

## Wybrane rozkłady dyskretne cech statystycznych

### rozkład dwumianowy oraz rozkład Poissona


(literatura: Ostasiewicz, Rusnak, Siedlecka. Statystyka elementy teorii i zadania. Wydawnictwo AE we Wrocławiu, Wrocław 1999 (2006 – wydanie 6) – rozdział 5

**Przykład 1.** Funkcja rozkładu prawdopodobieństwa  $(x_i, p_i)$  dla dyskretnej zmiennej losowej  $X$  podany jest w tablicy:

(i)	1	2	3	4
Wartość zmiennej ( $x_i$ )	-1	0	1	2
Prawdopodobieństwo ( $p_i$ )	0,2	0,2	0,4	0,2

- Narysować wykres (histogram) rozkładu prawdopodobieństwa dla tej zmiennej losowej.
- Wyznaczyć dystrybuantę zmiennej losowej  $X$  oraz narysować jej wykres.
- Obliczyć wartość oczekiwaną oraz wariancję dla zmiennej losowej  $X$ .
- Znaleźć modalną oraz medianę zmiennej losowej  $X$ .

Ad a) Histogram rozkładu przedstawia rysunek (rys. 1)



**Rys. 1.** Funkcja rozkładu prawdopodobieństwa skokowej (dyskretnej) zmiennej losowej  $X$ .

gdzie:  $\sum_{i=1}^{n=4} p_i = 1$

Ad b)

Dystrybuantę zmiennej losowej  $X$  wyznaczymy ze wzoru  $F(x) = \sum_{(x_i < x)} p_i$ .

Zatem


- Dla  $x \leq -1$  ( $x \in (-\infty, 1]$ ) wartość dystrybuanty wynosi  $F(x) = 0$
- Dla  $x \in (-1, 0]$  wartość dystrybuanty wynosi  $F(x) = p_1 = 0,2$ .
- Dla  $x \in (0, 1]$  wartość dystrybuanty wynosi  $F(x) = p_1 + p_2 = 0,2 + 0,2 = 0,4$ .
- Dla  $x \in (1, 2]$  wartość dystrybuanty wynosi  $F(x) = p_1 + p_2 + p_3 = 0,2 + 0,2 + 0,4 = 0,8$ .

- Dla  $x > 2$  ( $x \in (2, +\infty)$ ) wartość dystrybuanty wynosi  $F(x) = p_1 + p_1 + p_1 + p_4 = 1$ .

Ostateczna funkcja dystrybuanty rozkładu badanej statystyki ma postać:

$$F(x) = \begin{cases} 0 & \text{dla } x \leq -1 \\ 0,2 & \text{dla } -1 < x \leq 0 \\ 0,4 & \text{dla } 0 < x \leq 1 \\ 0,8 & \text{dla } 1 < x \leq 2 \\ 1 & \text{dla } x > 2 \end{cases}$$

Wykres dystrybuanty przedstawia rysunek (rys. 2).



**Rys. 2.** Dystrybuanta rozkładu prawdopodobieństwa dla skokowej (dyskretnej) zmiennej losowej X.

Ad c)

Wartość średnią (oczekiwaną) dla rozważanej statystyki (zmiennej losowej) dyskretnej X wyznaczamy ze wzoru:

$$E[x] = \bar{x} = \sum_{i=1}^{n=4} x_i * p_i$$

$$\text{Zatem } E[x] = -1 * 0,2 + 0 * 0,2 + 1 * 0,4 + 2 * 0,2 = 0,6$$

Wariancję dla rozważanej statystyki (zmiennej losowej) dyskretnej X wyznaczamy ze wzoru:

$$V[x] = \sum_{i=1}^{n=4} (x_i - E[x])^2 * p_i$$

$$\text{Zatem } V[x] = (-1 - 0,6)^2 * 0,2 + (0 - 0,6)^2 * 0,2 + (1 - 0,6)^2 * 0,4 + (2 - 0,6)^2 * 0,2 = 1,04$$

$$\text{Odchylenie standardowe wyniesie wtedy: } \sigma[x] = \sqrt{V[x]} = \sqrt{1,04} = 1,02.$$

Wariancję możemy policzyć także z innego równoważnego wzoru:

$$V[x] = \sum_{i=1}^{n=4} x_i^2 * p_i - E[x]^2 = 1,4 - 0,6^2 = 1,04 - \text{co daje ten sam wynik.}$$

Ad d)

Modalna dla rozkładu statystyki X istnieje i wynosi  $M_o = x_3 = 1$ , dla której prawdopodobieństwo realizacji jest największe (wynoszące 0,4).

Medianą rozkładu nazywamy wartość zmiennej X spełniającą łącznie układ nierówności (warunków):

$$P(X \leq x) \geq \frac{1}{2} \text{ oraz } P(X \geq x) \geq \frac{1}{2}.$$

$$\text{Zatem } M_e = x_3 = 1, \text{ gdyż: } P(X \leq 1) = \frac{8}{10} > \frac{1}{2} \text{ oraz } P(X \geq 1) = \frac{6}{10} > \frac{1}{2}.$$

**Przykład 2.** Wiadomo, że 25% wszystkich szkód zgłaszanych do PZU przez firmy transportowe stanowią kolizje i zdarzenia drogowe. Jakie jest prawdopodobieństwo, że wśród zgłoszonych 10 szkód liczba kolizji będzie:

- a) równa 5
- b) większa niż 2
- c) nie przekroczy 4
- d) nie mniejsza niż 4 i nie większa niż 6 ?
- e) Obliczyć wartość oczekiwaną i wariancję dla zmiennej losowej  $X$

Zmienna losowa (statystyka)  $X$  ma rozkład dwumianowy, gdzie  $X = k$  – oznacza liczbę (tzw. sukcesów) szkód będących kolizjami drogowymi w wielokrotnym powtórzeniu pewnego zdarzenia losowego (identyfikacji rodzaju szkody zgłaszanej do PZU).

W naszym przypadku liczba powtórzeń doświadczenia losowego ( $n=10$ ) – liczba zgłoszonych szkód. Prawdopodobieństwo sukcesu  $p = 0,25$  (szkoda była kolizją), zaś prawdopodobieństwo zdarzenia przeciwnego (porażki)  $q = 1 - p = 0,75$  – inny rodzaj szkody zgłoszonej do PZU.

Zatem rozkład badanej (modelowanej) zmiennej losowej o rozkładzie dwumianowym jest następujący:

$X = \{x_i = k\} = \{0, 1, 2, \dots, 10\}$ , z prawdopodobieństwem  $p_i = P(X = x_i = k) = B(n, p, k) = \binom{n}{k} * p^k * q^{n-k}$ ,  
 $p + q = 1$ .

Wyznamy prawdopodobieństwa rozkładu:

$$p_1 = P(X = x_1 = 0) = B(10; 0,25; 0) = \binom{10}{0} * 0,25^0 * 0,75^{10-0} = 1 * 1 * 0,75^{10} = 0,056.$$

$$p_2 = P(X = x_2 = 1) = B(10; 0,25; 1) = \binom{10}{1} * 0,25^1 * 0,75^{10-1} = 0,188.$$

$$p_3 = P(X = x_3 = 2) = B(10; 0,25; 2) = \binom{10}{2} * 0,25^2 * 0,75^{10-2} = 0,282.$$

$$p_4 = P(X = x_4 = 3) = B(10; 0,25; 3) = \binom{10}{3} * 0,25^3 * 0,75^{10-3} = 0,250.$$

$$p_5 = P(X = x_5 = 4) = B(10; 0,25; 4) = \binom{10}{4} * 0,25^4 * 0,75^{10-4} = 0,146.$$

$$p_6 = P(X = x_6 = 5) = B(10; 0,25; 5) = \binom{10}{5} * 0,25^5 * 0,75^{10-5} = 0,058.$$

$$p_7 = P(X = x_7 = 6) = B(10; 0,25; 6) = \binom{10}{6} * 0,25^6 * 0,75^{10-6} = 0,016.$$

$$p_8 = P(X = x_8 = 7) = B(10; 0,25; 7) = \binom{10}{7} * 0,25^7 * 0,75^{10-7} = 0,003.$$

$$p_9 = P(X = x_9 = 8) = B(10; 0,25; 8) = \binom{10}{8} * 0,25^8 * 0,75^{10-8} = 0,0004.$$


$$p_{10} = P(X = x_{10} = 9) = B(10; 0,25; 9) = \binom{10}{9} * 0,25^9 * 0,75^{10-9} = 0,00003.$$

$$p_{11} = P(X = x_{11} = 10) = B(10; 0,25; 10) = \binom{10}{10} * 0,25^{10} * 0,75^{10-10} = 0,000001.$$


Funkcja dystrybuanty rozkładu badanej statystyki ma postać:

$$F(x) = \begin{cases} 0 & \text{dla } x \leq 0 \\ 0,056 & \text{dla } 0 < x \leq 1 \\ 0,244 & \text{dla } 1 < x \leq 2 \\ 0,526 & \text{dla } 2 < x \leq 3 \\ 0,776 & \text{dla } 3 < x \leq 4 \\ 0,922 & \text{dla } 4 < x \leq 5 \\ 0,980 & \text{dla } 5 < x \leq 6 \\ 0,996 & \text{dla } 6 < x \leq 7 \\ 0,9995 & \text{dla } 7 < x \leq 8 \\ 0,99997 & \text{dla } 8 < x \leq 9 \\ 0,999999 & \text{dla } 9 < x \leq 10 \\ 1 & \text{dla } x > 10 \end{cases}$$

Rysunek (rys. 3) przedstawia funkcję rozkładu prawdopodobieństwa, zaś rysunek (rys. 4) dystrybuantę rozkładu badanej statystyki X.



**Rys. 3.** Funkcja rozkładu prawdopodobieństwa analizowanej zmiennej losowej X o rozkładzie dwumianowym.



**Rys. 4.** Dystrybuanta rozkładu prawdopodobieństwa analizowanej zmiennej losowej X o rozkładzie dwumianowym.

Szukane prawdopodobieństwa wynoszą:

Ad a)

$$p_6 = P(X = x_6 = 5) = B(10; 0,25; 5) = 0,058 \text{ (5,8\%)}$$

Ad b)

Skrzystamy ze zdarzenia przeciwnego

$$P(X > 2) = 1 - P(X \leq 2) = 1 - P(X = 0) - P(X = 1) - P(X = 2) = 1 - 0,056 - 0,188 - 0,282 = 0,474 \text{ (47\%)}$$

Ad c)

$$P(X \leq 4) = P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3) + P(X = 4) = 0,922 \text{ (92\%)}$$

lub inaczej - skorzystamy z wartości dystrybuantry:

$$P(X \leq 4) = F(4) + P(X = 4) = 0,776 + 0,146 = F(5) = 0,922.$$

Ad d)

$$P(4 \leq X \leq 6) = P(X = 4) + P(X = 5) + P(X = 6) = 0,146 + 0,058 + 0,016 = 0,22 \text{ (22\%)}$$

lub inaczej – oszacujemy szukane prawdopodobieństwo korzystając z wartości dystrybuantry:

$$P(4 \leq X \leq 6) = F(6) - F(4) = 0,980 - 0,776 = 0,2 \text{ (20\%)}$$

Ad e)

Wartość oczekiwana wynosi:

$$E[x] = \sum_{i=1}^{n=11} x_i * p_i = 2,5$$

Wariancja wynosi:

$$V[x] = \sum_{i=1}^{n=11} (x_i - E[x])^2 * p_i = \sum_{i=1}^{n=11} x_i^2 * p_i - E[x]^2 = 8,125 - 2,5^2 = 1,875.$$

$$\text{Odchylenie standardowe wynosi zatem: } \sigma[x] = \sqrt{V[x]} = \sqrt{1,875} = 1,37.$$

**Przykład 3.** Oszacowano, że w 1999 roku 3% samochodów w Polsce miało zainstalowane katalizatory. W pewnym dniu stacja benzynowa obsługiwała 200 samochodów. Jakie jest prawdopodobieństwo, że:

- a) 2 samochody miały katalizatory
- b) więcej niż 2 samochody miały katalizatory
- c) żaden samochód nie miał katalizatora
- d) nie więcej niż 3 samochody miały katalizatory ?

Statystyka  $X=k$  – liczba obsługiwanych samochodów na stacji benzynowej, które miały katalizator ma oczywiście rozkład dwumianowy Bernoulliego  $B(n,p,k)$ , gdzie:  $n=200$ ,  $p=0,03$  – prawdopodobieństwo, że obsługiwany samochód ma katalizator,  $q = 1 - p = 1 - 0,03 = 0,97$  – prawdopodobieństwo, że nie ma katalizatora.

Jednak przy tak dużym  $n=200$  nie dałoby się wyznaczyć takich prawdopodobieństw bezpośrednio ze wzorów dla rozkładu dwumianowego. Wiemy jednak, że dla dużych  $n$  ( $n > 20, n \rightarrow \infty$ ), gdy mamy zachowany stały iloczyn  $n * p = m$  oraz  $p < 0,2$  (nieduże), to rozkład dwumianowy możemy przybliżać innym rozkładem dyskretnym, a mianowicie rozkładem Poissona (z parametrem  $m$  – który jest dla niego wartością oczekiwaną - średnią oraz wariancją).

Zmienna losowa dyskretna posiada rozkład Poissona z parametrem „ $m$ ”, gdy przyjmuje wartości:

$$X = k = 0, 1, 2, 3, \dots$$

z prawdopodobieństwem:

$$P(X = k) = \frac{m^k}{k!} * e^{-m}$$

Dla naszego przykładu możemy przybliżać analizowany rozkład dwumianowy rozkładem Poissona z parametrem  $m = n * p = 200 * 0,03 = 6$ .

Dla granicznego rozkładu Poissona policzmy prawdopodobieństwa rozkładu dla kilku początkowych wartości „ $k$ ”:

$$P(X = k = 0) = \frac{6^0}{0!} * 2,7173^{-6} = 0,0025$$

$$P(X = k = 1) = \frac{6^1}{1!} * 2,7173^{-6} = 0,015$$

$$P(X = k = 2) = \frac{6^2}{2!} * 2,7173^{-6} = 0,045$$

$$P(X = k = 3) = \frac{6^3}{3!} * 2,7173^{-6} = 0,089$$

$$P(X = k = 4) = \frac{6^4}{4!} * 2,7173^{-6} = 0,134$$

$$P(X = k = 5) = \frac{6^5}{5!} * 2,7173^{-6} = 0,161$$

$$P(X = k = 6) = \frac{6^6}{6!} * 2,7173^{-6} = 0,161$$

$$P(X = k = 7) = \frac{6^7}{7!} * 2,7173^{-6} = 0,138$$

$$P(X = k = 8) = \frac{6^8}{8!} * 2,7173^{-6} = 0,103$$

$$P(X = k = 9) = \frac{6^9}{9!} * 2,7173^{-6} = 0,069$$


$$P(X = k = 10) = \frac{6^{10}}{10!} * 2,7173^{-6} = 0,041$$

.....

$$P(X = k = 20) = \frac{6^{20}}{20!} * 2,7173^{-6} = 0,000004$$

.....

Rysunek (rys. 5) przedstawia histogram rozkładu prawdopodobieństwa granicznego rozkładu Poissona z parametrem  $m = 6$ .



**Rys. 5.** Funkcja rozkładu prawdopodobieństwa analizowanej zmiennej losowej X o rozkładzie Poissona ( $m = 6$ )

Szukane prawdopodobieństwa oszacowane na podstawie granicznego rozkładu Poissona wynoszą:

Ad a)

$$P(X = 2) = 0,045 \text{ (4,5\%).}$$

Wartości rozkładu Poissona (dystrybuanty tego rozkładu) są tablicowane w tablicach statystycznych (np. Tablica V – na końcu książki: Ostasiewicz S. (red.), Statystyka elementy teorii i zadania, str. 384).

Podane tam są skumulowane wartości prawdopodobieństwa:  $P(X \leq k) = \sum_{r=0}^k \frac{m^r}{r!} * e^{-m}$ .

$$\text{Korzystając z tablic mamy: } P(X = 2) = P(X \leq 2) - P(X \leq 1) = 0,062 - 0,017 = 0,045 \text{ (4,5\%)}$$

Ad b)

Skorzystamy ze zdarzenia przeciwnego oraz tablic skumulowanego rozkładu Poissona:

$$P(X > k = 2) = 1 - P(X \leq k = 2) = 1 - [P(X = 0) + P(X = 1) + P(X = 2)] = 1 - 0,062 = 0,94 \text{ (94\%).}$$

Ad c)

$$\text{Z tablic lub ze wzoru: } P(X = k = 0) = 0,002$$

Ad d)

$$\text{Z tablic lub ze wzorów: } (X \leq k = 3) = P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3) = 0,151.$$

Policzmy jeszcze podstawowe parametry badanego rozkładu. Wartość oczekiwana dla analizowanego rozkładu Poissona wynosi  $E[x] = m = 6$ , zaś wariancja również wynosi  $V[x] = m = 6$ , zatem odchylenie standardowe jest równe  $\sigma[x] = \sqrt{V[x]} = \sqrt{6} = 2,45$ . Zatem średnia liczba samochodów z katalizatorem obsługiwanych na stacji benzynowej to 6 z odchyleniem  $\pm 2,45$  samochodu.

**Zadania do samodzielnego rozwiązania (Ostasiewicz S. [red.], Statystyka elementy teorii i zadania, str. 185-193):** Zad. 5.5, 5.6, 5.10, 5.45