

Twierdzenie 10.1 (Łączna gęstość prawdopodobieństwa).

Funkcja f może być łączną gęstością prawdopodobieństwa wektora losowego (X, Y) wtedy i tylko wtedy gdy:

-

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

-

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$$

Własności dystrybuanty i łącznej gęstości pr. ciągłego wektora losowego:

- Niech $a, b, c, d \in \mathbb{R}$ gdzie $a < b$ i $c < d$ mamy

$$\begin{aligned} P(a < X \leq b, c < Y \leq d) &= \int_a^b \left[\int_c^d f(x, y) dy \right] dx \\ &= \int_c^d \left[\int_a^b f(x, y) dx \right] dy \end{aligned}$$

- Dystrybuanta $F(s, t)$ jest ciągła
- Jeżeli $F(x, y)$ jest różniczkowalna w pewnym punkcie (x, y) to

$$f(x, y) = \frac{\partial^2}{\partial x \partial y} F(x, y)$$

W przypadku gdy obszar całkowania C nie jest prostokątem

$$\begin{aligned} P((X, Y) \in C) &= \iint_C f(x, y) dx dy \\ &= \int_{x_{min}}^{x_{max}} \left[\int_{y_{min}(x)}^{y_{max}(x)} f(x, y) dy \right] dx \\ &= \int_{y_{min}}^{y_{max}} \left[\int_{x_{min}(y)}^{x_{max}(y)} f(x, y) dx \right] dy \end{aligned}$$

Przykład 10.2 (Łączna gęstość brawdopodobieństwa).

Ciągły wektor losowy (X, Y) ma łączną gęstość prawdopodobieństwa

$$f(x, y) = cx(x + y) \quad \text{dla } C = \{(x, y) : x \geq 0 \wedge y \geq 0 \wedge x + y \leq 1\}$$

Ile wynosi prawdopodobieństwo $P(X < 1/2)$?

Pierwszym krokiem jest wyznaczenie stałej c z warunku unormowania gęstości prawdopodobieństwa. Obszar w którym gęstość przyjmuje wartości niezerowe jest trójkątem ograniczonym dodatnimi półosiąmi OX i OY oraz prostą $y = 1 - x$, zatem

$$\begin{aligned}
 1 = \iint_C f(x, y) dx dy &= \int_0^1 \left[\int_0^{1-x} cx(x+y) dy \right] dx \\
 &= \int_0^1 \left[cx \left(xy + \frac{y^2}{2} \right) \Big|_0^{1-x} \right] dx \\
 &= \int_0^1 \frac{c}{2} (-x^3 + x) dx \\
 &= \frac{c}{2} \left(-\frac{x^4}{4} + \frac{x^2}{2} \Big|_0^1 \right) \\
 &= \frac{c}{8} \Rightarrow c = 8
 \end{aligned}$$

$$\begin{aligned}
 P(X < 1/2) &= \int_0^{1/2} \left[\int_0^{1-x} 8x(x+y) dy \right] dx \\
 &= \int_0^{1/2} \left[8x \left(xy + \frac{y^2}{2} \right) \Big|_0^{1-x} \right] dx \\
 &= \int_0^{1/2} 4(-x^3 + x) dx \\
 &= \frac{7}{16}
 \end{aligned}$$

Znając rozkład łączny wektora losowego (X, Y) można obliczyć rozkład zmiennej X niezależnie od wartości jakie przyjmuje zmienna Y i odwrotnie. Rozkłady takie nazywamy rozkładami brzegowymi

Definicja 10.5 (Dyskretne rozkłady brzegowe).

Niech dyskretny wektor losowy (X, Y) ma łączny rozkład pr. $p(x_j, y_k)$. Rozkłady brzegowe dane są przez:

$$p_X(x_j) = \sum_{k=1} p(x_j, y_k), \quad j = 1, 2, \dots$$

$$p_Y(y_j) = \sum_{k=1} p(x_j, y_k), \quad k = 1, 2, \dots$$

Przykład 10.3 (Dyskretne rozkłady brzegowe).

Jakie są rozkłady brzegowe zmiennych X i Y z przykładu 10.1

Odpowiednie rozkłady otrzymamy sumując wartości z tabeli rozkładu prawdopodobieństwa wzdłuż wierszy lub kolumn tak jak to przedstawia poniższa tabela.

$Y \setminus X$	2	3	4	5	6	7	8	9	10	11	12	$p_Y(y_k)$
1	1/36	0	0	0	0	0	0	0	0	0	0	1/36
2	0	2/36	1/36	0	0	0	0	0	0	0	0	3/36
3	0	0	2/36	2/36	1/36	0	0	0	0	0	0	5/36
4	0	0	0	2/36	2/36	2/36	1/36	0	0	0	0	7/36
5	0	0	0	0	2/36	2/36	2/36	2/36	1/36	0	0	9/36
6	0	0	0	0	0	2/36	2/36	2/36	2/36	2/36	1/36	11/36
$p_X(x_j)$	1/36	2/36	3/36	4/36	5/36	6/36	5/36	4/36	3/36	2/36	1/36	

Definicja 10.6 (Gęstości brzegowe).

Niech (X, Y) jest ciągłym wektorem losowym o łącznej gęstości $f(x, y)$. Gęstości brzegowe mają postać:

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy$$

$$f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx$$

Przykład 10.4 (Gęstości brzegowe).

Jakie są gęstości brzegowe zmiennych X i Y z przykładu 11.2

$$f(x, y) = 8x(x + y) \quad \text{dla } C = \{(x, y) : x \geq 0 \wedge y \geq 0 \wedge x + y \leq 1\}$$

Należy pamiętać, że gęstość $f(x, y)$ przyjmuje niezerowe wartości w obszarze w kształcie trójkąta zatem granice całkowania po każdej ze zmiennych będą zależą od wartości drugiej ze zmiennych.

$$\begin{aligned} f_X(x) &= \int_{-\infty}^{\infty} f(x, y) dy = \int_0^{1-x} 8x(x + y) dy \\ &= 4x(1 - x^2) \quad \text{dla } 0 < x < 1 \end{aligned}$$

$$\begin{aligned} f_Y(y) &= \int_{-\infty}^{\infty} f(x, y) dx = \int_0^{1-y} 8x(x + y) dx \\ &= \frac{4(1 - y^2)}{3}(y + 2) \quad \text{dla } 0 < y < 1 \end{aligned}$$

Niezależność zmiennych losowych

Niezależność zmiennych losowych definiuje się poprzez niezależność zdarzeń losowych

Definicja 10.7.

Zmienne losowe X i Y są **niezależne** jeśli zdarzenia losowe $\{X \in A\}$ i $\{Y \in B\}$ są niezależne dla **wszystkich** zbiorów A, B

$$P(X \in A, Y \in B) = P(X \in A)P(Y \in B) \quad \text{dla wszystkich } A, B$$

Sprawdzanie niezależności zgodnie z definicją jest bardzo kłopotliwe w praktyce korzystamy z następującego twierdzenia:

Twierdzenie 10.2 (Niezależność zmiennych losowych).

Zmienne losowe X i Y są niezależne wtedy i tylko wtedy gdy:

$$F(x, y) = F_X(x)F_Y(y)$$

lub dla zmiennych dyskretnych

$$p(x, y) = p_X(x)p_Y(y)$$

lub dla zmiennych ciągłych

$$f(x, y) = f_X(x)f_Y(y)$$

Prostym wnioskiem z powyższego twierdzenia jest następująca obserwacja:

Zmienne losowe X i Y są niezależne jeśli:

- Dla zmiennych dyskretnych w tabelce łącznego rozkładu nie pojawia się wartość zerowa.
- Dla zmiennych ciągłych obszar w którym łączna gęstość $f(x, y)$ przyjmuje wartości niezerowe jest prostokątem.

Zmienne losowe z przykładów 11.1 i 11.2 są przykładami zmiennych statystycznie zależnych.

Twierdzenie 11.3 wykorzystujemy nie tylko do sprawdzenia niezależności zmiennych losowych ale także jako sposób konstrukcji łącznego rozkładu w przypadku gdy wiemy, że zmienne losowe są statystycznie niezależne.

Przykład 10.5 (Łączna gęstość zmiennych niezależnych).

Tadeusz i Zosia umówili się w kawiarni między 17:00 i 18:00. Obydwoje są bardzo dumni i nie zamierzają czekać na partnera dłużej niż 15 minut. Ile wynosi prawdopodobieństwo, że randka dojdzie do skutku?

- $f_T(t)$ - gęstość pr. czasu przyjścia Tadeusza
- $f_Z(z)$ - gęstość pr. czasu przyjścia Zosi

gdzie $z, t \in [0, 1]$. Zakładamy, że oba czasy przyjścia są **niezależne**.

Jeśli rozkłady czasu przyjścia Zosi i Tadeusza nie są jednostajne to nie możemy skorzystać z twierdzenia o prawdopodobieństwie geometrycznym gdyż różne czasy nie są równie prawdopodobne. Należy skonstruować łączną gęstość prawdopodobieństwa a następnie wyciąkać go po obszarze $|z - t| < 1/4$

$$f(z, t) = f_Z(z)f_T(t)$$

$$\begin{aligned} P(|z - t| < 1/4) &= \iint_{|z-t| < 1/4} f(z, t) dz dt \\ &= \iint_{|z-t| < 1/4} f_Z(z)f_T(t) dz dt \\ &= \int_0^{1/4} \left[\int_0^{z+1/4} f_Z(z)f_T(t) dt \right] dz + \int_{1/4}^{3/4} \left[\int_{z-1/4}^{z+1/4} f_Z(z)f_T(t) dt \right] dz + \int_{3/4}^1 \left[\int_{z-1/4}^1 f_Z(z)f_T(t) dt \right] dz \end{aligned}$$

Znając rozkład łączny wektora losowego (X, Y) można zastanowić się w jaki sposób rozkład zmiennej losowej X zależy od wartości zmiennej losowej Y i na odwrót. Rozkłady takie nazywamy rozkładami warunkowymi i definiujemy je w analogi do definicji prawdopodobieństwa warunkowego zdarzeń losowych $P(A|B) = P(A \cap B)/P(B)$, czyli rozkłady warunkowe to stosunki rozkładów łącznych i odpowiednich rozkładów brzegowych.

Definicja 10.8 (Dyskretne rozkłady warunkowe).

Niech dyskretny wektor losowy (X, Y) ma łączny rozkład pr. $p(x_j, y_k)$. **Rozkładami warunkowymi** nazywamy:

$$p_Y(y_k|x_j) = \frac{p(x_j, y_k)}{p_X(x_j)}$$

$$p_X(x_j|y_k) = \frac{p(x_j, y_k)}{p_Y(y_k)}$$

Przykład 10.6 (Dyskretne rozkłady warunkowe).

Jakie są rozkłady warunkowe $p_X(x_j|Y = 6)$ oraz $p_Y(y_k|X = 6)$ wektora losowego z przykładu 10.1?

Odpowiednie rozkłady otrzymamy dzieląc wartości z tabeli rozkładu prawdopodobieństwa przez odpowiednie prawdopodobieństwa brzegowe, tak jak przedstawiono w poniższych tabelach:

$Y \setminus X$	2	3	4	5	6	7	8	9	10	11	12
1	1/36	0	0	0	0	0	0	0	0	0	0
2	0	2/36	1/36	0	0	0	0	0	0	0	0
3	0	0	2/36	2/36	1/36	0	0	0	0	0	0
4	0	0	0	2/36	2/36	2/36	1/36	0	0	0	0
5	0	0	0	0	2/36	2/36	2/36	2/36	1/36	0	0
6	0	0	0	0	0	2/36	2/36	2/36	2/36	2/36	1/36

$$p_Y(Y = 6) = 11/36$$

X	7	8	9	10	11	12
$p_X(x_j Y = 6)$	2/11	2/11	2/11	2/11	2/11	1/11

$$p_X(X = 6) = 5/36$$

Y	3	4	5
$p_Y(y_k X = 6)$	1/5	2/5	2/5

Definicja 10.9 (Gęstości warunkowe).

Niech ciągły wektor losowy (X, Y) ma łączną gęstość prawdopodobieństwa $f(x, y)$. **Gęstościami warunkowymi** nazywamy:

$$f_X(x|y) = \frac{f(x, y)}{f_Y(y)}, \quad f_Y(y|x) = \frac{f(x, y)}{f_X(x)}$$

Przykład 10.7 (Gęstości warunkowe).

Jakie są rozkłady warunkowe zmiennych losowych z przykładu 11.2?

$$f(x, y) = 8x(x + y) \quad \text{dla } C = \{(x, y) : x \geq 0 \wedge y \geq 0 \wedge x + y \leq 1\}$$

Rozwiązanie.

$$f_X(x|y) = \frac{6x(x + y)}{(1 - y^2)(y + 2)}$$

$$f_Y(y|x) = \frac{2(x + y)}{1 - x^2}$$

Definicje rozkładów warunkowych umożliwiają konstrukcję rozkładów łącznych dla zmiennych losowych zależnych.

- Dla zmiennych dyskretnych

$$p(x_j, y_k) = p_X(x_j|y_k)p_Y(y_k) = p_Y(y_k|x_j)p_X(x_j)$$

- Dla zmiennych ciągłych

$$f(x, y) = f_X(x|y)f_Y(y) = f_Y(y|x)f_X(x)$$

Przykład 10.8 (Łączna gęstość prawdopodobieństwa zmiennych zależnych).

Niech zmienną losową X będzie liczba z rozkładu jednostajnego na przedziale $[0, a]$ a Y liczba z rozkładu jednostajnego na przedziale $[x, a]$. Jaki jest rozkład prawdopodobieństwa zmiennej losowej Y ?

Zmienne losowe X i Y są statystycznie zależne znamy rozkład brzegowy zmiennej X

$$f_X(x) = \frac{1}{a} \quad 0 < x < a$$

oraz rozkład warunkowy zmiennej losowej Y

$$f_Y(y|x) = \frac{1}{a-x} \quad x < y < a$$

Zatem łączna gęstość prawdopodobieństwa ma postać

$$f(x, y) = f_Y(y|x)f_X(x) = \frac{1}{a(x-a)} \quad 0 < x < y < a$$

Rozkład brzegowy zmiennej losowej Y ma postać

$$f_Y(y) = \int_0^y \frac{1}{a(x-a)} dx = \frac{1}{a} \ln \frac{a}{a-y} \quad 0 < y < a$$

Mieszanina rozkładów

- (X, Y) - wektor losowy
- X jest ciągłą zmienną losową a Y dyskretną.
- $Y \in \{y_1, y_2, \dots\}$ o rozkładzie pr. $p(y_k)$
- $f(x|y_k) = f_k(x)$

Twierdzenie 10.3 (Mieszanina rozkładów).

Rozkład brzegowy zmiennej X ma postać:

$$f_X(x) = \sum_k f_k(x)p(y_k)$$

Dowód.

$$\begin{aligned}
 P(a < X < b) &= \sum_k P(a < X < b | Y = y_k) P(Y = y_k) \\
 &= \sum_k \int_a^b f(x|y_k) dx \cdot p(y_k) \\
 &= \sum_k \int_a^b f_k(x) dx \cdot p(y_k) \\
 &= \int_a^b \sum_k f_k(x) p(y_k) dx
 \end{aligned}$$

Zatem

$$f_X(x) = \sum_k f_k(x) p(y_k)$$

□

Przykład 10.9 (Mieszanka rozkładów).

- Y - wynik rzutu kostką do gry. Zatem $Y = \{1, 2, \dots, 6\}$; $P_Y(y) = 1/6$ dla $i = 1, \dots, 6$.
- Mając $Y = y$, losujemy X z rozkładu jednostajnego na przedziale $[0, y]$.
- Jaki jest rozkład X ?

Rozwiązanie.

$$\begin{aligned}
 f(x|y) &= \frac{1}{y} \quad 0 < x < y \\
 f_X(x) &= \sum_{y>x}^6 f(x|y) P_Y(y) = \frac{1}{6} \sum_{y>x}^6 \frac{1}{y} \quad 0 < x < 6
 \end{aligned}$$

Wartości powyższej funkcji znajdują się w poniższej tabeli:

X	[0, 1]	[1, 2]	[2, 3]	[3, 4]	[4, 5]	[5, 6]
$f_X(x)$	$\frac{147}{360}$	$\frac{87}{360}$	$\frac{57}{360}$	$\frac{37}{360}$	$\frac{22}{360}$	$\frac{10}{360}$

11 Funkcja wektora losowego

Niech (X, Y) -wektor losowy

- $Z = g(X, Y) \quad g : \mathbb{R}^2 \rightarrow \mathbb{R}$

$$p(z) = ? \quad \text{lub} \quad f(z) = ?$$

- $(U, V) = g(X, Y) \quad g : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

$$p(u, v) = ? \quad \text{lub} \quad f(u, v) = ?$$

Twierdzenie 11.1 (Funkcja dyskretnego wektora losowego).

Niech $X = \{x_1, x_2, \dots\}$ a $Y = \{y_1, y_2, \dots\}$ o łącznym rozkładzie $p(x_j, y_k) = P(X = x_j, Y = y_k)$. Wtedy $Z = g(X, Y)$ również jest *dyskretną zmienną losową* o rozkładzie prawdopodobieństwa

$$\begin{aligned} P(Z = z_l) &= P(Z = g(x_j, y_k) = z_l) \\ &= P((X, Y) = (x_j, y_k) : g(x_j, y_k) = z_l) \\ &= \sum_{(x_j, y_k) : g(x_j, y_k) = z_l} p(x_j, y_k) \end{aligned}$$

- Niech (X, Y) będzie *ciągłym* wektorem losowym o gęstości pr. $f(x, y)$.
- Niech $Z = g(X, Y)$. Jaka jest gęstość pr. zmiennej Z ?
- Najpewniejszym sposobem określenia rozkładu Z jest obliczenie dystrybucyjności F_Z .

$$\begin{aligned} F_Z(z) = P(Z \leq z) &= P(g(X, Y) \leq z) \\ &= \int_{(x, y) : g(x, y) \leq z} f(x, y) dx dy \\ f_Z(z) &= \frac{d}{dz} F_Z(z) \end{aligned}$$

Przykład 11.1 (Rozkład sumy zmiennych losowych).

Jaki jest rozkład sumy, $Z = X + Y$, *niezależnych* zmiennych losowych o rozkładach *równomiernych* na przedziale $[0, a]$?

$$\begin{aligned} f(x, y) &= f_X(x) f_Y(y) = \frac{1}{a^2} \quad C = \{0 < x < a, 0 < y < a\} \\ F_Z(z) &= \begin{cases} \int_0^z \int_0^{z-x} f(x, y) dy dx & \text{dla } 0 < z < a, \\ \int_0^{z-a} \int_0^a f(x, y) dy dx + \int_{z-a}^a \int_0^{z-x} f(x, y) dy dx & \text{dla } a < z < 2a \end{cases} \\ F_Z(z) &= \begin{cases} \frac{1}{2} \frac{z^2}{a^2} & \text{dla } 0 < z < a, \\ 2 \frac{z}{a} - \frac{1}{2} \frac{z^2}{a^2} - 1 & \text{dla } a < z < 2a \end{cases} \\ f_Z(z) &= \frac{d}{dz} F_Z(z) = \begin{cases} \frac{z}{a^2} & \text{dla } 0 < z < a, \\ \frac{2a - z}{a^2} & \text{dla } a < z < 2a \end{cases} \end{aligned}$$

Twierdzenie 11.2 (Rozkład wartości maksymalnej).

Niech (X, Y) jest *ciągłym* wektorem losowym a X i Y są *niezależne*. Dystrybucyjność zmiennej losowej $Z = \text{Max}(X, Y)$ ma postać

$$F_Z(z) = F_X(z) F_Y(z)$$

Gęstość pr. ma postać:

$$f_Z(z) = f_X(z) F_Y(z) + F_X(z) f_Y(z)$$

Twierdzenie 11.3 (Rozkład wartości minimalnej).

Dystrybucja zmiennej losowej $V = \text{Min}(X, Y)$ ma postać

$$F_V(v) = 1 - [1 - F_X(v)][1 - F_Y(v)]$$

Gęstość pr. ma postać:

$$f_V(v) = f_X(v)[1 - F_Y(v)] + [1 - F_X(v)]f_Y(v)$$

Dowód.

$$Z = \text{Max}(X, Y)$$

$$\begin{aligned} F_Z(z) = P(Z < z) &= P(\text{Max}(X, Y) < z) \\ &= P(X < z, Y < z) \\ &= P(X < z) \cdot P(Y < z) \\ &= F_X(z) \cdot F_Y(z) \end{aligned}$$

$$\begin{aligned} f_Z(z) = \frac{d}{dz} F_Z(z) &= \left[\frac{d}{dz} F_X(z) \right] F_Y(z) + F_X(z) \left[\frac{d}{dz} F_Y(z) \right] \\ &= f_X(z) F_Y(z) + F_X(z) f_Y(z) \end{aligned}$$

□

Dowód.

$$V = \text{Min}(X, Y)$$

$$\begin{aligned} F_V(v) = P(V < v) &= P(\text{Min}(X, Y) < v) \\ &= 1 - P(\text{Min}(X, Y) > v) \\ &= 1 - P(X > v, Y > v) \\ &= 1 - P(X > v) \cdot P(Y > v) \\ &= 1 - (1 - F_X(v)) \cdot (1 - F_Y(v)) \end{aligned}$$

$$\begin{aligned} f_V(v) &= \frac{d}{dv} F_V(v) \\ &= -\frac{d}{dv} [1 - F_X(v)][1 - F_Y(v)] - [1 - F_X(v)] \frac{d}{dv} [1 - F_Y(v)] \\ &= f_X(v)[1 - F_Y(v)] + [1 - F_X(v)] f_Y(v) \end{aligned}$$

□

- (X, Y) -ciągły wektor losowy o gęstości $f(x, y)$ na obszarze $C = \{(x, y) : f(x, y) > 0\}$.
- Niech $Z = \phi(X, Y)$, $W = \eta(X, Y)$; $g(z, w) = ?$
- Na ogół $g(z, w) \neq f_Z(z) \cdot f_W(w)$

Twierdzenie 11.4.

Jeśli odwzorowanie $(x, y) \rightarrow (z, w)$ jest *odwracalne* tzn.

$$x = \alpha(z, w) \quad y = \beta(z, w)$$

to

$$g(z, w) = f(\alpha(z, w), \beta(z, w)) |J| \quad \text{dla } (z, w) \in D$$

gdzie

$$J = \det \begin{bmatrix} \frac{\partial \alpha}{\partial z} & \frac{\partial \alpha}{\partial w} \\ \frac{\partial \beta}{\partial z} & \frac{\partial \beta}{\partial w} \end{bmatrix}$$

a D jest obrazem obszaru C na płaszczyźnie (z, w)

$$D = \{(z, w) : (\alpha(z, w), \beta(z, w)) \in C\}$$

Przykład 11.2 (Rozkład sumy i różnicy zmiennych losowych).

Jaki jest łączny rozkład sumy i różnicy, $Z = X + Y$; $W = X - Y$, niezależnych zmiennych losowych o rozkładach równomiernych na przedziale $[0, a]$?

- $f(x, y) = f_X(x)f_Y(y) = \frac{1}{a^2}$ $C = \{0 < x < a \wedge 0 < y < a\}$

- Układ równań: $Z = X + Y$ oraz $W = X - Y$ ma rozwiązanie w postaci

$$X = \alpha(Z, W) = \frac{Z + W}{2} \quad Y = \beta(Z, W) = \frac{Z - W}{2}$$

- Zbiór D będący obrazem zbioru C na płaszczyźnie z, w ma postać:

$$D = \{(z, w) : 0 < \frac{z + w}{2} < a \wedge 0 < \frac{z - w}{2} < a\}$$

- Jakobian transformacji ma postać:

$$J = \begin{vmatrix} \frac{\partial \alpha}{\partial z} & \frac{\partial \alpha}{\partial w} \\ \frac{\partial \beta}{\partial z} & \frac{\partial \beta}{\partial w} \end{vmatrix} = \begin{vmatrix} \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & -\frac{1}{2} \end{vmatrix} = \frac{1}{2}$$

- Łączna gęstość prawdopodobieństwa zmiennych Z, W ma postać:

$$g(z, w) = \frac{1}{2} \frac{1}{a^2} \quad D = \{0 < z + w < 2a \wedge 0 < z - w < 2a\}$$

Przykład 11.3 (Rozkład sumy i różnicy zmiennych losowych).

Jakie są rozkłady sumy i różnicy, $Z = X + Y$; $W = X - Y$, niezależnych zmiennych losowych o rozkładach równomiernych na przedziale $[0, a]$? Czy zmienne Z i W są statystycznie niezależne?

-

$$g(z, w) = \frac{1}{2} \frac{1}{a^2} \quad D = \{0 < z + w < 2a \wedge 0 < z - w < 2a\}$$

- Rozkład brzegowy zmiennej Z ma postać:

$$f_Z(z) = \begin{cases} \int_{2a-z}^z \frac{1}{2a^2} dw = \frac{z}{a^2} & 0 < z < a \\ \int_{z-2a}^{-z} \frac{1}{2a^2} dw = \frac{2a-z}{a^2} & a < z < 2a \end{cases}$$

- Rozkład brzegowy zmiennej W ma postać:

$$f_W(w) = \begin{cases} \int_{-w}^{w+2a} \frac{1}{2a^2} dz = \frac{w+a}{a^2} & -a < w < 0 \\ \int_w^{2a-w} \frac{1}{2a^2} dz = \frac{a-w}{a^2} & 0 < w < a \end{cases}$$

- Zmienne Z i W są statystycznie **zależne**