

# 1 Podstawy rachunku prawdopodobieństwa

Dystrybuantą zmiennej losowej  $X$  nazywamy prawdopodobieństwo przyjęcia przez zmienną losową  $X$  wartości mniejszej od  $x$ , tzn.  $F(x) = P[X < x]$ .

1. dla zmiennej losowej skokowej (dyskretnej)

$$F(x) = P[X < x] = \sum_{x_i < x} P[X = x_i] = \sum_{x_i < x} p_i$$

$P[X < x]$  oblicza się przez sumowanie wszystkich prawdopodobieństw  $p_i$  dla  $x_i < x$

2. dla zmiennej losowej ciągłej


$$F(x) = \int_{-\infty}^x f(t) dt, \quad \text{gdzie } f - \text{funkcja gęstości}$$

Charakterystyki liczbowe zmiennej losowej:

Zmienna losowa skokowa (dyskretna)	Zmienna losowa ciągła
$EX = \sum_{i=1}^n x_i p_i$ gdzie $p_i = P(X = x_i)$	$EX = \int_{-\infty}^{\infty} x f(x) dx$ gdzie $f$ - funkcja gęstości
$D^2 X = E(X - EX)^2 =$ $= \sum_{i=1}^n (x_i - EX)^2 p_i$ $D^2 X = EX^2 - (EX)^2$ gdzie $EX^2 = \sum_{i=1}^n x_i^2 p_i$	$D^2 X = E(X - EX)^2 =$ $= \int_{-\infty}^{\infty} (x - EX)^2 f(x) dx$ $D^2 X = EX^2 - (EX)^2$ gdzie $EX^2 = \int_{-\infty}^{\infty} x^2 f(x) dx$
$DX = \sqrt{D^2 X}$	$DX = \sqrt{D^2 X}$
$Mo$ - jest to wartość $x_i$ o największym prawdopodobieństwie wystąpienia lub wartość najczęściej występująca w próbie (różna od wartości skrajnych)	$Mo$ - jest to wartość $x$ , dla której funkcja gęstości $f(x)$ osiąga wartość największą (osiąga maksimum)
$Me$ - jest to liczba spełniająca warunki: $P(X \leq Me) \geq \frac{1}{2}$ i $P(X \geq Me) \geq \frac{1}{2}$	$Me$ - jest to liczba $x$ spełniająca równanie $F(x) = \frac{1}{2}$
kwantyl rzędu $p$ , $p \in (0, 1)$ - jest to liczba $x_p$ spełniająca warunki: $P(X \leq x_p) \geq p$ i $P(X \geq x_p) \geq 1 - p$	kwantyl rzędu $p$ , $p \in (0, 1)$ - jest to liczba $x$ spełniająca równanie $F(x) = p$

Podstawowe rozkłady zmiennej losowej ciągłej:


1. Rozkład normalny  $N(\mu, \sigma)$



Wartość	Excel 2016, LibreOffice
$\alpha = P[N(\mu, \sigma) < x]$	ROZKŁ.NORMALNY(x;μ;σ;PRAWDA)
$x : P[N(\mu, \sigma) < x] = \alpha$	ROZKŁ.NORMALNY.ODWR(α;μ;σ)

Wartość	Excel, OpenOffice, LibreOffice
$\alpha = P[N(\mu, \sigma) < x]$	ROZKŁAD.NORMALNY(x;μ;σ;PRAWDA)
$x : P[N(\mu, \sigma) < x] = \alpha$	ROZKŁAD.NORMALNY.ODW(α;μ;σ)


2. Rozkład chi-kwadrat  $\chi^2(n)$



Wartość	Excel 2016, LibreOffice
$\alpha = P[\chi^2(n) < x]$	ROZKŁ.CHI(x;n;PRAWDA)
$x : P[\chi^2(n) < x] = \alpha$	ROZKŁ.CHI.ODWR( $\alpha$ ;n)

Wartość	Excel, OpenOffice, LibreOffice
$\alpha = P[\chi^2(n) < x]$	1-ROZKŁAD.CHI(x;n)
$\alpha = P[\chi^2(n) > x]$	ROZKŁAD.CHI(x;n)
$x : P[\chi^2(n) < x] = \alpha$	ROZKŁAD.CHI.ODW(1 - $\alpha$ ;n)
$x : P[\chi^2(n) > x] = \alpha$	ROZKŁAD.CHI.ODW( $\alpha$ ;n)


### 3. Rozkład F Fishera-Snedecora $F(m, n)$



Wartość	Excel 2016, LibreOffice
$\alpha = P[F(m, n) < x]$	ROZKŁ.F(x;m;n;PRAWDA)
$x : P[F(m, n) < x] = \alpha$	ROZKŁ.F.ODWR( $\alpha$ ;m;n)

Wartość	Excel, OpenOffice, LibreOffice
$\alpha = P[F(m, n) < x]$	1-ROZKŁAD.F(x;m;n)
$\alpha = P[F(m, n) > x]$	ROZKŁAD.F(x;m;n)
$x : P[F(m, n) < x] = \alpha$	ROZKŁAD.F.ODW(1 - $\alpha$ ;m;n)
$x : P[F(m, n) > x] = \alpha$	ROZKŁAD.F.ODW( $\alpha$ ;m;n)

4. Rozkład t Studenta  $t(n)$



Wartość	Excel 2016, LibreOffice
$\alpha = P[t(n) < y]$	ROZKŁ.T(y;n;PRAWDA)
$y : P[t(n) < y] = \alpha$	ROZKŁ.T.ODWR( $\alpha$ ;n)

Wartość	Excel, OpenOffice, LibreOffice
$\alpha = P[t(n) < x]$ dla $x \geq 0$	1-ROZKŁAD.T(x;n;1)
$\alpha = P[t(n) > x] = P[t(n) < -x]$ dla $x \geq 0$	ROZKŁAD.T(x;n;1)
$\alpha = P[t(n) > x] + P[t(n) < -x]$ dla $x \geq 0$	ROZKŁAD.T(x;n;2)
$x : P[t(n) > x] = \alpha$ dla $x \geq 0$	ROZKŁAD.T.ODW( $2\alpha$ ;n)
$x : P[t(n) < x] = \alpha$ dla $x \geq 0$	ROZKŁAD.T.ODW( $2-2\alpha$ ;n)
$y : P[t(n) < y] = \alpha$ dla $y < 0$	-ROZKŁAD.T.ODW( $2\alpha$ ;n)
$(x > 0) : P[t(n) < -x] + P[t(n) > x] =$ $= 2P[t(n) > x] = 2P[t(n) < -x] = \alpha$	ROZKŁAD.T.ODW( $\alpha$ ;n)
$(x > 0) : P[-x < t(n) < x] = \alpha$	ROZKŁAD.T.ODW( $1-\alpha$ ;n)

## 2 Statystyka opisowa

Etapy tworzenia szeregu rozdzielczego przedziałowego:

1. wyznaczamy  $x_{\max}$  oraz  $x_{\min}$
2. wyznaczamy rozstęp z próby  $R = x_{\max} - x_{\min}$
3. wyznaczamy ilość przedziałów klasowych  $K$  (w zależności od liczebności próby  $n$ )
  - $K = \sqrt{n}$
  - $K = 1 + 3,322 \log n$
  - $K \leq 5 \log n$
  - tabela:

liczba pomiarów $n$	liczba przedziałów klasowych $K$
30-60	6-8
60-100	7-10
100-200	9-12
200-500	11-17
500-1500	16-25

4. wyznaczamy długość przedziału klasowego  $h$   
minimalna długość przedziału klasowego  $h_{\min} \approx \frac{R + \alpha}{K}$ , gdzie  $\alpha$  jest dokładnością pomiaru
5. wyznaczamy lewy koniec pierwszego przedziału klasowego

$$x_0 = x_{\min} - \frac{\alpha}{2}, \quad \text{gdzie } \alpha \text{ jest dokładnością pomiaru}$$

Miary statystyczne można podzielić na :

1. **miary położenia** - służą do określenia tej wartości cechy, wokół której skupiają się wszystkie pozostałe wartości; mierzą przeciętny poziom cechy

a) średnia z próby

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i - \text{dane nie pogrupowane}$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i n_i - \text{szereg rozdzielczy punktowy}$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i^* n_i - \text{szereg rozdzielczy przedziałowy, gdzie}$$

$x_i^*$  - środek przedziału klasowego

b) moda (dominanta) - wartość najczęstsza

- dane nie pogrupowane i szereg rozdzielczy punktowy:  
moda to wartość najczęstsza, o ile nie jest to wartość skrajna
- szereg rozdzielczy przedziałowy:

$$Mo = x_m + \frac{(n_m - n_{m-1}) h}{n_m - n_{m-1} + n_m - n_{m+1}}$$

gdzie  $x_m$  - lewy koniec przedziału z modą (czyli przedziału o największej liczebności, ale różnego od przedziału pierwszego i ostatniego),  $h$  - długość przedziału z modą,  $n_m$  - liczebność przedziału z modą,  $n_{m-1}$  - liczebność przedziału poprzedzającego przedział z modą,  $n_{m+1}$  - liczebność przedziału następującego po przedziale z modą

c) mediana - wartość środkowa w uporządkowanej próbie

- dane nie pogrupowane i szereg rozdzielczy punktowy:

$$Me = \begin{cases} x_{(\frac{n+1}{2})} & , \text{ gdy } n \text{ jest nieparzyste} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & , \text{ gdy } n \text{ jest parzyste} \end{cases}$$

tzn. mediana jest to środkowa liczba, gdy  $n$  jest liczbą nieparzystą, albo średnia arytmetyczna dwóch środkowych liczb, gdy  $n$  jest liczbą parzystą

- szereg rozdzielczy przedziałowy:

$$Me = x_{Me} + \frac{h}{n_{Me}} \left( \frac{n}{2} - \sum_{i=1}^{k-1} n_i \right)$$

gdzie  $x_{Me}$  - lewy koniec przedziału z medianą,  $h$  - długość przedziału z medianą,  $n_{Me}$  - liczebność przedziału z medianą,  $k$  - numer przedziału zawierającego medianę;  $\sum_{i=1}^{k-1} n_i$  - sumujemy liczebności przedziałów poprzedzających przedział z medianą

d) kwartyle (dolny  $Q_1$  i górny  $Q_3$ ) - wartości, które dzielą uporządkowaną próbę w stosunku 1:3 i 3:1

- szereg rozdzielczy przedziałowy:

$$Q_1 = x_{Q_1} + \frac{h}{n_{Q_1}} \left( \frac{n}{4} - \sum_{i=1}^{k-1} n_i \right)$$

$$Q_3 = x_{Q_3} + \frac{h}{n_{Q_3}} \left( \frac{3n}{4} - \sum_{i=1}^{k-1} n_i \right)$$

gdzie  $x_{Q_1}$  - lewy koniec przedziału zawierającego  $Q_1$ ,  $h$  - długość przedziału zawierającego  $Q_1$ ,  $n_{Q_1}$  - liczebność przedziału zawierającego  $Q_1$ ,  $k$  - numer przedziału zawierającego  $Q_1$

e) kwantyle rzędu  $p$ ,  $p \in (0, 1)$  - wartości, które dzielą uporządkowaną próbę w stosunku  $p : (1 - p)$

f) inne średnie (geometryczna, harmoniczna)

2. **miary rozproszenia** (zmienności, rozrzutu) - służą do badania stopnia zróżnicowania jednostek populacji ze względu na wartość badanej cechy

a) rozstęp  $R = x_{\max} - x_{\min}$

b) wariancja

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 - \text{dane nie pogrupowane}$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 n_i - \text{szereg rozdzielczy punktowy}$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i^* - \bar{x})^2 n_i - \text{szereg rozdzielczy przedziałowy, gdzie}$$

$x_i^*$  - środek przedziału klasowego

c) odchylenie standardowe  $s = \sqrt{s^2}$

typowy przedział zmienności  $(\bar{x} - s; \bar{x} + s)$



d) odchylenie przeciętne od średniej

$$d_1 = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| \text{ - dane niepogrupowane}$$

$$d_1 = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| n_i \text{ - szereg rozdzielczy punktowy}$$

$$d_1 = \frac{1}{n} \sum_{i=1}^n |x_i^* - \bar{x}| n_i \text{ - szereg rozdzielczy przedziałowy, gdzie}$$

$x_i^*$  - środek przedziału klasowego

e) odchylenie przeciętne od mediany

$$d_2 = \frac{1}{n} \sum_{i=1}^n |x_i - Me| \text{ - dane niepogrupowane}$$

$$d_2 = \frac{1}{n} \sum_{i=1}^n |x_i - Me| n_i \text{ - szereg rozdzielczy punktowy}$$

$$d_2 = \frac{1}{n} \sum_{i=1}^n |x_i^* - Me| n_i \text{ - szereg rozdzielczy przedziałowy, gdzie}$$

$x_i^*$  - środek przedziału klasowego

f) odchylenie ćwiartkowe  $Q = \frac{1}{2} (Q_3 - Q_1)$

rozstęp kwartyłowy  $Q = Q_3 - Q_1$

g) współczynnik zmienności  $V = \frac{s}{\bar{x}} \cdot 100\%$

h) współczynnik nierównomierności  $H = \frac{d_1}{\bar{x}} \cdot 100\%$ ,  $H_2 = \frac{d_2}{M_o} \cdot 100\%$

3. **miary asymetrii** - służą do badania kierunku zróżnicowania wartości badanej cechy; mierzą czy przeważająca liczba jednostek znajduje się powyżej czy poniżej przeciętnego poziomu badanej cechy

a) wskaźnik asymetrii  $ws_1 = \bar{x} - M_o$ ,  $ws_2 = \bar{x} - Me$

b) współczynnik asymetrii

$$A = \frac{M_3}{s^3}, \text{ gdzie}$$

$$M_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3 - \text{dane niepogrupowane}$$

$$M_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3 n_i - \text{szereg rozdzielczy punktowy}$$

$$M_3 = \frac{1}{n} \sum_{i=1}^n (x_i^* - \bar{x})^3 n_i - \text{szereg rozdzielczy przedziałowy, gdzie}$$

$x_i^*$  - środek przedziału klasowego

c) współczynnik skośności

$$A_1 = \frac{\bar{x} - Mo}{s}, \quad A_2 = \frac{\bar{x} - Mo}{d_1}, \quad A_3 = \frac{Q_1 + Q_3 - 2Me}{2Q}$$

4. **miary spłaszczenia** (koncentracji) - służą do analizy stopnia skupienia poszczególnych jednostek wokół średniej

a) kurtoza (współczynnik skupienia)

$$K = \frac{M_4}{s^4}, \quad \text{gdzie}$$

$$M_4 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4 - \text{dane niepogrupowane}$$

$$M_4 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4 n_i - \text{szereg rozdzielczy punktowy}$$

$$M_4 = \frac{1}{n} \sum_{i=1}^n (x_i^* - \bar{x})^4 n_i - \text{szereg rozdzielczy przedziałowy, gdzie}$$

$x_i^*$  - środek przedziału klasowego

b) eksces  $q = K - 3$

Miary statystyczne można podzielić na:

1. **miary pozycyjne** - są niewrażliwe na obserwacje mocno odstające (moda, mediana, kwartyle, rozstęp kwartyłowy)
2. pozostałe

### 3 Estymacja przedziałowa

#### 1. PRZEDZIAŁY UFNOŚCI DLA ŚREDNIEJ

##### (a) MODEL I

Badana cecha ma rozkład normalny  $N(\mu, \sigma)$  o **nieznanym parametrze  $\mu$  i znanym  $\sigma$** . Przedział ufności:

$$\mu \in \left[ \bar{x} - u\left(1 - \frac{\alpha}{2}\right) \frac{\sigma}{\sqrt{n}} ; \bar{x} + u\left(1 - \frac{\alpha}{2}\right) \frac{\sigma}{\sqrt{n}} \right]$$

gdzie  $u(1 - \frac{\alpha}{2})$  jest kwantylem rzędu  $1 - \frac{\alpha}{2}$  rozkładu normalnego  $N(0, 1)$ ;  $\bar{x}$ ,  $n$  - to średnia i liczebność próby.

##### (b) MODEL II

Badana cecha ma rozkład normalny  $N(\mu, \sigma)$  o **nieznanych parametrach  $\mu$  i  $\sigma$** . Przedział ufności:

$$\mu \in \left[ \bar{x} - t\left(1 - \frac{\alpha}{2}, n - 1\right) \frac{s}{\sqrt{n - 1}} ; \bar{x} + t\left(1 - \frac{\alpha}{2}, n - 1\right) \frac{s}{\sqrt{n - 1}} \right]$$

gdzie  $t(1 - \frac{\alpha}{2}, n - 1)$  jest kwantylem rzędu  $1 - \frac{\alpha}{2}$  rozkładu Studenta o  $n - 1$  stopniach swobody;  $\bar{x}$ ,  $s$ ,  $n$  - to średnia, odchylenie standardowe i liczebność próby.

##### (c) MODEL III

Badana cecha ma dowolny rozkład (niekoniecznie normalny), o nieznannej wartości oczekiwanej  $\mu$  i nieznanym odchyleniu standardowym  $\sigma$ , zaś liczebność próby jest duża ( $n \geq 100$ ). Przedział ufności:

$$\mu \in \left[ \bar{x} - u\left(1 - \frac{\alpha}{2}\right) \frac{s}{\sqrt{n}} ; \bar{x} + u\left(1 - \frac{\alpha}{2}\right) \frac{s}{\sqrt{n}} \right]$$

gdzie  $u(1 - \frac{\alpha}{2})$  jest kwantylem rzędu  $1 - \frac{\alpha}{2}$  rozkładu normalnego  $N(0, 1)$ ;  $\bar{x}$ ,  $s$ ,  $n$  - to średnia, odchylenie standardowe i liczebność próby.

Jeśli  $\sigma$  jest parametrem znanym, to zamiast  $s$  wstawiamy  $\sigma$ .

## 2. PRZEDZIAŁY UFNOŚCI DLA WARIANCJI

### (a) MODEL I

Badana cecha ma rozkład normalny  $N(\mu, \sigma)$  o nieznanach parametrach  $\mu$  i  $\sigma$ , zaś próba jest mała ( $n \leq 50$ ). Przedział ufności:

$$\sigma^2 \in \left[ \frac{ns^2}{\chi^2\left(1 - \frac{\alpha}{2}, n - 1\right)} ; \frac{ns^2}{\chi^2\left(\frac{\alpha}{2}, n - 1\right)} \right]$$

gdzie  $\chi^2\left(1 - \frac{\alpha}{2}, n - 1\right)$  i  $\chi^2\left(\frac{\alpha}{2}, n - 1\right)$  są kwantylami rzędu  $1 - \frac{\alpha}{2}$  i  $\frac{\alpha}{2}$  (odpowiednio) rozkładu chi-kwadrat o  $n - 1$  stopniach swobody;  $s^2$ ,  $n$  - to wariancja i liczebność próby.

### (b) MODEL II

Badana cecha ma rozkład normalny  $N(\mu, \sigma)$  o nieznanach parametrach  $\mu$  i  $\sigma$ , zaś próba jest duża ( $n > 50$ ). Przedział ufności:

$$\sigma^2 \in \left[ \frac{2ns^2}{\left(\sqrt{2n-3} + u\left(1 - \frac{\alpha}{2}\right)\right)^2} ; \frac{2ns^2}{\left(\sqrt{2n-3} - u\left(1 - \frac{\alpha}{2}\right)\right)^2} \right]$$

gdzie  $u\left(1 - \frac{\alpha}{2}\right)$  jest kwantylem rzędu  $1 - \frac{\alpha}{2}$  rozkładu normalnego  $N(0, 1)$ ;  $s^2$ ,  $n$  - to wariancja i liczebność próby.

## 3. PRZEDZIAŁY UFNOŚCI DLA WSKAŹNIKA STRUKTURY

Jeśli próba jest duża ( $n \geq 100$ ), to przedział ufności dla wskaźnika struktury  $p$  jest postaci:

$$p \in \left[ q - u\left(1 - \frac{\alpha}{2}\right)\sqrt{\frac{q(1-q)}{n}} ; q + u\left(1 - \frac{\alpha}{2}\right)\sqrt{\frac{q(1-q)}{n}} \right]$$

gdzie  $q = \frac{m}{n}$ ;  $m$  jest liczbą elementów w próbie, które posiadają badaną cechę;  $u\left(1 - \frac{\alpha}{2}\right)$  jest kwantylem rzędu  $1 - \frac{\alpha}{2}$  rozkładu normalnego  $N(0, 1)$ .