

14.04.2021

$$\mathbb{E} X \stackrel{\text{def}}{=} \int_{\Omega} X(\omega) dP(\omega) = \int_{\mathbb{R}} x d\mu_X(x)$$

Przykład Ile średnio musimy wykonać rzut kostką, aby otrzymać 6?

Ogólniej: sukces z prawdopodobieństwem p , ile razy musimy wykonać doświadczenie, aby otrzymać sukces?

X - l. prób do pierwszego sukcesu.


$$P[X=k] = (1-p)^{k-1} \cdot p, \quad k \geq 1$$

$$X \sim \text{Geom}(p)$$

$$\mathbb{E} X = \sum_{k=1}^{\infty} P[X=k] = \sum_{k=1}^{\infty} k(1-p)^{k-1} p =$$

$$= \frac{p}{1-p} \cdot \sum_{k=1}^{\infty} k(1-p)^k$$


Przykład Trosnąmy talie 52 kart metodą
 TOP TO RANDOM, tzn. kartę z góry
 wkładamy w losowe miejsce w talii,
 a następnie powtarzamy czynność.
 Ile należy wykonać tasowań, żeby
 talie uznać za posortowaną?



Z lematu B-C wynika, że w pewnym
 momencie karta z góry zostanie
 włożona pod kartę A.


Z przykładu wiemy, że l. oczekiwanych
 kroków wynosi 52.

Po pewnej l. operacji kolejna karta znajdzie się pod A. (teraz pstwo to $\frac{2}{52}$, więc powinno się to stać po 26 krokach)



Pod A mamy B lub C.

Obie te możliwości są równie prawdopodobne. Potem trafi pod A następną kartę i znowu karty pod nią są dobrze potasowane.



Niech X_i - czas, który karta A spędza
na i -tej pozycji. $E X_i =$

$$E X = E[X_1 + X_2 + \dots + X_{52}] = \sum_{i=1}^{52} E X_i = 52 + \frac{52}{2} + \dots + 1 =$$

$$= 52 \left(1 + \frac{1}{2} + \dots + \frac{1}{52} \right) = 52 \cdot \sum_{i=1}^{52} \frac{1}{i} \sim 52 \cdot (\log 52 + \gamma)$$

$$\sim 235$$

$\log 52 + \gamma$ stała
eulera

Definicja 5.8 Niech X będzie zmienną
losową taką, że $E X^2 < \infty$. Liczbę

$$\text{Var } X = E[(X - EX]^2)$$

nazywamy wariancją zmienną losową X .

Pierwiastek z wariancji nazywamy

odchyleniem standardowym

$$\sigma = \sqrt{\text{Var } X}$$

TW. 5.9 X - zm. los. t. ie $\mathbb{E}X^2 < \infty$. Wtedy

1. $\text{Var } X < \infty$

2. $\text{Var } X = \mathbb{E}X^2 - (\mathbb{E}X)^2$

3. $\text{Var } X \geq 0$

4. $\text{Var}(aX) = a^2 \text{Var } X$

5. $\text{Var}(X + a) = \text{Var } X$

6. $\text{Var } X = 0 \iff \mathbb{P}[X = c] = 1$ dla pewnego c

7. Jeżeli X, Y niez. to $\text{Var}(X + Y) = \text{Var } X + \text{Var } Y$

D-o. 7. $\text{Var}(X + Y) = \mathbb{E}[X + Y - \mathbb{E}(X + Y)]^2 =$

$$\stackrel{(2)}{=} \mathbb{E}(X + Y)^2 - (\mathbb{E}(X + Y))^2 = \mathbb{E}X^2 + 2\mathbb{E}X \cdot Y + \mathbb{E}Y^2 - (\mathbb{E}X)^2 - 2\mathbb{E}X \cdot Y - (\mathbb{E}Y)^2 = \mathbb{E}X^2 - (\mathbb{E}X)^2 + \mathbb{E}Y^2 - (\mathbb{E}Y)^2 = \text{Var } X + \text{Var } Y \quad \blacksquare$$

Jeżeli X ma rozkład dyskretny

$\mathbb{P}[X = x_i] = p_i, \quad m = \mathbb{E}X = \sum x_i p_i, \quad \text{to}$

$$\text{Var } X = \sum p_i (x_i - m)^2 = \left(\sum p_i x_i^2 \right) - m^2$$

Jeżeli X ma rozkład abs. ciągły z gęstością g , $m = EX = \int xg(x)dx$, to
$$\text{Var } X = \int_{\mathbb{R}} (x-m)^2 g(x) dx = \int_{\mathbb{R}} x^2 g(x) dx - m^2$$

Przykład X ma rozkład dwumianowy z par. n i p , $X \sim \text{Bin}(n, p)$.

Zdefiniujmy $X_i = \begin{cases} 1 & \text{w } i\text{-tym sukces} \\ 0 & \text{w p.p.} \end{cases}$

Wtedy $X = \sum_{i=1}^n X_i$. X_i są niezależne,

$$P[X_i = 0] = 1 - p, \quad P[X_i = 1] = p.$$

$$EX_i = p, \quad \text{Var } X_i = EX_i^2 - (EX_i)^2 = \\ = p - p^2 = p(1-p)$$

$$EX = \sum EX_i = n \cdot p$$

$$\text{Var } X = \sum_{i=1}^n \text{Var } X_i = n p (1-p)$$

↑
niezależność

Przykład Żebyśmy, że zmienna losowa X ma rozkład $X \sim \text{Geom}(p)$, tzn. $P[X=k] = p(1-p)^{k-1}$ dla $k \in \mathbb{N}$. Przypomnijmy, że X oznacza moment pierwszego sukcesu w nieskończonym schemacie Bernoulliego. Wówczas

$$EX = \sum_{k=1}^{\infty} k p (1-p)^{k-1} = \frac{1}{p}$$

$$\text{Var } X = \frac{1-p}{p^2}$$

Przykład Jeżeli $X \sim \mathcal{N}(m, \sigma^2)$, to

$$EX = \frac{1}{\sqrt{2\pi}\sigma} \int_{\mathbb{R}} x e^{-\frac{(x-m)^2}{2\sigma^2}} dx \stackrel{y=(x-m)/\sigma}{=} \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} (\sigma y + m) e^{-\frac{y^2}{2}} dy = m$$

$$\text{Var } X = E(X-m)^2 = \frac{1}{\sqrt{2\pi}\sigma} \int_{\mathbb{R}} (x-m)^2 e^{-\frac{(x-m)^2}{2\sigma^2}} dx$$

f. niep. więc całka = 0

$$= \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \sigma^2 y^2 e^{-\frac{y^2}{2}} dy = \frac{\sigma^2}{\sqrt{2\pi}} \left(-y e^{-\frac{y^2}{2}} \right) \Big|_{-\infty}^{\infty} + \frac{\sigma^2}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{-\frac{y^2}{2}} dy =$$

$$= \sigma^2$$

Przykład Zmienna losowa ma rozkład

Cauchy'ego, jeżeli jej rozkład jest
zadany gęstością $f(x) = \frac{1}{\pi} \frac{1}{1+x^2}$

Zauważmy, że wówczas zmienna losowa

nie posiada wartości oczekiwanej:

$$E|X| = \frac{1}{\pi} \int_{\mathbb{R}} |x| \cdot \frac{1}{1+x^2} dx = \infty$$

Definicja 5.10 Niech X będzie d -wymiarową
zmienną losową. Wówczas wektor

$$EX = (EX_1, EX_2, \dots, EX_d)$$

nazywamy wartością oczekiwaną zmienną
losową X , o ile EX_i istnieją.

Tw. 5.11

1. $E[aX + bY] = aEX + bEY$

2. d -wymiarowa zmienna losowa ma
wartość oczekiwaną $\Leftrightarrow E|X| < \infty$

3. $|EX| \leq E|X|$

Q-d. 3 Niech v będzie dowolnym wektorem

o długości $\frac{1}{d}$. Wtedy

$$\langle EX, v \rangle = \sum_{j=1}^d EX_j \cdot v_j = E \langle X, v \rangle \leq E|X| \cdot |v| = E|X|$$

Przyjmując $v = \frac{EX}{|EX|}$ otrzymujemy tezę.

Definicja 5.12 Niech X, Y będą zm. los.

takimi, że $EX^2, EY^2 < \infty$. Liczbę

$$\text{Cov}(X, Y) = E[(X - EX)(Y - EY)]$$

nazywamy kowariancją X i Y . Jeżeli

$\text{Cov}(X, Y) = 0$, to X i Y są nieskorelowane.

Uwaga. Kowariancja jest skończona.

$$\begin{aligned} |\text{Cov}(X, Y)| &= |E[(X - EX)(Y - EY)]| \leq \\ &\leq \sqrt{E(X - EX)^2} \cdot \sqrt{E(Y - EY)^2} < \infty \\ &\quad \sqrt{\text{Var} X} \quad \sqrt{\text{Var} Y} \end{aligned}$$

Tw. 5.13 Jeżeli $\mathbb{E}X^2 < \infty$, $\mathbb{E}Y^2 < \infty$, $\mathbb{E}Z^2 < \infty$, to

1. $\text{Cov}(X, Y) = \mathbb{E}XY - \mathbb{E}X\mathbb{E}Y$

2. $\text{Cov}(X, X) = \text{Var} X$

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

4. $\text{Cov}(aX + bY, Z) = a\text{Cov}(X, Z) + b\text{Cov}(Y, Z)$

5. Jeżeli X, Y niezależne, to $\text{Cov}(X, Y) = 0$

ALE implikacja odwrotna nie jest prawdziwa.

Tw. 5.14 Jeżeli $\mathbb{E}X_i^2 < \infty$ dla $i = 1, \dots, n$, to

$$\text{Var}(X_1 + \dots + X_n) = \sum_{i=1}^n \text{Var} X_k + 2 \sum_{k < l} \text{Cov}(X_k, X_l)$$

W szczególności, jeżeli X_i są zmiennymi

niezależnymi, to $\text{Var}(X_1 + \dots + X_n) = \sum_{k=1}^n \text{Var} X_k$

Przykład Niech σ będzie losową permutacją

liczb $1, \dots, n$ i niech X oznacza liczbę

punktów stałych σ . Oblicz $\text{Var} X$.

Niech $X_i = \begin{cases} 1 & i \text{ jest pkt. statym} \\ 0 & \text{w p.w.} \end{cases}$

Wtedy $X = \sum X_i$. $\mathbb{E}X_i = \frac{1}{n}$, $\mathbb{E}X = 1$

Zmiennie X_i są zależne!

$$\begin{aligned} \text{Var } X_i &= \mathbb{E}X_i^2 - (\mathbb{E}X_i)^2 = \mathbb{E}X_i - (\mathbb{E}X_i)^2 = \\ &= \frac{1}{n} - \frac{1}{n^2} = \frac{n-1}{n^2}. \end{aligned} \quad \text{Dla } i \neq j:$$

$$\text{Cov}(X_i, X_j) = \mathbb{E}X_i X_j - \mathbb{E}X_i \cdot \mathbb{E}X_j = (*)$$

$$\mathbb{E}X_i X_j = 0 \cdot \mathbb{P}[X_i X_j = 0] + 1 \cdot \mathbb{P}[X_i X_j = 1] = \frac{1}{n} \cdot \frac{1}{n-1}$$

$$\text{Var } X = \sum_{k=1}^n \text{Var } X_k + 2 \sum_{k < l} \text{Cov}(X_k, X_l) =$$

$$= \sum_{k=1}^n \frac{n-1}{n^2} + 2 \sum_{k < l} \left(\frac{1}{n(n-1)} - \frac{1}{n^2} \right) =$$

$$= \frac{n-1}{n} + 2 \cdot \frac{n \cdot (n-1)}{2} \cdot \frac{n - (n-1)}{n^2(n-1)} = \frac{n-1}{n} + \frac{1}{n} = \underline{1}$$