



**STATYSTYKA**  
**PODSTAWOWE WZORY DOZWOLONE**  
**NA EGZAMINIE NA STUDIACH LICENCJACKICH**

Opracowanie przygotowane przez dr Marię Wieczorek na podstawie:

1. P. Kuszewski, J. Podgórski: Statystyka. Wzory i tablice. SGH, Warszawa, 2008
2. M. Wieczorek: Statystyka. Lubię to! Zbiór zadań. SGH, Warszawa 2016

# 1. Statystyki opisowe rozkładu empirycznego

## Dystrybuanta empiryczna

$$F_n(x) = \begin{cases} 0 & \text{dla } x < x_{\min} \\ \sum_{s=1}^i w_s & \text{dla } x_i \leq x < x_{i+1} \quad i=1,2,\dots,k-1 \\ 1 & \text{dla } x \geq x_{\max} \end{cases} \quad (1)$$

## Średnia arytmetyczna

$$\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j \quad (2)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k x_i n_i = \sum_{i=1}^k x_i w_i \quad (3)$$

$$\bar{x} \cong \frac{1}{n} \sum_{i=1}^k \dot{x}_i n_i = \sum_{i=1}^k \dot{x}_i w_i \quad (4)$$

## Mediana

$$me = \begin{cases} x_{\frac{n+1}{2}} & \text{gdy } n \text{ nieparzyste} \\ \frac{x_n + x_{n+2}}{2} & \text{gdy } n \text{ parzyste} \end{cases} \quad (5)$$

$$me = x_{0m} + \left[ \frac{n}{2} - n(x_{0m}) \right] \frac{h_m}{n_m} = x_{0m} + \left[ \frac{1}{2} - F_n(x_{0m}) \right] \frac{h_m}{w_m} \quad (6)$$

## Kwantyl rzędu p

$$k_p = x_{0p} + \left[ p - F_n(x_{0p}) \right] \frac{h_p}{w_p} \quad (7)$$

## Wariancja:

obciążona

$$s^2 = \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2 = \frac{1}{n} \left( \sum_{j=1}^n x_j^2 - n\bar{x}^2 \right) \quad (8)$$

$$s^2 = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^2 n_i = \frac{1}{n} \left( \sum_{i=1}^k x_i^2 n_i - n\bar{x}^2 \right) \quad (9)$$

$$s^2 = \sum_{i=1}^k (x_i - \bar{x})^2 w_i = \sum_{i=1}^k x_i^2 w_i - \bar{x}^2 \quad (10)$$

nieobciążona

$$s^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{j=1}^n x_j^2 - n\bar{x}^2 \right) \quad (11)$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^k (x_i - \bar{x})^2 n_i = \frac{1}{n-1} \left( \sum_{i=1}^k x_i^2 n_i - n\bar{x}^2 \right) \quad (12)$$

### Odchylenie standardowe

$$s = \sqrt{s^2} \quad (13)$$

### Współczynnik zmienności

$$V = \frac{s}{\bar{x}} (\cdot 100\%) \quad (14)$$

### Rozstęp

$$x_{\max} - x_{\min} \quad (15)$$

### Rozstęp ćwiartkowy

$$Q_3 - Q_1 \quad (16)$$

### Odchylenie ćwiartkowe

$$Q = \frac{Q_3 - Q_1}{2} \quad (17)$$

### Współczynnik zmienności (pozycyjny)

$$V = \frac{Q}{me} (\cdot 100\%) \quad (18)$$

### Współczynnik asymetrii

$$A = \frac{M_3'}{s^3} \quad \text{gdzie (trzeci moment centralny): } M_3' = \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^3 \quad (19)$$

$$\text{lub } M_3' = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^3 n_i \quad (20)$$

### 3. Rozkład zmiennej losowej

#### Funkcja prawdopodobieństwa zmiennej losowej skokowej X

$$P(X = x_i) = p_i \quad i=1,2,\dots \quad \text{przy czym} \quad \sum_i p_i = 1 \quad (1)$$

#### Dystrybuanta zmiennej losowej skokowej X

$$F(x) = \sum_{x_i \leq x} p_i \quad (-\infty < x < \infty) \quad (2)$$

#### Wartość oczekiwana zmiennej losowej skokowej X

$$E(X) = \sum_i x_i p_i \quad (3)$$

#### Wariancja zmiennej losowej (definicja)

$$D^2(X) = E[X - E(X)]^2 = E(X^2) - [E(X)]^2 \quad (4)$$

#### Wariancja zmiennej losowej skokowej X (metoda obliczania)

$$D^2(X) = \sum_i [x_i - E(X)]^2 p_i = \sum_i x_i^2 p_i - [E(X)]^2 \quad (5)$$

#### Standaryzacja zmiennej losowej X

$$U = \frac{X - E(X)}{D(X)} \quad (6)$$

## 4. Wybrane typy rozkładów

### Rozkład zero-jedynkowy (dwupunktowy)

$$\begin{cases} P(X = 1) = p & (1) \\ P(X = 0) = 1-p & (2) \end{cases}$$

$$\text{przy czym: } E(X) = p; \quad D(X) = \sqrt{p(1-p)} \quad (3)$$

### Rozkład dwumianowy

$$\text{liczby sukcesów: } P(X = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad k=0, 1, 2, \dots, n \quad (4)$$

$$\text{przy czym: } E(X) = np; \quad D(X) = \sqrt{np(1-p)} \quad (5)$$

$$\text{częstości sukcesów: } P\left(W = \frac{k}{n}\right) = \binom{n}{k} p^k (1-p)^{n-k} \quad k=0, 1, 2, \dots, n \quad (6)$$

$$\text{przy czym: } E(W) = p; \quad D(W) = \sqrt{\frac{p(1-p)}{n}} \quad (7)$$

### Rozkład normalny $N(m, \sigma)$

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (-\infty < x < \infty) \quad (8)$$

$$\text{przy czym: } E(X) = m; \quad D(X) = \sigma \quad (9)$$

### Rozkład normalny standardowy $N(0,1)$

$$f(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} \quad (-\infty < u < \infty) \quad (10)$$

$$\text{przy czym: } E(U)=0; \quad D(U) = 1 \quad (11)$$

#### 4. Rozkłady statystyk z próby

Założenia	Wielkość próby	Rozkład statystyki
<b>Rozkłady dokładne średniej arytmetycznej z próby</b>		
$X: N(m, \sigma)$ $\sigma$ – znane	próba dowolna	$\bar{X} : N\left(m, \frac{\sigma}{\sqrt{n}}\right)$ (1)
$(X: N(m, \sigma))$ $\sigma$ – nieznane	próba dowolna <sup>a)</sup>	$t = \frac{\bar{X} - m}{s} \sqrt{n}$ (2) $t; \quad v = n - 1$ gdzie $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
<b>Rozkłady dokładne różnicy średnich z dwóch prób</b>		
$X_1: N(m_1, \sigma_1)$ $X_2: N(m_2, \sigma_2)$ $\sigma_1, \sigma_2$ – znane	próby dowolne	$\bar{X}_1 - \bar{X}_2 : N\left(m_1 - m_2, \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}\right)$ (3)
$X_1: N(m_1, \sigma)$ $X_2: N(m_2, \sigma)$ $\sigma$ – nieznane, ale jednakowe	próby dowolne <sup>a)</sup>	$t = \frac{(\bar{X}_1 - \bar{X}_2) - (m_1 - m_2)}{\sqrt{s_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} t; \quad v = n_1 + n_2 - 2$ (4) gdzie $s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$
<b>Rozkłady graniczne: średniej, sumy wartości, częstości i liczby sukcesów w rozkładzie dwumianowym, różnicy średnich i częstości</b>		
$X$ ma dowolny rozkład (niekoniecznie normalny) ze średnią $m$ i odchyleniem standardowym $\sigma$ .	próba duża $n \geq 100$	$\bar{X} : as.N\left(m, \frac{\sigma}{\sqrt{n}}\right)$ (5)
$X$ ma dowolny rozkład (niekoniecznie normalny) ze średnią $m$ i odchyleniem standardowym $\sigma$ .	próba duża $n \geq 100$	$Z_n = \sum_{i=1}^n x_i ; Z_n : as N(nm, \sqrt{n}\sigma)$ (6)

$X_1$ i $X_2$ mają dowolne rozkłady (niekoniecznie normalne) z parametrami odpowiednio $m_1$ i $\sigma_1$ oraz $m_2$ i $\sigma_2$ .	próby duże	$\bar{X}_1 - \bar{X}_2 : as.N\left(m_1 - m_2, \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}\right) \quad (7)$
Populacja zero-jedynkowa <sup>b)</sup> ; $X$ ma rozkład dwumianowy z parametrami $n$ i $p$ .  $W = \frac{X}{n} \quad E(W) = p \quad D(W) = \sqrt{\frac{p(1-p)}{n}}$	próba duża $n \geq 100$	$W : as.N\left(p, \sqrt{\frac{p(1-p)}{n}}\right) \quad (8)$
Populacja zero-jedynkowa <sup>b)</sup> ; $X$ ma rozkład dwumianowy z parametrami $n$ i $p$ ( $X$ oznacza liczbę sukcesów w $n$ próbach)	próba duża $n \geq 100$	$X : as.N(np, \sqrt{np(1-p)}) \quad (9)$
Populacje zero-jedynkowe; $X_1$ i $X_2$ mają rozkłady dwumianowe z parametrami odpowiednio $n_1$ i $p_1$ oraz $n_2$ i $p_2$ .  $W_1 - W_2 = \frac{X_1}{n_1} - \frac{X_2}{n_2}$	próby duże	$W_1 - W_2 : as.N\left(p_1 - p_2, \sqrt{\frac{p_1(1-p_1)}{n_1} + \frac{p_2(1-p_2)}{n_2}}\right) \quad (10)$
<b>Twierdzenia de Moivre'a - Laplace'a oraz Lindeberga - Levy'ego</b>		
Populacja zero-jedynkowa <sup>b)</sup> ; $X$ ma rozkład dwumianowy z parametrami $n$ i $p$ ( $X$ oznacza liczbę sukcesów w $n$ próbach)	próba duża $n \geq 100$	$U_n = \frac{X - np}{\sqrt{np(1-p)}}; U_n : as.N(0,1) \quad (11)$ (Tw. de Moivre'a-Laplace'a)
$X$ ma dowolny rozkład (niekoniecznie normalny) ze średnią $m$ i odchyleniem standardowym $\sigma$ .	próba duża $n \geq 100$	$U_n = \frac{\sum_{i=1}^n x_i - nm}{\sqrt{n}\sigma}; U_n : as.N(0,1) \quad (12)$ (Tw. Lindeberga-Levy'ego)

<sup>a)</sup> Niektórzy autorzy uznają, że już przy próbie  $n > 30$  dobrym przybliżeniem rozkładu *t Studenta* jest rozkład normalny, a w związku z tym rozkład *t* stosują dla prób  $n \leq 30$ .

<sup>b)</sup> Z populacji o rozkładzie zero-jedynkowym losujemy niezależnie  $n$  elementów.  $X$  – liczba elementów wyróżnionych w próbie.

## 5. Przedziały ufności

Założenia	Wielkość próby	Przedział ufności	Współczynnik ufności
<b>Przedział ufności dla średniej <math>m</math></b>			
Populacja normalna $X: N(m, \sigma)$ $m$ – nieznane $\sigma$ – znane	próba dowolna	(1) $P\left(\bar{X} - u_\alpha \frac{\sigma}{\sqrt{n}} < m < \bar{X} + u_\alpha \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$	$P(-u_\alpha < U < u_\alpha) = 1 - \alpha$ tzn. $P( U  \geq u_\alpha) = \alpha$
Populacja normalna $X: N(m, \sigma)$ $m, \sigma$ – nieznane	próba dowolna <sup>a)</sup>	(2) $P\left(\bar{X} - t_{\alpha, n-1} \frac{s}{\sqrt{n}} < m < \bar{X} + t_{\alpha, n-1} \frac{s}{\sqrt{n}}\right) = 1 - \alpha$	$P(-t_{\alpha, n-1} < t < t_{\alpha, n-1}) = 1 - \alpha$ tzn. $P( t  \geq t_{\alpha, n-1}) = \alpha$
Populacja o dowolnym rozkładzie $m$ i $\sigma$ – nieznane	próba duża $n \geq 100$	(3) $P\left(\bar{X} - u_\alpha \frac{s}{\sqrt{n}} < m < \bar{X} + u_\alpha \frac{s}{\sqrt{n}}\right) \cong 1 - \alpha$	$P(-u_\alpha < U < u_\alpha) = 1 - \alpha$ tzn. $P( U  \geq u_\alpha) = \alpha$
<b>Przedział ufności dla parametru <math>p</math> w zero-jedynkowym rozkładzie populacji</b>			
Populacja o rozkładzie zero-jedynkowym $p$ – nieznane	próba duża $n \geq 100$	(4) $P\left(\hat{p} - u_\alpha \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} < p < \hat{p} + u_\alpha \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}\right) \cong 1 - \alpha$	$P(-u_\alpha < U < u_\alpha) = 1 - \alpha$ tzn. $P( U  \geq u_\alpha) = \alpha$

<sup>a)</sup> Niektórzy autorzy uznają, że już przy próbie  $n > 30$  dobrym przybliżeniem rozkładu *t Studenta* jest rozkład normalny, a w związku z tym rozkład *t* stosują dla prób  $n \leq 30$ .

### Minimalna liczebność próby przy szacowaniu $m$

$$n = \frac{u_\alpha^2 \sigma^2}{d^2} \quad d - \text{dopuszczalny błąd szacunku} \quad (5)$$

### Minimalna liczebność próby przy szacowaniu $p$

$$n = \frac{u_\alpha^2 p(1-p)}{d^2} \quad d - \text{dopuszczalny błąd szacunku} \quad (6)$$



## 6. Testowanie hipotez statystycznych

### Testy istotności

Hipoteza zerowa	Założenia	Wielkość próby	Statystyka testująca i jej rozkład
$H_0: m = m_0$	populacja normalna $X: N(m, \sigma)$ $\sigma$ – znane	próba dowolna	$U = \frac{\bar{X} - m_0}{\sigma} \sqrt{n}$ $N(0, 1)$ (1)
	populacja normalna $X: N(m, \sigma)$ $\sigma$ – nieznanne	próba dowolna <sup>a)</sup>	$t = \frac{\bar{X} - m_0}{s} \sqrt{n}$ $t; v = n - 1$ (2)
	populacja normalna $X: N(m, \sigma)$ $\sigma$ – nieznanne lub dowolny (nieznany) rozkład populacji	próba duża $n \geq 100$	$U = \frac{\bar{X} - m_0}{s} \sqrt{n}$ as. $N(0, 1)$ (3)
$H_0: m_1 = m_2$	populacje normalne $X_1: N(m_1, \sigma_1)$ $X_2: N(m_2, \sigma_2)$ $\sigma_1, \sigma_2$ – znane	próby dowolne	$U = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$ $N(0, 1)$ (4)
	populacje normalne $X_1: N(m_1, \sigma_1)$ $X_2: N(m_2, \sigma_2)$ $\sigma_1, \sigma_2$ – nieznanne, ale jednakowe	próby dowolne <sup>a)</sup>	$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{s_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}$ $t; v = n_1 + n_2 - 2$ gdzie $s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$ (5)
	populacje normalne $X_1: N(m_1, \sigma_1)$ $X_2: N(m_2, \sigma_2)$ $\sigma_1, \sigma_2$ – nieznanne lub dowolne (nieznane) rozkłady populacji	próby duże $n_1 + n_2 \geq 100$	$U = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$ as. $N(0, 1)$ (6)
$H_0: m_R = m_0$	próby zależne różnice $R_i$ mają rozkład normalny  $\sigma_R$ – nieznanne	próby dowolne	$t = \frac{\bar{R} - m_0}{s_R} \sqrt{n}$ $t; v = n - 1$ (7) gdzie: $\bar{R} = \frac{\sum_{i=1}^n R_i}{n} = \frac{\sum_{i=1}^n (X_{i1} - X_{i2})}{n}$ $s_R^2 = \frac{1}{n-1} \sum_{i=1}^n (R_i - \bar{R})^2$

$H_0: p = p_0$	populacja o rozkładzie zero-jedynkowym	próba duża $n \geq 100$	$U = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \quad (8)$ <p style="text-align: right;">as. <math>N(0, 1)</math></p> <p style="text-align: right;">gdzie: <math>\hat{p} = \frac{X}{n}</math></p>
$H_0: p_1 = p_2$	populacje o rozkładzie zero-jedynkowym	próby duże	$U = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \quad (9)$ <p style="text-align: right;">as. <math>N(0, 1)</math></p> <p style="text-align: right;">gdzie: <math>\hat{p}_1 = \frac{X_1}{n_1}</math>   <math>\hat{p}_2 = \frac{X_2}{n_2}</math>   <math>\hat{p} = \frac{X_1 + X_2}{n_1 + n_2}</math></p>

<sup>a)</sup> Niektórzy autorzy uznają, że już przy próbie  $n > 30$  dobrym przybliżeniem rozkładu *t Studenta* jest rozkład normalny, a w związku z tym rozkład *t* stosują dla prób  $n \leq 30$ .

### Test zgodności

$$\chi^2 = \sum_{i=1}^r \frac{(n_i - \hat{n}_i)^2}{\hat{n}_i} = \sum_{i=1}^r \frac{(n_i - np_i)^2}{np_i} \quad v = r - k - 1 \quad (10)$$

## 7. Analiza wariancji

$H_0: m_1 = m_2 = \dots = m_r$

$H_1: m_i \neq m_j$  dla co najmniej jednej pary  $i, j$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^r \sum_{k=1}^{n_i} y_{ki} = \frac{1}{n} \sum_{i=1}^r \bar{y}_i n_i \quad \text{Średnia ogólna} \quad (1)$$

$$\bar{y}_i = \frac{1}{n_i} \sum_{k=1}^{n_i} y_{ki} \quad \text{Średnia w } i\text{-tej grupie} \quad (2)$$

$$s_i^2 = \frac{1}{n_i - 1} \sum_{k=1}^{n_i} (y_{ki} - \bar{y}_i)^2 \quad \text{Wariancja w } i\text{-tej grupie} \quad (3)$$

$$\sum_{i=1}^r \sum_{k=1}^{n_i} (y_{ki} - \bar{y})^2 = \sum_{i=1}^r n_i (\bar{y}_i - \bar{y})^2 + \sum_{i=1}^r \sum_{k=1}^{n_i} (y_{ki} - \bar{y}_i)^2 \quad (4)$$

$$\text{SKC (SST)} = \text{SKM (SSB)} + \text{SKW (SSE)}$$

$$\text{gdzie } SKW = \sum_{i=1}^r (n_i - 1) s_i^2 \quad (5)$$

$$F = \frac{s_m^2}{s_w^2} \quad v_1 = r - 1; \quad v_2 = n - r \quad (6)$$

$$\text{gdzie } s_m^2 = \frac{SKM}{r - 1} \quad \text{oraz } s_w^2 = \frac{SKW}{n - r} \quad (7)$$

$$\text{Obszar krytyczny: } P(F \geq F_\alpha) = \alpha \quad (8)$$

## 8. Zmienna losowa dwuwymiarowa

**Funkcja prawdopodobieństwa zmiennej losowej (X,Y)**

$$p_{ij} = P(X = x_i, Y = y_j) \quad i, j = 1, 2, \dots \quad \text{przy czym} \quad \sum_i \sum_j p_{ij} = 1 \quad (1)$$

**Funkcja prawdopodobieństwa rozkładu brzegowego zmiennej losowej X**

$$p_{i\cdot} = \sum_j p_{ij} = P(X = x_i) \quad i = 1, 2, \dots \quad \text{przy czym} \quad \sum_i p_{i\cdot} = 1 \quad (2)$$

**Funkcja prawdopodobieństwa rozkładu brzegowego zmiennej losowej Y**

$$p_{\cdot j} = \sum_i p_{ij} = P(Y = y_j) \quad j = 1, 2, \dots \quad \text{przy czym} \quad \sum_j p_{\cdot j} = 1 \quad (3)$$

**Funkcja prawdopodobieństwa rozkładu warunkowego zmiennej losowej X**

$$P(X = x_i | Y = y_j) = \frac{p_{ij}}{p_{\cdot j}} \quad i, j = 1, 2, \dots \quad (4)$$

**Funkcja prawdopodobieństwa rozkładu warunkowego zmiennej losowej Y**

$$P(Y = y_j | X = x_i) = \frac{p_{ij}}{p_{i\cdot}} \quad i, j = 1, 2, \dots \quad (5)$$

**Warunek niezależności zmiennych losowych skokowych X i Y**

$$p_{ij} = p_{i\cdot} \cdot p_{\cdot j} \quad \text{dla wszystkich par } i, j \quad (6)$$

**Kowariancja zmiennych losowych X i Y**

$$\text{cov}(X, Y) = E\{[X - E(X)] \cdot [Y - E(Y)]\} = E(XY) - E(X)E(Y) \quad (7)$$

**Kowariancja zmiennych losowych skokowych X i Y**

$$\text{cov}(X, Y) = \sum_i \sum_j [x_i - E(X)] \cdot [y_j - E(Y)] p_{ij} = \sum_i \sum_j x_i y_j p_{ij} - E(X) \cdot E(Y) \quad (8)$$

**Współczynnik korelacji liniowej Pearsona zmiennych losowych X i Y**

$$\rho = \frac{\text{cov}(X, Y)}{D(X)D(Y)} \quad (9)$$

## 9. Badanie zależności dwóch cech

### Rozkłady brzegowe w próbie

Średnie

$$\bar{x} = \frac{\sum_{i=1}^k x_i n_{i\bullet}}{n} \qquad \bar{y} = \frac{\sum_{j=1}^l y_j n_{\bullet j}}{n} \qquad (1)$$

Wariancje (nieobciążone) (2)

$$s_x^2 = \frac{\sum_{i=1}^k (x_i - \bar{x})^2 n_{i\bullet}}{n-1} = \frac{1}{n-1} \left( \sum_{i=1}^k x_i^2 n_{i\bullet} - n\bar{x}^2 \right) \qquad s_y^2 = \frac{\sum_{j=1}^l (y_j - \bar{y})^2 n_{\bullet j}}{n-1} = \frac{1}{n-1} \left( \sum_{j=1}^l y_j^2 n_{\bullet j} - n\bar{y}^2 \right)$$

### Rozkłady warunkowe w próbie

Średnie

$$\bar{x}_j = \frac{\sum_{i=1}^k x_i n_{ij}}{n_{\bullet j}} \qquad \bar{y}_i = \frac{\sum_{j=1}^l y_j n_{ij}}{n_{i\bullet}} \qquad (3)$$

Wariancje (nieobciążone) (4)

$${}_j s_x^2 = \frac{\sum_i (x_i - \bar{x}_j)^2 n_{ij}}{n_{\bullet j} - 1} = \frac{1}{n_{\bullet j} - 1} \left( \sum_{i=1}^k x_i^2 n_{ij} - n_{\bullet j} \bar{x}_j^2 \right) \qquad {}_i s_y^2 = \frac{\sum_j (y_j - \bar{y}_i)^2 n_{ij}}{n_{i\bullet} - 1} = \frac{1}{n_{i\bullet} - 1} \left( \sum_{j=1}^l y_j^2 n_{ij} - n_{i\bullet} \bar{y}_i^2 \right)$$

### Średnie ogólne (brzegowe) wyliczone ze średnich warunkowych

$$\bar{x} = \frac{\sum_{j=1}^l \bar{x}_j n_{\bullet j}}{n} \qquad \bar{y} = \frac{\sum_{i=1}^k \bar{y}_i n_{i\bullet}}{n} \qquad (5)$$

### Kowariancja (nieobciążona)

dane indywidualne:

$$c_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n-1} \left( \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right) \qquad (6)$$

dane pogrupowane w tablicy korelacyjnej:

$$c_{xy} = \frac{1}{n-1} \sum_{i=1}^k \sum_{j=1}^l (x_i - \bar{x})(y_j - \bar{y})n_{ij} = \frac{1}{n-1} \left( \sum_{i=1}^k \sum_{j=1}^l x_i y_j n_{ij} - n\bar{x}\bar{y} \right) \quad (7)$$

### Test niezależności

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}} \quad v=(k-1)(l-1) \quad \text{gdzie } \hat{n}_{ij} = \frac{n_{i \cdot} \cdot n_{\cdot j}}{n} \quad (8) \quad (9)$$

### Współczynnik zbieżności VCramera

$$V = \sqrt{\frac{\chi^2}{n(m-1)}} \quad \text{gdzie } m=\min(k,l) \quad (10)$$

### Współczynnik korelacji liniowej Pearsona

$$r_{yx} = r_{xy} = \frac{c_{xy}}{s_x s_y} \quad (11)$$

### Test na nieskorelowanie liniowe zmiennych

$$t = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2} \quad v=n-2 \quad (12)$$

### Współczynnik korelacji rang Spearmana

$$r_d = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2-1)} \quad (13)$$

## 10. Klasyczny model regresji liniowej z jedną zmienną objaśniającą

$$Y = E(Y|X = x_i) + \varepsilon_i = \alpha x_i + \beta + \varepsilon_i \quad i=1,2,\dots,n \quad (1)$$

Założenia:

$$E(\varepsilon_i) = 0$$

$$D^2(\varepsilon_i) = E(\varepsilon_i^2) = \sigma^2$$

$$\text{cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \text{dla } i \neq j$$

$$\varepsilon_i : N(0, \sigma)$$

$$\text{Funkcja regresji liniowej: } \hat{y}_i = \hat{\alpha} \cdot x_i + \hat{\beta} \quad (2)$$

**Parametry strukturalne:**

$$\hat{\alpha} = \frac{\sum_{i=1}^n x_i y_i - \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{c_{xy}}{s_x^2} = r_{xy} \frac{s_y}{s_x} \quad (3)$$

$$\hat{\beta} = \bar{y} - \hat{\alpha} \bar{x} \quad (4)$$

**Parametry stochastyczne**

a) **Wariancja i odchylenie standardowe składnika resztowego**

$$s_e^2 = \frac{\sum_{i=1}^n e_i^2}{n-2} \quad s_e = \sqrt{s_e^2} \quad (5)$$

$e_i = y_i - \hat{y}_i$  - reszty  
 $y_i$  - wartości empiryczne  
 $\hat{y}_i = \hat{\alpha} x_i + \hat{\beta}$  - wartości teoretyczne

b) **Błędy standardowe oszacowań parametrów:**

$$s_{\hat{\alpha}} = \frac{\sqrt{s_e^2}}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} = \frac{\sqrt{s_e^2}}{\sqrt{\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n}}} = \sqrt{\frac{s_e^2}{(n-1)s_x^2}} \quad (6)$$

$$s_{\hat{\beta}} = \sqrt{\frac{s_e^2 \sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2}} = \sqrt{\frac{s_e^2 \sum_{i=1}^n x_i^2}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2}} = \sqrt{\frac{s_e^2 \sum_{i=1}^n x_i^2}{n(n-1)s_x^2}} \quad (7)$$

### Podział całkowitej sumy kwadratów odchyłeń

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

### Współczynnik determinacji liniowej:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n e_i^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{(n-2)s_e^2}{(n-1)s_y^2} \quad (9)$$

### Przedział ufności dla $\alpha$

$$P(\hat{\alpha} - t_{\gamma, n-2} s_{\hat{\alpha}} < \alpha < \hat{\alpha} + t_{\gamma, n-2} s_{\hat{\alpha}}) = 1 - \gamma \quad (10)$$

### Test dla hipotezy $H_0: \alpha = 0$

$$t = \frac{\hat{\alpha}}{s_{\hat{\alpha}}}, \quad v = n-2 \quad (11)$$

### Prognoza Y dla $X=x^p$

$$\hat{y}^p = \hat{\alpha} \cdot x^p + \hat{\beta} \quad (12)$$

### Błąd standardowy prognozy Y dla $X=x^p$

$$s(y_x^p) = s_e \sqrt{1 + \frac{1}{n} + \frac{(x^p - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad \text{gdzie } \sum_{i=1}^n (x_i - \bar{x})^2 = (n-1)s_x^2 \quad (13)$$

### Przedział ufności dla prognozowanej wartości Y

$$P[\hat{y}_x - t_{\gamma, n-2} \cdot s(y_x^p) < \hat{y} < \hat{y}_x + t_{\gamma, n-2} \cdot s(y_x^p)] = 1 - \gamma \quad (14)$$



## 11. Wyrównywanie szeregów czasowych

### Średnia ruchoma zwykła

$$\bar{y}_t = \frac{1}{2q+1} \sum_{r=-q}^q y_{t+r} \quad t=q+1, q+2, \dots, n-q; \quad q=1, 2, \dots \quad (1)$$

### Średnia ruchoma scentrowana

$$\bar{y}_t = \frac{1}{2q} \left[ \frac{1}{2} y_{t-q} + \sum_{r=-q+1}^{q-1} y_{t+r} + \frac{1}{2} y_{t+q} \right] \quad (2)$$

Instytut Statystyki i Demografii SGH

## 12. Indeksy statystyczne

### Indeksy indywidualne

$t = 1, \dots, n$

Przyrost absolutny łańcuchowy $\Delta y_t = y_t - y_{t-1}$	(1)	Przyrost absolutny jednopodstawowy $\Delta y_t = y_t - y_{t^*}$	(4)
Przyrost względny łańcuchowy $\delta_t = \frac{y_t - y_{t-1}}{y_{t-1}}$	(2)	Przyrost względny jednopodstawowy $\delta_t = \frac{y_t - y_{t^*}}{y_{t^*}}$	(5)
Indeks indywidualny łańcuchowy $i_{t/t-1} = \frac{y_t}{y_{t-1}}$	(3)	Indeks indywidualny jednopodstawowy $i_{t/t^*} = \frac{y_t}{y_{t^*}}$	(6)

### Średnie tempo zmian w okresie (1, n)

$$r(1, n) = \bar{i}_g - 1 \quad (7)$$

gdzie:

$$\bar{i}_g = \sqrt[n-1]{\prod_{t=2}^n i_{t/t-1}} = \sqrt[n-1]{\frac{y_n}{y_1}} = \sqrt[n-1]{i_{n/1}} \quad (8) \quad (9) \quad (10)$$

$$\text{Prognoza na podstawie średniego tempa: } y_{n+k} = y_n \cdot (\bar{i}_g)^k \quad (11)$$

$${}_j i_p = \frac{p_{j1}}{p_{j0}} \quad \text{indywidualny indeks cen } j\text{-tego produktu} \quad (12)$$

$${}_j i_q = \frac{q_{j1}}{q_{j0}} \quad \text{indywidualny indeks ilości } j\text{-tego produktu} \quad (13)$$

$${}_j i_w = \frac{w_{j1}}{w_{j0}} \quad \text{indywidualny indeks wartości } j\text{-tego produktu} \quad (14)$$

$${}_j i_w = {}_j i_p \cdot {}_j i_q \quad (15)$$

## Indeksy agregatowe wartości, ilości i cen

(sumowanie w indeksach agregatowych po  $j$  składnikach agregatu)

**Agregatowy indeks wartości (zmian nominalnych):** (16)

$$I_w = \frac{\sum_j w_{j1}}{\sum_j w_{j0}} = \frac{\sum_j p_{j1} \cdot q_{j1}}{\sum_j p_{j0} \cdot q_{j0}}$$

**Agregatowy indeks cen:**

Ogólna postać standaryzacyjna: (17)

$$I_p = \frac{\sum_j p_{j1} q_{jt=const}}{\sum_j p_{j0} q_{jt=const}}$$

a) według formuły Laspeyresa: (18)

$${}^L I_p = \frac{\sum_j p_{j1} q_{j0}}{\sum_j p_{j0} q_{j0}} = \frac{\sum_j j i_p p_{j0} q_{j0}}{\sum_j p_{j0} q_{j0}} = \frac{\sum_j j i_p w_{j0}}{\sum_j w_{j0}} = \sum_j j i_p u_{j0}$$

b) według formuły Paaschego: (19)

$${}^P I_p = \frac{\sum_j p_{j1} q_{j1}}{\sum_j p_{j0} q_{j1}} = \frac{\sum_j p_{j1} q_{j1}}{\sum_j \frac{p_{j1} q_{j1}}{j i_p}} = \frac{\sum_j w_{j1}}{\sum_j \frac{w_{j1}}{j i_p}} = \frac{1}{\sum_j \frac{u_{j1}}{j i_p}}$$

c) według formuły Fishera: (20)

$${}^F I_p = \sqrt{{}^L I_p {}^P I_p}$$

**Agregatowy indeks ilości (zmian realnych):**

Ogólna postać standaryzacyjna: (21)

$$I_q = \frac{\sum_j q_{j1} P_{jt=const}}{\sum_j q_{j0} P_{jt=const}}$$

a) według formuły Laspeyresa: (22)

$${}^L I_q = \frac{\sum_j p_{j0} q_{j1}}{\sum_j p_{j0} q_{j0}} = \frac{\sum_j {}^j i_q p_{j0} q_{j0}}{\sum_j p_{j0} q_{j0}} = \frac{\sum_j {}^j i_q w_{j0}}{\sum_j w_{j0}} = \sum_j {}^j i_q u_{j0}$$

b) według formuły Paaschego: (23)

$${}^P I_q = \frac{\sum_j p_{j1} q_{j1}}{\sum_j p_{j1} q_{j0}} = \frac{\sum_j p_{j1} q_{j1}}{\sum_j \frac{p_{j1} q_{j1}}{{}^j i_q}} = \frac{\sum_j w_{j1}}{\sum_j \frac{w_{j1}}{{}^j i_q}} = \frac{1}{\sum_j \frac{u_{j1}}{{}^j i_q}}$$

c) według formuły Fishera: (24)

$${}^F I_q = \sqrt{{}^L I_q {}^P I_q}$$

**Równość indeksowa** (25)

$$I_w = {}^L I_p \cdot {}^P I_q = {}^P I_p \cdot {}^L I_q = {}^F I_p \cdot {}^F I_q$$