

3 i 4. WEKTORY LOSOWE

Definicja. Niech X_1, X_2, \dots, X_d będą zmiennymi losowymi określonymi niekoniecznie na tej samej przestrzeni probabilistycznej. Wtedy wektor

$$\mathbb{X} = (X_1, X_2, \dots, X_d)$$

nazywamy *wielowymiarową (d-wymiarową) zmienną losową* lub inaczej *(d-wymiarowym) wektorem losowym*.

Aby opisać rozkład wektora losowego \mathbb{X} nie wystarczy podać rozkładów zmiennych losowych X_1, X_2, \dots, X_d (czyli tzw. *rozkładów brzegowych*), bo nie zawierają one informacji o zależnościach pomiędzy X_1, X_2, \dots, X_d .

(a) W przypadku dyskretnych wektorów losowych (czyli wektorów losowych, gdzie X_1, X_2, \dots, X_d to zmienne losowe dyskretne) podajemy tzw. *łącną (d-wymiarową) funkcję masy prawdopodobieństwa*:

$$p(x_1, x_2, \dots, x_d) := P(X_1 = x_1, X_2 = x_2, \dots, X_d = x_d).$$

Oczywiście musimy mieć

1. $p(x_1, x_2, \dots, x_d) \geq 0$ dla każdego (x_1, x_2, \dots, x_d) ,
2. $\sum_{x_1, x_2, \dots, x_d} p(x_1, x_2, \dots, x_d) = 1$, gdzie sumowanie odbywa się po wszystkich (x_1, x_2, \dots, x_d) , dla których $p(x_1, x_2, \dots, x_d) > 0$.

Ponadto powyższe warunki 1. i 2. gwarantują, że $p(x_1, x_2, \dots, x_d)$ jest łącną funkcją masy prawdopodobieństwa pewnego dyskretnego wektora losowego $\mathbb{X} = (X_1, X_2, \dots, X_d)$.

Rozkład brzegowy zmiennej losowej X_i , $i = 1, 2, \dots, d$, uzyskamy z łączonej funkcji masy prawdopodobieństwa $p(x_1, x_2, \dots, x_d)$ używając wzoru

$$P(X_i = x_i) = \sum_{x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_d} p(x_1, x_2, \dots, x_d),$$

gdzie sumowanie odbywa się po wszystkich $(x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_d)$, dla których $p(x_1, x_2, \dots, x_d) > 0$.

(b) W przypadku (absolutnie) ciągłych wektorów losowych podajemy tzw. *łącną (d-wymiarową) gęstość*, czyli nieujemną funkcję $f_{\mathbb{X}}(x_1, x_2, \dots, x_d)$ taką, że dla każdego $A \in \mathcal{B}(\mathbb{R}^d)$ mamy

$$P(\mathbb{X} \in A) = \int_A f_{\mathbb{X}}(x_1, x_2, \dots, x_d) dx_1 dx_2 \dots dx_d.$$

Skoro $P(\mathbb{X} \in \mathbb{R}^d) = 1$, to w szczególności otrzymujemy

$$\int_{\mathbb{R}^d} f_{\mathbb{X}}(x_1, x_2, \dots, x_d) dx_1 dx_2 \dots dx_d = 1. \quad (1)$$

Ponadto każda nieujemna funkcja $f_{\mathbb{X}}(x_1, x_2, \dots, x_d)$ spełniająca (1) jest łączną gęstością pewnego wektora losowego $\mathbb{X} = (X_1, X_2, \dots, X_d)$. Gęstość brzegową zmiennej losowej X_i , $i = 1, 2, \dots, d$, uzyskamy z gęstości łącznej $f_{\mathbb{X}}$ używając wzoru

$$f_{X_i}(x_i) = \int \dots \int_{\mathbb{R}^{d-1}} f_{\mathbb{X}}(x_1, x_2, \dots, x_d) dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_d;$$

(c) Rozkład dowolnego wektora losowego możemy opisać poprzez *łączną (d -wymiarową) dystrybuantę*:

$$F_{\mathbb{X}}(x_1, x_2, \dots, x_d) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_d \leq x_d);$$

dystrybuantę brzegową zmiennej losowej X_i , $i = 1, 2, \dots, d$, uzyskamy z dystrybuanty łącznej $F_{\mathbb{X}}$ używając wzoru

$$F_{X_i}(x_i) = \lim_{x_j \rightarrow \infty, j=1, \dots, i-1, i+1, \dots, d} F_{\mathbb{X}}(x_1, x_2, \dots, x_d).$$

Niezależność zmiennych losowych

Definicja. Zmienne losowe X_1, X_2, \dots, X_d , tworzące wektor losowy \mathbb{X} , są *niezależne* wtedy i tylko wtedy, gdy ich łączna dystrybuanta to iloczyn dystrybuant brzegowych: dla każdego $(x_1, x_2, \dots, x_d) \in \mathbb{R}^d$ mamy

$$F_{\mathbb{X}}(x_1, x_2, \dots, x_d) = F_{X_1}(x_1) \cdot F_{X_2}(x_2) \cdot \dots \cdot F_{X_d}(x_d),$$

tzn. dla każdego $(x_1, x_2, \dots, x_d) \in \mathbb{R}^d$ zachodzi

$$P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_d \leq x_d) = P(X_1 \leq x_1)P(X_2 \leq x_2) \dots P(X_d \leq x_d).$$

Twierdzenie 3.1. Jeśli $\mathbb{X} = (X_1, X_2, \dots, X_d)$ jest dyskretnym wektorem losowym, to X_1, X_2, \dots, X_d są niezależne wtedy i tylko wtedy, gdy dla każdego $(x_1, x_2, \dots, x_d) \in \mathbb{R}^d$ mamy

$$P(X_1 = x_1, X_2 = x_2, \dots, X_d = x_d) = P(X_1 = x_1)P(X_2 = x_2) \dots P(X_d = x_d);$$

natomiast jeśli $\mathbb{X} = (X_1, X_2, \dots, X_d)$ jest ciągłym wektorem losowym, to X_1, X_2, \dots, X_d są niezależne wtedy i tylko wtedy, gdy dla każdego $(x_1, x_2, \dots, x_d) \in \mathbb{R}^d$ mamy

$$f_{\mathbb{X}}(x_1, x_2, \dots, x_d) = f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdot \dots \cdot f_{X_d}(x_d).$$

Kowariancja i współczynnik korelacji

W podrozdziale tym będziemy zakładać, że X i Y to zmienne losowe, takie że $E(X^2) < \infty$ i $E(Y^2) < \infty$. Założenie to gwarantuje, że istnieją skończone $E(X)$, $E(Y)$, $Var(X)$, $Var(Y)$ oraz $E(XY)$ zdefiniowane poniżej.

Definicja. Kowariancją zmiennych losowych X i Y nazywamy liczbę oznaczaną $Cov(X, Y)$ i daną wzorem

$$Cov(X, Y) = E(XY) - E(X)E(Y),$$

gdzie

$$E(XY) = \begin{cases} \sum_{k,l} x_k y_l P(X = x_k, Y = y_l) & \text{dla zmiennych losowych dyskretnych,} \\ \iint_{\mathbb{R}^2} xy f_{(X,Y)}(x, y) dx dy & \text{dla zmiennych losowych ciągłych.} \end{cases}$$

Definicja. Współczynnikiem korelacji zmiennych losowych X i Y , mających niezerowe wariancje, nazywamy liczbę oznaczaną ρ_{XY} lub ρ i daną wzorem

$$\rho_{XY} = \frac{Cov(X, Y)}{\sigma_X \sigma_Y}.$$

Ponadto jeśli $\rho_{XY} = 0$, to mówimy, że zmienne losowe X i Y są *nieskorelowane*.

Twierdzenie 3.2. Niech X i Y to zmienne losowe o niezerowych wariancjach. Wtedy

(a) $-1 \leq \rho_{XY} \leq 1$.

(b) ρ_{XY} to pewna miara siły zależności liniowej pomiędzy X i Y . Dokładniej:

$|\rho_{XY}| = 1$ wtedy i tylko wtedy, gdy istnieją $a \neq 0$ i $b \in \mathbb{R}$, takie że
 $P(Y = aX + b) = 1$ ($a > 0$ odpowiada przypadkowi $\rho_{XY} = 1$
zaś $a < 0$ odpowiada przypadkowi $\rho_{XY} = -1$);

Twierdzenie 3.3. Jeśli $a, b, c \in \mathbb{R}$, to

$$E(aX + bY + c) = aE(X) + bE(Y) + c,$$

$$Var(aX + bY + c) = a^2 Var(X) + b^2 Var(Y) + 2ab Cov(X, Y).$$

Twierdzenie 3.4. Jeśli zmienne losowe X i Y są niezależne, to

$$E(XY) = EX \cdot EY,$$

co pociąga za sobą

$$\text{Cov}(X, Y) = 0$$

i dalej

$$\text{Var}(X \pm Y) = \text{Var}(X) + \text{Var}(Y).$$

Jeśli dodatkowo założymy, że wariancje X i Y są niezerowe, to otrzymamy

$$\rho_{XY} = 0.$$

Definicja. *Macierz kowariancji* wektora losowego $\mathbb{X} = (X_1, X_2, \dots, X_d)$, takiego że $EX_i^2 < \infty$, $i = 1, \dots, d$, to macierz zwykle oznaczana Σ i dana wzorem

$$\Sigma = \begin{bmatrix} \sigma_{X_1}^2 & \sigma_{X_1X_2} & \cdots & \sigma_{X_1X_d} \\ \sigma_{X_2X_1} & \sigma_{X_2}^2 & \cdots & \sigma_{X_2X_d} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{X_dX_1} & \sigma_{X_dX_2} & \cdots & \sigma_{X_d}^2 \end{bmatrix},$$

gdzie

- $\sigma_{X_j}^2 = \text{Var}(X_j)$ dla $j = 1, 2, \dots, d$;
- $\sigma_{X_jX_k} = \text{Cov}(X_j, X_k)$ dla $j \neq k$.

Twierdzenie 3.5. Dana macierz jest macierzą kowariancji pewnego wektora losowego wtedy i tylko wtedy, gdy macierz ta jest symetryczna i nieujemnie określona.

Przykład 3.1. Dwuwymiarowa zmienna losowa (X, Y) ma rozkład dany tabelką

$X \backslash Y$	0	1	2
-1	0,2	0	0
0	0,2	a	0
1	0	$2a$	0
2	0	0,1	$2a$

- a). Wyznaczyć $P(X = 0, Y = 1)$,
- b). Podać rozkłady brzegowe X i Y ,
- c). Obliczyć $F(0, \frac{3}{2})$,
- d). Sprawdzić czy X i Y są niezależne,
- e). Podać rozkład zmiennej losowej $Z = X + Y$,
- f). Obliczyć współczynnik korelacji X i Y .

Przykład 3.2. Dwuwymiarowa zmienna losowa (X, Y) ma rozkład o gęstości

$$f(x, y) = \begin{cases} Cx & \text{dla } 0 \leq x \leq 1 \text{ i } 0 \leq y \leq 1 - x^2 \\ 0 & \text{dla pozostałych } (x, y). \end{cases}$$

- a). Wyznaczyć stałą C ,
- b). Podać gęstości brzegowe X i Y ,
- c). Sprawdzić niezależność X i Y ,
- d). Obliczyć $F(\frac{1}{2}, 2)$,

Rozkład sumy zmiennych losowych

Twierdzenie 3.6. Niech wektor losowy (X, Y) ma gęstość $f(x, y)$. Wtedy zmienna losowa $Z = X + Y$ ma gęstość daną wzorem

$$f_Z(z) = \int_{\mathbb{R}} f(x, z - x) dx.$$

Przykład 3.3. Wektor losowy (X, Y) ma gęstość

$$f(x, y) = \begin{cases} y & \text{dla } (x, y) \in D \\ 0 & \text{dla } (x, y) \notin D, \end{cases}$$

gdzie $D = [1, 2] \times [0, 1]$. Wyznaczyć rozkład zmiennej losowej $Z = X + Y$.

Pewne rozkłady sum niezależnych zmiennych losowych

Jeśli X_1, X_2, \dots, X_n to niezależne zmienne losowe i

- (1) $X_i, i = 1, 2, \dots, n$, ma rozkład dwupunktowy o prawdopodobieństwie sukcesu θ , to

$$X_1 + X_2 + \dots + X_n \text{ ma rozkład dwumianowy } \mathit{binom}(n, \theta);$$

ogólniej, jeśli $X_i, i = 1, 2, \dots, n$, ma rozkład dwumianowy $\mathit{binom}(m_i, \theta)$, to

$$X_1 + X_2 + \dots + X_n \text{ ma rozkład dwumianowy } \mathit{binom}(m_1 + m_2 + \dots + m_n, \theta).$$

- (2) X_i ma rozkład Poissona $\mathit{Pois}(\lambda_i)$ dla $i = 1, 2, \dots, n$, to

$$X_1 + X_2 + \dots + X_n \text{ ma rozkład Poissona } \mathit{Pois}(\lambda_1 + \lambda_2 + \dots + \lambda_n);$$

- (3) X_i ma rozkład normalny $\mathcal{N}(\mu_i, \sigma_i^2)$ dla $i = 1, 2, \dots, n$, to

$$X_1 + X_2 + \dots + X_n \text{ ma rozkład normalny } \mathcal{N}(\mu_1 + \mu_2 + \dots + \mu_n, \sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2);$$

- (4) $X_i, i = 1, 2, \dots, n$, ma rozkład gamma $\mathit{Gamma}(a_i, s)$, to

$$X_1 + X_2 + \dots + X_n \text{ ma rozkład gamma } \mathit{Gamma}(a_1 + a_2 + \dots + a_n, s).$$