

27.03.2024

Def. 4.1 (Ω, \mathcal{F}, P) -p.prob. Zmienną losową o wartościach w \mathbb{R}^d nazywamy dowolną funkcję mierzalną $X: \Omega \rightarrow \mathbb{R}^d$.

Jeżeli $d=1$, to powyższa definicja opisuje zmienną losową z poprzedniego wykładu.

Przykład Wylosowano 13 kart z 32.

Niech X_1 oznacza liczbę pików, a X_2 liczbę kierów. Wówczas $X = (X_1, X_2)$.

Podstawowe własności wielowymiarowych zmiennych losowych są analogiczne do zwykłych zmiennych losowych. Np.:

- jeżeli X_1, X_2 są d -wymiarowymi

zmiennymi losowymi, to $X_1 + X_2, X_1 - X_2$ też

- jeżeli $\phi: \mathbb{R}^d \rightarrow \mathbb{R}^k$ mierzalne, to $\phi(X)$ jest k -wymiarową zm. los.

Definicja 4.2

Rozkładem d -wymiarowej

zmiennnej losowej X nazywamy miarę prob.

$$\mu(B) = P[X \in B] = P[\omega : X(\omega) \in B].$$

Wówczas $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d), \mu)$ jest p. prob.

Definicja 4.3 Dystrybucja d -wymiarowej

zmiennnej losowej X nazywamy funkcję

$F: \mathbb{R}^d \rightarrow [0, 1]$ zadana wzorem

$$\begin{aligned} F(t_1, \dots, t_d) &= \mu((-\infty, t_1] \times (-\infty, t_2] \times \dots \times (-\infty, t_d]) \\ &= P[X_1 \leq t_1, \dots, X_d \leq t_d] \end{aligned}$$

T.W. 4.4 F - dystrybucja X . Wtedy

1. jeżeli $x_i \rightarrow -\infty$ dla pewnego i , to

$$F(x_1, \dots, x_d) \rightarrow 0$$

2. jeżeli $x_i \rightarrow \infty$ dla pewnego i , to

$$F(x_1, \dots, x_d) \rightarrow 1$$

3. dystrybucja X jedn. wyznacza rozkład.

Definicja 4.5 d -wym. zm. los. X ma rozkład dyskretny, jeżeli istnieje przeliczalny zbiór S taki, że $\mu(S) = 1$. Wtedy istnieje ciąg $p_1, p_2, \dots \in (0, 1]$, $s_1, \dots \in \mathbb{R}^d$ t. że

$$\sum p_i = 1, \quad P[X = s_i] = p_i$$

Definicja 4.6 d -wymiarowa zm. los. X ma rozkład absolutnie ciągły, jeżeli istnieje funkcja borelowska $f: \mathbb{R}^d \rightarrow [0, \infty)$ t. że

$$P[X \in B] = \mu(B) = \int_B f(x) dx, \quad B \in \mathcal{B}(\mathbb{R}^d).$$

Wówczas

$$F(t_1, \dots, t_d) = \int_{-\infty}^{t_1} \dots \int_{-\infty}^{t_d} f(x_1, \dots, x_d) dx_1 dx_2 \dots dx_d$$

Ponadto, jeżeli $F \in C^d(\mathbb{R}^d)$, to

$$f(x_1, \dots, x_d) = \frac{\partial^d F}{\partial x_1 \partial x_2 \dots \partial x_d}(x_1, \dots, x_d)$$

Przykład. W urnie są 2 kule czerwone, 5 białych i 3 zielone. Wybieramy losowo 3 kule (jedn.). X_1 oznacza # białych kul, X_2 # kul czerwonych. Wówczas (X_1, X_2) jest 2-wymiarową zmienną losową i rozkład dyskretny:

$X_1 \setminus X_2$	0	1	2	$P[X_1 = x]$
0	$\frac{1}{120}$	$\frac{6}{120}$	$\frac{3}{120}$	$\frac{10}{120}$
1	$\frac{15}{120}$	$\frac{30}{120}$	$\frac{5}{120}$	$\frac{50}{120}$
2	$\frac{30}{120}$	$\frac{20}{120}$	0	$\frac{50}{120}$
3	$\frac{10}{120}$	0	6	$\frac{10}{120}$
$P[X_2 = y]$	$\frac{56}{120}$	$\frac{56}{120}$	$\frac{8}{120}$	1

$$P[X_1 \leq X_2] = \frac{45}{120} = \frac{3}{8}$$

$$P[X_1 = 1 | X_1 \leq X_2] = \frac{P[X_1 = 1 \text{ i } X_1 \leq X_2]}{P[X_1 \leq X_2]} = \frac{7}{9}$$

Wniosek: znajomość rozkładu X_1, X_2 nie daje nam jeszcze rozkładu (X_1, X_2) .

Przykład.

$(\mathbb{R}^2, \mathcal{B}(\mathbb{R}^2), \frac{1}{\lambda(S)} \lambda|_S)$

↑
p. prob.



$$P[(x_1, x_2) \in A] = \frac{\lambda(A \cap S)}{\lambda(S)}$$

zm. losowe
↑
 $X(\omega) = \omega$

Rozkład identyczności

to po prostu miara przestrzeni.

Przykład. Rozkład Gaussa (normalny) na \mathbb{R}^d ,

$\mathcal{N}(m, A^{-1})$: m - ustalony wektor w \mathbb{R}^d ,

A - macierz $d \times d$, symetryczna,
dodatnio określona

(forma kw. określona przez A
jest ilocz. skalarnym)

gęstość: $f(x) = \frac{\sqrt{\det A}}{(2\pi)^{\frac{d}{2}}} \cdot e^{-\frac{1}{2} \langle (x-m), (x-m) \rangle}$
 iloczyn skalarny
 zdefiniowany przez A

Widocznie, że $f(x) \geq 0$.

Trzeba sprawdzić, że $\int_{\mathbb{R}^d} f(x) dx = 1$

Macierz $A = BDB^{-1}$
 \uparrow diagonalna \uparrow izometria

$$D = \begin{bmatrix} a_1 & & & \\ & a_2 & & \\ & & \ddots & \\ & & & a_d \end{bmatrix}, a_i > 0$$

Podstawiając $x-m = By$ otrzymujemy

$$\int_{\mathbb{R}^d} f(x) dx = \frac{\sqrt{\det A}}{(2\pi)^{\frac{d}{2}}} \int_{\mathbb{R}^d} e^{-\frac{1}{2} \langle By, By \rangle} |\det B| dy =$$

$$= C \int_{\mathbb{R}^d} e^{-\frac{1}{2} y^t D y} dy = C \int_{\mathbb{R}^d} e^{-\frac{1}{2} \sum_{i=1}^d a_i y_i^2} dy =$$

$$= C \prod_{i=1}^d \int_{\mathbb{R}} e^{-\frac{1}{2} a_i y_i^2} dy_i = \frac{1}{\sqrt{2\pi a_i}} \prod_{i=1}^d \int_{\mathbb{R}} e^{-\frac{z^2}{2}} dz = 1$$

Definicja 4.7 $X = (X_1, \dots, X_d)$. Wówczas dla $k \leq d$
rozkład X_k nazywamy rozkładem brzegowym

UWAGA: jeśli znamy wyłącznie rozkłady
brzegowe, to cały rozkład nie wynika
z nich jednocześnie.

Definicja 4.8 (Ω, \mathcal{F}, P) - p.p.rob., $\{X_i\}_{i \in I}$

rodzina zmiennych losowych. Zmiennie te

są niezależne, jeżeli $\sigma(X_i)$ (σ -cieta

generowane przez X_i) są niezależne.

$$\left[\sigma(X) = \sigma(\{X^{-1}[B]\}_{B \in \mathcal{B}(\mathbb{R})}) \subseteq \mathcal{F} \right]$$

Innymi słowy, $\{X_i\}_{i \in I}$ są niezależne,

gdy dla dowolnych, parami różnych

$i_1, i_2, \dots, i_n \in I$ oraz dowolnych $B_1, \dots, B_n \in \mathcal{B}(\mathbb{R})$

zachodzi

$$P[X_{i_1} \in B_1, \dots, X_{i_n} \in B_n] = P[X_{i_1} \in B_1] \cdot \dots \cdot P[X_{i_n} \in B_n]$$

Disclaimer: $\sigma(X)$ to najmniejsze σ -ciało
zawarte w \mathcal{F} , w którym X jest
mieralne: $X: (\Omega, \sigma(X)) \rightarrow (\mathbb{R}, \mathcal{P}(\mathbb{R}))$

Przykład. Rozważmy schemat Bernoulliego

zdefiniujemy

$$X_i(\omega) = X_i(\omega_1, \dots, \omega_n) = \begin{cases} 1 & \text{gdzi sukces w } i\text{-tej} \\ 0 & \text{ } \end{cases}$$

Wówczas X_1, \dots, X_n są niezależnymi zmiennymi
losowymi.

$$P[X_1=1, X_2=0] = P[\exists (\omega_1, \omega_2): X_1(\omega) = 1, X_2(\omega) = 0]$$

$$= P[X_1(\omega) = 1] \cdot P[X_2(\omega) = 0]$$

↑
wynika z tego, że
 X_1, X_2 są f. chw.
niezależnych zdarzeń.

Tw. 4.9 Niech X_1, \dots, X_n będą zmiennymi losowymi, $X = (X_1, \dots, X_n)$. NWSR:

1. X_1, \dots, X_n są niezależne.

2. dla dowolnych $B_1, \dots, B_n \in \mathcal{B}(\mathbb{R})$ zdarzenia $\{X_1 \in B_1\}, \dots, \{X_n \in B_n\}$ są niezależne.

$$3. \mu_X = \mu_{X_1} \otimes \mu_{X_2} \otimes \dots \otimes \mu_{X_n}$$

$$4. F_X(t_1, \dots, t_n) = F_{X_1}(t_1) \cdot \dots \cdot F_{X_n}(t_n)$$

D-d.

• $1 \Leftrightarrow 2$ z def.

• $2 \Rightarrow 4$ $B_i = (-\infty, t_i]$

$$F_X(t_1, \dots, t_n) = \mathbb{P}[X_1 \leq t_1, \dots, X_n \leq t_n] =$$

$$= \mathbb{P}[\{X_1 \in B_1\} \cap \dots \cap \{X_n \in B_n\}] \stackrel{2}{=} \mathbb{P}[X_1 \in B_1] \cdot \dots \cdot \mathbb{P}[X_n \in B_n]$$

• $4 \Rightarrow 3$ Niech X' - zm. los. o rozkładzie

$\mu_{X_1} \otimes \dots \otimes \mu_{X_n}$. Pokażemy $F_X = F_{X'}$.

$$(\Rightarrow \mu_X = \mu_{X'})$$

$$\begin{aligned}
 F_X(t_1, \dots, t_n) &= \mu_{X_1} \otimes \dots \otimes \mu_{X_n}([-\infty, t_1] \times \dots \times [-\infty, t_n]) = \\
 &= \mu_{X_1}([-\infty, t_1]) \cdot \dots \cdot \mu_{X_n}([-\infty, t_n]) = \\
 &= F_{X_1}(t_1) \cdot \dots \cdot F_{X_n}(t_n) \stackrel{4}{=} F_X(t_1, \dots, t_n)
 \end{aligned}$$

• 3 \Rightarrow 2

$$\begin{aligned}
 P[X_1 \in B_1, \dots, X_n \in B_n] &= \mu_X(B_1 \times \dots \times B_n) \stackrel{(3)}{=} \\
 &= \mu_{X_1}(B_1) \cdot \dots \cdot \mu_{X_n}(B_n) = \\
 &= P[X_1 \in B_1] \cdot \dots \cdot P[X_n \in B_n]
 \end{aligned}$$

~~□~~

Wniosek 4.10 Zmienne losowe X_1, \dots, X_n

mające wartości dyskretne są niezależne

iff dla dowolnych $s_1 \in S_{X_1}, \dots, s_n \in S_{X_n}$

zachodzi

$$(*) \quad P[X_1 = s_1, \dots, X_n = s_n] = P[X_1 = s_1] \cdot \dots \cdot P[X_n = s_n]$$

Dowód. Jeżeli zmienne losowe X_1, \dots, X_n są

niezależne to (*) jest prawdziwe.

Implikacja odwrotna (dla uproszczenia $n=2$):

Korzystając z (*) otrzymujemy dla dowolnych zbiorów borelowskich B_1, B_2 :

$$\begin{aligned} P[X_1 \in B_1, X_2 \in B_2] &= P[X_1 \in B_1 \cap S_{X_1}, X_2 \in S_2 \cap S_{X_2}] \\ &= \sum_{\substack{x_1 \in B_1 \cap S_{X_1} \\ X_2 \in B_2 \cap S_{X_2}}} P[X_1 = x_1, X_2 = x_2] = \\ &= \sum_{x_1 \in B_1 \cap S_{X_1}} \sum_{x_2 \in B_2 \cap S_{X_2}} P[X_1 = x_1] P[X_2 = x_2] = \\ &= P[X_1 \in B_1] \cdot P[X_2 \in B_2] \end{aligned}$$

Wniosek 4.11 Zmienne losowe X_1, \dots, X_n

o gęstościach f_1, \dots, f_n są niezależne iff

zmienne losowe $X = (X_1, \dots, X_n)$ ma

gęstość

$$f_X(x_1, \dots, x_n) = f_1(x_1) \cdot \dots \cdot f_n(x_n)$$


Przykład. Niech $X = (X_1, X_2)$ będzie losowym

punktem z kwadratu $[0,1] \times [0,1]$. Czy zmienne X_1, X_2 są niezależne?

$$(\Omega, \mathcal{F}, \mathbb{P}) = ([0, 1]^2, \mathcal{B}([0, 1]^2), \lambda)$$

$$f_X(x_1, x_2) =$$

$$= 1 \cdot \mathbb{1}_{[0, 1] \times [0, 1]}(x_1, x_2)$$



Jak wygląda gęstość X_1 ?

$$A \in \mathcal{B}([0, 1])$$

$$\mathbb{P}[X_1 \in A] = \lambda[(X_1, X_2) \in A \times [0, 1]] =$$

$$= \lambda[A] = \int_A 1 dx \Rightarrow f_{X_1}(x) = \mathbb{1}_{[0, 1]}(x)$$

Analogicznie $f_{X_2}(x) = \mathbb{1}_{[0, 1]}(x)$

Mamy $f_X = f_{X_1} f_{X_2} \Rightarrow X_1, X_2$ niezależne

Przykład. Niech $X = (X_1, X_2)$ będzie losowym punktem w trójkącie $d(x_1, x_2) : 0 \leq x_2 \leq x_1 \leq 1$.

Czy X_1, X_2 niezależne?

$$f_X(x_1, x_2) = \begin{cases} 2 & 0 \leq x_2 \leq x_1 \\ 0 & \text{poza} \end{cases}$$



+ trochę naturzynie
↓

$$\text{Dla } A \in [0, 1] \quad P[X_1 \in A] = P[(X_1, X_2) \in A \times \mathbb{R}] =$$

$$= \int_{A \times \mathbb{R}} f_X(x_1, x_2) dx_1 dx_2 = \int_A \int_{\mathbb{R}} f_X(x_1, x_2) dx_2 dx_1 =$$

Tw. Fubiniego

$$= \int_A \int_0^{x_1} 2 dx_2 dx_1 = \int_A 2x_1 dx_1$$

\parallel
 $f_{X_1}(x_1)$

$$\text{Teraz } P[X_2 \in A] = \int_A \int_{\mathbb{R}} f_X(x_1, x_2) dx_1 dx_2 =$$

$$= \int_A \int_{x_2}^1 2 dx_1 dx_2 = \int_A 2(1-x_2) dx_2$$

\parallel
 $f_{X_2}(x_2)$

$$f_X\left(\frac{1}{2}, \frac{1}{2}\right) = 2$$

$$f_{X_1}\left(\frac{1}{2}\right) = 1, \quad f_{X_2}\left(\frac{1}{2}\right) = 1$$

$f_X \neq f_{X_1} \cdot f_{X_2} \Rightarrow X_1, X_2$ nie są
niezależne.

Tw. 4.12 Załóżmy, że X_1, X_2 są nrl. zm. los.

o rozkładach ciągłych z gęstościami f_1, f_2 .

Wówczas zmienna losowa $X_1 + X_2$ ma rozkład z gęstością

$$f(x) = f_1 * f_2(x) = \int_{\mathbb{R}} f_1(x-y) f_2(y) dy$$

Funkcję f nazwemy splotem f_1, f_2 .

--- --- --- --- --- --- --- --- --- --- ---

$$\text{dane, } \text{dane}, f(x) = \sum_{n=0}^{\infty} a_n x^n, g(x) = \sum_{n=0}^{\infty} b_n x^n$$

$$f(x) \cdot g(x) = \sum_{n=0}^{\infty} c_n x^n, c_n = \sum_{k=0}^n a_k b_{n-k}$$

To jest splot

--- --- --- --- --- --- --- --- --- --- ---