

Statystyka w analizie i planowaniu eksperymentu

Paweł Błażej

6 marca 2013

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 nie liczbowych),
 - 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 nie liczbowych),
 - 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,

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

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 ω_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 ∞

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 λ , 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 χ^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 χ^2

Zmienna losowa X ma rozkład χ^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 χ^2 o $n = 2, 3, 4$ stopniach swobody

