariancja	<b>Q</b> – odchylenie ćwiartkowe
<b>V<sub>x</sub></b> - współczynnik zmienności	<b>V<sub>Me</sub></b> – pozycyjny współczynnik zmienności
<i>Ocena asymetrii</i>	
<b>W<sub>S</sub></b> – współczynnik asymetrii	<b>A<sub>S</sub></b> – współczynnik asymetrii
<b>α<sub>3</sub></b> – moment 3 centralny, standaryzowany	
<i>Ocena skupienia</i>	
<b>α<sub>4</sub></b> – moment 4 centralny, standaryzowany	

# Średnia arytmetyczna (SA)

- Jest to suma wartości cechy wszystkich jednostek badanej zbiorowości podzieloną przez liczbę tych jednostek.
- Wadą SA jest wrażliwość na przypadki odstające.
- Wartości badanej cechy oznaczmy przez:  $x_1, x_2, x_3, \dots, x_n$ , SA szeregu statystycznego wyznaczmy z poniższego wzoru:

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

---

---

# Średnia arytmetyczna — przykład

- Dwóch pedagogów bada uczniów. Przeprowadzono obserwację czasu trwania tych badań w minutach i zanotowano następujące wyniki:
- Dla pedagoga A: 12, 15, 15, 18, 20
- Dla pedagoga B: 10, 10, 12, 12, 15, 15, 18, 20, 21, 21
- Korzystając ze wzoru uzyskujemy:

$$\bar{x}_A = \frac{12 + 15 + 15 + 18 + 20}{5} = \frac{80}{5} = 16 \text{ min}$$

$$\bar{x}_B = \frac{10 + 10 + 12 + 12 + 15 + 15 + 18 + 20 + 21 + 21}{10} = \frac{154}{10} = 15,4 \text{ min}$$

# Średnia geometryczna (SG)

- Jest pierwiastkiem  $n$ -tego stopnia z iloczynu  $n$  wartości zmiennej.
- Jest właściwą charakterystyką centralnego skupienia:
  - gdy wartości jednostek zbiorowości statystycznej mają charakter miar względnych.
  - gdy zjawisko wykazuje wyraźną asymetrię,
  - gdy brak ważkich argumentów dla pominięcia wartości ekstremalnych.
- Jest wykorzystywana do opisywania średniego tempa zmian zjawisk.

$$\bar{x}_G = \sqrt[n]{x_1 x_2 \cdots x_n} = \sqrt[n]{\prod_{i=1}^n x_i}$$

# Średnia geometryczna — przykład

- W ciągu trzech kolejnych lat liczba dzieci przyjętych do przedszkoli wynosiła odpowiednio: 500, 750, 825. Jaki był średni względny przyrost liczby nowych wychowanków?
- Uwaga: wartości cechy statystycznej w tym zadaniu to przyrosty liczby wychowanków w kolejnych latach, tzn.:

$$x_1 = \frac{750}{500} = 1,5$$

$$x_2 = \frac{825}{750} = 1,1$$

$$\bar{x}_G = \sqrt{1,5 \cdot 1,1} = 1,28$$

Gdyby w tym przykładzie zastosować średnią arytmetyczną  $(1,5+1,1) \div 2 = 1,3$ , to wynikałoby z tego, że w 3-cim roku, powinno być  $500 \times 1,3 \times 1,3 = 845$  nowych wychowanków.

---

---



# Średnia harmoniczna (SH)

- Jest odwrotnością średniej arytmetycznej z odwrotności wartości zmiennych.
- Jest stosowana zdecydowanie rzadziej niż arytmetyczna. Konieczność jej użycia zachodzi, gdy wartości cechy statystycznej podawane są w przeliczeniu na stałą jednostkę innej zmiennej, np. prędkość w km/h, gęstość zaludnienia w osobach/km<sup>2</sup>, spożycie w kg/osobę, itp.
- W przypadku szeregów szczegółowych SH obliczamy według wzoru:

$$\bar{x}_H = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}$$

# Średnia harmoniczna — przykład

- W ciągu 8 godzin pracy w zakładzie poprawczym obserwowano pracę trzech wychowawców. Na wykonanie obowiązków związanych z jednym wychowankiem wychowawca A potrzebował 4 min, wychowawca B – 6 min, a wychowawca C – 12 min. Jaki jest średni czas zużywany na jednego wychowanka?

$$\bar{x}_H = \frac{3}{\frac{1}{4} + \frac{1}{6} + \frac{1}{12}} = 6 \text{ min/osobę}$$

Średnia arytmetyczna wynosi w tym przypadku 7.3 min/osobę, przy takim tempie pracy, trzech wychowawców w ciągu zmiany (8 godzin) zbadałoby  $3 \times 480 \div 7,333 = 196$  osób. W rzeczywistości wychowawca A mógłby zbadać  $480 \div 4 = 120$  wychowanków, wychowawca B –  $480 \div 6 = 80$ , a wychowawca C –  $480 \div 12 = 40$ , co daje łącznie  $120 + 80 + 40 = 240$  wychowanków.

# Wartość modalna (dominanta)

- Jest to wartość cechy, która najczęściej (najliczniej) występuje w badanej zbiorowości statystycznej.
  - Można, stwierdzić, że jest to wartość typowa dla tej zbiorowości.
  - Wartość modalną przedstawiać będziemy następująco:  $D = x_d$ , gdzie  $x_d$  wartość  $i$ -tej cechy, dla której  $n_i = \max$ .
  - Wartość modalna, jako miara pozycyjna, jest odporna na występowanie przypadków odstających.
- 
-

# Mediana albo wartość środkowa (1)

- Jest to wartość cechy, która rozdziela zbiorowość na dwie równe części, zajmując środkową pozycję w szeregu statystycznym.
  - Sposób wyznaczania wartości mediany  $M_e$  uzależniony jest od wielu czynników, a do najważniejszych należy zaliczyć:
    - liczbę elementów szeregu (parzysta czy nieparzysta),
    - typ szeregu (szereg szczegółowy czy rozdzielczy).
- 
-

# Mediana albo wartość środkowa (2)

Gdy  $n$  jest nieparzyste

$$M_e = x_{\frac{n+1}{2}}$$

$$P_{Me} = \frac{n+1}{2}$$

Gdy  $n$  jest parzyste

$$M_e = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2}$$

$$P_{Me} = \frac{n}{2}$$

# Kwantyle

- Mediana informuje, poniżej i powyżej jakiej wartości cechy znajduje się 50% zbiorowości.
  - Można podzielić zbiorowość na większą liczbę części.
  - Wartości ustalające podział nazywamy kwantylami.
  - Najczęściej stosowane są:
    - *kwartyle* – dzielą szereg statystyczny na 4 części,
    - *decyle* – dzielą szereg statystyczny na 10 części,
    - *centyle* – dzielą szereg statystyczny na 100 części.
- 
-

# Kwartyle

- *Kwartyl pierwszy ( $Q1$ )* dzieli zbiorowość na dwie części tak, że 25% jednostek zbiorowości ma wartości cechy niższe bądź równe kwartyłowi pierwszemu, a 75% równe bądź wyższe.
  - *Kwartyl drugi* jest to mediana (Me).
  - *Kwartyl trzeci ( $Q3$ )* dzieli zbiorowość na dwie części tak, że 75% jednostek zbiorowości ma wartości cechy niższe bądź równe kwartyłowi trzeciemu, a 25% równe bądź wyższe.
  - Kwartyle wyznacza się w sposób analogiczny do mediany.
- 
-

# Decyle

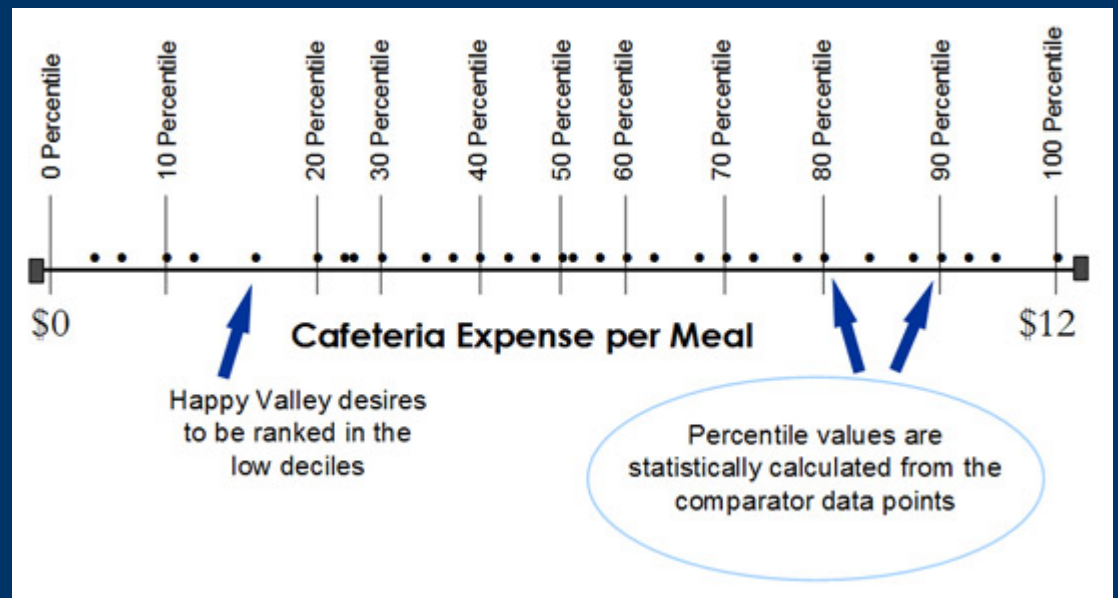


Table I. Response Decile Analysis

Decile	Number of Individuals	Number of Responders	Decile Response Rate	Cumulative Response Rate	Cum Lift
top	7,410	911	12.30%	12.30%	294
2	7,410	544	7.30%	9.80%	235
3	7,410	437	5.90%	8.50%	203
4	7,410	322	4.30%	7.50%	178
5	7,410	258	3.50%	6.70%	159
6	7,410	188	2.50%	6.00%	143
7	7,410	130	1.80%	5.40%	129
8	7,410	163	2.20%	5.00%	119
9	7,410	124	1.70%	4.60%	110
bottom	7,410	24	0.30%	4.20%	100
Total	74,100	3,101	4.20%		



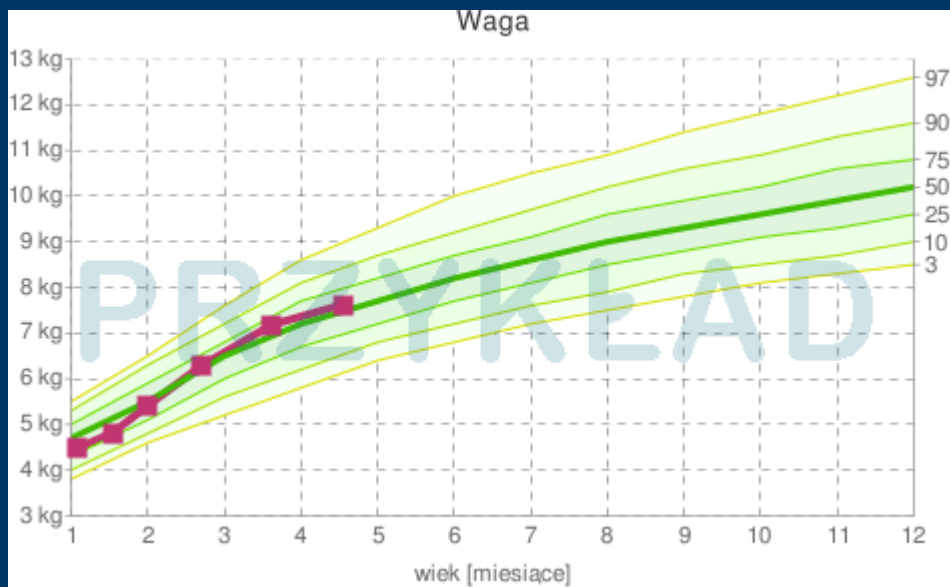


# Centyle

- Centyle stosowane są dla prób o dużej liczebności. Centyl 50 odpowiada medianie, a centyle 25 i 75 to odpowiednio kwartyle Q1 i Q3.
  - Centyle są często stosowane do odnoszenie różnych pomiarów antropometrycznych u badanego dziecka do ogółu populacji dzieci.
  - Siatki centylowe są to wykresy na których zaznaczono kilka wybranych centyli (zwykle 3, 10, 25, 50, 75, 90 i 97) w zależności od wieku dla wybranego parametru antropometrycznego.
- 
-

# Siatki centylowe (1)


Siatki centylowe wskaźnika względnej masy ciała (BMI) chłopców i dziewcząt warszawskich (opr. I. Palczewska, Z. Niedźwiecka, 1999 r.)



# Siatki centylowe (2)

Siatka centylowa wzrostu u  
chłopców

Przykładowe zadanie:  
Ocenić wzrost 10 letniego  
chłopca, mierzącego 130 cm.



# Ocena rozproszenia populacji

- Rozrzut wartości cechy statystycznej wokół wartości przeciętnej opisują miary zmienności.
  - *Miary zmienności* charakteryzują stopień różnicowania elementów zbiorowości pod względem badanej cechy:
    - *Miary klasyczne* – ich wartość jest wyznaczana w oparciu o wszystkie obserwacje – są to *wariancja, odchylenie standardowe, odchylenie przeciętne, współczynnik zmienności*.
    - *Miary pozycyjne* – na ich wartość wpływają tylko wybrane obserwacje z próby uporządkowanej – są to *rozstęp, odchylenie ćwiartkowe, współczynniki zmienności*.
- 
-

# Wariancja

- Jest to średnia arytmetyczna kwadratów odchyleń poszczególnych obserwacji od średniej arytmetycznej zbiorowości.
- Nie jest wyrażona w jednostkach cechy, ale w jednostkach podniesionych do kwadratu.
- Jest wskaźnikiem "rozrzutu" wartości zmiennej losowej wokół jej wartości oczekiwanej – średniej.

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

# Odchylenie standardowe

- Jest pierwiastkiem kwadratowym wariancji.
- Jest miarą zmienności o jednostce zgodnej z mianem badanej cechy statystycznej.
- Określa przeciętne zróżnicowanie poszczególnych wartości cechy od średniej arytmetycznej.

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

# Typowy obszar zmienności populacji

- Określamy, znając średnią arytmetyczną i odchylenie standardowe próby:

$$(\bar{x} - s) < x_{\text{typowe}} < (\bar{x} + s)$$

- W tym zakresie mieszczą się około 2/3 (dokładniej 68%) wszystkich elementów badanej zbiorowości statystycznej:
    - Poza przedział  $\pm$  jednego odchylenia standardowego od średniej wykracza około 32% obserwacji.
    - Poza przedział  $\pm$  dwóch odchyłeń standardowych – tylko około 5% obserwacji.
    - Prawdopodobieństwo, wystąpienia obserwacji spoza przedziału  $\pm$  trzech odchyłeń standardowych od średniej jest uważane za znikome, bo wynosi około 0,3%.
- 
-

# Odchylenie przeciętne

- Jest to średnia arytmetyczna bezwzględnych odchyłeń wartości cechy od jej średniej arytmetycznej.
- Jest miarą rzadziej stosowaną w analizach statystycznych niż odchylenie standardowe.
- Odchylenie przeciętne jest zawsze mniejsze od odchylenia standardowego, policzonego dla tego samego szeregu.

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



## Cd. przykładu ze slajdu 6

- Wariancja czasu badania ucznia przez pedagogów A i B wynosi:

$$s_A^2 = \frac{(12-16)^2 + (15-16)^2 + (15-16)^2 + (18-16)^2 + (20-16)^2}{5} =$$

$$\frac{16+1+1+4+16}{5} = \frac{38}{5} = 7,6 \text{min}^2 \Rightarrow s_A = \sqrt{7,6} = 2,76 \text{min}$$

$$s_B^2 = 17,24 \text{min}^2 \Rightarrow s_B = \sqrt{17,24} = 4,15 \text{min}$$

- Więc, typowy obszar zmienności wynosi:
  - dla pedagoga A:  $16 \pm 2,76$  min (13,24 min; 18,76 min)
  - dla pedagoga B:  $15,4 \pm 4,15$  min (11,25 min; 19,55 min)

# Rozstęp

- Jest to różnica między najwyższą i najniższą zaobserwowaną wartością cechy statystycznej:

$$R = x_{max} - x_{min}.$$

- Jest najprostszą miarą zmienności.
  - Opisuje empiryczny obszar zmienności badanej cechy, nie dając informacji o zróżnicowaniu poszczególnych wartości cechy w całej zbiorowości.
  - Zależy od jednostkowych przypadków ekstremalnych, a nie od zróżnicowania typowych obserwacji przeważających w zbiorowości.
- 
-

# Odchylenie ćwiartkowe


- Jest to połową różnicy między trzecim, a pierwszym kwartylem: 
$$Q = \frac{(Q_3 - Q_1)}{2}$$
  - Jest miarą zmienności najczęściej używaną w parze z medianą.
  - Mierzy poziom zróżnicowania 50% elementów, pozostałych po odrzuceniu wartości najmniejszych (25%) i największych (25%).
  - Typowy obszar zmienności przez kwartyli wyrażamy tak:  $(Q_1 < x_{typ} < Q_3)$
- 
-

# Współczynniki zmienności

- Jest to iloraz bezwzględnej miary zmienności cechy i przeciętnej wartości tej cechy ( $V_x$  i  $V_{Me}$ ).
  - Stosuje się do oceny zróżnicowania kilku zbiorowości pod względem tej samej cechy, ewentualnie tej samej zbiorowości pod względem kilku cech.
  - Jest wielkością niemianowaną. Wartości współczynników podaje się z reguły w procentach.
  - Jest przyjęte, że *zbiorowość* uważa się za *niejednorodną*, gdy współczynnik zmienności jest większy niż 10%.
- 
-

# Miary asymetrii zbiorowości

- Porównanie średniego poziomu cechy i jej rozproszenia nie zawsze wykazuje różnic między badanymi zbiorowościami.
- Rozkłady mogą być symetryczne lub asymetryczne (prawostronnie lub lewostronnie) przy tym samym rozproszeniu.



# Miary asymetrii zbiorowości

- Asymetrię można ocenić porównując różnice pomiędzy średnią arytmetyczną, a medianą lub modalną.
  - Asymetria prawostronna:  $\bar{x} > Me > Mo$
  - Asymetria lewostronna:  $\bar{x} < Me < Mo$
- Współczynnik asymetrii (wskaźnik skośności) przyjmuje wartość 0 przy braku asymetrii, wartości dodatnie przy asymetrii prawostronnej, a wartości ujemne przy asymetrii lewostronnej:

$$W_s = (\bar{x} - Mo)$$

$$A_s = (Q_3 - Me) - (Me - Q_1)$$

# Klasyczny współczynnik asymetrii

$$a_3 = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{s^3 \cdot n} = \frac{(x_1 - \bar{x})^3 + (x_2 - \bar{x})^3 + \dots + (x_n - \bar{x})^3}{s^3 \cdot n}$$