

## STATYSTYKA OPISOWA – WZORY

## I. ANALIZA STRUKTURY

## 1. MIARY TENDENCJI CENTRALNEJ (ŚREDNIE, PRZECIĘTNE)

Średnia arytmetyczna		
Dla szeregu wyliczającego:	Dla sz. ważonego dla zmiennej skokowej	Dla sz. ważonego dla zm. ciągłej (przedziałowego)
$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$	$\bar{x} = \frac{1}{N} \sum_{i=1}^k x_i n_i = \sum_{i=1}^k x_i w_i$	$\bar{x} = \frac{1}{N} \sum_{i=1}^k \hat{x}_i n_i = \sum_{i=1}^k \hat{x}_i w_i$
gdzie $n_i$ – liczebności, $w_i$ – częstości, $\hat{x}_i$ – środek przedziału $k$ , – liczba przedziałów (grup)		
Dominanta		
Dla sz. ważonego dla zmiennej skokowej	Dla sz. ważonego dla zm. ciągłej (przedziałowego)	
$D = x_D$ dla której $n_D = \max\{n_i\}$	$D = x_D + \frac{g_D - g_{D-1}}{(g_D - g_{D-1}) + (g_D - g_{D+1})} \cdot \Delta_D,$ gdzie $x_D$ – lewy koniec przedziału z $D$ (tj. przedziału o największej gęstości), $g_D$ – gęstość przedziału z $D$ , $g_{D-1}$ – gęstość przedziału poprzedzającego przedział $D$ , $g_{D+1}$ – gęstość przedziału następującego po przedziale $D$ , $\Delta_D$ – długość przedziału $D$ .	
	Jeśli szereg ma przedziały o równej długości, to można korzystać ze wzoru: $D = x_D + \frac{n_D - n_{D-1}}{(n_D - n_{D-1}) + (n_D - n_{D+1})} \cdot \Delta_D,$ gdzie $n_D$ – liczebność przedziału z $D$ , $n_{D-1}$ – liczebność przedziału poprzedzającego przedział $D$ , $n_{D+1}$ – liczebność przedziału następującego po przedziale $D$ ,	
Kwantyl rzędu $p$		
Dla sz. ważonego dla zmiennej skokowej	Dla sz. ważonego dla zm. ciągłej (przedziałowego)	
$Q_p = x_{[N \cdot p] + 1}$ gdzie $p$ to rząd kwantyla  <b>Mediana</b> to $Me = Q_{0,5}$  jeśli $N$ jest parzyste, to $Me = \frac{x_{0,5N} + x_{0,5N+1}}{2}$  jeśli $N$ jest nieparzyste, to $Me = x_{0,5(N+1)}$	$Q_p = x_{Q_p} + \frac{p \cdot N - cum n_{Q_p-1}}{n_{Q_p}} \cdot \Delta_{Q_p}$ lub $Q_p = x_{Q_p} + \frac{p - cum w_{Q_p-1}}{w_{Q_p}} \cdot \Delta_{Q_p}$ gdzie $x_{Q_p}$ – lewy koniec przedziału z $Q_p$ $cum n_{Q_p-1}$ – skumulowana liczebność do przedziału poprzedzającego przedział z $Q_p$ , $cum w_{Q_p-1}$ – skumulowana częstość do przedziału poprzedzającego przedział z $Q_p$ , $n_{Q_p}$ – liczebność przedziału z $Q_p$ , $w_{Q_p}$ – częstość przedziału z $Q_p$ , $\Delta_{Q_p}$ – długość przedziału z $Q_p$ ,	

## 2. MIARY ZRÓŻNICOWANIA (ROZPROSZENIA, ZMIENNOŚCI, DYSPERSJI)

<b>Wariancja</b>		
Dla szeregu wyliczającego:	Dla sz. ważonego dla zmiennej skokowej	Dla sz. ważonego dla zm. ciągłej (przedziałowego)
$S^2(x) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$	$S^2(x) = \frac{1}{N} \sum_{i=1}^k (x_i - \bar{x})^2 n_i$	$S^2(x) = \frac{1}{N} \sum_{i=1}^k (\hat{x}_i - \bar{x})^2 n_i$
<b>Odchylenie standardowe</b>		
$s(x) = \sqrt{S^2(x)}$		
<b>Odchylenie przeciętne</b>		
Dla szeregu wyliczającego:	Dla sz. ważonego dla zmiennej skokowej	Dla sz. ważonego dla zm. ciągłej (przedziałowego)
$d(x) = \frac{1}{N} \sum_{i=1}^N  x_i - \bar{x} $	$d(x) = \frac{1}{N} \sum_{i=1}^k  x_i - \bar{x}  n_i$	$d(x) = \frac{1}{N} \sum_{i=1}^k  \hat{x}_i - \bar{x}  n_i$
<b>Klasyczny współczynnik zmienności</b>		
$V(x) = \frac{s(x)}{\bar{x}} \cdot 100\%$		
<b>Rozstęp</b>		
$R = x_{max} - x_{min}$		
<b>Odchylenie ćwiartkowe</b>		
$Q = \frac{Q_3 - Q_1}{2}$		
<b>Pozycyjny współczynnik zmienności</b>		
$V_Q = \frac{Q}{Me}$		

## 3. MIARY ASYMETRII (SKOŚNOŚCI)

<b>Moment centralny trzeciego rzędu</b>		
Dla szeregu wyliczającego:	Dla sz. ważonego dla zmiennej skokowej	Dla sz. ważonego dla zm. ciągłej (przedziałowego)
$M_3(x) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3$	$M_3(x) = \frac{1}{N} \sum_{i=1}^k (x_i - \bar{x})^3 n_i$	$M_3(x) = \frac{1}{N} \sum_{i=1}^k (\hat{x}_i - \bar{x})^3 n_i$
<b>Zestandaryzowany moment centralny trzeciego rzędu</b>		
$\lambda_3(x) = \frac{M_3(x)}{(s(x))^3}$		
<b>Wskaźnik asymetrii</b>		
$W_s = \bar{x} - D$		
<b>Współczynnik asymetrii Pearsona</b>		
$\gamma = \frac{\bar{x} - D}{s(x)}$		
<b>Współczynnik asymetrii Yule'a-Kendall'a (pozycyjny)</b>		
$A = \frac{(Q_3 - Me) - (Me - Q_1)}{Q_3 - Q_1}$		

**Kowariancja**

$$\text{cov}(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}) \cdot (y_i - \bar{y})$$

**Współczynnik korelacji liniowej Pearsona**

$$r_{xy} = \frac{\text{cov}(x, y)}{s(x) \cdot s(y)}$$

gdzie

$s(x), s(y)$  – odchylenia standardowe zmiennych  $x, y$ .

- \*  $r_{xy}$  bada tylko **liniową** zależność między zmiennymi,
- \*  $r_{xy} \in \langle -1, 1 \rangle$  i pozwala określić siłę i kierunek zależności liniowej
  - jeśli  $|r_{xy}|$  jest bliskie 0, to mamy słabą zależność liniową między zmiennymi,
  - jeśli  $|r_{xy}|$  jest bliskie 1, to mamy silną zależność liniową między zmiennymi,
  - jeśli  $r_{xy} > 0$ , to zależność między zmiennymi jest dodatnia,
  - jeśli  $r_{xy} < 0$ , to zależność między zmiennymi jest ujemna.

**Funkcja regresji (II rodzaju)**

$$\hat{y}_i = ax_i + b$$

gdzie

$$a = \frac{\text{cov}(x, y)}{S^2(x)}, \quad b = \bar{y} - a\bar{x}$$

$\hat{y}_i$  to wartości teoretyczne zm.  $Y$ ,  $S^2(x)$  – wariancja zm.  $X$ , zaś  $\bar{x}, \bar{y}$  – średnie dla zm.  $X$  i  $Y$ .

**Miary dopasowania funkcji regresji**

- \* odchylenie standardowe reszt:

$$s_u = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N - k}}$$

gdzie  $k$  to liczba parametrów funkcji regresji;

- \* współczynnik zbieżności:

$$\varphi^2 = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

- \* współczynnik determinacji:

$$R^2 = 1 - \varphi^2$$

- $R^2 \in \langle 0, 1 \rangle$ ,
- im większe  $R^2$  tym lepsze dopasowanie funkcji regresji do danych.

**Standardowy błąd prognozy**

$$s_u \cdot \sqrt{1 + \frac{1}{N} + \frac{(x_{new} - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}}$$

gdzie  $x_{new}$  to nowa obserwacja, dla której chcemy zrobić prognozę  $\hat{f}(x_{new})$ ;

**Tablica korelacyjna**

$X \setminus Y$	$y_1$	$y_2$	$\dots$	$y_m$	$n_{i \cdot}$
$x_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1m}$	$n_{1 \cdot}$
$x_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2m}$	$n_{2 \cdot}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$x_n$	$n_{n1}$	$n_{n2}$	$\dots$	$n_{nm}$	$n_{n \cdot}$
$n_{\cdot j}$	$n_{\cdot 1}$	$n_{\cdot 2}$	$\dots$	$n_{\cdot m}$	$N$

**Stosunki korelacyjne (wskaźniki siły korelacyjnej)**\* zm.  $Y$  względem zm.  $X$ 

$$e_{y/x} = \sqrt{\frac{S^2(\bar{y}|x_i)}{S^2(y)}}$$

$$\text{gdzie } S^2(\bar{y}|x_i) = \frac{1}{N} \sum_{i=1}^n (\bar{y}|x_i - \bar{y})^2 n_i. \quad \text{oraz} \quad S^2(y) = \frac{1}{N} \sum_{j=1}^m (y_j - \bar{y})^2 n_j$$

\* zm.  $X$  względem zm.  $Y$ 

$$e_{x/y} = \sqrt{\frac{S^2(\bar{x}|y_j)}{S^2(x)}}$$

$$\text{gdzie } S^2(\bar{x}|y_j) = \frac{1}{N} \sum_{j=1}^m (\bar{x}|y_j - \bar{x})^2 n_j \quad \text{oraz} \quad S^2(x) = \frac{1}{N} \sum_{i=1}^n (x_i - \bar{x})^2 n_i$$

 $e_{y/x}, e_{x/y} \in \langle 0, 1 \rangle$ ,  $\bar{x}|y_j, \bar{y}|x_i$  – średnie warunkowe.**III. ANALIZA DYNAMIKI ZJAWISK****Przyrosty absolutne**\* o stałej podstawie:  $\Delta_{t/c} = y_t - y_c$       \* łańcuchowe:  $\Delta_{t/t-1} = y_t - y_{t-1}$ **Przyrosty względne**\* o stałej podstawie:  $d_{t/c} = \frac{y_t - y_c}{y_c}$       \* łańcuchowe:  $d_{t/t-1} = \frac{y_t - y_{t-1}}{y_{t-1}}$ **Indeksy indywidualne**\* o stałej podstawie:  $i_{t/c} = \frac{y_t}{y_c}$       \* łańcuchowe:  $i_{t/t-1} = \frac{y_t}{y_{t-1}}$ **Średni indeks zmian**

$$\bar{i}_G = \sqrt[n-1]{\prod_{t=2}^n i_{t/t-1}} = \sqrt[n-1]{\frac{y_n}{y_1}}$$

**Prognoza na  $k$  okresów w przyszłość**

$$\tilde{y}_{t+k} = y_t \cdot (\bar{i}_G)^k$$

**Agregatowy indeks wartości**

$$I_w = \frac{\sum_{i=1}^n p_{it} q_{it}}{\sum_{i=1}^n p_{i0} q_{i0}}$$

gdzie  $p_{i0}, p_{it}$  – ceny w okresie bazowym i badanym,  $q_{i0}, q_{it}$  – ilości w okresie bazowym i badanym.**Agregatowe indeksy cen**\* formuła Laspeyresa  $I_{p/q_0} = \frac{\sum_{i=1}^n p_{it} q_{i0}}{\sum_{i=1}^n p_{i0} q_{i0}}$       \* formuła Paaschego:  $I_{p/q_t} = \frac{\sum_{i=1}^n p_{it} q_{it}}{\sum_{i=1}^n p_{i0} q_{it}}$ **Agregatowe indeksy ilości**\* formuła Laspeyresa  $I_{q/p_0} = \frac{\sum_{i=1}^n p_{i0} q_{it}}{\sum_{i=1}^n p_{i0} q_{i0}}$       \* formuła Paaschego:  $I_{q/p_t} = \frac{\sum_{i=1}^n p_{it} q_{it}}{\sum_{i=1}^n p_{it} q_{i0}}$