

# Statystyka w analizie i planowaniu eksperymentu

Paweł Błażej

10 marca 2014

Przeprowadzane w praktyce badania i eksperymenty mają bardzo różnorodny charakter, niemniej jednak wiążą się one z rejestracją jakiś sygnałów (danych). Mogą to być na przykład:

- 1 odczyty na skali;

Przeprowadzane w praktyce badania i eksperymenty mają bardzo różnorodny charakter, niemniej jednak wiążą się one z rejestracją jakiś sygnałów (danych). Mogą to być na przykład:

- 1 odczyty na skali;
- 2 końcowe parametry jakiegoś procesu technologicznego;

Przeprowadzane w praktyce badania i eksperymenty mają bardzo różnorodny charakter, niemniej jednak wiążą się one z rejestracją jakiś sygnałów (danych). Mogą to być na przykład:

- 1 odczyty na skali;
- 2 końcowe parametry jakiegoś procesu technologicznego;
- 3 liczba osób w kolejce.

- 1 Zmienne jakościowe (nazywane również kategoriowymi, czynnikowymi), to zmienne przyjmujące określoną liczbę wartości (najczęściej nieliczbowych):
  - binarne, np. płeć (kobieta/mężczyzna);
  - nominalne, np. marka samochodu;
  - porządkowe, np. wykształcenie (podstawowe, średnie, wyższe).

- 1 Zmienne jakościowe (nazywane również kategorycznymi, czynnikowymi), to zmienne przyjmujące określoną liczbę wartości (najczęściej nieliczbowych):
  - binarne, np. płeć (kobieta/mężczyzna);
  - nominalne, np. marka samochodu;
  - porządkowe, np. wykształcenie (podstawowe, średnie, wyższe).
- 2 Zmienne ilościowe, opisują ilość. Wyróżnia się skale:
  - licznikową (liczebność wystąpień pewnego zjawiska, opisywana przez liczby naturalne) np. liczba lat nauki;
  - przedziałową (interwałową) skala, w której zmienna może przyjmować dowolne wartości z określonego przedziału.

Tej definicji nie trzeba uczyć się na pamięć!

Zmienną losową nazywamy funkcję  $X$  określoną na przestrzeni zdarzeń elementarnych  $\Omega$ , o wartościach ze zbioru liczb rzeczywistych  $\mathbf{R}$ .

Uwaga

Zmienne losowe oznaczamy dużymi literami  $X, Y, Z$  a ich konkretne wartości małymi literami  $x, y, z$ .

Niech  $\Omega = \{\omega_1, \dots, \omega_6\}$ , gdzie  $\omega_i$ ,  $i = 1, 2, \dots, 6$  oznacza zdarzenie elementarne polegające na wyrzuceniu  $i$ -oczek. Określmy zmienną losową

$$X(\omega_i) = i, \quad i = 1, 2, \dots, 6.$$



# Prawdopodobieństwo przyjęcia przez zmienną losową wartości z danego zbioru

Zdarzeniami losowymi są również zbiory definiowane w następujący sposób:

$$\{\omega : X(\omega) \in A\}$$

gdzie  $A$  jest dowolnym podzbiorem  $\mathbf{R}$ .

# Prawdopodobieństwo przyjęcia przez zmienną losową wartości z danego zbioru

Prawdopodobieństwo  $P(X \in A)$  przyjęcia przez zmienną losową  $X$  wartości ze zbioru  $A$  gdzie  $A \subset \mathbf{R}$ , określamy następującą równością:

$$P(X \in A) = P(\{\omega : X(\omega) \in A\}).$$

## Dystrybuanta zmiennej losowej $X$

Funkcję  $F_X$  określoną na zbiorze  $\mathbf{R} = (-\infty, +\infty)$  liczb rzeczywistych wzorem:

$$F_X(x) = P(X \leq x), \quad x \in \mathbf{R}$$

nazywamy dystrybuantą zmiennej losowej  $X$ .

Jeżeli nie ma wątpliwości z jaką zmienną losową mamy do czynienia wtedy dystrybuantę oznaczamy przez  $F$ .

Założmy, że prawdopodobieństwo wylosowania wadliwego towaru wynosi  $0 < p < 1$ . Wówczas dystrybuanta zmiennej losowej  $X$  przyjmuje postać

$$F(x) = \begin{cases} 0, & \text{dla } x < 0 \\ 1 - p & \text{dla } 0 \leq x < 1 \\ 1 & \text{dla } x \geq 1 \end{cases}$$

- 1  $0 \leq F(x) \leq 1$  dla każdego  $x \in \mathbf{R}$ ;

# Własności dystrybuanty

- 1  $0 \leq F(x) \leq 1$  dla każdego  $x \in \mathbf{R}$ ;
- 2  $\lim_{x \rightarrow -\infty} F(x) = 0$  oraz  $\lim_{x \rightarrow +\infty} F(x) = 1$ ;

- 1  $0 \leq F(x) \leq 1$  dla każdego  $x \in \mathbf{R}$ ;
- 2  $\lim_{x \rightarrow -\infty} F(x) = 0$  oraz  $\lim_{x \rightarrow +\infty} F(x) = 1$ ;
- 3 jest funkcją niemalejącą;

- 1  $0 \leq F(x) \leq 1$  dla każdego  $x \in \mathbf{R}$ ;
- 2  $\lim_{x \rightarrow -\infty} F(x) = 0$  oraz  $\lim_{x \rightarrow +\infty} F(x) = 1$ ;
- 3 jest funkcją niemalejącą;
- 4  $P(a < X \leq b) = F(b) - F(a)$



## Zmienna losowa typu dyskretnego

Mówimy, że zmienna losowa  $X$  jest typu skokowego (dyskretnego) jeżeli istnieje skończony albo przeliczalny zbiór  $W_x = \{x_1, x_2, \dots, \dots\}$  jej wartości taki, że

$$P(X = x_i) = p_i, \quad i \in \mathbf{N},$$

$$\sum_{i=1} p_i = 1,$$

gdzie górna granica sumowania wynosi  $n$  albo  $\infty$

## Funkcja prawdopodobieństwa

Funkcję  $p$  przyjmującą wartości  $p(x_i) = P(X = x_i)$  oznaczaną często przez  $p_i$  nazywamy funkcją prawdopodobieństwa zmiennej losowej  $X$ .


Gdy dane jest funkcja prawdopodobieństwa zmiennej losowej  $X$ , to prawdopodobieństwo przyjęcia przez tą zmienną wartości ze zbioru  $A$  jest określone równością:

$$P(X \in A) = \sum_{x_i \in A} p_i$$

W szczególności dla dowolnego przedziału  $(a, b)$  zachodzi

$$P(-\infty < X < b) = \sum_{-\infty < x_i < b} p_i$$

## Wykres dystrybuanty



- 1 wartość średnia (parametr położenia)

$$\mu = \sum_{i=1}^k x_i p_i;$$

- 2 wariancja (parametr skali)

$$\sigma^2 = \sum_{i=1}^k (x_i - \mu)^2 p_i.$$

- 3 skośność

$$\gamma = \sum_{i=1}^k (x_i - \mu)^3 p_i / \sigma^3$$

- 4 kurtoza

$$\eta = \sum_{i=1}^k (x_i - \mu)^4 p_i / \sigma^4$$

- 1 Rozkład Bernoulliego (rzut monetą);

# Ważne rozkłady typu dyskretnego

- 1 Rozkład Bernoulliego (rzut monetą);
- 2 Rozkład dwumianowy (rzut wieloma monetami);

# Ważne rozkłady typu dyskretnego

- 1 Rozkład Bernoulliego (rzut monetą);
- 2 Rozkład dwumianowy (rzut wieloma monetami);
- 3 Rozkład Poissona (liczba sygnałów);



# Ważne rozkłady typu dyskretnego

- 1 Rozkład Bernoulliego (rzut monetą);
- 2 Rozkład dwumianowy (rzut wieloma monetami);
- 3 Rozkład Poissona (liczba sygnałów);
- 4 Rozkład hipergeometryczny (ryby w stawie).

## Rozkład Bernoulliego

Zmienna losowa  $X$  ma rozkład Bernoulliego, jeżeli jej funkcja prawdopodobieństwa jest postaci

$x_i$	0	1
$p_i$	$q$	$p$

$$\mu = p$$

$$\sigma^2 = pq$$

Zmienna losowa  $X$  ma rozkład dwumianowy z parametrami  $(n, p)$ ,  $n \in \mathbf{N}$ ,  $0 < p < 1$ , jeżeli jej funkcja prawdopodobieństwa jest postaci

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

$$\mu = np$$

$$\sigma^2 = npq$$

Rzucamy 6 razy symetryczną monetą oblicz prawdopodobieństwo wyrzucenia conajmniej jednego „orła”

# Rozkład hipergeometryczny

Zmienna losowa  $X$  ma rozkład hipergeometryczny z parametrami  $(N, M, n)$ , gdzie  $N, M, n$  to liczby naturalne oraz  $M, n \leq N$ , jeżeli jej funkcja prawdopodobieństwa jest postaci

$$P(k; N, M, n) = \frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}}$$

$$\mu = np$$

$$\sigma^2 = npq \frac{N-n}{N-1}$$

W stawie jest  $N = 100$  ryb odławiamy  $M = 40$  z nich znakujemy je i z powrotem wrzucamy do stawu. Następnie łowimy  $n = 20$  sztuk. Jakie jest prawdopodobieństwo, że wśród nich będzie dokładnie  $k$  oznakowanych?

Zmienna losowa  $X$  ma rozkład Poissona z parametrem  $\lambda$ , gdzie  $\lambda > 0$ , jeżeli jej funkcja prawdopodobieństwa jest postaci

$$P(k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

$$\mu = \lambda$$

$$\sigma^2 = \lambda$$

Rozkład Poissona jest związany z sytuacją zliczania zdarzeń losowych określonego typu w pewnym odcinku czasu. Może to być na przykład zliczenie ilości kolejnych klientów pojawiających się w kasie w banku, ilość samochodów przejeżdżających punkt kontrolny.



## Twierdzenie Poissona

Jeżeli  $n \rightarrow \infty$ ,  $p_n \rightarrow 0$ ,  $np_n \rightarrow \lambda$ , to

$$\binom{n}{k} p_n^k (1 - p_n)^{n-k} \rightarrow \frac{\lambda^k}{k!} e^{-\lambda}$$

## Zadanie

Udowodnij twierdzenie Poissona

Prawdopodobieństwo trafienia „szóstki ”w Toto-Lotku jest równe  $1/\binom{49}{6} = 1/139883816$ . Ilu szóstek należy się spodziewać w każdym tygodniu, jeżeli grający wypełniają kupony niezależnie od siebie i całkowicie losowo, kuponów jest  $n = 10^7$ ?

Dana jest funkcja prawdopodobieństwa zmiennej losowej  $X$

$x_i$	2	3	4	5
$p_i$	0,2	0,4	0,3	0,1


wyznacz:

- 1 funkcję dystrybuanty i jej wykres;
- 2 prawdopodobieństwo  $P(X < 3,5)$  korzystając z wykresu dystrybuanty;
- 3 prawdopodobieństwo  $P(3 < X \leq 4,5)$ .

# Zmienne losowe typu ciągłego

Zmienne losowe typu ciągłego mogą przyjmować nieskończenie wiele wartości (np. temperatura powietrza, waga ciała, prędkość samochodu w zadanej chwili czasu)


## wykres dystrybuanty



Funkcja gęstości zmiennej losowej  $X$  typu ciągłego, to nieujemna funkcja  $f$ , taka, że dla każdego przedziału  $(x_1, x_2)$

$$P(\{\omega : x_1 \leq X \leq x_2\}) = \int_{x_1}^{x_2} f(x) dx.$$

# Gęstość zmiennej losowej typu ciągłego





# Własności funkcji gęstości

- 1  $f(x) \geq 0$  dla każdego  $x$ ;
- 2  $\int_{-\infty}^{+\infty} f(x) dx = 1$ .

# Wybrane rozkłady typu ciągłego

- 1 Rozkład normalny;
- 2 Rozkład Studenta;
- 3 Rozkład  $\chi^2$ ;
- 4 Rozkład  $F$ .


## Rozkład normalny

Niech  $X$  będzie ciągłą zmienną losową o gęstości prawdopodobieństwa

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad x \in \mathbf{R},$$

gdzie  $\mu \in \mathbf{R}$  i  $\sigma > 0$  są danymi parametrami. Mówimy wtedy, że  $X$  ma *rozkład normalny* co oznaczamy  $N(\mu, \sigma)$ .

# Funkcja gęstości rozkładu normalnego $N(\mu, \sigma)$ .



## Rozkład $t$ -Studenta

Zmienna losowa  $X$  ma rozkład  $t$ -Studenta o  $n$  stopniach swobody, jeżeli jej gęstość  $f$  wyraża się wzorem


$$f(x) = \frac{\Gamma([n+1]/2)}{\sqrt{n\pi}\Gamma(n/2)} \left(1 + \frac{x^2}{n}\right)^{-(n+1)/2}, x \in \mathbf{R}, n \in \mathbf{N}.$$

gdzie  $\Gamma(n) = \int_0^{+\infty} x^{n-1} e^{-x} dx, n > 0$


## Uwaga

Gdy  $n \rightarrow \infty$ , gęstość  $f$  „dąży” do gęstości rozkładu normalnego  $N(0, 1)$ , co wykorzystuje się w praktyce dla  $n \geq 30$  do przybliżania rozkładu Studenta rozkładem normalnym.

# Wykresy gęstości rozkładu Studenta i rozkładu normalnego



# Wykresy gęstości rozkładu Studenta i rozkładu normalnego



## Rozkład $\chi^2$

Zmienna losowa  $X$  ma rozkład  $\chi^2$  o  $n$  stopniach swobody, jeżeli jej gęstość  $f$  wyraża się wzorem

$$f(x) = \begin{cases} \frac{1}{2^{n/2}\Gamma(n/2)} x^{n/2-1} e^{-x/2} & \text{gdy } x > 0 \\ 0 & \text{gdy } x \leq 0 \end{cases}$$



# Wykresy gęstości rozkładu $\chi^2$ o $n = 2, 3, 4$ stopniach swobody

