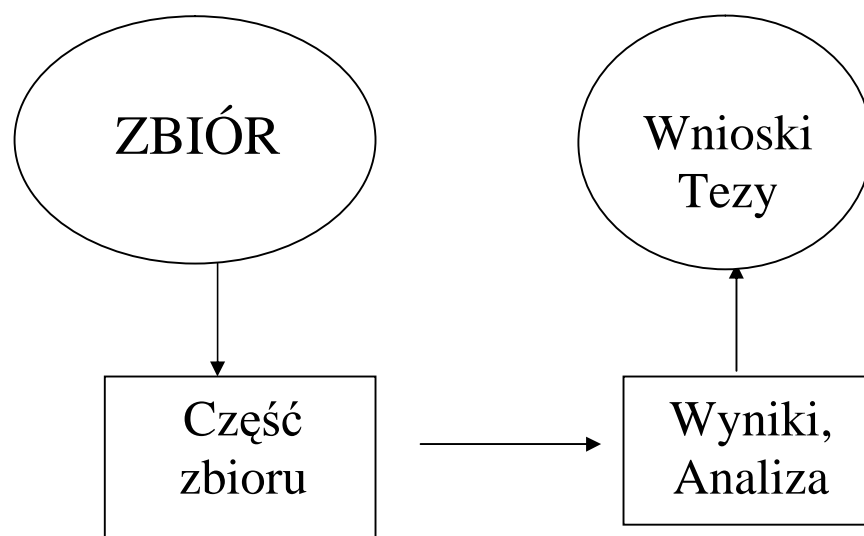


**STATYSTYKA MATEMATYCZNA** - dział matematyki stosowanej oparty na rachunku prawdopodobieństwa; zajmuje się badaniem zbiorów na podstawie analizy ich części. Nauka, której przedmiotem zainteresowania są metody pozyskiwania i prezentacji, a przede wszystkim analizy danych opisujących zjawisk

*(C. Gauss, P. Laplace, Bernoulli, R. Fisher, J. Sława-Neyman)  
Wikipedia 2008*



Zbiorem (populacją) jest interesujący nas typ obiektu i jego właściwości, które chcemy poznać. Częścią zbioru jest próba, którą obserwujemy podczas badania.

Statystyka jest stosowana w wielu dziedzinach wiedzy, w niektórych doczekała się własnej terminologii i wyspecjalizowanych metod. Wytworzyły się dziedziny z pogranicza statystyki i innych nauk.

Należą do nich:

- . Biometria
- . Demografia
- . Ekonometria
- . Fizyka statystyczna
- . Psychologia statystyczna
- . Socjologia statystyczna
- . Statystyka gospodarcza

Obecnie standardem w naukach eksperymentalnych jest potwierdzanie istnienia obserwowanych zależności przy pomocy metod statystyki matematycznej. Pozwala to odróżnić rzeczywiste wyniki od przypadkowej zbieżności – odróżnienie efektów działających praw od efektu przypadku (prawidłowości w zakresie zjawisk masowych)

Od starożytności do około połowy XIX wieku termin *statystyka* oznaczał *podany w tabelarycznej formie zbiór danych na temat stanu państwa*. W pewnym momencie posiadanie podstawowych danych stało się niewystarczające, szczególnie przy coraz szybciej rozwijającej się gospodarce światowej.

Konieczne stało się nie tylko ulepszanie metod pozyskiwania danych, ale również ich opisu i analizy. Zbiegło się to w czasie z szybkim rozwojem metod matematycznych, szczególnie teorii prawdopodobieństwa.

Obecnie (od połowy XX wieku) rozwój statystyki jest związany z możliwością wykorzystania komputerów do przeprowadzania skomplikowanych (lub żmudnych) obliczeń.

# ELEMENTY RACHUNKU PRAWDOPODOBIENSTWA

Rachunek prawdopodobieństwa – analiza praw rządzących zdarzeniami losowymi.

Pojęcia pierwotne – zdarzenie elementarne  $\omega$  oraz zbiór zdarzeń elementarnych  $\Omega$ .

Zdarzenie losowe  $A$  – podzbiór zbioru zdarzeń elementarnych  $\Omega$ .

Prawdopodobieństwo (klasyczna definicja Laplace'a): Jeżeli  $\Omega$  składa się z  $n$  jednakowo prawdopodobnych zdarzeń elementarnych, to prawdopodobieństwo zdarzenia  $A$  składającego się z  $k$  zdarzeń elementarnych wyraża się wzorem:

$$P(A) = \frac{k}{n}$$

Prawdopodobieństwo (aksjomatyczna definicja Kołmogorowa):

1.  $P(A) \in \langle 0, 1 \rangle$
2.  $P(\Omega) = 1$
3.  $P(A \cup B) = P(A) + P(B)$  dla  $A$  i  $B$  rozłącznych

Punkt 3 jest prawdziwy również dla nieskończonej liczby zbiorów rozłącznych

### **Prawdopodobieństwo zbioru pustego**

$$P(\emptyset) = 0$$

Przykład: rzucamy kostką idealną – zawsze coś wypadnie i wszystkie możliwości są równie prawdopodobne. Prawdopodobieństwo, że nic nie wypadnie jest równe zeru

**Prawdopodobieństwo zdarzenia  $A'$**   
(przeciwego do zdarzenia  $A$ ):

$$P(A') = 1 - P(A)$$

Przykład: rzucamy kostką.  $A$ -wypadnie „6”.

Wtedy  $A'$ -nie wypadło „6”.

$$P(A) = 1/6 \text{ więc } P(A') = 1 - 1/6 = 5/6$$

**Zdarzenia rozłączne.** Zdarzenia  $A$  i  $B$  są rozłączne, jeżeli

$$(A \cap B) = \emptyset$$

Wtedy

$$P(A \cap B) = 0$$

$A$  i  $A'$  są rozłączne. Wypadnie „1” i wypadnie „6” na kostce też są rozłączne.

$C$ - wypadnie parzysta liczba i  $D$ - wypadnie mniej niż 4 nie są rozłączne, bo wynik 2 należy zarówno do zdarzenia  $C$  jak i  $D$ .

Prawdopodobieństwo **sumy** i **iloczynu** zbiorów:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

przykład:  $C \cup D = \{1, 2, 3, 4, 6\}$        $C \cap D = \{2\}$   
 $5/6 = 3/6 + 3/6 - 1/6$

**Prawdopodobieństwo warunkowe** zajścia zdarzenia  $B$  pod warunkiem realizacji zdarzenia  $A$ :

$$P(B/A) = \frac{P(B \cap A)}{P(A)}$$

przykład:  $A$ -wypadnie parzysta liczba oczek,  $B$ -wypadnie conajwyżej 3.  $P(A)=3/6$ ,  $P(B)=3/6$  ale  $P(B/A)=1/3$  – wiemy że wypadło jedno z  $A=\{2,4,6\}$  więc  $P(\{2\})=1/3$ . Korzystając ze wzoru:  $A \cap B = \{2\}$ , więc  $P(A \cap B)=1/6$ ,  $P(A)=3/6 \Rightarrow P(B/A) = \frac{1/6}{3/6}$

**Zdarzenia niezależne:** Zdarzenia  $A$  i  $B$  są niezależne, jeżeli

$$P(A \cap B) = P(A) \cdot P(B)$$

Równoważnie

$$P(B/A) = P(B)$$

$$P(A/B) = P(A)$$

przykład: wypadnięcie orła w rzucie monetą i wypadnięcie parzystej liczby oczek w rzucie kostką są niezależne.  $A$ - parzysta liczba,  $B$ - conajwyżej 4 też są niezależne.

## Schemat Bernoulliego

- ciąg  $n$  niezależnych zdarzeń,
- w pojedynczym zdarzeniu realizuje się sukces lub porażka,
- prawdopodobieństwo sukcesu jest stałe, równe  $p$

$$P(k \text{ sukcesów}) = \binom{n}{k} p^k (1-p)^{n-k}$$

$$q = 1-p$$

$$k = 0, 1, 2, \dots, n$$

Przykład: Prawdopodobieństwo spełnienia normy dla klasy I przez pewien produkt wynosi 70%. Jakie jest prawdopodobieństwo, że przy kontroli jakości na 5 losowo wybranych produktów normę spełni przynajmniej 4 z nich? (53%)

$$P_{n=5}(k=4) = \frac{5!}{4! \cdot 1!} 0,7^4 0,3^1 \approx 36\%$$

$$P_{n=5}(k=5) = \frac{5!}{5! \cdot 0!} 0,7^5 0,3^0 \approx 17\%$$



## ZMIENNA LOSOWA (CECHA)

**Zmienna losowa:** funkcja o wartościach rzeczywistych, określona na zbiorze zdarzeń elementarnych  $\Omega$ . Innymi słowy zmienna losowa  $X$  jest liczbową prezentacją wyniku doświadczenia losowego.

$$\Omega \longrightarrow \mathbb{R}$$

**Skala nominalna** ang: *nominal scale* (cecha jakościowa): wartości liczbowe stanowią tylko etykiety. Nie wynika z nich żadna zależność (porządek, różnice, ilorazy nie mają merytorycznego znaczenia) np. rodzaj przetworu mlecznego, ID osoby. Skala nominalna dychotomiczna – możliwe są tylko dwie wartości.

**Skala porządkowa** ang: *Ordinal scale*, (przypisanie rangi każdej jednostce populacji): zmienne przyjmują wartości, dla których dane jest uporządkowanie (kolejność), ale ani różnica ani iloraz między dwiema wartościami nie mają merytorycznego znaczenia (np. klasa jakościowa, wykształcenie).

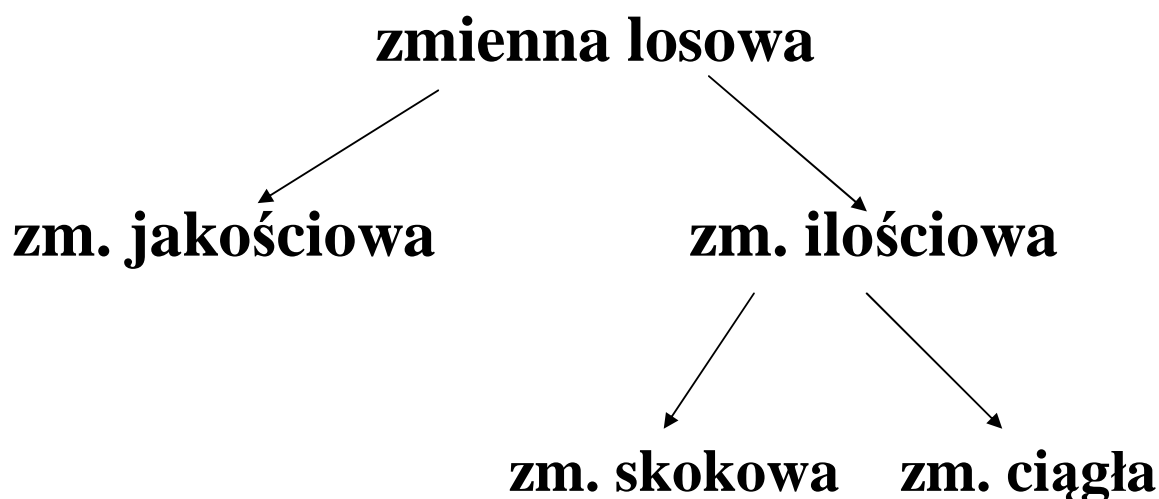
**Skala interwałowa** ang: *Interval scale*  
różnice między dwiema jej wartościami mają interpretację, jednak dzielenie dwóch wartości (iloraz) nie ma merytorycznego sensu (określona jest jednostka, jednak punkt zero jest wybrany umownie np. miary temperatury).

**Skala absolutna** Wymaga ustalenia jednostki miary i wyznaczenia naturalnego punktu zerowego np. liczba produktów.  
**Skala ilorazowa** ang: *Ratio measurement*: merytorycznie uzasadnione jest położenie zera, zaś jednostka jest umowna (nie wynika z natury zjawiska). Nie wprowadza to ograniczeń w stosowaniu operacji arytmetycznych do wyników pomiaru (np. średnia geometryczna i harmoniczna). przykładem jest temperatura w stopniach Kelwina.

**Zmienna jakościowa** (skala nominalna): przyjmuje wartości nie będące liczbami (np. kolor, płeć, smakowitość).

**Zmienna ilościowa skokowa** (interwałowa, ilorazowa lub absolutna): przyjmuje pewne wartości liczbowe i nie przyjmuje wartości pośrednich (np. liczba bakterii, liczba kolonii drożdży, liczba pracowników). Nazywana jest również zmienną **dyskretną**.

**Zmienna ilościowa ciągła** (interwałowa, ilorazowa lub absolutna): przyjmuje wartości z pewnego przedziału liczbowego (np. wzrost, plon, kaloryczność).



**Rozkład zmiennej losowej skokowej  $X$ :** zbiór wartości zmiennej losowej  $x_i$  oraz prawdopodobieństwa  $p_i$  z jakimi te wartości są przyjmowane (dla każdej możliwej  $x_i$  z  $X$ , odpowiednio  $w_i$  z  $W$ , ma pewne  $p_i$  realizacji).

$$p_i = P(X = x_i), \quad p_i \in \langle 0,1 \rangle, \quad \sum_i p_i = 1$$

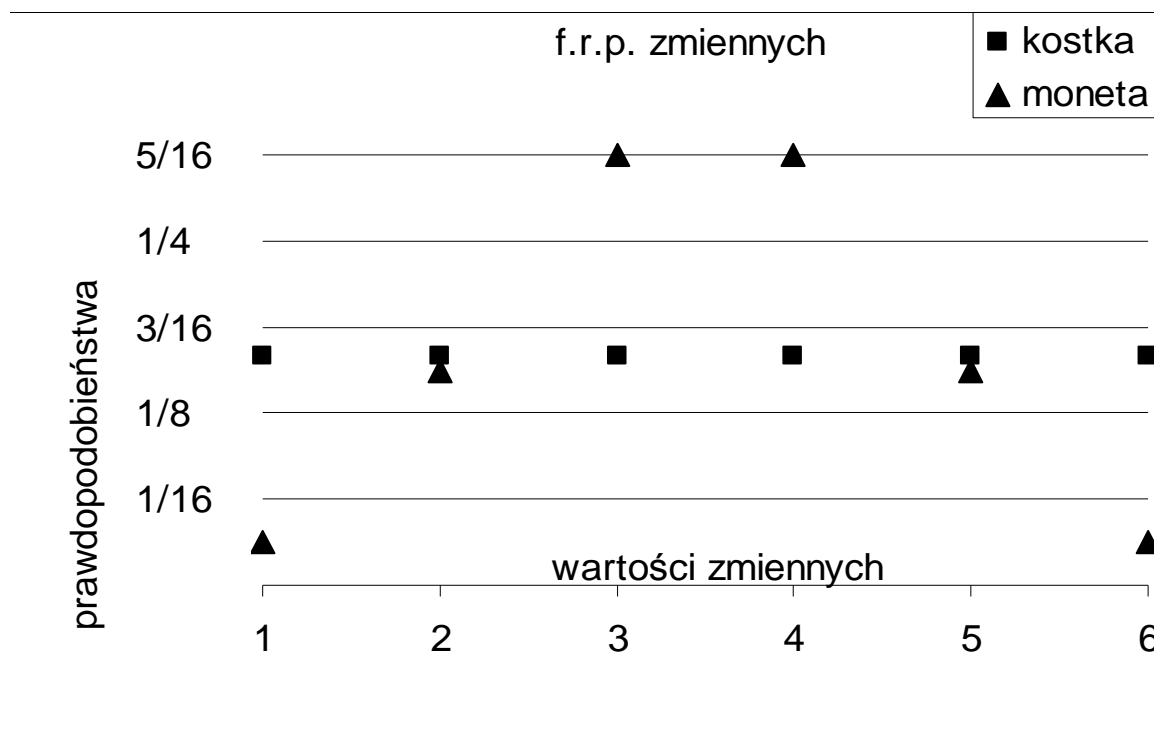
**Przykład.** Jednokrotny rzut kostką. Zmienna losowa  $X$  to liczba wyrzuconych oczek.

Rozkład: liczba oczek w rzucie kostką

$x_i$	1	2	3	4	5	6
$p_i$	1/6	1/6	1/6	1/6	1/6	1/6

Rozkład: jeden plus liczba orłów w 5 rzutach

$x_i$	1	2	3	4	5	6
$p_i$	1/32	5/32	10/32	10/32	5/32	1/32



**Rozkład zmiennej losowej ciągłej  $X$**  określony jest funkcją gęstości prawdopodobieństwa  $f(x)$ . Funkcja ta posiada własności:

- $f(x) \geq 0$
- $\int_{-\infty}^{+\infty} f(x)dx = 1$
- $P(a < x < b) = \int_a^b f(x)dx$

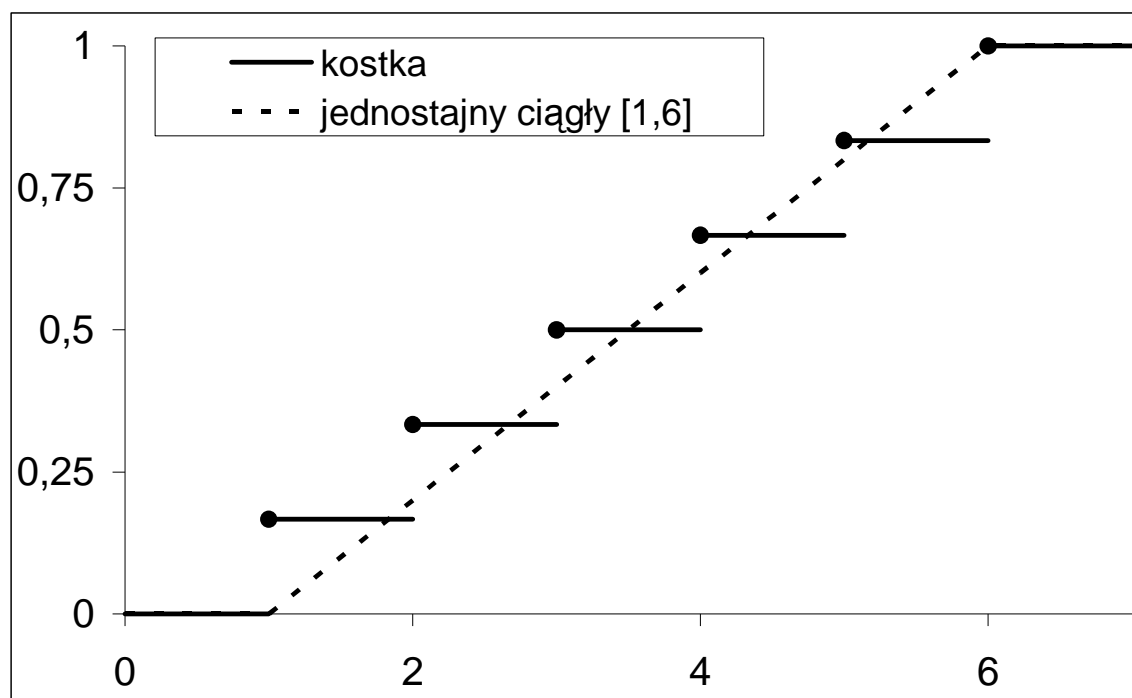
Zdefiniowane prawdopodobieństwo realizacji jakiejś wartości z dowolnie wybranego przedziału, np. dla rozkładu jednostajnego ciągłego (równomiernego ciągłego) na  $[0,1]$  prawdopodobieństwo realizacji wartości z przedziału (będącego podzbiorem  $[0,1]$ ) równe jest długości przedziału, więc  $P([0; 0,2])=0,2$ .

Rozkład zmiennej losowej, obydwu typów, można przedstawić przy pomocy funkcji dystrybuanty  $F(x)$ . Dystrybuanta  $F$  jest funkcją określoną na zbiorze liczb rzeczywistych  $\mathbb{R}$  wzorem:

$$F(x_0) = P(X \leq x_0) = \begin{cases} \sum_{x_i \leq x_0} P(x = x_i) & \text{dla zmiennej skokowej} \\ \int_{-\infty}^{x_0} f(x) dx & \text{dla zmiennej ciągłej} \end{cases}$$

Funkcja dystrybuanty posiada własności:

- $0 \leq F(x) \leq 1$
- $F(-\infty) = 0, F(\infty) = 1$
- Jest funkcją niemalejącą
- $P(a < X \leq b) = F(b) - F(a)$



## Parametry zmiennej losowej

**Wartość oczekiwana (średnia)  $EX$**  zmiennej losowej  $X$  jest liczbą charakteryzującą położenie zbioru jej wartości:

$$EX = \begin{cases} \sum x_i p_i & \text{dla zmiennej skokowej} \\ \int x f(x) dx & \text{dla zmiennej ciągłej} \end{cases}$$

**Wariancja  $D^2X$  i odchylenie standardowe  $DX$**  zmiennej losowej  $X$  są liczbami charakteryzującymi rozrzut zbioru jej wartości wokół wartości średniej  $EX$ :

$$D^2X = \begin{cases} \sum (x_i - EX)^2 p_i & \text{dla zmiennej skokowej} \\ \int (x - EX)^2 f(x) dx & \text{dla zmiennej ciągłej} \end{cases}$$

$$DX = \sqrt{D^2X}$$

**przykład:** dla rzutu kostką

$$\begin{aligned} EX &= 1 * \frac{1}{6} + 2 * \frac{1}{6} + 3 * \frac{1}{6} + 4 * \frac{1}{6} + 5 * \frac{1}{6} \\ &+ 6 * \frac{1}{6} = 3,5; \quad D^2X = (1-3,5)^2 * \frac{1}{6} + (2-3,5)^2 * \frac{1}{6} \\ &+ (3-3,5)^2 * \frac{1}{6} + (4-3,5)^2 * \frac{1}{6} + \\ &+ (5-3,5)^2 * \frac{1}{6} + (6-3,5)^2 * \frac{1}{6} = 2 + \frac{11}{12} \end{aligned}$$