

2. ZMIENNE LOSOWE

Definicja. Niech $(\Omega, \mathcal{F}, \mathcal{P})$ będzie przestrzenią probabilistyczną. *Zmienną losową* nazywamy dowolną funkcję $X : \Omega \rightarrow \mathbb{R}$ spełniającą warunek

$$\{\omega : X(\omega) \leq a\} \in \mathcal{F} \text{ dla każdego } a \in \mathbb{R}. \quad (1)$$

O funkcji X spełniającej (1) mówimy, że jest mierzalna. Zatem, innymi słowy, zmienna losowa to dowolna mierzalna funkcja $X : \Omega \rightarrow \mathbb{R}$.

Przykład 2.1. Gra polega na rzucie symetryczną kostką do gry. Jeśli wypadnie 6 oczek, to wygrywamy 10 zł, jeśli 4 lub 5 oczek, to wygrywamy 2 zł, w pozostałych przypadkach tracimy 4 zł. Niech X oznacza wysokość naszej wygranej.

Mamy $\Omega = \{1, 2, 3, 4, 5, 6\}$ i

$$X(1) = X(2) = X(3) = -4, \quad X(4) = X(5) = 2, \quad X(6) = 10.$$

Skoro $\mathcal{F} = 2^\Omega$, to warunek (1) jest na pewno spełniony i X jest zmienną losową. Prawdopodobieństwa otrzymania kolejnych, możliwych wartości dla zmiennej losowej X opiszemy tabelką:

x_k	-4	2	10
p_k	$\frac{1}{2}$	$\frac{1}{3}$	$\frac{1}{6}$

Tabela ta podaje rozkład X . Zauważmy, że musimy mieć $p_k > 0$ dla wszystkich k i $\sum_k p_k = 1$.

Przykład 2.2. Wykładowca zawsze spóźnia się na wykład i rozpoczyna go w losowym momencie pomiędzy 10:15 a 10:30. Niech X oznacza opóźnienie rozpoczęcia wykładu liczone w minutach. Wtedy X przyjmuje nieprzeliczalną liczbę wartości (wszystkie liczby z przedziału $(0, 15)$) i jest zmienną losową. Rzeczywiście, możemy przyjąć $\Omega = (15, 30)$, $\mathcal{F} = \mathcal{B}(15, 30)$,

$$\{\omega : X(\omega) \leq a\} = \begin{cases} \emptyset & \text{dla } a \leq 0, \\ (15, 15 + a] & \text{dla } a \in (0, 15), \\ \Omega & \text{dla } a \geq 15 \end{cases}$$

i widzimy, że warunek $\{\omega : X(\omega) \leq a\} \in \mathcal{F}$ jest spełniony dla każdego $a \in \mathbb{R}$, bo, bezpośrednio z definicji σ -ciała

$$\Omega \in \mathcal{F} \Rightarrow \emptyset = \Omega \setminus \Omega \in \mathcal{F},$$

a z definicji borelowskiego σ -ciała

$$\begin{aligned} (15 + a, 30) &\in \mathcal{B}(15, 30) \Rightarrow \\ (15, 15 + a] &= (15, 30) \setminus (15 + a, 30) \in \mathcal{B}(15, 30). \end{aligned}$$

Wyróżniamy trzy rodzaje zmiennych losowych.

1. **Zmienne losowe dyskretne** (inaczej zwane **skokowymi**).

Przyjmują one skończoną bądź przeliczalną liczbę wartości. Rozkład tych o skończonej liczbie wartości wygodnie jest opisywać za pomocą tabelki, tak jak to zrobiliśmy w przykładzie 2.1.

2. **Zmienne losowe absolutnie ciągłe**.

Przyjmują one nieprzeliczalną liczbę wartości i ich rozkład daje się opisać przez *funkcję gęstości* $f(x)$, czyli nieujemną funkcję, taką że

$$P(X \in A) = \int_A f(x)dx \quad \text{dla dowolnego } A \in \mathcal{B}(\mathbb{R}).$$

Każda funkcja $f : \mathbb{R} \rightarrow \mathbb{R}$ spełniająca warunki:

(a) $f(x) \geq 0$ dla wszystkich $x \in \mathbb{R}$,

(b) $\int_{\mathbb{R}} f(x)dx = 1$

jest gęstością pewnej absolutnie ciągłej zmiennej losowej.

Zauważmy, że dla zmiennych losowych absolutnie ciągłych mamy

$$P(X = a) = \int_{\{a\}} f(x)dx = 0,$$

pomimo, że zdarzenie $\{X = a\}$ nie musi być niemożliwe.

W przykładzie 2.2 mamy zmienną losową absolutnie ciągłą o funkcji gęstości

$$f(x) = \begin{cases} \frac{1}{15} & \text{dla } x \in (0, 15) \\ 0 & \text{dla } x \notin (0, 15). \end{cases}$$

3. **Zmienne losowe singularne**.

Przykłady rozkładów (i zmiennych losowych) dyskretnych

- 1). Rozkład dwupunktowy: Wykonujemy doświadczenie, które może zakończyć się jedynie sukcesem (z prawdopodobieństwem $p \in (0, 1)$) albo porażką. Zmienna losowa X przyjmuje wartość 1, gdy znajdzie sukces, oraz wartość 0, gdy znajdzie porażkę. Wtedy rozkład X opisuje poniższa tabelka:

x_k	0	1
p_k	$1 - p$	p

co równoważnie można zapisać następująco:

$$P(X = 0) = 1 - p \quad \text{i} \quad P(X = 1) = p.$$

2). Rozkład dwumianowy: $X \sim \text{binom}(n, p)$.

Powtarzamy n -krotnie doświadczenie, które może zakończyć się jedynie sukcesem (z prawdopodobieństwem $p \in (0, 1)$) albo porażką. Zakładamy, że kolejne powtórzenia doświadczenia przebiegają niezależnie od pozostałych. Wtedy X to liczba uzyskanych sukcesów.

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad \text{dla } k = 0, 1, \dots, n.$$

3). Rozkład Poissona: $X \sim \text{Pois}(\lambda)$, gdzie $\lambda > 0$, jeśli

$$P(X = k) = e^{-\lambda} \frac{\lambda^k}{k!} \quad \text{dla } k = 0, 1, \dots$$

4). Rozkład geometryczny: $X \sim \text{Ge}(p)$, gdzie $p \in (0, 1)$.

Powtarzamy doświadczenie, które może zakończyć się sukcesem (z prawdopodobieństwem p) albo porażką. Zakładamy, że kolejne powtórzenia doświadczenia przebiegają niezależnie od pozostałych. Wtedy X to liczba porażek poprzedzających pierwszy sukces.

$$P(X = k) = p(1-p)^k \quad \text{dla } k = 0, 1, \dots$$

5). Rozkład ujemny dwumianowy: $X \sim \text{nb}(p, r)$, gdzie $p \in (0, 1)$, $r \in \{1, 2, \dots\}$.

Powtarzamy doświadczenie, które może zakończyć się sukcesem (z prawdopodobieństwem p) albo porażką. Zakładamy, że kolejne powtórzenia doświadczenia przebiegają niezależnie od pozostałych. Wtedy X to liczba porażek poprzedzających r -ty sukces.

$$P(X = k) = \binom{r+k-1}{k} p^r (1-p)^k \quad \text{dla } k = 0, 1, \dots$$

Przykłady rozkładów (i zmiennych losowych) absolutnie ciągłych**1).** Rozkład jednostajny na przedziale (a, b) , oznaczany $U(a, b)$, czyli rozkład o gęstości

$$f(x) = \begin{cases} \frac{1}{b-a} & \text{dla } x \in (a, b) \\ 0 & \text{dla } x \notin (a, b). \end{cases}$$

2). Rozkład wykładniczy z parametrem $\lambda > 0$, oznaczany $\text{Exp}(\lambda)$, czyli rozkład o gęstości

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & \text{dla } x > 0 \\ 0 & \text{dla } x \leq 0. \end{cases}$$

- 3). Rozkład normalny o parametrach μ i σ^2 , oznaczany $\mathcal{N}(\mu, \sigma^2)$, czyli rozkład o gęstości

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right), \quad x \in \mathbb{R}, \text{ gdzie } \mu \in \mathbb{R}, \sigma > 0.$$

Wykres tej gęstości to tzw. *krzywa gaussa*.

Własności rozkładu normalnego:

- Rozkład normalny $\mathcal{N}(\mu, \sigma^2)$ jest rozkładem symetrycznym względem μ .
- Jeśli $X \sim \mathcal{N}(\mu, \sigma^2)$, to $U = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1)$. Rozkład $\mathcal{N}(0, 1)$ nazywamy *standardowym rozkładem normalnym*.
- Ogólniej jeśli $X \sim \mathcal{N}(\mu, \sigma^2)$ i a, b są liczbami rzeczywistymi, to $aX + b \sim \mathcal{N}(a\mu + b, a^2\sigma^2)$.

- 4). Rozkład gamma z parametrem kształtu a i drugim parametrem β , oznaczany $Gamma(a, \beta)$, czyli rozkład o gęstości

$$f(x) = \begin{cases} \frac{\beta^a}{\Gamma(a)} x^{a-1} \exp(-\beta x) & \text{dla } x > 0 \\ 0 & \text{dla } x \leq 0 \end{cases}, \quad a > 0, \beta > 0,$$

gdzie $\Gamma(a) = \int_0^\infty x^{a-1} e^{-x} dx$.

- 5). Rozkład chi-kwadrat o n stopniach swobody, który będziemy oznaczać symbolem $\chi_{[n]}^2$, czyli rozkład o gęstości

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

Rozkład $\chi_{[n]}^2$ to to samo co rozkład $Gamma(a = \frac{n}{2}, \beta = \frac{1}{2})$.

- 6). Rozkład t-Studenta o n stopniach swobody, który będziemy oznaczać symbolem $t_{[n]}$, czyli rozkład o gęstości

$$f(x) = \frac{\Gamma((n+1)/2)}{\Gamma(n/2)} \frac{1}{\sqrt{n\pi}} \frac{1}{(1+x^2/n)^{(n+1)/2}} \quad \text{dla } x \in \mathbb{R}.$$

- 7). Rozkład F-Snedecora o stopniach swobody m i n , który będziemy oznaczać symbolem $F_{[m,n]}$, czyli rozkład o gęstości

$$f(x) = \begin{cases} \frac{\Gamma((m+n)/2)}{\Gamma(m/2)\Gamma(n/2)} \left(\frac{m}{n}\right)^{m/2} \frac{x^{(m-2)/2}}{\left(1+\frac{m}{n}x\right)^{(m+n)/2}} & \text{dla } x > 0 \\ 0 & \text{dla } x \leq 0 \end{cases}.$$

Wielkości służące do opisu zmiennych losowych:

1). Dystrybuanta : $F(x) = P(X \leq x)$.

Jeśli X jest zmienną losową dyskretną, to jej dystrybuanta jest funkcją schodkową, prawostronnie ciągłą.

Jeśli natomiast X jest zmienną losową absolutnie ciągłą, to jej dystrybuantę wyznaczamy korzystając ze wzoru

$$F(t) = P(X \leq t) = \int_{-\infty}^t f(x)dx$$

i otrzymujemy funkcję ciągłą.

Twierdzenie 2.1. Dystrybuanta ma następujące własności:

1. jest funkcją niemalejącą,
2. jest co najmniej prawostronnie ciągła,
3. $\lim_{x \rightarrow -\infty} F(x) = 0$ i $\lim_{x \rightarrow \infty} F(x) = 1$.

Prawdziwe jest także twierdzenie odwrotne do powyższego.

Twierdzenie 2.2. Każda funkcja $F : \mathbb{R} \rightarrow \mathbb{R}$, mająca własności 1.-3. z poprzedniego twierdzenia, jest dystrybuantą pewnej zmiennej losowej.

2). Ogon dystrybuanty (funkcja przeżycia) :

$$\bar{F}(x) = 1 - F(x) = P(X > x).$$

3). Kwantyl rzędu $\alpha \in (0, 1)$:

q_α to najmniejsza liczba spełniająca $F(q_\alpha) \geq \alpha$.

W szczególności kwantyl rzędu $\alpha = \frac{1}{2}$ to **mediana** med , kwantyl rzędu $\alpha = \frac{1}{4}$ to **dolny (pierwszy) kwantyl** Q_1 , zaś kwantyl rzędu $\alpha = \frac{3}{4}$ to **górny (trzeci) kwantyl** Q_3 .

4). Wartość oczekiwana (wartość średnia, wartość przeciętna) :

$$EX = \begin{cases} \sum_k x_k p_k & \text{dla zmiennych losowych dyskretnych,} \\ \int_{\mathbb{R}} x f(x) dx & \text{dla zmiennych losowych absolutnie ciągłych,} \end{cases}$$

przy czym mówimy, że EX nie istnieje, gdy $\sum_{k: x_k \leq 0} x_k p_k = -\infty$

i $\sum_{k: x_k \geq 0} x_k p_k = \infty$ (w przypadku zmiennych losowych dyskretnych) lub $\int_{-\infty}^0 x f(x) dx = -\infty$ i $\int_0^{\infty} x f(x) dx = \infty$ (w przypadku zmiennych losowych absolutnie ciągłych).

Własności wartości oczekiwanej: jeśli $a \in \mathbb{R}$, to

- $E(a) = a$,
- $E(aX) = aE(X)$, jeśli tylko EX istnieje (przy czym przyjmujemy tu, że $0 \cdot \pm\infty = 0$),
- $E(X \pm Y) = EX \pm EY$, jeśli tylko EX i EY istnieją i wyrażenie $EX \pm EY$ ma sens (tzn. nie prowadzi do $\infty - \infty$ lub $-\infty + \infty$),
- jeśli $X \leq Y$ i EX oraz EY istnieją, to $EX \leq EY$.

5). Wariancja : $Var(X) = E((X - EX)^2) = E(X^2) - (EX)^2$, gdzie

$$E(X^2) = \begin{cases} \sum_k x_k^2 p_k & \text{dla zmiennych losowych dyskretnych,} \\ \int_{\mathbb{R}} x^2 f(x) dx & \text{dla zmiennych losowych absolutnie ciągłych} \end{cases}$$

i ogólniej, jeśli g jest funkcją taką, że $g(X)$ jest zmienną losową (w szczególności, jeśli g jest funkcją ciągłą), to

$$E(g(X)) = \begin{cases} \sum_k g(x_k) p_k & \text{dla zmiennych losowych dyskretnych,} \\ \int_{\mathbb{R}} g(x) f(x) dx & \text{dla zmiennych losowych absolutnie ciągłych,} \end{cases}$$

przy czym mówimy, że $E(g(X))$ nie istnieje, gdy $\sum_{k:g(x_k) \leq 0} g(x_k) p_k = -\infty$

i $\sum_{k:g(x_k) \geq 0} g(x_k) p_k = \infty$ (w przypadku zmiennych losowych dyskretnych) lub $\int_{\mathbb{R}} g^-(x) f(x) dx = \int_{\mathbb{R}} g^+(x) f(x) dx = \infty$, gdzie

$$g^-(x) = \begin{cases} 0 & \text{gdym } g(x) > 0 \\ -g(x) & \text{gdym } g(x) \leq 0 \end{cases} \quad \text{i} \quad g^+(x) = \begin{cases} 0 & \text{gdym } g(x) < 0 \\ g(x) & \text{gdym } g(x) \geq 0 \end{cases}$$

(w przypadku zmiennych losowych absolutnie ciągłych).

Własności wariancji:

- jeśli $a, b \in \mathbb{R}$ i $Var(X)$ istnieje, to $Var(aX + b) = a^2 Var(X)$; w szczególności $Var(b) = 0$;
- dla dowolnej zmiennej losowej X , takiej że $Var(X)$ istnieje, mamy $Var(X) \geq 0$.

6). Odchylenie standardowe : $\sigma_X = \sqrt{Var(X)}$.

Dla przykładowych rozkładów zmiennych losowych mamy:

- jeśli $X \sim \text{binom}(1, p)$, to $EX = p$ i $Var(X) = p(1 - p)$;
- jeśli $X \sim \text{binom}(n, p)$, to $EX = np$ i $Var(X) = np(1 - p)$;
- jeśli $X \sim \text{Pois}(\lambda)$, to $EX = Var(X) = \lambda$;
- jeśli $X \sim \text{Ge}(p)$, to $EX = \frac{1-p}{p}$ i $Var(X) = \frac{1-p}{p^2}$;
- jeśli $X \sim \text{nb}(p, r)$, to $EX = \frac{(1-p)r}{p}$ i $Var(X) = \frac{(1-p)r}{p^2}$;
- jeśli $X \sim U(a, b)$, to $EX = \frac{a+b}{2}$ i $Var(X) = \frac{(b-a)^2}{12}$;
- jeśli $X \sim \text{Exp}(\lambda)$, to $EX = \frac{1}{\lambda}$ i $Var(X) = \frac{1}{\lambda^2}$;
- jeśli $X \sim \mathcal{N}(\mu, \sigma^2)$, to $EX = \mu$ i $Var(X) = \sigma^2$;
- jeśli $X \sim \text{Gamma}(a, \beta)$, to $EX = \frac{a}{\beta}$ i $Var(X) = \frac{a}{\beta^2}$;
- jeśli $X \sim t_{[n]}$, to $EX = 0$ dla $n > 1$ i $Var(X) = \frac{n}{n-2}$ dla $n > 2$;
- jeśli $X \sim F_{[m, n]}$, to $EX = \frac{n}{n-2}$ dla $n > 2$ i $Var(X) = \frac{2n^2(m+n-2)}{m(n-2)^2(n-4)}$ dla $n > 4$.

FUNKCJE W PAKIECIE R:

rozkład	$P(X = x)$ dla rozkładów dyskretnych lub $f(x)$ dla rozkładów ciągłych
$binom(n, p)$	<code>dbinom(x, size=n, prob=p)</code>
$Pois(\lambda)$	<code>dpois(x, lambda= λ)</code>
$Ge(p)$	<code>dgeom(x, prob=p)</code>
$nb(p, r)$	<code>dnbinom(x, size=r, prob=p)</code>
$U(a, b)$	<code>dunif(x, min=a, max=b)</code>
$Exp(\lambda)$	<code>dexp(x, rate= λ)</code>
$\mathcal{N}(\mu, \sigma^2)$	<code>dnorm(x, mean= μ, sd= σ)</code>
$Gamma(a, \beta)$	<code>dgamma(x, shape=a, rate= β)</code>
$\chi_{[n]}^2$	<code>dchisq(x, n=n)</code>
$t_{[n]}$	<code>dt(x, n=n)</code>
$F_{[m,n]}$	<code>df(x, n=n, m=m)</code>

Ponadto dla rozkładu dwumianowego:

- dystrybuanta: $P(X \leq x) = \text{pbinom}(q=x, \text{size}=n, \text{prob}=p, \text{lower.tail}=\text{TRUE})$;
- ogon dystrybuanty: $P(X > x) = \text{pbinom}(q=x, \text{size}=n, \text{prob}=p, \text{lower.tail}=\text{FALSE})$;
- kwantyl rzędu $\alpha \in (0, 1)$: q_α , czyli najmniejsza liczba spełniająca $P(X \leq q_\alpha) \geq \alpha$:

$$q_\alpha = \text{qbinom}(p = \alpha, \text{size}=n, \text{prob}=p, \text{lower.tail}=\text{TRUE});$$

- $\text{qbinom}(p = \alpha, \text{size}=n, \text{prob}=p, \text{lower.tail}=\text{FALSE})$ wyznaczy najmniejszą liczbę c_α spełniającą $P(X > c_\alpha) \leq \alpha$;
- $\text{rbinom}(n, \text{size}, \text{prob})$ wygeneruje n liczb losowych z rozkładu $binom(\text{size}, \text{prob})$

i analogicznie dla pozostałych rozkładów (fragmenty napisane na niebiesko można pominąć).

Przykład 2.3. Pojemność wyprodukowanej partii kondensatorów jest zmienną losową o rozkładzie normalnym z wartością przeciętną 500pF i odchyleniem standardowym 25pF.

- Oblicz prawdopodobieństwo tego, że losowo wybrany kondensator z tej partii ma pojemność większą niż 450pF i jednocześnie mniejszą niż 800pF.
- Wyznacz wartość pojemności, której nie przekracza 75% kondensatorów z tej partii.