

Zdawenia elementarne.

Przebiegi (zbiory) zdarzeń elementarnych: $\Omega = \{\omega_1, \omega_2, \dots, \omega_6\}$ 0-biał zmienną, 1-zmienną

$\omega_1 = (B_1, 0)$ $\omega_2 = (B_2, 0)$ $\omega_3 = (B_3, 0)$
 $\omega_4 = (B_1, 1)$ $\omega_5 = (B_2, 1)$ $\omega_6 = (B_3, 1)$

Zdawenia spełniające wygromy:

$A = \{\omega_1, \omega_5, \omega_6\}$ $P_{wygromy} = \frac{3}{6} = \frac{1}{2}$

Strategia 1.

$\Omega_1 = \{\omega_1, \omega_2, \omega_3\}$ $P_{wygromy}^1 = \frac{1}{3}$
 $A_1 = \{\omega_1\}$

Strategia 2.

$\Omega_2 = \{\omega_4, \omega_5, \omega_6\}$ $P_{wygromy}^2 = \frac{2}{3}$
 $A_2 = \{\omega_5, \omega_6\}$

Definicja 1.

Przestrzeń probabilistyczna nazywamy trójką (Ω, \mathcal{F}, P) , gdzie:

- Ω - zbiór niepusty (zbiór zdarzeń elementarnych, np: $\{1, 2, \dots, 6\}$, Elementy Ω nazywamy zdarzeniami elementarnymi. (punkt adan $\omega \in \Omega$)
- \mathcal{F} - rodzina podzbiornów Ω (zdarzenia losowe) Elementy \mathcal{F} na Ω podzbiornami Ω (punkt adan A) + własności.

Własności rodziny \mathcal{F} :

- $\emptyset, \Omega \in \mathcal{F}$
- jeśli $A \in \mathcal{F}$ to $\Omega \setminus A \in \mathcal{F}$ (dopełnienie)
- jeśli $A_i \in \mathcal{F}$ $i \in \mathbb{N}$ to $\bigcup_{i=1}^n A_i \in \mathcal{F}$ (unijna)

Elementy \mathcal{F} nazywamy zdarzeniami.

- P jest funkcją określona na \mathcal{F} o wartościach w $[0, 1]$: $P: \mathcal{F} \rightarrow [0, 1]$ taka że: (P przypisuje podzbiornom liczbę $\frac{1}{3}$ prawdopodobieństwo)

04.11.14r.

$$1.) P(\Omega) = 1$$

2.) jeśli $A_i \in \mathcal{F}$ $i \in \mathbb{N}$, tak że $i \neq j \implies A_i \cap A_j = \emptyset$

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$$

Wniosek:

$$1) P(\emptyset) = 0$$

$$2) P(\Omega \setminus A) + P(A) = 1$$

Ad. 1) $A_i = \emptyset$ $i \in \mathbb{N}$

$$P(\emptyset) = P\left(\bigcup_{i=1}^{\infty} \emptyset\right) = \sum_{i=1}^{\infty} P(\emptyset) \implies P(\emptyset) = 0$$

Ad. 2.) \approx 1.) myślik: $A_1, \dots, A_m: A_i \cap A_j = \emptyset$

$$\text{dla } i \neq j \text{ to } P\left(\bigcup_{i=1}^m A_i\right) = \sum_{i=1}^m P(A_i)$$

Zauważmy, że $A \cap (\Omega \setminus A) = \emptyset$ oraz $A \cup \Omega \setminus A = \Omega$.

$$1 = P(\Omega) = P(A) + P(\Omega \setminus A)$$

Przykład:

Jeżeli jest prawdopodobieństwo, że w grupie n osób, dwie lub więcej osób ma urodziny w tym samym dniu.

Podać różniczkowo w języku odpowiedniej przestrzeni probabilistycznej.

Przekształć zadanie elementarnych:

$$\Omega = \{(k_1, k_2, \dots, k_n) : k_i \in \overline{1, 365}\}$$

$$|\Omega| = 365^m - \text{liczba wariacji z powtórzeniami zbioru } [1, 365]$$

Interesuje nas zbiór

A tych n -elementowych ciągów, które mają "co najmniej jedno powtórzenie".

$\frac{|A|}{|\Omega|} = p(n)$ - prawdopodobieństwo tego, że w grupie n osób dwie lub więcej osób ma urodziny tego samego dnia. Zauważmy.

Niech $A' = \Omega \setminus A$ - n -elementowe ciągi dat bez powtórzeń

$$|A'| = \frac{365!}{(365-n)!} - \text{liczba wariacji bez powtórzeń zbioru } [1, 365]$$

$$p(m) = 1 - \frac{|A'|}{|\Omega|} = 1 - \frac{365 \cdot 364 \cdot \dots \cdot (365 - (m-1))}{365^m}$$

m	$p(m)$
10	11,4 %
20	41,1 %
23	50,4 %
50	94 %
54	99 %
100	99,99997 %

Schematy kombinatoryczne

Definicja 2.

Niech \mathcal{Y} będzie zbiorem m -elementowym

k -elementową wariację z powtórzeniami zbioru \mathcal{Y} nazywamy dowolną funkcję

$$f: \{1, 2, \dots, k\} \rightarrow \mathcal{Y}$$

Równocześnie piszemy $(f(1), f(2), f(3), \dots, f(k))$

Kolejność jest istotna.

Oznaczenie A_k^m - liczba wariacji z powtórzeniami.

$$A_k^m = m^k$$

Definicja 3.

\mathcal{Y} j.n. k -elementową wariację bez powtórzeń zbioru \mathcal{Y} nazywamy każdą różnowartościową funkcję

$$f: \{1, 2, \dots, k\} \rightarrow \mathcal{Y}$$

$(f(1), f(2), \dots, f(k))$ - nie ma powtórzeń, kolejność jest istotna

Oznaczenie: $V_k^m = \frac{m!}{(m-k)!} = m(m-1)(m-2) \cdot \dots \cdot (m-k+1) =$

Definicja 4

\times j.w. k -elementowa kombinacja to k -elementowy podzbiór X .

$\{y_1, y_2, \dots, y_k\}$ kolejność nie jest istotna. Spok powstaje.

$$C_k^m = \frac{n!}{(n-k)! k!}$$

Definicja 5.

Permutacja elementów zbioru X to n -elementowa wariacja bez powtórzeń.

$$P_n = V_n^n = \frac{n!}{(n-n)!} = \frac{n!}{0!} = n!$$

Przykład.

Populacja o liczebności n dzielimy na k -części o liczebnościach

n_1, n_2, \dots, n_k , gdzie $n_1 + n_2 + \dots + n_k = n$.

Znaleźć liczbę takich przedzieleni.

Wyznaczymy sample tego, że dany miesiąc 3H opór możliwości /₃ /₃ następująco: 6 miesięcy po 3 opoby, 2 miesiące po 4 opoby i 4 miesiące po 2 opoby.

na uproszczenia $k=4$.

$$\binom{n}{n_1} \cdot \binom{n-n_1}{n_2} \cdot \binom{n-n_1-n_2}{n_3} \cdot \binom{n-n_1-n_2-n_3}{n_4} =$$

$$\frac{n!}{n_1!(n-n_1)!} \cdot \frac{(n-n_1)!}{n_2!(n-n_1-n_2)!} \cdot \frac{(n-n_1-n_2)!}{n_3!(n-n_1-n_2-n_3)!} = \frac{n!}{n_1! \cdot n_2! \cdot n_3! \cdot n_4!}$$

Ogólnie:

$$\frac{n!}{n_1! \cdot n_2! \cdot \dots \cdot n_k!}$$

Yak wygledza przestrzeń zdarzeń elementarnych?

$$\Omega = \{(k_1, k_2, \dots, k_{34}) : k_i \in [1, 12]\}$$

$$|\Omega| = 12^{34}$$

A - ciągi spełniającego warunki zadania.

$$|A| = \frac{12!}{6! 2! 4!} \cdot \frac{34!}{3! 3! \dots 3! \cdot \underbrace{1! \cdot 1!}_2 \cdot \underbrace{2! \cdot 2! \cdot 2! \cdot 2!}_4}$$

$$P(A) = \frac{|A|}{|\Omega|}$$

Prawdopodobieństwo warunkowe.

Definicja 6:

(Ω, \mathcal{F}, P) i $B \in \mathcal{F}$, taki że $P(B) \neq 0$.

Niech $A \in \mathcal{F}$. Prawdopodobieństwem zdarzenia A pod warunkiem,

że zdarzenie B definiujemy jako $\frac{P(A \cap B)}{P(B)}$ i oznaczamy

prawdopodobieństwem B -m warunkowy zdarzenia A oraz oznaczamy symbolem $P(A|B)$.

Przykład.

Rzucamy dwoma kostkami. Znając sumę liczb oczek = 5, wyznaczyc prawdopodobieństwo, że na pierwszej kostce liczba oczek ≤ 2 .

Rozwiązanie 1.

$$\Omega = \{(1,4), (2,3), (3,2), (4,1)\}$$

$$D = \{(1,4), (2,3)\} \quad P = \frac{2}{4} = \frac{1}{2}$$

Rozwiązanie 2.

$$B = \{(1,4), (2,3), (3,2), (4,1)\}$$

$$P(B) = \frac{4}{36} \quad A \cap B = \{(1,4), (2,3)\} \quad P(A \cap B) = \frac{2}{36}$$

$$P(A|B) = \frac{2/36}{4/36} = \frac{2}{4}$$

Stwierdzenie.

Niech (Ω, \mathcal{F}, P) - przestrzeń probabilistyczna. Niech $A_i \in \mathcal{F}$.

$$i \in \mathbb{N}, A_i \cap A_j = \emptyset \quad i \neq j \quad \text{oraz} \quad \Omega = \bigcup_{i=1}^{\infty} A_i$$

$$\text{Wówczas} \quad \forall B \in \mathcal{F} \quad P(B) = \sum_{i=1}^{\infty} P(B|A_i) \cdot P(A_i)$$

Dowód

$$P(B) = P\left(\bigcup_{i=1}^{\infty} B \cap A_i\right) = \sum_{i=1}^{\infty} P(B \cap A_i) = \sum_{i=1}^{\infty} \frac{P(B \cap A_i)}{P(A_i)} \cdot P(A_i) = \sum_{i=1}^{\infty} P(B|A_i) \cdot P(A_i)$$



Wzór Bayesa:

$$P(A|B) \text{ jeśli jest } \frac{P(A \cap B)}{P(B)} \quad P(B|A)$$

Niech A_i, B będą f.w.

$$P(A_i|B) = \frac{P(A_i \cap B)}{P(B)} = \frac{P(A_i \cap B)}{\sum_{j=1}^{\infty} P(B|A_j) P(A_j)} = \frac{P(B|A_i) \cdot P(A_i)}{\sum_{j=1}^{\infty} P(B|A_j) P(A_j)}$$

Przykład.

Test wykrywający zakażenie pewnym wirusem ma 95% skuteczność: prawdopodobieństwo wykrycia wirusa u osoby chorej wynosi 95%, a u zdrowej 5%. Załóżmy, że $\frac{1}{1000}$ populacji jest nosicielem wirusa.

Jakie jest prawdopodobieństwo, że losowo wybrana osoba, u której test stwierdził wirusa jest niosicielem jego nosicielem?

C - zdrowy, Z - zdrowy, P - wynik pozytywny, N - r. negatywny

$$P(C|T) = ?$$

Wiemy, że:

$$P(T|C) = 0,95$$

$$P(T|Z) = 0,05$$

$$P(C) = 0,001$$

$$P(Z) = 0,999$$

$$P(C|T) = \frac{P(T|C) \cdot P(C)}{P(T|Z) \cdot P(Z) + P(T|C) \cdot P(C)} = \frac{0,95 \cdot \frac{1}{1000}}{\frac{5}{100} \cdot \frac{999}{1000} + \frac{95}{100} \cdot \frac{1}{1000}} =$$

$$= 0,0186 < 2\%$$

2% jest znacznie większe niż 0,1%.

Pytanie: jaka pusteni probabilistyczna modeluje doświadczenie polegające na losowaniu punktu z odcinka $[0, 1]$; tak, że wylosowanie każdego punktu jest równie prawdopodobne.

Czy istnieje pusteni probabilistyczna (Ω, \mathcal{F}, P) tak, że:

a) $\Omega = [0, 1]$

b) $[a, b] \in \mathcal{F}$ dla wszystkich $0 \leq a < b \leq 1$.

c) $P([a, b]) = b - a$.

Odpowiedź: Jeśli \mathcal{F} będzie najmniejszą σ -algebrą podzbioru Ω , taka że: $\forall 0 \leq a < b \leq 1, [a, b] \in \mathcal{F}$ oraz spełniająca aksjomaty pusteni probabilistycznej dotyczące \mathcal{F} .

Wówczas $\exists!$ $P: \mathcal{F} \rightarrow [0, 1]$ spełniająca aksjomaty pusteni probabilistycznej i ma własność c).

Prawdopodobieństwo B-warynkowe

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Definicja 1: Mówimy, że zdarzenia A i B są niezależne jeśli $P(A \cap B) = P(A) \cdot P(B)$.

Uwaga: odpowiednio $P(A|B) = \frac{P(A) \cdot P(B)}{P(B)} = P(A)$

Przykład: Rozważmy dwa niezależne symetryczne identycznymi monetami. $\Omega = \{0, 1\} \times \{0, 1\} = \{(0,0), (0,1), (1,0), (1,1)\}$

Rozważmy trzy zdarzenia losowe: O_1, O_2, S .

O_1 - na pierwszej monetzie wypadł orzeł; $O_1 = \{(0,0), (0,1)\}$.

O_2 - na drugiej monetzie wypadł orzeł; $O_2 = \{(0,0), (1,0)\}$.

S - na obu monetach mamy to samo; $S = \{(0,0), (1,1)\}$. $P(S) = \frac{1}{2}$.

Zdarzenia O_1, O_2, S są parami niezależne:

np. $P(O_1, O_2) = P(\{(0,0)\}) = \frac{1}{4} = P(O_1) \cdot P(O_2)$, itd.

(Nie można powiedzieć, że te trzy zmiennye są niezależne statystycznie)

Ad. Pustzeń probabilistyczna.

Pytanie: jaka pustzeń probabilistyczna modeluje doświadczenie polegające na losowaniu punktu z odcinka $[0, 1]$; tak że wyprowadzenie każdego punktu jest równie prawdopodobne.

Czy istnieje pustzeń probabilistyczny (Ω, \mathcal{F}, P) tak, że:

a) $\Omega = [0, 1]$

b) $[a, b] \in \mathcal{F}$ dla wszystkich $0 \leq a < b \leq 1$.

c) $P([a, b]) = b - a$.

Odpowiedź: Jeśli \mathcal{F} będzie najmniejszą σ -algebrą podzbiorem Ω , taką że: $\forall 0 \leq a < b \leq 1, [a, b] \in \mathcal{F}$ oraz spełniająca aksjomaty

mierzenia probabilistycznej dotyczące \mathcal{F} .

Wówczas $\exists!$ $P: \mathcal{F} \rightarrow [0, 1]$ spełniająca aksjomaty pustżenia probabilistycznej i ma własność c).

Prawdopodobieństwo B-warynkowe:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Definicja 1: Mówimy, że zdarzenia A i B są niezależne jeśli

$$P(A \cap B) = P(A) \cdot P(B).$$

Uwaga: odpowiednio $P(A|B) = \frac{P(A) \cdot P(B)}{P(B)} = P(A)$

Przykład: Rozważmy dwa niezależnymi identycznymi monetami. $\Omega = \{0, 1\} \times \{0, 1\} = \{(0, 0), (0, 1), (1, 0), (1, 1)\}$

Rozważmy trzy zdarzenia losowe: O_1, O_2, S .

O_1 - na pierwszej monetzie wypadł orzeł; $O_1 = \{(0, 0), (0, 1)\}$.

O_2 - na drugiej monetzie wypadł orzeł; $O_2 = \{(0, 0), (1, 0)\}$.

S - na obu monetach mamy to samo; $S = \{(0, 0), (1, 1)\}$. $P(S) = \frac{1}{2}$.

Zdarzenia O_1, O_2, S są parami niezależne:

np. $P(O_1, O_2) = P(\{(0, 0)\}) = \frac{1}{4} = P(O_1) \cdot P(O_2)$, itd.

(Nie można powiedzieć, że te trzy zmiennym są zależne statystycznie)

Zauważmy, że тройка O_1, O_2 i S nie jest niezależna statystycznie.
 $O_1 \cap O_2 \subset S$, $O_1 \cap S \subset O_2$, $O_2 \cap S \subset O_1$.

Definicja 2:

Mówimy, że rodzina zdarzeń elementarnych A_1, A_2, \dots, A_m jest statystycznie niezależna, jeśli $\forall 1 \leq k \leq m$ oraz $1 \leq i_1 < i_2 < \dots < i_k \leq m$ zachodzi równość: $P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \cdot P(A_{i_2}) \cdot \dots \cdot P(A_{i_k})$.

Wracając do przykładu:

$$P(O_1 \cap O_2 \cap S) = P(\{0, 0\}) = \frac{1}{4} \neq \frac{1}{8} = P(O_1) \cdot P(O_2) \cdot P(S)$$

"Jak w terminach teorii prawdopodobieństwa modelujemy zdarzenia niezależne"?

Mamy 2 przestrzenie.

Niech $(\Omega_1, \mathcal{F}_1, P_1)$, $(\Omega_2, \mathcal{F}_2, P_2)$.

$\exists!$ (Ω, \mathcal{F}, P) taki, że:

1.) $\Omega = \Omega_1 \times \Omega_2$

2.) \mathcal{F} jest najmniejszą rodzimą podzbiorów Ω , tak, że

$$\forall A_1 \in \mathcal{F}_1, A_2 \in \mathcal{F}_2: A_1 \times A_2 \in \mathcal{F}$$

3.) $P: \mathcal{F} \rightarrow [0, 1]$ oraz $P(A_1 \times A_2) = P(A_1) \cdot P(A_2)$.

Schemat Bernoulliego.

Rozpatrzmy doświadczenie losowe o dwóch możliwych wynikach $\Omega = \{0, 1\}$, które ma ryzykowne z prawdopodobieństwem p, q (-odpowiednio).

Yaknie jest prawdopodobieństwo, tego że przy n -krotnym powtórzeniu tego doświadczenia otrzymamy k -razy wynik 0?

$$\Omega = \underbrace{\{0, 1\} \times \dots \times \{0, 1\}}_{n\text{-razy}}$$

Elementy tej przestrzeni to ciąg $(0, 1, 1, \dots, 0)$ - pseudopodob. $p^k q^{n-k}$

liczba zdarzeń sprzyjających wynosi $\binom{n}{k} = \frac{n!}{k!(n-k)!}$

Zatem:

$$P_{n,k} = \binom{n}{k} p^k q^{n-k} \quad \text{- schemat Bernoulliego}$$

Ustalmy liczbę $n, k \in \mathbb{N}$.

Niech $A_{n,k} = \left\{ \begin{array}{l} 2n\text{-elementowe} \\ \text{ciągi bitów} \\ \text{mówiące} \end{array} : |\text{liczba 0-ów} - \text{liczba 1-ów}| \leq 2k \right\}$

$$P(A_{n,k}) = \sum_{j=n-k}^{n+k} \binom{2n}{j} \cdot \frac{1}{2^{2n}} \xrightarrow[n \rightarrow \infty]{\text{ustalimy } k} 0$$

↑
schemat Bernoulliego

↑
daje się udomowić, że granica ta dąży do 0.

Definicja 3:

Zmienna losowa na przestrzeni probabilistycznej (Ω, \mathcal{F}, P)

jest to każda funkcja $X: \Omega \rightarrow \mathbb{R}$ taka, że: $\forall -\infty < a < b < \infty$ mamy $\{\omega \in \Omega : a \leq X(\omega) \leq b\} \in \mathcal{F} = \sigma(X^{-1}([a, b])) \rightarrow$ jeśli $a=b$ to będziemy pisali $X^{-1}(\{a\})$

Uwaga: Powyższy zbiór jest zdarzeniem losowym, można mu przypisać pseudopodobieństwo.

Przykład:

Przykład - ustalmy $A \in \mathcal{F}$

$$X_A(\omega) = \begin{cases} 1 & \omega \in A \\ 0 & \omega \notin A \end{cases}$$

$$\Omega = \{1, 2, \dots, 6\} \times \{1, 2, \dots, 6\} \ni (i, j) \mapsto X((i, j)) = i + j$$

wartości zmiennej X	{	2	$\{(1, 1)\} = X^{-1}(\{2\}) \stackrel{\text{ozn.}}{=} \{x=2\}$	}	ozn. $\{x=j\}$
		3	$\{(1, 2), (2, 1)\} = X^{-1}(\{3\}) \stackrel{\text{ozn.}}{=} \{x=3\}$		
		4	$\{(1, 3), (2, 2), (3, 1)\} = X^{-1}(\{4\}) \stackrel{\text{ozn.}}{=} \{x=4\}$		
			
		12	$\{(6, 6)\} = X^{-1}(\{12\}) \stackrel{\text{ozn.}}{=} \{x=12\}$		

zmienna losowa w przestrzeni

$$X = \sum_{j=2}^{12} j \cdot \chi_{\{x=j\}}$$

Wartość oczekiwana zmiennej X :

$$E(X) = 2 \cdot \frac{1}{36} + 3 \cdot \frac{2}{36} + \dots + 12 \cdot \frac{1}{36} = 4$$

$$= \sum_{j=2}^{12} j \cdot P(\{x=j\})$$

Definicja 4.

Mówimy, że zmienna losowa jest dodatnia jeśli $\forall \omega \in \Omega \quad X(\omega) \geq 0$.

Mówimy, że dodatnia zmienna losowa X jest dyskretna jeśli \exists ciąg $(x_i)_{i=1}^{\infty}$, $x_i \geq 0$ taki, że $X = \sum_{i=1}^{\infty} X_i \chi_{\{X=x_i\}}$

Wartość oczekiwaną takiej zmiennej losowej nazywamy liczbę $\sum_{i=1}^{\infty} x_i \cdot P(\{X=x_i\})$.

Ogólniej interesują nas zmienne losowe dyskretne postaci $X = X_+ - X_-$, gdzie X_+, X_- - j.n. oraz t, że $E(X_+) < \infty, E(X_-) < \infty$

Wówczas definiujemy wartość oczekiwaną:

$$E(X) = E(X_+) - E(X_-)$$

Wartość zmienną maksymalną całkowalną

liniowość wartości oczekiwanej:

Stwierdzenie:

Niech X_1, X_2 będą dyskretnymi ^{całkowalnymi} zmiennymi losowymi.

Wówczas $\forall d_1, d_2 \in \mathbb{R}$ zmienna $X = d_1 X_1 + d_2 X_2$ jest dyskretną całkowalną zmienną losową oraz $E(X) = d_1 E(X_1) + d_2 E(X_2)$.

Dowód: (ćwiczenia!).

Co jeśli $X \geq 0$, ale nie jest dyskretna?

$\forall m \in \mathbb{N}$ definiujemy m -te przybliżenie X zmienną dyskretną X_m , gdzie $X_m = \sum_{k=1}^{m \cdot 2^m} \frac{k-1}{2^m} \cdot \chi_{\{\frac{k-1}{2^m} \leq X < \frac{k}{2^m}\}}$

Własności X_m :

1.) $\forall \omega \in \Omega : X_m(\omega) \leq X_{m+1}(\omega)$

2.) $\forall \omega \in \Omega \quad \lim_{m \rightarrow \infty} X_m(\omega) = X(\omega)$.

Definiujemy $E(X)$ wzorem:

$$E(X) = \lim_{m \rightarrow \infty} E(X_m)$$

DYSTRYBUANTA I GĘSTOŚĆ ZMIENNEJ LOSOWEJ, A WARTOŚĆ OCEKIWANA.

Dystrybuanta zmiennej losowej X nazywamy funkcją

$F_X: \mathbb{R} \rightarrow \mathbb{R}$ daną wzorem

$$F_X(t) = P(\{X \leq t\})$$

Własności dystrybuanty:

1.) $t_1 \leq t_2$ to $F_X(t_1) \leq F_X(t_2)$

2.) Waga F_X musi być ciągła, ale jej ciągłość z prawej strony.
 $\lim_{t \rightarrow t_0} F_X(t) = F_X(t_0)$

Mówimy, że X ma gęstość jeśli dystrybuanta F_X jest funkcją różniczkowalną. Wówczas gęstość g_X definiujemy wzorem:

$$g_X(t) = \frac{d}{dt} F_X(t) = F_X'(t).$$

Stricteżenie.

Jeśli X jest całkowalną i posiada gęstość to wartość oczekiwaną X

$$E(X) = \int_{\mathbb{R}} t \cdot g_X(t) dt$$

25.11.14r.

(Ω, \mathcal{F}, P) , $X: \Omega \rightarrow \mathbb{R}$ - zmienna losowa

Jeśli $X(\omega) \geq 0$ dla wszystkich $\omega \in \Omega$ to $E(X) \in \mathbb{R}_+ \cup \{\infty\}$.

Jeśli X przyjmuje wartości dodatnie i ujemne to przedstawiamy $X = X_+ - X_-$.

gdzie

$$X_+(\omega) = \begin{cases} X(\omega) & \text{jeśli } X(\omega) \geq 0 \\ 0 & \text{jeśli } X(\omega) < 0. \end{cases}$$

$$X_-(\omega) = \begin{cases} -X(\omega) & \text{jeśli } X(\omega) < 0. \\ 0 & \text{jeśli } X(\omega) \geq 0. \end{cases}$$

$$X^+ = X \{ \omega : X(\omega) \geq 0 \}, \quad X^- = X \{ \omega : X(\omega) \leq 0 \} \quad \text{to}$$

$$X^+ + X^- = 1 \text{ owa } 2 \quad X^+ = X \cdot X^+, \quad X^- = -X \cdot X^-$$

$$X^+ - X^- = X \cdot X^+ + X \cdot X^- = X \cdot (X^+ + X^-) = X.$$

Definicja

Mówimy, że zmienna losowa X jest całkowalą jeśli $E(X^+) < \infty, E(X^-) < \infty$

Zmiennej całkowalnej przypisujemy wartość oczekiwaną ~~wartość~~
 wzorem: $E(X) = E(X^+) - E(X^-)$

$$E(X) = \int_{\Omega} X(\omega) dP(\omega)$$

Możemy także taki
 definiujemy wartość
 Lebesgue'a

Charakterystyka

X jest całkowalną $\Leftrightarrow E(|X|) < \infty$.

$$|X| = X^+ + X^-; \quad E(|X|) = E(X^+) + E(X^-) < \infty$$

$$\updownarrow$$

$$E(X^+), E(X^-) < \infty$$

Własności E

1) X_1, X_2 - całkowalne, $\forall \omega \in \Omega \quad X_1(\omega) \leq X_2(\omega)$

$$\text{to} \quad E(X_1) \leq E(X_2)$$

2) X_1, X_2 - całkowalne, to $aX_1 + bX_2$ jest całkowalną owa

$$E(aX_1 + bX_2) = aE(X_1) + bE(X_2)$$

3.) Twierdzenie o zbieżności monotonicznej

Niech X_n - ciąg dodatnich zmiennych losowych,

t. z.e. $\forall \omega \in \Omega \quad X_{n+1}(\omega) \geq X_n(\omega)$

Zdefiniujemy $X(\omega) = \lim_{n \rightarrow \infty} X_n(\omega)$. Wówczas

$$E(X) = \lim_{n \rightarrow \infty} E(X_n) \quad \left\{ \int_{\Omega} X(\omega) dP(\omega) = \lim_{n \rightarrow \infty} \int_{\Omega} X_n(\omega) dP(\omega) \right\}$$

4.) Twierdzenie o zbieżności zmajorizowanej

Niech X_n będzie ciągiem całkowalnych zmiennych losowych,

t. z.e. $\forall \omega \in \Omega$ istnieje granica $\lim_{n \rightarrow \infty} X_n(\omega)$.

Niech $X(\omega) = \lim_{n \rightarrow \infty} X_n(\omega)$. Przyjmijmy, że istnieje całkowalna

zmienna losowa Y t. z.e. $\forall n \forall \omega \in \Omega \quad |X_n(\omega)| \leq Y(\omega)$.

Wówczas $\lim_{n \rightarrow \infty} E(X_n) = E(X) \quad \left\{ \lim_{n \rightarrow \infty} \int_{\Omega} X_n(\omega) dP(\omega) = \int_{\Omega} X(\omega) dP(\omega) \right\}$

X -zmienna losowa $F_X: \mathbb{R} \rightarrow [0, 1] : F_X(t) = P(\{\omega : X(\omega) \leq t\})$

gęstość $g_X(t) = F_X'(t)$

jeśli pochodna istnieje to oznaczmy, że X posiada gęstość

Obszar

$$P(a < X \leq b) = F_X(b) - F_X(a) = \int_a^b F_X'(t) dt = \int_a^b g_X(t) dt$$

Stwierdzenie

Niech X będzie zmienną losową całkowalną posiadającą

gęstość, wówczas $E(X) = \int_{\mathbb{R}} t \cdot g_X(t) dt$

Łatwo. Bez straty ogólności $X \geq 0$

$$E(X) = \lim_{n \rightarrow \infty} E(X_n), \quad \text{gdzie } X_n = \sum_{l=1}^{n \cdot 2^n} \frac{l-1}{2^n} \cdot \chi_{\left\{ \omega : \frac{l-1}{2^n} < X(\omega) \leq \frac{l}{2^n} \right\}}$$

$$E(X_n) = \sum_{l=1}^{n \cdot 2^n} \frac{l-1}{2^n} P\left(\left\{ \omega : \frac{l-1}{2^n} < X \leq \frac{l}{2^n} \right\}\right) = \sum_{l=1}^{n \cdot 2^n} \frac{l-1}{2^n} (F_X\left(\frac{l}{2^n}\right) - F_X\left(\frac{l-1}{2^n}\right)) \approx$$

$$\approx \sum_{l=1}^{n \cdot 2^n} \frac{l-1}{2^n} \cdot g_X\left(\frac{l}{2^n}\right) \cdot \frac{1}{2^n} \xrightarrow{n \rightarrow \infty} \int_{\mathbb{R}} t g_X(t) dt$$

$$\Omega \xrightarrow{X} \mathbb{R} \xrightarrow{\psi} \mathbb{R}$$

$\psi(x)$ - też jest zmienną losową.

Mozna wykazać, że:

$$E(\psi(X)) = \int_{\mathbb{R}} \psi(t) g_X(t) dt$$

$$\text{np. } E(X^2) = \int_{\mathbb{R}} t^2 g_X(t) dt \quad \text{itd...}$$

Przykład.

Znaleźć wartość oczekiwaną pła prostokąta, którego obwód wynosi 20, a jeden bok jest zmienną losową o rozkładzie jednostajnym na odcinku $[1, 10]$.

X -zmienna losowa = długość losowego boku.

$$\text{Gęstość } X: g_X(t) = \begin{cases} \frac{1}{9} & \text{dla } 1 \leq t \leq 10 \\ 0 & \text{dla } t < 1 \text{ lub } t > 10 \end{cases}$$

Długi bok $Y = 10 - X$ - zmienna losowa

Pole prostokąta $X \cdot (10 - X)$. W takim razie

$$E(X(10-X)) = \int_1^{10} t(10-t) \cdot \frac{1}{9} dt = 18.$$

Definicja.

Niech X - zmienna losowa całkowalna, t. że X^2 też jest

zmienną całkowalną. Wówczas X ma zmienne wariancję $D^2(X) = E((X - E(X))^2) \in \mathbb{R}_+$

Własności wariancji:

$$1. D^2(aX) = a^2 D^2(X), \quad D^2(X-a) = D^2(X)$$

$$2. D^2(X) = E(X^2) - (E(X))^2$$

$$\text{Dowód: } D^2(X) = E(X^2 - 2X \cdot E(X) + E(X)^2) = E(X^2) - 2E(X) \cdot E(X) + E(X)^2 \\ = E(X^2) - E(X)^2 \quad \blacksquare$$

Definicja

Niech X, Y będą zmiennymi losowymi całkowalnymi, takimi że X^2, Y^2 też są całkowalne.

Wówczas kowariancję X i Y nazywamy liczbę $E((X - E(X))(Y - E(Y)))$ i oznaczamy symbolem $cov(X, Y)$.

Uwaga: Dowodzi się, że kowariancja

$$|cov(X, Y)| \leq \sqrt{D^2(X) D^2(Y)}$$

← obie nierówności dowodzi się identycznie

Przypomnijmy nierówność Schwarz'a $|(v_1, v_2)| \leq \|v_1\| \|v_2\|$

Współczynnikiem korelacji X i Y nazywamy

$$\frac{cov(X, Y)}{\sqrt{D^2(X) D^2(Y)}} = \rho(X, Y) \quad -1 \leq \rho(X, Y) \leq 1$$

ZMIENNE

1. Mówimy, że X jest zmienną losową o rozkładzie dyskretnym,

jeśli X jest postaci $X = a \cdot \chi_{\{X=a\}} + b \cdot \chi_{\{X=b\}}$ $a, b \in \mathbb{R}$

$$p, q: \quad p = P(\{X=a\}) \quad p+q=1$$

$$q = P(\{X=b\}) \quad 0 \leq p, q \leq 1$$

$$E(X) = a \cdot p + b \cdot q$$

$$D^2(X) = E(X^2) - E(X)^2 = a^2 p + b^2 q - (ap + bq)^2 = pq(a-b)^2$$

2. Zmienna X jest zmienną Bernoulliego, jeśli $P(\{X=k\}) = \binom{n}{k} p^k (1-p)^{n-k}$

Wartość oczekiwana: $E(X) = np$

$$D^2(X) = n \cdot p \cdot (1-p)$$

3. Zmienna o rozkładzie Poissona:

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

$$E(X) = \sum_{k=0}^{\infty} k \cdot e^{-\lambda} \frac{\lambda^k}{k!} = e^{-\lambda} \cdot \lambda \cdot \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} = \lambda$$

Zmienna Poissonowska jest przypadkiem granicznym zmiennych

o rozkładzie Bernoulliego: biorąc $n \rightarrow \infty$, $p \rightarrow 0$, $n \cdot p = \lambda$

dostajemy
$$\lim_{\substack{n \rightarrow \infty \\ p \rightarrow 0 \\ n \cdot p = \lambda \\ k \text{ - ustalone}}} \frac{n!}{k!(n-k)!} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k} =$$

$\downarrow \frac{\lambda^k}{k!}$ $\downarrow e^{-\lambda}$

$$= \frac{\lambda^k}{k!} e^{-\lambda} \lim_{\substack{n \rightarrow \infty \\ k \text{ - ustalone}}} \frac{n(n-1)\dots(n-k+1)}{n \cdot n \dots n}$$

$\downarrow \rightarrow 1$

Przykład

Opracować prawdopodobieństwo wygranej w totolotce jeśli wypełnimy 10^7 kuponów. (kupiemy 2 losiadały Poissonowskiej)

$$P = \frac{1}{\binom{49}{6}} \approx 4 \cdot 10^{-8}$$

$$\lambda = n \cdot p = \frac{4}{10}$$

$$P(\{X=0\}) = e^{-\lambda} \approx 0,4891$$

$$P(\{X=1\}) = e^{-\lambda} \cdot \frac{\lambda^1}{1!} = 0,3498$$

$$P(\{X=2\}) = 0,1251$$

ZMIENNE POSIADAJĄCE GĘSTOŚĆ

4. zmienna o rozkładzie jednorodnym na odcinku $[a, b]$,

$$g_X(t) = \frac{1}{b-a} \cdot \chi_{[a, b]}^{(t)}$$

mnożość avelimara $\overline{a} \text{---} \overline{b}$

$$E(X) = \int_{\mathbb{R}} t \cdot g_X(t) dt = \int_a^b \frac{1}{(b-a)} t dt = \frac{1}{b-a} \frac{b^2 - a^2}{2} = \frac{a+b}{2}$$

$$D^2(X) = \frac{(b-a)^2}{12} = \frac{1}{(b-a)} \int_a^b t^2 dt - \left(\frac{a+b}{2}\right)^2$$

5. X - zmienna o rozkładzie normalnym ze średnią μ

oraz wariancją σ^2 - $\frac{(x - \mu)^2}{2\sigma^2}$

$$f_X(t) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x - \mu)^2}{2\sigma^2}}$$

6. zmienna o rozkładzie χ^2 (chi kwadrat).

$$f_X(t) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} t^{\frac{n}{2} - 1} e^{-\frac{t}{2}} \chi_{[0, \infty[}^{(t)}$$

Jest gęstość zmiennych, która jest sumą kwadratów n zmiennych Gaussowskich:

$$E(X) = n \quad D^2(X) = 2n$$

NIEZALEŻNE ZMIENNE LOSOWE:

Definicja

Niech X_1, X_2, \dots, X_k będą zmiennymi losowymi na przestrzeni probabilistycznej (Ω, \mathcal{F}, P) .

Mówimy, że X_1, \dots, X_k są niezależne jeśli $\forall A_1, A_2, \dots, A_k \subseteq \mathbb{R}$

$$P(\{\omega: X_1(\omega) \in A_1, X_2(\omega) \in A_2, \dots, X_k(\omega) \in A_k\}) =$$

$$= P(\{\omega: X_1(\omega) \in A_1\}) \cdot P(\{\omega: X_2(\omega) \in A_2\}) \cdot \dots \cdot P(\{\omega: X_k(\omega) \in A_k\})$$

Stwierdzenie

Niech X, Y będą niezależnymi zmiennymi losowymi, które są całkowalne i takie $E(X^2) < \infty, E(Y^2) < \infty$.

Mówimy:

$$(1) E(X \cdot Y) = E(X) \cdot E(Y)$$

$$(2) \text{cov}(X, Y) = 0$$

Ważne: niezależność zmiennych losowych jest ^{własnością} własnością ^{własnością} niezależności ^{własnością} niezależności ^{własnością} niezależności
niezależność zmiennych losowych jest ^{własnością} własnością ^{własnością} niezależności ^{własnością} niezależności ^{własnością} niezależności
niezależność zmiennych losowych jest ^{własnością} własnością ^{własnością} niezależności ^{własnością} niezależności ^{własnością} niezależności

Przywołanie: (Ω, \mathcal{F}, P) ; $X, Y: \Omega \rightarrow \mathbb{R}$ niezależne jeśli
 $\forall A_1, A_2 \subset \mathbb{R}$: odcinki.

$$P(\{\omega \in \Omega: X_1(\omega) \in A_1, X_2(\omega) \in A_2\}) =$$

$$P(\{\omega \in \Omega: X_1(\omega) \in A_1\}) \cdot P(\{\omega \in \Omega: X_2(\omega) \in A_2\})$$

Strzedzenie:

$X_1, \dots, X_k: \Omega \rightarrow \mathbb{R}$ - niezależne zmienne losowe

$$\text{t.j. } E(|X_i|) < \infty \quad i=1, \dots, k$$

Wówczas iloczyn $X_1 \cdot X_2 \cdot \dots \cdot X_k$ posiada wartość oczekiwaną
 oraz $E(X_1 \cdot \dots \cdot X_k) = E(X_1) \cdot \dots \cdot E(X_k)$.

Wniosek:

X_1, X_2 - niezależne to $\text{cov}(X_1, X_2) = 0$ oraz

$$\mathcal{D}^2(X_1 + X_2) = \mathcal{D}^2(X_1) + \mathcal{D}^2(X_2)$$

$$\text{cov}(X_1, X_2) = E(\underbrace{(X_1 - E(X_1))}_{\text{niezależne zmienne losowe}} \underbrace{(X_2 - E(X_2))}_{\text{niezależne zmienne losowe}}) =$$

$$= E((X_1 - E(X_1))) E((X_2 - E(X_2))) = 0 \cdot 0 = 0$$

$$\mathcal{D}^2(X_1 + X_2) = E((X_1 + X_2 - E(X_1 + X_2))^2) =$$

$$= E((X_1 - E(X_1) + X_2 - E(X_2))^2) = E((X_1 - E(X_1))^2) + E((X_2 - E(X_2))^2) +$$

$$+ 2E((X_1 - E(X_1))(X_2 - E(X_2))) = \mathcal{D}^2(X_1) + \mathcal{D}^2(X_2) + 2\text{cov}(X_1, X_2)$$

$$\stackrel{\text{niezależność}}{=} \mathcal{D}^2(X_1) + \mathcal{D}^2(X_2)$$

Łatwość.

$k=2$ rozwiązanie dodatkowe: $X = \sum_{i=1}^{\infty} x_i \chi_{\{X=x_i\}}$

$$\text{dyskretność} \leftarrow \begin{cases} X = \sum_{j=1}^{\infty} y_j \chi_{\{Y=y_j\}} \end{cases}$$

$$x_i, y_j \in \mathbb{R}$$

$$E(X \cdot Y) \stackrel{(*)}{=} E\left(\sum_{i,j} x_i y_j \chi_{\{X=x_i\}} \chi_{\{Y=y_j\}}\right)$$

$$= E\left(\sum_{i,j} x_i y_j \chi_{\{X=x_i, Y=y_j\}}\right)$$

$$= \sum_{i,j} x_i y_j P(\{X=x_i, Y=y_j\}) \quad \text{niezależność } X, Y$$

$$\sum_{i,j} x_i y_j P(\{X=x_i\}) P(\{Y=y_j\}) = \sum_i x_i P(\{X=x_i\}) \cdot \sum_j y_j P(\{Y=y_j\}) = E(X) \cdot E(Y)$$

Wniosek:

1) X, Y - niezależne zmienne losowe

$$\varphi_1, \varphi_2: \mathbb{R} \rightarrow \mathbb{R}$$

$$\text{wówczas } E(\varphi_1(X) \cdot \varphi_2(Y)) = E(\varphi_1(X)) \cdot E(\varphi_2(Y)).$$

stosujemy poprzednie stwierdzenie

do niezależnych zmiennych losowych $\varphi_1(X), \varphi_2(Y)$

2) Przyjmijmy, że X, Y są niezależne i mają gęstości g_x, g_y .

Niech ponadto $g: \mathbb{R}^2 \rightarrow \mathbb{R}$ i rozważmy zmienną losową $g(X, Y)$.

Wówczas wartość oczekiwaną

$$E(g(X, Y)) = \iint_{\mathbb{R}^2} g(s, t) g_x(t) g_y(s) dt ds$$

Stwierdzenie.

$$X, Y, g_x, g_y \text{ j.n.}$$

Wówczas zmienna $Z = X + Y$ posiada gęstość daną wzorem

$$g_z(t) = \int_{\mathbb{R}} g_x(s) \cdot g_y(t+s) ds$$

Oznaczanie $g_z = g_x * g_y$ ← splot gęstości

Ławód

$$\int_{[a,b]} \overset{\text{funkcja } g}{g_z(s)} ds = P(\{Z \in [a, b]\}) = P(\{X + Y \in [a, b]\}) = P(\{(X, Y) \in \{(s, t) \in \mathbb{R}^2: s+t \in [a, b]\}\}) \stackrel{\text{wniosek 2)}}{=} \underline{\underline{\quad}}$$

wniosek 2)

$$\iint_{\mathbb{R}} \chi_{\{s,t: s+t \in [a,b]\}} g_x(s) g_y(t) dt ds =$$

$$= \int_{\mathbb{R}} g_y(t) \left(\int_{a-t}^{b-t} g_x(s) ds \right) dt = \int_{\mathbb{R}} g_y(t) \left(\int_a^b g_x(s+t) ds \right) dt =$$

$$= \int_{[a,b]} ds \underbrace{\left(\int_{\mathbb{R}} g_y(t) g_x(s+t) dt \right)}_{\text{funkcja od } s.}$$

Wniosek:

$$g_z(s) = \int_{\mathbb{R}} g_y(t) g_x(s+t) dt$$

Definicja.

Nech $X: \Omega \rightarrow \mathbb{R}$. Wówczas funkcja $\varphi_X(t)$ definiujemy wzorem:

$$\varphi_X(t) = E(e^{itX})$$

Obserwacja 1) X, g_x , to $\varphi_X(t) = E(e^{itX}) = \int_{\mathbb{R}} e^{its} g_x(s) ds$

2.) X, Y - niezależne zmienne losowe

$$\begin{aligned} \varphi_{X+Y}(t) &= E(e^{it(X+Y)}) = E(e^{itX} \cdot e^{itY}) = E(e^{itX}) \cdot E(e^{itY}) = \\ &= \varphi_X(t) \cdot \varphi_Y(t) \end{aligned}$$

Centralne Twierdzenie Graniczne - przyporządkowanie

X_1, X_2, \dots, X_k - niezależne zmienne losowe (o tym samym rozkładzie, posiadające wartość oczekiwaną i skończoną wariancję) o skończonej średniej i wariancji.

$$\equiv \mu\text{-średnia: } \mu = E(X_i)$$

$$\equiv \sigma\text{-wariancja: } \sigma = D^2(X_i) \quad i=1,2,\dots$$

Rozważmy zmienną

$$Y_n = X_1 + \dots + X_n, \quad E(Y_n) = n \cdot \mu$$

$$D^2(Y_n) = n \cdot \sigma$$

$Z_n = \frac{(Y_n - n\mu)}{\sqrt{n\sigma}}$ ← CTG. Z_n "zbiega" do zmiennej Gaussowskiej

CTG: $-\infty < a < b < \infty$

$$\lim_{n \rightarrow \infty} P(a \leq Z_n \leq b) = \frac{1}{\sqrt{2\pi}} \int_{[a,b]} e^{-\frac{s^2}{2}} ds.$$

Dowód.

Bez straty ogólności od $\mu=0, \sigma=1$.

Wzrost: $Z_n = \frac{X_1 + \dots + X_n}{\sqrt{n}}$

Idea: Wykażemy, że Z_n zbiega do funkcji Gaussowskiej.

Udowodnimy, że funkcja charakterystyczna zmiennej Gaussowskiej jest funkcją Gaussa.

Dowód.

Obserwacja: $\varphi_X(t) = E(e^{itx}) = E\left(\sum_{k=0}^{\infty} \frac{(itx)^k}{k!}\right) \stackrel{(*)}{=} 1 + E(itx) - \frac{t^2}{2} E(X^2)$

$\left. \begin{matrix} \mu=0 \\ \sigma \end{matrix} \right\} = 1 - \frac{t^2}{2} \sigma^2$

Dalej: $\varphi_{Z_n}(t) = \varphi_{\frac{X_1 + \dots + X_n}{\sqrt{n}}}(t) \stackrel{\text{niezależność}}{=} \varphi_{\frac{X_1}{\sqrt{n}}}(t) \dots \varphi_{\frac{X_n}{\sqrt{n}}}(t) \stackrel{(*)}{=} \underbrace{\left(1 - \frac{t^2}{2n} \sigma^2\right) \dots \left(1 - \frac{t^2}{2n} \sigma^2\right)}_{\text{iloczyn } n\text{-krotny}} = \left(1 - \frac{t^2}{2n} \sigma^2\right)^n \xrightarrow{n \rightarrow \infty} e^{-\frac{t^2}{2\sigma^2}}$

Wniosek: Wyznaczyć funkcję charakterystyczną zmiennej o rozkładzie Gaussowskim.

$\varphi_X(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}}$

$\varphi_X(t) = \int_{\mathbb{R}} e^{its} \frac{1}{\sqrt{2\pi}} e^{-\frac{s^2}{2}} ds = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{-\frac{1}{2}(s^2 - 2its)} ds = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{-\frac{1}{2}((s-it)^2 + t^2)} ds = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} \int_{\mathbb{R}} e^{-\frac{(s-it)^2}{2}} ds = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} \int_{\mathbb{R}} e^{-\frac{s'^2}{2}} ds' = e^{-\frac{t^2}{2}}$

$\left. \begin{matrix} s' = s - it \\ ds' = ds \end{matrix} \right\}$

Schemat Bernoulliego.

X - zmienna przyjmująca wartości 0 z prawdopodob. q oraz 1 z prawdopodob. p .

X_1, X_2, X_3, \dots - niezależne zmiennne losowe j.w.

Mieci $S_n = X_1 + X_2 + \dots + X_n$ - zmienna o rozkładzie Bernoulliego

$$P(S_n = k) = \binom{n}{k} p^k q^{n-k}$$

Czy $\frac{S_n}{n}$ zbiega do p ?

Twierdzenie. (Mocne prawo wielkich liczb)

Z prawdopodobieństwem równym 1 $\lim_{n \rightarrow \infty} \frac{S_n}{n} = p$.

Twierdzenie. (Słabe prawo)

Ustalmy $\epsilon > 0$. Wówczas:

$$P\left(\left|\frac{S_n}{n} - p\right| \geq \epsilon\right) \leq 2e^{-2n\epsilon^2}$$

Dowód.

$$P\left(\frac{S_n}{n} \geq p + \epsilon\right) = P(S_n \geq n(p + \epsilon)) = \sum_{n(p+\epsilon) \leq k \leq n} \binom{n}{k} p^k q^{n-k} \quad \left. \begin{array}{l} \text{wzrostający} \\ \lambda > 0, \text{ zsumujemy} \\ -\lambda(n(p+\epsilon) - k) \end{array} \right\}$$

$$\leq \sum_{n(p+\epsilon) \leq k \leq n} e^{-\lambda(n(p+\epsilon) - k)} \binom{n}{k} p^k q^{n-k} \leq \sum_{k=0}^n \binom{n}{k} e^{-\lambda(n(p+\epsilon) - k)} p^k q^{n-k} =$$

$$= e^{-\lambda n \epsilon} \sum_{k=0}^n (pe^{\lambda q})^k \cdot (qe^{-\lambda p})^{n-k} \binom{n}{k} = e^{-\lambda n \epsilon} (pe^{\lambda q} + qe^{-\lambda p})^n$$

$$\left\{ \text{dk. } pe^{\lambda q} + qe^{-\lambda p} \leq e^{\frac{\lambda^2}{8}} \right\} \leq e^{-\lambda n \epsilon} e^{\frac{\lambda^2 n}{8}} \left\{ \lambda = 4\epsilon \right\} \leq e^{-2n\epsilon^2}$$

Wniosek:

$$\forall \epsilon > 0 : \lim_{n \rightarrow \infty} P\left(\left|\frac{S_n}{n} - p\right| \geq \epsilon\right) \rightarrow 0$$

Słabe prawo wielkich liczb.