

12 Własności wartości oczekiwanej

Twierdzenie 12.1 (Wartość oczekiwana funkcji wektora losowego).

Jeśli znamy rozkład łączny wektora (X, Y) to wartość oczekiwana funkcji $Z = g(X, Y)$ wynosi:
Dla zmiennych dyskretnych

$$E[Z] = \sum_{j,k} g(x_j, y_k) P(X = x_j, Y = y_k)$$

a dla zmiennych ciągłych

$$\begin{aligned} E[Z] &= \int_{-\infty}^{\infty} \left[\int_{-\infty}^{\infty} g(x, y) f(x, y) dx \right] dy \\ &= \int_{-\infty}^{\infty} \left[\int_{-\infty}^{\infty} g(x, y) f(x, y) dy \right] dx \end{aligned}$$

Twierdzenie 12.2 (Liniowa kombinacja zmiennych losowych).

Dla dowolnych zmiennych losowych zachodzi:

- $E[X + Y] = E[X] + E[Y]$
- $E[X_1 + X_2 + \dots + X_n] = E[X_1] + E[X_2] + \dots + E[X_n]$
- $E \left[\sum_i \alpha_i X_i + \beta \right] = \sum_i \alpha_i E[X_i] + \beta$

Twierdzenie 12.3 (Wartość oczekiwana iloczynu zmiennych losowych).

Jeśli zmienne losowe są statystycznie *niezależne* to:

$$E[XY] = E[X]E[Y]$$

Dowód.

$$\begin{aligned} E[XY] &= \iint_{-\infty}^{\infty} xy f(x, y) dx dy \\ &= \iint_{-\infty}^{\infty} xy f_x(x) f_Y(y) dx dy \\ &= \left[\int_{-\infty}^{\infty} x f_x(x) dx \right] \times \left[\int_{-\infty}^{\infty} y f_Y(y) dy \right] \\ &= E[X]E[Y] \end{aligned}$$

□

Powyższe twierdzenie obowiązuje dla zmiennych losowych statystycznie niezależnych. Zatem różnicę $E[XY] - E[x]E[y]$ można interpretować jak miarę zależności zmiennych losowych podobnie jak różnicę $P(A \cap B) - P(A)P(B)$ interpretujemy jako miarę zależności zdarzeń losowych.

Twierdzenie 12.4 (Wariancja sumy zmiennych losowych).

Przyjmijmy, że $\mu_X = E[X]$ oraz $\mu_Y = E[Y]$

$$\begin{aligned} \text{Var}[X + Y] &= E \left[(X + Y - (\mu_X + \mu_Y))^2 \right] \\ &= E \left[((X - \mu_X) + (Y - \mu_Y))^2 \right] \\ &= E \left[(X - \mu_X)^2 + 2(X - \mu_X)(Y - \mu_Y) + (Y - \mu_Y)^2 \right] \\ &= \text{Var}[X] + \text{Var}[Y] + 2E[(X - \mu_X)(Y - \mu_Y)] \end{aligned}$$

Ostatni człon powyższego wyrażenia odgrywa bardzo ważną rolę gdyż na mocy twierdzenia 13.3 przyjmuje wartość zerową dla zmiennych statystycznie niezależnych.

Definicja 12.1 (Kowariancja).

Kowariancją nazywamy wielkość

$$\text{Cov} [X, Y] = E[(X - \mu_X)(Y - \mu_Y)] = E[XY] - \mu_X \mu_Y$$

Zmienne losowe nazywamy **nieskorelowanymi** jeśli $\text{Cov} [X, Y] = 0$

Zmienne losowe niezależne są nieskorelowane. Zmienne losowe nieskorelowane mogą być statystycznie zależne.

Twierdzenie 12.5 (Kombinacja liniowa zmiennych losowych).

Dla dowolnych zmiennych losowych zachodzi:

- $\text{Var} [X + Y] = \text{Var} [X] + \text{Var} [Y] + 2\text{Cov} [X, Y]$
- $\text{Var} [X_1 + X_2 + \dots + X_n] = \sum_{i=1}^n \text{Var} [X_i] + 2 \sum_{i < j} \text{Cov} [X_i, X_j]$
- $\text{Var} \left[\sum_i \alpha_i X_i + \beta \right] = \sum_i \alpha_i^2 \text{Var} [X_i] + 2 \sum_{i < j} \alpha_i \alpha_j \text{Cov} [X_i, X_j]$

Kowariancja jest uogólnionym pojęciem wariancji:

$$\text{Cov} [X, X] = E[(X - \mu_X)(X - \mu_X)] = \text{Var} [X]$$

Twierdzenie 12.6 (Liniowa kombinacja zmiennych losowych).

$$\text{Niech } X = \sum_{i=1}^n \alpha_i X_i + \beta \quad Y = \sum_{j=1}^m \gamma_j Y_j + \delta$$

$$\text{Cov} [X, Y] = \sum_{i=1}^n \sum_{j=1}^m \alpha_i \gamma_j \text{Cov} [X_i, Y_j]$$

Kowariancja zmiennych statystycznie zależnych przyjmuje wartości zależne od wariancji tych zmiennych, aby móc porównywać stopień zależności różnych zmiennych losowych analizuje się kowariancje między zmiennymi standaryzowanymi

Definicja 12.2 (Współczynnik korelacji).

Współczynnikiem korelacji pomiędzy zmiennymi losowymi X i Y nazywamy kowariancję zmiennych standaryzowanych:

$$\rho(X, Y) = \text{Cov} \left[\frac{X - \mu_X}{\sqrt{\text{Var} [X]}}, \frac{Y - \mu_Y}{\sqrt{\text{Var} [Y]}} \right] = \frac{\text{Cov} [X, Y]}{\sqrt{\text{Var} [X] \text{Var} [Y]}}$$

Przykład 12.1 (Współczynnik korelacji).

Niech U, V, W będą **niezależnymi** zmiennymi losowymi oraz: $\text{Var} [U] = \sigma_u^2$, $\text{Var} [v] = \sigma_v^2$, $\text{Var} [W] = \sigma_w^2$. Niech $X = U + W$ oraz $Y_{\pm} = V \pm W$, $\rho(X, Y_{\pm}) = ?$

Na mocy twierdzenia 13.5

$$\text{Var} [X] = \sigma_u^2 + \sigma_w^2; \quad \text{Var} [Y_{\pm}] = \sigma_v^2 + \sigma_w^2$$

a na mocy twierdzenia 13.6

$$\begin{aligned}\text{Cov}[X, Y_{\pm}] &= \text{Cov}[U, V] \pm \text{Cov}[U, W] + \text{Cov}[W, V] \pm \text{Cov}[W, W] \\ &= \pm \text{Var}[W] = \pm \sigma_w^2\end{aligned}$$

Zatem

$$\rho(X, Y_{\pm}) = \frac{\pm \sigma_w^2}{\sqrt{(\sigma_u^2 + \sigma_w^2)(\sigma_v^2 + \sigma_w^2)}} = \frac{\pm 1}{\sqrt{(\frac{\sigma_u^2}{\sigma_w^2} + 1)(\frac{\sigma_v^2}{\sigma_w^2} + 1)}}$$

Dla $\sigma_w^2 \gg \sigma_u^2, \sigma_v^2$ współczynnik korelacji przyjmuje wartość ± 1 .

Dla $\sigma_w^2 \ll \sigma_u^2, \sigma_v^2$ współczynnik korelacji przyjmuje wartość 0.

Twierdzenie 12.7 (Własności współczynnika korelacji).

- $-1 \leq \rho(X, Y) \leq 1$
- $|\rho(X, Y)| = 1$ wtedy i tylko wtedy gdy $Y = \alpha X + \beta$; $\alpha \neq 0$

Dowód. Wariancja jest wielkością nieujemną, rozpatrzmy wariancję sumy i różnicy standaryzowanych zmiennych losowych:

$$\begin{aligned}0 &< \text{Var} \left[\frac{X}{\sqrt{\text{Var}[X]}} \pm \frac{Y}{\sqrt{\text{Var}[Y]}} \right] \\ &= \frac{\text{Var}[X]}{\text{Var}[X]} + \frac{\text{Var}[Y]}{\text{Var}[Y]} \pm 2 \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}[X]\text{Var}[Y]}} \\ &= 2 \pm 2\rho(X, Y)\end{aligned}$$

□

Z powyższej nierówności wynika pierwsza własność współczynnika korelacji.

Dowód. Dla $Y = \alpha X + \beta$

$$\begin{aligned}\rho(X, Y) &= \rho(X, \alpha X + \beta) \\ &= \frac{\alpha \text{Cov}[X, X]}{\sqrt{\text{Var}[X] \alpha^2 \text{Var}[X]}} \\ &= \frac{\alpha \text{Var}[X]}{|\alpha| \text{Var}[X]} \\ &= \frac{\alpha}{|\alpha|} \\ &= \pm 1 \text{ dla } \alpha \neq 0\end{aligned}$$

□

13 Wybrane rozkłady prawdopodobieństwa


Definicja 13.1 (Rozkład dwumianowy).

Jeśli X ma rozkład prawdopodobieństwa:

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad k = 0, 1, 2, \dots, n$$

to mówimy, że ma rozkład **dwumianowy** o parametrach n i p ($n = 1, 2, \dots$, $0 < p < 1$)

- oznaczmy go jako $\text{bin}(n, p)$;
- X opisuje ilość sukcesów w n niezależnych próbach;
- p jest prawdopodobieństwem sukcesu w pojedynczej próbie.



Rysunek 8: Przykłady rozkładu dwumianowego dla różnych wartości parametru p

Twierdzenie 13.1 (Rozkład dwumianowy).

Niech $X \sim \text{bin}(n, p)$

$$E[X] = np; \quad \text{Var}[X] = np(1 - p)$$

Dowód.

$$\begin{aligned}
 E[X] &= \sum_{k=0}^n k \binom{n}{k} p^k (1-p)^{n-k} \\
 &= \sum_{k=1}^n k \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} \\
 &= np \sum_{k=1}^n \frac{(n-1)!}{(k-1)!((n-1)-(k-1))!} p^{k-1} (1-p)^{(n-1)-(k-1)} \\
 &= np \sum_{l=0}^{n-1} \frac{(n-1)!}{l!((n-1)-l)!} p^l (1-p)^{(n-1)-l} \quad l = k-1 \\
 &= np \sum_{l=0}^{n-1} \binom{n-1}{l} p^l (1-p)^{(n-1)-l} \\
 &= np \sum_{l=0}^{n-1} \text{bin}(n-1, p) = np
 \end{aligned}$$

□

$$\begin{aligned}
E[X^2] &= \sum_{k=0}^n k^2 \binom{n}{k} p^k (1-p)^{n-k} \\
&= \sum_{k=1}^n k^2 \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} \\
&= np \sum_{k=1}^n k \frac{(n-1)!}{(k-1)!((n-1)-(k-1))!} p^{k-1} (1-p)^{(n-1)-(k-1)} \\
&= np \sum_{l=0}^{n-1} (l+1) \frac{(n-1)!}{l!((n-1)-l)!} p^l (1-p)^{(n-1)-l} \quad l = k-1 \\
&= np \sum_{l=0}^{n-1} (l+1) \binom{n-1}{l} p^l (1-p)^{(n-1)-l} \\
&= np \left[\sum_{l=0}^{n-1} l \binom{n-1}{l} p^l (1-p)^{(n-1)-l} + \sum_{l=0}^{n-1} \binom{n-1}{l} p^l (1-p)^{(n-1)-l} \right] \\
&= np[(n-1)p + 1] = n^2 p^2 + np(1-p) \\
\text{Var}[X] &= E[X^2] - E[X]^2 = np(1-p)
\end{aligned}$$

Definicja 13.2 (Rozkład geometryczny).

Jeśli X ma rozkład prawdopodobieństwa:

$$P(X = k) = p(1-p)^{k-1} \quad k = 1, 2, \dots,$$

to mówimy, że ma rozkład **geometryczny** o parametrze p ($0 < p < 1$)

- oznaczymy go jako $\text{geom}(p)$;
- X opisuje **ilość niezależnych** prób zanim pojawi się pierwszy sukces;
- p jest **prawdopodobieństwem** sukcesu w pojedynczej próbie.

Twierdzenie 13.2 (Rozkład geometryczny).

Niech $X \sim \text{geom}(p)$

$$E[X] = \frac{1}{p}; \quad \text{Var}[X] = \frac{1-p}{p^2}$$


Definicja 13.3 (Rozkład Poissona).

Jeśli X ma rozkład prawdopodobieństwa:

$$P(X = k) = e^{-\mu} \frac{\mu^k}{k!} \quad k = 0, 1, 2, \dots,$$

to mówimy, że ma rozkład **Poissona** o parametrze μ ($\mu > 0$)

- oznaczymy go jako $\text{Poi}(\mu)$;
- X opisuje **ilość** wystąpień **nieprzewidywalnych** najczęściej **rzadkich** zdarzeń w przeciągu **krótkiego** okresu czasu lub w **małym** obszarze przestrzeni;



Rysunek 9: Przykłady rozkładu geometrycznego dla różnych wartości parametru p

- μ jest intensywnością zdarzenia.

Twierdzenie 13.3 (Rozkład Poissona).

Niech $X \sim Poi(\mu)$

$$E[X] = \mu; \quad Var[X] = \mu$$

Twierdzenie 13.4 (Rozkład Poissona a rozkład dwumianowy).

Jeśli w rozkładzie dwumianowym $n \rightarrow \infty$ i $p \rightarrow 0$ w taki sposób, że $0 < np < \infty$ wtedy

$$\lim_{n \rightarrow \infty} bin(n, p) = Poi(\mu = np)$$