

Komputerowa Analiza Danych Doświadczalnych

Prowadząca:
dr inż. Hanna Zbroszczyk

e-mail: *gos@if.pw.edu.pl*

Tel: +48 22 234 58 51

Konsultacje:

Poniedziałek: 10.15-11.00

Środa: 11.15-12.00

www: <http://www.if.pw.edu.pl/~gos/students/kadd>

Politechnika Warszawska
Wydział Fizyki
Pok. 117b (wejście przez 115)

Zmienne losowe dwuwymiarowe

Zmienne losowe dwuwymiarowe – $f(x,y)$, $F(x,y)$

Mamy 2 zmienne losowe x oraz y , które spełniają warunek: $x < x$ oraz $y < y$

Dystrybuanta: $F(x,y) = P(x < x, y < y)$

Jeśli dystrybuanta jest funkcją ciągłych zmiennych x oraz y :

Łączna gęstość prawdopodobieństwa zmiennych losowych x, y :


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

Prawdopodobieństwo:


$$P(a \leq x < b, c \leq y < d) = \int_a^b \left[\int_c^d f(x, y) dy \right] dx$$

Zmienne losowe dwuwymiarowe – $f(x,y)$

Gestosc prawdopodobienstwa




Gestosc prawdopodobienstwa




Zmienne losowe dwuwymiarowe – $f(x,y)$, $F(x,y)$

Gęstość prawdopodobieństwa



Dystrybuanta



Zmienne losowe dwuwymiarowe – gęstości brzegowe

Mierzone są 2 zmienne losowe: x, y .

Możliwe jest doświadczalne wyznaczenie dystrybuanty $F(x, y)$.

Jaka jest zależność zmiennej x dla ustalonego y ?

$$P(a \leq x < b, -\infty < y < \infty) = \int_a^b \left[\int_{-\infty}^{\infty} f(x, y) dy \right] dx = \int_a^b g(x) dx$$

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

$g(x)$ – brzegowa gęstość prawdopodobieństwa dla zmiennej x .

Analogicznie:

$$P(-\infty < x < \infty, c < y < d) = \int_c^d \left[\int_{-\infty}^{\infty} f(x, y) dx \right] dy = \int_c^d h(y) dy$$

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


$h(y)$ – brzegowa gęstość prawdopodobieństwa dla zmiennej y .

Dystrybuanty brzegowe.


$$F_X(x) = \lim_{y \rightarrow \infty} F(x, y)$$

$$F_Y(y) = \lim_{x \rightarrow \infty} F(x, y)$$


Gestosc prawdopodobienstwa $f(x,y)$




Dystrybuanta



Gestosc brzegowa $g(x)$



Gestosc brzegowa $h(y)$



Zmienne losowe dwuwymiarowe – niezależność zmiennych

Niezależność zmiennych losowych:

$$f(x, y) = g(x)h(y)$$

Prawdopodobieństwo warunkowe dla zmiennej y przy znanej wartości x :

$$P(y \leq y < y + dy | x \leq x < x + dx)$$


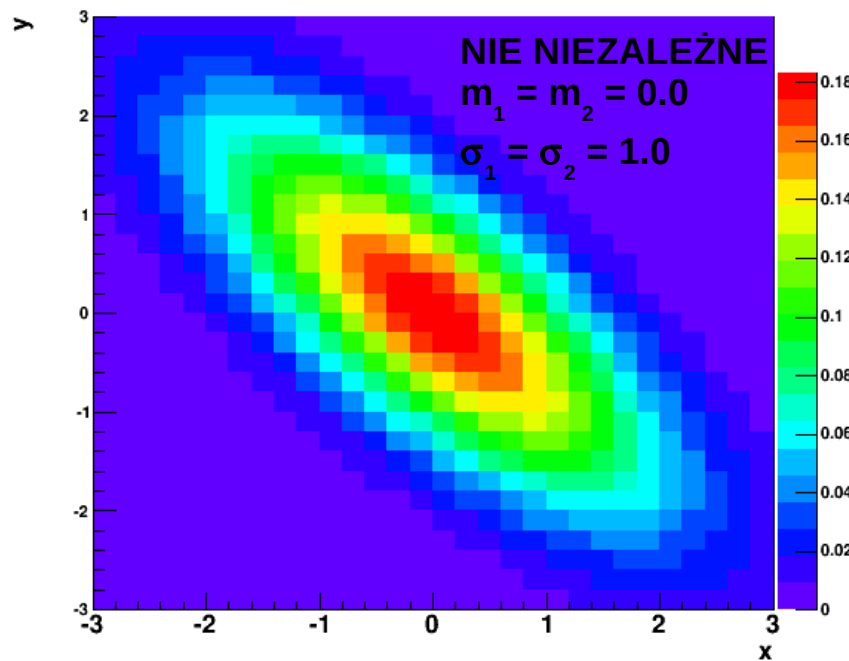

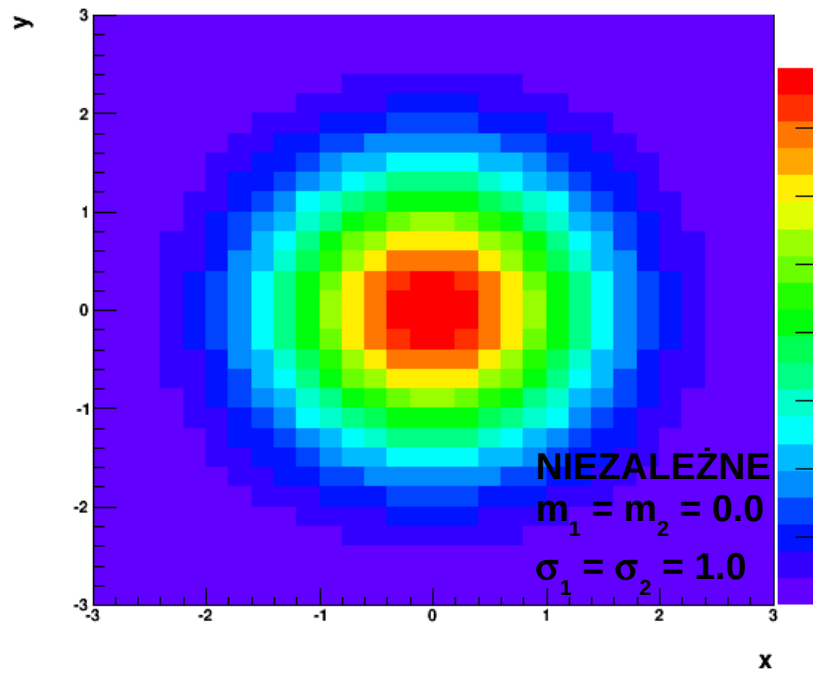
Gęstość prawdopodobieństwa warunkowego:

$$f(x|y) = \frac{f(x, y)}{g(x)}$$

Prawdopodobieństwo warunkowe:

$$P(y \leq y < y + dy | x \leq x < x + dx) = f(x|y) dy$$

Zmienne losowe dwuwymiarowe – niezależność zmiennych



Gęstość prawdopodobieństwa warunkowego

Prawdopodobieństwo całkowite:

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

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

Dla zmiennych niezależnych:

$$f(y|x) = \frac{f(x, y)}{g(x)} = \frac{g(x)h(y)}{g(x)} = h(y)$$

$$f(x|y) = \frac{f(x, y)}{h(y)} = \frac{g(x)h(y)}{h(y)} = g(x)$$

Warunek narzucony na jedną zmienną nie może mieć wpływu na drugą zmienną.

Wartości oczekiwane rozkładu dwuwymiarowego

Wartość oczekiwana funkcji $H(x,y)$ zmiennych losowych x, y :

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

Wariancja:

$$\sigma^2\{H(x, y)\} = E\{[H(x, y) - E(H(x, y))]^2\}$$

Jeśli:

$$H(x, y) = a x + b y$$

To:

$$E(a x + b y) = a E(x) + b E(y)$$

Wartości oczekiwane rozkładu dwuwymiarowego - momenty

Wartości oczekiwane dla funkcji iloczynowych:

$$H(x, y) = x^l y^m \quad l, m - \text{liczny całkowite nieujemne}$$

to momentami rzędu l oraz m względem x oraz y .

$$\lambda_{lm} = E(x^l y^m)$$

Uogólniając:

$$H(x, y) = (x - a)^l (y - b)^m$$

Wartości oczekiwane:

$$\alpha_{lm} = E\{(x - a)^l (y - b)^m\}$$

To momenty rzędu l oraz m względem punktów a oraz b .

Momenty rozkładów dwuwymiarowych, kowariancja

Najważniejsze momenty:

$$\mu_{lm} = E\{(\mathbf{x} - \lambda_{10})^l (\mathbf{y} - \lambda_{01})^m\}$$

$$\mu_{00} = 1$$

$$\mu_{11} = 0$$

$$\lambda_{10} = E(\mathbf{x}) = \hat{\mathbf{x}}$$

$$\lambda_{01} = E(\mathbf{y}) = \hat{\mathbf{y}}$$

$$\mu_{11} = E\{(\mathbf{x} - \hat{\mathbf{x}})(\mathbf{y} - \hat{\mathbf{y}})\} = \text{cov}(\mathbf{x}, \mathbf{y})$$

$$\mu_{20} = E\{(\mathbf{x} - \hat{\mathbf{x}})^2\} = \sigma^2(\mathbf{x})$$

$$\mu_{02} = E\{(\mathbf{y} - \hat{\mathbf{y}})^2\} = \sigma^2(\mathbf{y})$$

Wariancja, wartość oczekiwana rozkładu dwuwymiarowego

Wariancja rozkładu $ax + by$:

$$\sigma^2(ax + by) = E\{[(ax + by) - E(ax + by)]^2\} = E\{[a(x - \hat{x}) + b(y - \hat{y})]^2\}$$

$$\sigma^2(ax + by) = E\{a^2(x - \hat{x})^2 + b^2(y - \hat{y})^2 + 2ab(x - \hat{x})(y - \hat{y})\}$$

$$\sigma^2(ax + by) = a^2\sigma^2(x) + b^2\sigma^2(y) + 2ab\text{cov}(x, y)$$

Kiedy funkcja $H(x, y)$ jest postaci iloczynowej:

$$H(x, y) = x y$$

W celu wyznaczenia wartości oczekiwanej, zakładamy niezależność zmiennych x oraz y :

$$E(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x y g(x) h(y) dx dy = \left(\int_{-\infty}^{\infty} x g(x) dx\right) \left(\int_{-\infty}^{\infty} y h(y) dy\right)$$

Czyli zachodzi związek:



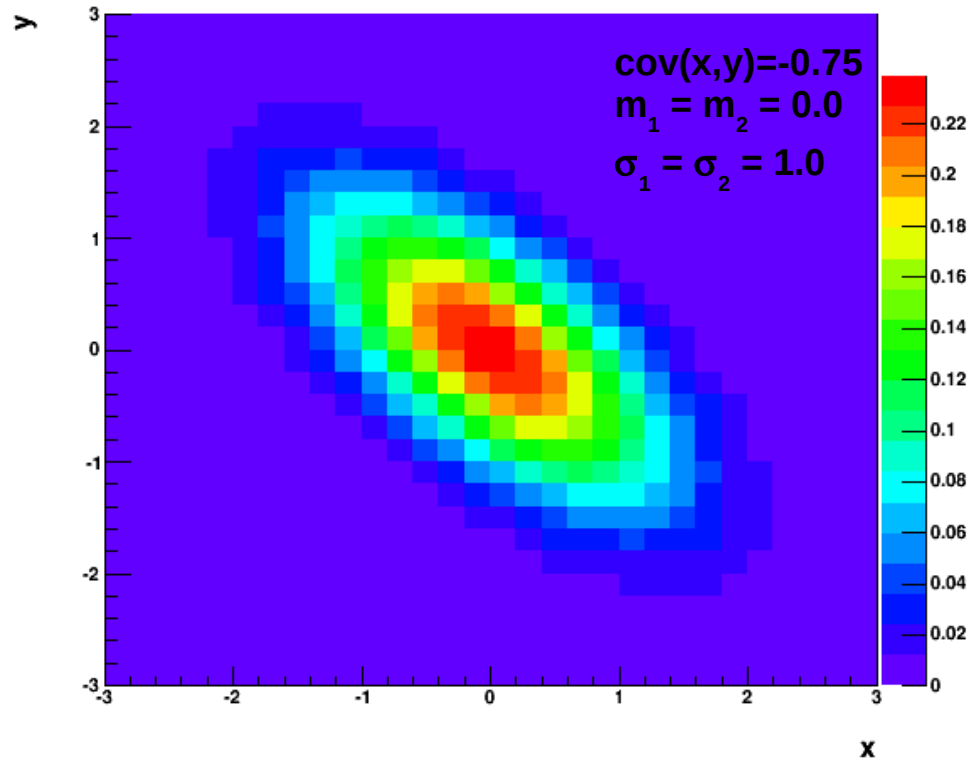

$$E(x, y) = E(x)E(y)$$

Charakterystyki rozkładu dwuwymiarowego


Wielkości: $E(x)$, $E(y)$, $\sigma^2(x)$, $\sigma^2(y)$ są podobne do analogicznych wielkości zdefiniowanych w przypadku jednej zmiennej.

- Kowariancja $\text{cov}(x,y)$ nie ma odpowiednika w dziedzinie funkcji jednej zmiennej.
- Kowariancja $\text{cov}(x,y)$ jest dodatnia, kiedy: $x > \hat{x}$ oraz $y > \hat{y}$
- Kowariancja $\text{cov}(x,y)$ jest ujemna, kiedy: $x > \hat{x}$ oraz $y < \hat{y}$
- Jeśli znajomość wartości x nie daje żadnej informacji o wartości y , kowariancja jest równa zeru.


$$\sigma^2(a x + b y) = E \{ [(a x + b y) - E(a x + b y)]^2 \} = E \{ [a(x - \hat{x}) + b(y - \hat{y})]^2 \}$$




$\text{cov}(x,y)=0.0$
 $m_1 = m_2 = 0.0$
 $\sigma_1 = \sigma_2 = 1.0$




$\text{cov}(x,y)=-0.75$
 $m_1 = m_2 = 0.0$
 $\sigma_1 = \sigma_2 = 1.0$



$\text{cov}(x,y)=-0.5$
 $m_1 = m_2 = 0.0$
 $\sigma_1 = \sigma_2 = 1.0$



$\text{cov}(x,y)=0.5$
 $m_1 = m_2 = 0.0$
 $\sigma_1 = \sigma_2 = 1.0$



Współczynnik korelacji

Współczynnik korelacji:

$$\rho(x, y) = \frac{\text{cov}(x, y)}{\sigma(x)\sigma(y)}$$

Kowariancja i współczynnik korelacji to miary współzależności x oraz y .

Dowodziemy, że $-1 \leq \rho(x, y) \leq 1$

Wprowadzamy zmienne losowe zredukowane: $u = \frac{x - \hat{x}}{\sigma(x)}$ $v = \frac{y - \hat{y}}{\sigma(y)}$

Wariancja: $\sigma^2(u + v) = \sigma^2(u) + \sigma^2(v) + 2\rho(u, v)\sigma(u)\sigma(v)$

Ponieważ: $\sigma^2(u) = \sigma^2(v) = 1$

$$\sigma^2(u + v) = 2(1 + \rho(u, v))$$

$$\sigma^2(u - v) = 2(1 - \rho(u, v))$$

Współczynnik korelacji

Wariancja jest nieujemna oraz $\rho(u, v) = \rho(x, y)$ oraz $-1 \leq \rho(x, y) \leq 1$

Zbadajmy wartości krańcowe: $\rho(u, v) = \pm 1$

Kiedy $\rho(u, v) = 1$ wariancja znika $\sigma(u - v) = 0$ zmienna losowa $(u - v) = \text{const}$

$$(u - v) = \frac{x - \hat{x}}{\sigma(x)} - \frac{y - \hat{y}}{\sigma(y)} = \text{const}$$

Równanie jest spełnione, kiedy:





$$y = a + b x$$

Współczynnik a jest dowolną liczbą rzeczywistą, b jest liczbą rzeczywistą dodatnią,

Współczynnik korelacji $\rho(x, y) = +1$

Współczynnik a jest dowolną liczbą rzeczywistą, b jest liczbą rzeczywistą ujemną,

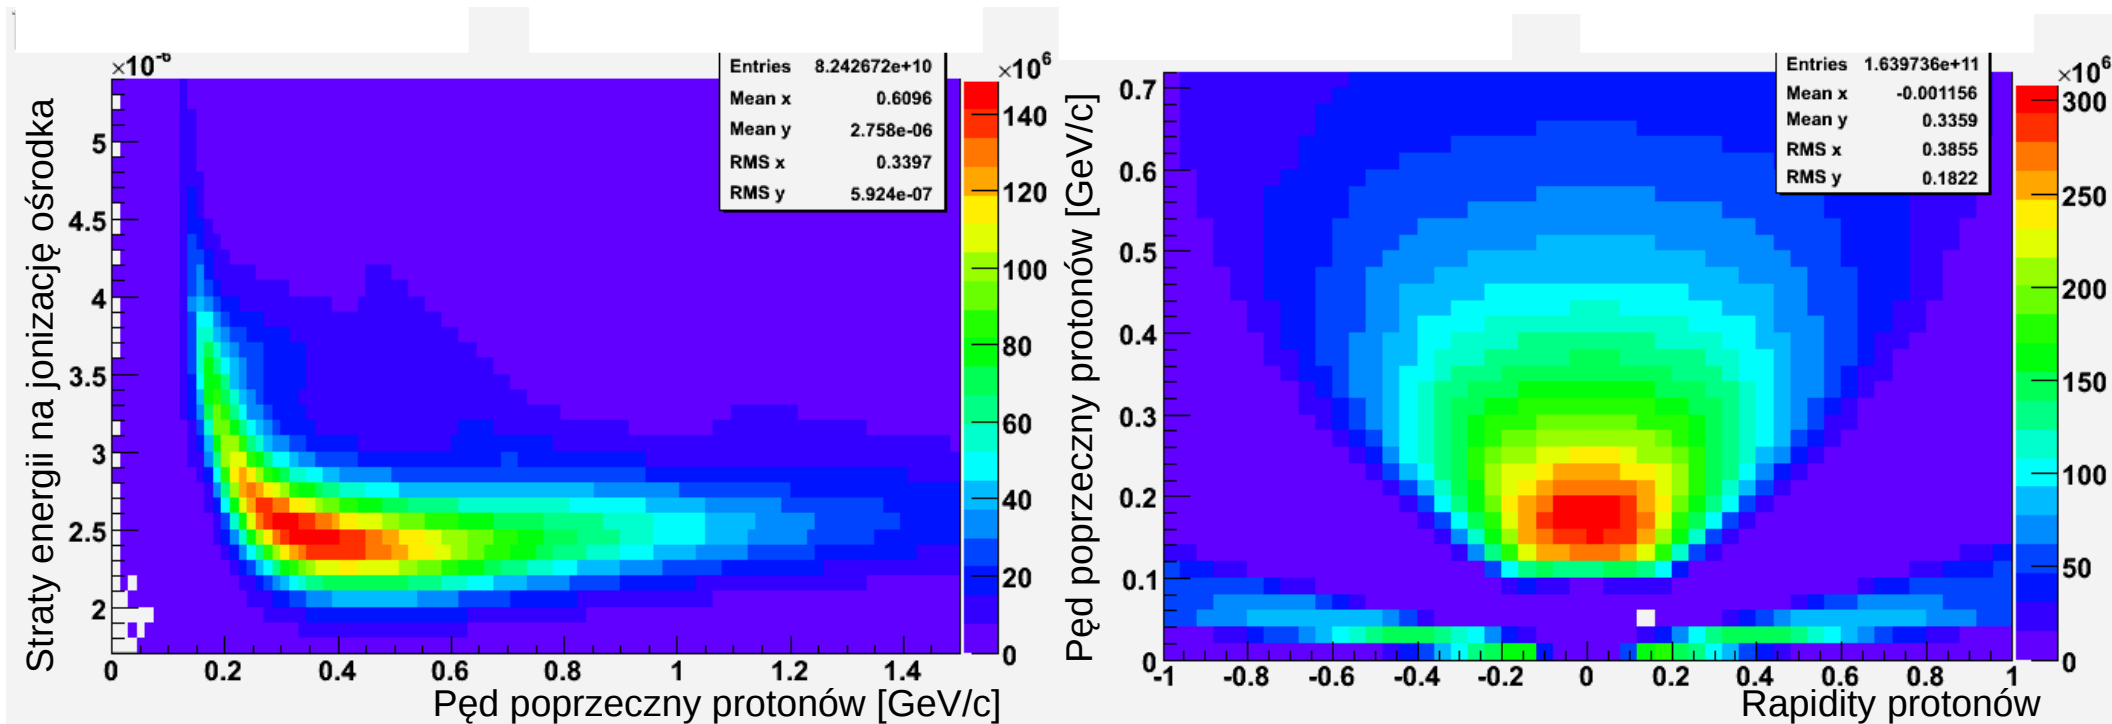
Współczynnik korelacji $\rho(x, y) = -1$



Rozkłady zmiennej losowej dwuwymiarowej

Dla dwóch zmiennych niezależnych kowariancja (i współczynnik korelacji) wynosi 0.

$$\text{cov}(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \hat{x})(y - \hat{y}) g(x) h(y) dx dy = \left(\int_{-\infty}^{\infty} (x - \hat{x}) g(x) dx \right) \left(\int_{-\infty}^{\infty} (y - \hat{y}) h(y) dy \right) = 0$$



$$Y = \frac{1}{2} \ln \frac{E + p_L}{E - p_L}$$

Zmienne losowe N-wymiarowe

Rozkłady wielu zmiennych losowych – dystrybuanta, gęstość prawdopodobieństwa

Dystrybuanta dla n zmiennych losowych x_1, x_2, \dots, x_n

$$F(x_1, x_2, \dots, x_n) = P(x_1 < x_1, x_2 < x_2, \dots, x_n < x_n)$$

Jeśli dystrybuanta jest funkcją ciągłą oraz posiada pochodne cząstkowe względem x_i ,

Łączna gęstość prawdopodobieństwa:

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

Gęstość rozkładu brzegowego:

$$g_r(x_r) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_{r-1} dx_{r+1} \dots dx_n$$

To gęstość prawdopodobieństwa zmiennej x_r .

Rozkłady wielu zmiennych losowych – ciąg dalszy

$H(x_1, x_2, \dots, x_n)$ - dowolna funkcja n zmiennych

Wartość oczekiwana:

$$E\{H(x_1, x_2, \dots, x_n)\} = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} H(x_1, x_2, \dots, x_n) f(x_1, x_2, \dots, x_n) dx_1 \dots dx_n$$

Jeśli $H(x) = x_r$ to:

$$E\{x_r\} = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} x_r f(x_1, x_2, \dots, x_n) dx_1 \dots dx_n$$

$$E\{x_r\} = \int_{-\infty}^{\infty} x_r g_r(x_r) dx_r$$

Niezależność zmiennych losowych:

$$f(x_1, x_2, \dots, x_n) = g_1(x_1)g_2(x_2)\dots g_n(x_n)$$

Łączna gęstość rozkładu brzegowego dla dowolnych l spośród n zmiennych ($l < n$):

$$g(x_1, x_2, \dots, x_l) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, x_2, \dots, x_n) dx_{l+1} \dots dx_n$$

Zmienne x_1, x_2, \dots, x_l są niezależne, kiedy:

$$g(x_1, x_2, \dots, x_l) = g_1(x_1)g_2(x_2)\dots g_l(x_l)$$

Rozkłady wielu zmiennych losowych - momenty

Momenty rzędu l_1, l_2, \dots, l_n to wartości oczekiwane funkcji:

$$H = x_1^{l_1} x_2^{l_2} \dots x_n^{l_n}$$

Oznaczamy je przez:

$$\lambda_{l_1 l_2 \dots l_n} = E(x_1^{l_1} x_2^{l_2} \dots x_n^{l_n})$$

W szczególności: $\lambda_{100\dots 0} = E(x_1) = \hat{x}_1$

$$\lambda_{010\dots 0} = E(x_2) = \hat{x}_2$$

$$\lambda_{000\dots 1} = E(x_n) = \hat{x}_n$$

Momenty (momenty centralne) względem wartości średnich:

$$\mu_{l_1 l_2 \dots l_n} = E\{(x_1 - \hat{x}_1)^{l_1} (x_2 - \hat{x}_2)^{l_2} \dots (x_n - \hat{x}_n)^{l_n}\}$$

Rozkłady wielu zmiennych losowych – momenty c.d.

Wariancje:

$$\mu_{200\dots 0} = \mathbb{E}\{(\mathbf{x}_1 - \hat{\mathbf{x}}_1)^2\} = \sigma^2(\mathbf{x}_1)$$

$$\mu_{020\dots 0} = \mathbb{E}\{(\mathbf{x}_2 - \hat{\mathbf{x}}_2)^2\} = \sigma^2(\mathbf{x}_2)$$

$$\mu_{000\dots 2} = \mathbb{E}\{(\mathbf{x}_n - \hat{\mathbf{x}}_n)^2\} = \sigma^2(\mathbf{x}_n)$$

Moment centralny dla $l_i = l_j = 1$ oraz $l_k = 0$ (i, k, j są różne), **kowariancja** między x_i, x_j

$$c_{ij} = \text{COV}(x_i, x_j) = \mathbb{E}\{(\mathbf{x}_i - \hat{\mathbf{x}}_i)(\mathbf{x}_j - \hat{\mathbf{x}}_j)\}$$

Notacja wektorowa dla zmiennych losowych n-wymiarowych

Reprezentacja n zmiennych x_1, x_2, \dots, x_n jako składowych wektora \mathbf{x} w przestrzeni n-wymiarowej.

Dystrybuanta: $F = F(\mathbf{x})$

Gęstość prawdopodobieństwa: $f(\mathbf{x}) = \frac{\partial^n}{\partial x_1 \partial x_2 \dots \partial x_n} F(\mathbf{x})$

Wartość oczekiwana: $E\{H(\mathbf{x})\} = \int H(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}$

Macierz kowariancji:
$$C = \begin{bmatrix} C_{11} & C_{12} & \dots & C_{1n} \\ C_{21} & C_{22} & \dots & C_{2n} \\ \dots & \dots & \dots & \dots \\ C_{n1} & C_{n2} & \dots & C_{nn} \end{bmatrix}$$

Elementy C_{ij} to współczynniki kowariancji, elementy diagonalne macierzy, to $C_{ii} = \sigma^2(x_i)$

Notacja wektorowa dla zmiennych losowych n-wymiarowych

Macierz kowariancji to macierz symetryczna: $C_{ij} = C_{ji}$

Wartości oczekiwane: $E(\mathbf{x}) = \hat{\mathbf{x}}$

Element macierzy kowariancji: $C_{ij} = E\{(\mathbf{x}_i - \hat{\mathbf{x}}_i)(\mathbf{x}_j - \hat{\mathbf{x}}_j)^T\}$

Jest to wartość średnia elementu o wskaźnikach ij iloczynu diadycznego wektorów:

$$(\mathbf{x}_i - \hat{\mathbf{x}}_i)(\mathbf{x}_j - \hat{\mathbf{x}}_j)^T$$

$$\mathbf{x}^T = (\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_n)$$

$$\mathbf{x} = \begin{pmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \dots \\ \mathbf{x}_n \end{pmatrix}$$

Macierz kowariancji: $C = E\{(\mathbf{x} - \hat{\mathbf{x}})(\mathbf{x} - \hat{\mathbf{x}})^T\}$