

5.05.2021

Lemat 8.3 (Kroneckera)

Żebyśmy, że a_n jest doggiem
liczbowym takim, że szereg $\sum_{n=1}^{\infty} \frac{a_n}{n}$ jest
zbieżny. Wtedy

$$\lim_{n \rightarrow \infty} \frac{a_1 + \dots + a_n}{n} \rightarrow 0$$

D-d. $S_n = \sum_{k=1}^n \frac{a_k}{k}$, $S_n = S_{n-1} + \frac{a_n}{n}$

$$a_n = n(S_n - S_{n-1}) \quad (*)$$

Przypomnienie z AM 1: Jeżeli $S_n \rightarrow S$,
to średnie $\frac{S_1 + \dots + S_n}{n} \rightarrow S$. (**)

$$\begin{aligned} \frac{a_1 + \dots + a_n}{n} &\stackrel{(*)}{=} \frac{S_1 + 2(S_2 - S_1) + \dots + n(S_n - S_{n-1})}{n} = \\ &= \frac{-S_1 - S_2 - \dots - S_{n-1} + nS_n}{n} = S_n - \frac{S_1 + \dots + S_{n-1}}{n} \end{aligned}$$

(**) $\rightarrow S - S = 0$

Tw. 8.4 (Mocne Prawo Wielkich Liczb Kolmogorowa)

Żeśmy, że $\{X_n\}$ jest ciągiem niezależnych zmiennych losowych (i.i.d, independent, identically distributed) o tym samym rozkładzie.

1. Jeżeli $\mathbb{E}|X_1| < \infty$ i $m = \mathbb{E}X_1$, to

$$\lim_{n \rightarrow \infty} \frac{X_1 + \dots + X_n}{n} = m \quad \text{p.n.}$$

2. Jeżeli $\mathbb{E}|X_1| = \infty$, to

$$\mathbb{P} \left[\limsup_{n \rightarrow \infty} \left| \frac{X_1 + \dots + X_n}{n} \right| = \infty \right] = 1$$

D-d. Z lematu Knoedekera wystarczy pokazać, że szereg $\sum_{n=1}^{\infty} \frac{X_n - m}{n}$ jest zbieżny p.n. Wówczas (*)

$$\begin{aligned} & \frac{(X_1 - m) + (X_2 - m) + \dots + (X_n - m)}{n} = \\ & = \frac{X_1 + \dots + X_n}{n} - m \xrightarrow{\text{p.n.}} 0 \end{aligned}$$

Dowód 1. Zażyczymy dodatkowo, że $\mathbb{E} X_n^2 < \infty$.

Pokażemy zbieżność szeregu (*) korzystając

z tw. o d. szeregach:

$$1^\circ \sum_{i=1}^{\infty} \mathbb{E} \left[\frac{X_i^{-m}}{i} \right] = 0 < \infty$$

$$2^\circ \sum_{i=1}^{\infty} \text{Var} \left(\frac{X_i^{-m}}{i} \right) = \sum_{i=1}^{\infty} \frac{1}{i^2} \text{Var} (X_i) =$$

$$= \text{Var} X_1 \cdot \sum_{i=1}^{\infty} \frac{1}{i^2} < \infty$$

Wtedy $\sum_{i=1}^{\infty} \frac{X_i^{-m}}{i} < \infty$. ■

Dowód w pełnej ogólności.

Zakładamy $\mathbb{E} |X_n| < \infty$.

Zde finiujemy $X'_n = X_n \cdot \mathbb{1}_{\{|X_n| \leq n\}} = \begin{cases} X_n & \text{jeżeli } |X_n| \leq n \\ 0 & \text{w p.p.} \end{cases}$



Zmienne losowe X_n^1 są nrl. oraz ograniczone,
więc również $E(X_n^1)^2 < \infty$. Mamy

$$\begin{aligned} \frac{X_1 + \dots + X_n}{n} - m &= \frac{(X_1 + \dots + X_n) - (X_1^1 + \dots + X_n^1)}{n} \\ &+ \frac{(X_1^1 + \dots + X_n^1) - (EX_1^1 + \dots + EX_n^1)}{n} + \frac{EX_1^1 + \dots + EX_n^1}{n} - m \\ &= I_n + II_n + III_n \end{aligned}$$

Pokażemy, że $I_n \rightarrow 0$, $II_n \rightarrow 0$, $III_n \rightarrow 0$.

III: z tw. Lebesgue'a o zbieżności

zdominowanej $EX_n^1 = E[X_n \mathbb{1}_{\langle -n, n \rangle}] = E[X_1 \mathbb{1}_{\langle -n, n \rangle}]$

$\xrightarrow{n \rightarrow \infty} EX_1 = m$, a zatem $III_n \rightarrow 0$

(z przypomnienia z AM1).

I: $\frac{X_1 + \dots + X_n - (X_1^1 + \dots + X_n^1)}{n} = \frac{(X_1 - X_1^1) + \dots + (X_n - X_n^1)}{n}$

Pokażemy, że z p-stwem 1 dla

dużych n $X_n = X_n^1$

$P[\omega: \exists N_\omega \forall n > N_\omega (X_n = X_n^1)] = 1$

$X_n - X_n^1 \rightarrow 0$ p.n.

A zatem $I_n \rightarrow 0$ p.n. (bo to są
śr. arytmetyczne ciągu $X_n - X'_n$).

Żeby pokazać, że $X_n - X'_n \rightarrow 0$,

skorzystamy z lematu Borela-Cantelliego.

Zauważmy, że

$$\sum_{n=1}^{\infty} P[X_n \neq X'_n] = \sum_{n=1}^{\infty} P[|X_n| \geq n] = \sum_{n=1}^{\infty} P[|X_1| \geq n] = (\star)$$

Przewidujemy, że $E|X_1| < \infty$ da nam zbieżność
szeregu.

$$(\star) = \sum_{n=1}^{\infty} \sum_{k=n}^{\infty} P[k \leq |X_1| < k+1] = \sum_{k=1}^{\infty} \sum_{n=1}^k P[k \leq |X_1| < k+1]$$

$$= \sum_{k=1}^{\infty} k \cdot P[k \leq |X_1| < k+1]$$

$$= \sum_{k=1}^{\infty} \int_{k \leq |X_1| < k+1} k dP \leq \sum_{k=1}^{\infty} \int_{k \leq |X_1| < k+1} |X_1| dP \leq E|X_1| < \infty$$

Z lematu B-C $P[X_n \neq X'_n \text{ i.o.}] = 0$

$$\Rightarrow P[X_n = X'_n \text{ od pewnego miejsca}] = 1$$

\mathbb{I}_n : Z lematu Kroneckera wystarczy
 pokazać, że $\sum_{n=1}^{\infty} \frac{X_n^1 - \mathbb{E}X_n^1}{n}$ jest zbieżnym
 p.n. Z tw. Kolmogorowa wystarczy
 pokazać, że szereg wariancji jest
 zbieżny.

$$\sum_{n=1}^{\infty} \text{Var} \left(\frac{X_n^1 - \mathbb{E}X_n^1}{n} \right) = \sum_{n=1}^{\infty} \frac{1}{n^2} \text{Var}(X_n^1)$$

$$= \sum_{n=1}^{\infty} \frac{1}{n^2} \left(\mathbb{E}(X_n^1)^2 - (\mathbb{E}X_n^1)^2 \right)$$

$$\leq \sum_{n=1}^{\infty} \frac{1}{n^2} \mathbb{E}(X_n^1)^2$$

$$= \sum_{n=1}^{\infty} \frac{1}{n^2} \sum_{k=1}^{\infty} \int_{k-1 \leq |X_n^1| < k} (X_n^1)^2 d\mathbb{P}$$

$$= \sum_{n=1}^{\infty} \frac{1}{n^2} \sum_{k=1}^n \int_{k-1 \leq |X_n^1| < k} (X_n^1)^2 d\mathbb{P}$$

$$\leq \sum_{n=1}^{\infty} \frac{1}{n^2} \sum_{k=1}^n k \int_{k-1 \leq |X_n^1| < k} |X_n^1| d\mathbb{P}$$

$$= \sum_{n=1}^{\infty} \sum_{k=1}^n \frac{k}{n^2} \mathbb{E} \left[|X_n^1| \cdot \mathbb{1}_{[k-1, k)}(|X_n^1|) \right]$$

$$= \sum_{k=1}^{\infty} \sum_{n=k}^{\infty} \frac{k}{n^2} \mathbb{E} \left[|X_1| \mathbb{1}_{[k-1, k)}(|X_1|) \right]$$

$$= \sum_{k=1}^{\infty} k \mathbb{E} \left[|X_1| \mathbb{1}_{[k-1, k)}(|X_1|) \right] \cdot \sum_{n=k}^{\infty} \frac{1}{n^2} = (*)$$

$$\underbrace{\sum_{n=k}^{\infty} \frac{1}{n^2}}_{\leq 2/k}$$

$$\left[\sum_{n=k}^{\infty} \frac{1}{n^2} = \sum_{n=k}^{\infty} \int_n^{n+1} \frac{1}{n^2} dx \leq \sum_{n=k}^{\infty} \int_n^{n+1} \frac{2}{x^2} dx \right]$$

$$= \int_k^{\infty} \frac{2}{x^2} dx = \frac{2}{k}$$

$$(*) \leq 2 \sum_{k=1}^{\infty} \mathbb{E} \left[|X_1| \mathbb{1}_{[k-1, k)}(|X_1|) \right]$$

$$= 2 \mathbb{E} |X_1| < \infty$$

Zastosowania MPWL

1° Metoda Monte Carlo. Cel: aproksymować $\int_0^1 f(x) dx$

Generujemy ciąg n.zl. zm. los. $\{X_n\}_0$

rozkładzie z gęstością g ($g \geq 0, \int_0^1 g(x) dx = 1$)

Obliczmy $S_n = \frac{1}{n} \sum_{i=1}^n \frac{f(X_i)}{g(X_i)}$ $\xrightarrow{\text{MPWL}}$ $\mathbb{E} \left[\frac{f(X_1)}{g(X_1)} \right] =$


i.i.d.

$$= \int_b^1 \frac{f(x)}{g(x)} \cdot g(x) dx = \int_0^1 f(x) dx$$

2° igła Buffona.

igła dl. l , deski

szerokości a



$$P[\text{igła przetnie deskę}] = \frac{2l}{a\pi}$$

Wykonujemy n doświadczeń:

$$X_i = \begin{cases} 1 & \text{w } i\text{-tym rzucie igła} \\ & \text{przecina deskę} \\ 0 & \text{w p.p.} \end{cases}$$

$$EX_i = P[X_i = 1] = \frac{2l}{a\pi}$$

z MPWL

$$\frac{\text{liczba przeurzeń}}{n} = \frac{X_1 + \dots + X_n}{n} \rightarrow EX_1 = \frac{2l}{a\pi}$$

$$\pi \approx \frac{2ln}{ak}$$

W 1901 roku Mario Lazzarini wykonał
3408 rzutów i otrzymał

$$\hat{\pi} \approx \frac{355}{113} = 3.141592\dot{9}203$$

zgodza się

Przykład, Oblicz:

$$\lim_{n \rightarrow \infty} \int_0^1 \dots \int_0^1 \frac{x_1^3 + \dots + x_n^3}{x_1 + \dots + x_n} dx_1 \dots dx_n$$

Niech (X_n) będzie ciągiem n.zl. zm. los.

o rozkładzie $U([0,1])$. Wtedy

$$\int_0^1 \dots \int_0^1 \frac{x_1^3 + \dots + x_n^3}{x_1 + \dots + x_n} dx_1 \dots dx_n = \mathbb{E} \left[\frac{X_1^3 + \dots + X_n^3}{X_1 + \dots + X_n} \right]$$

Z MPWL

$$\frac{X_1^3 + \dots + X_n^3}{X_1 + \dots + X_n} = \frac{\frac{X_1^3 + \dots + X_n^3}{n}}{\frac{X_1 + \dots + X_n}{n}} \xrightarrow{\text{p.n.}} \frac{\mathbb{E} X^3}{\mathbb{E} X} = \frac{1}{2}$$

Podsumowując

$$\lim_{n \rightarrow \infty} \int_0^1 \dots \int_0^1 \frac{x_1^3 + \dots + x_n^3}{x_1 + \dots + x_n} dx_1 \dots dx_n = \lim_{n \rightarrow \infty} \mathbb{E} \left[\frac{X_1^3 + \dots + X_n^3}{X_1 + \dots + X_n} \right] =$$

tzn. też $\mathbb{E} \left[\lim_{n \rightarrow \infty} \frac{X_1^3 + \dots + X_n^3}{X_1 + \dots + X_n} \right] = \frac{1}{2}$

Przykład [Dystrybuanta empiryczne]

Powtarzamy wielokrotnie pewne doświadczenie

o nieznanym rozkładzie. Na podstawie

otrzymanych wyników X_1, \dots, X_n chcemy

wyznaczyć ich dystrybuantę F . Definiujemy

$$[F_n(x, \omega) =] F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{X_i \leq x\}}$$

Powyższe funkcja $F_n(x) = F_n(x, \omega)$

nazywa się dystrybuantą empiryczną.

Tw. 8.5 (Glivenko - Cantelli)

Zachodzi

$$\sup_{x \in \mathbb{R}} |F_n(x) - F(x)| \rightarrow 0 \text{ p.n.}$$

Zauważmy, że dla zm. los. $Y_k = \mathbb{1}_{\{X_k \leq x\}}$

$$\text{zachodzi } \mathbb{E} Y_k = \mathbb{P}[X_k \leq x] = F(x)$$

a z MPWL

$$F_n(x) = \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{\{X_k \leq x\}} = \frac{Y_1 + \dots + Y_n}{n} \rightarrow \mathbb{E} \frac{Y}{n} = F(x) \text{ p.n.}$$

Tw. 8.6 Jeżeli (X_n) jest ciągiem n.z.l.

o takim samym rozkładzie oraz istnieje stała c taka, że

$$\mathbb{P}\left[\lim_n \frac{X_1 + \dots + X_n}{n} = c\right] > 0$$

to $\mathbb{E}|X_1| < \infty$ oraz $c = \mathbb{E}X_1$

D-d. z prawa 0-1 Kołmogorowa

$$\mathbb{P}\left[\lim_n \frac{X_1 + \dots + X_n}{n} = c\right] = 1$$

a stąd

$$\frac{X_n}{n} = \frac{S_n}{n} - \frac{S_{n-1}}{n-1} \cdot \frac{n-1}{n} \xrightarrow{p.n.}$$

Zatem z p-stwem 1 znajdzie jedynie skończenie wiele zdarzeń $\{|X_n| > n\}$.

lemat Borela - Cantelliego implikuje

$$\sum_{n=1}^{\infty} \mathbb{P}[|X_n| > n] = \sum_{n=1}^{\infty} \mathbb{P}[|X_1| > n] < \infty$$

a stąd wynika, że

$$\mathbb{E}|X_1| \leq \sum_{n=1}^{\infty} \mathbb{P}[|X_1| > n] < \infty$$

z MPWL wynika więc

$$\frac{X_1 + \dots + X_n}{n} \rightarrow \mathbb{E}X_1 \text{ p.n.}$$

TW. 8.7, ciekawostka raczej

MPWL, Etemadi

Niech $\{X_n\}$ ciąg zm. los. które są
PARAMI niezależne i mają jedynkowy
rozkład. Jeżeli $\mathbb{E}|X_1| < \infty$, to

$$\frac{X_1 + \dots + X_n}{n} \rightarrow \mathbb{E}X_1 \text{ p.n.}$$

12.04.2021 MPWL kontynuacja

Przykład liczby $a \in [0,1]$ nazywamy
normalną przy podstawie d ($d \in \{2,3,\dots\}$)
jeśli ma ona przedstawienie

$$a = \sum_{n=1}^{\infty} \frac{\epsilon_n}{d^n}, \quad \epsilon_n \in \{0,1,\dots,d-1\}$$

takie, że $\frac{\#\{i : \epsilon_i = k, i \leq n\}}{n} \rightarrow \frac{1}{d}$

dla każdego $k \in \{0,1,\dots,d-1\}$

Problem: • czy istnieją liczby, które
są normalne przy każdej podstawie?
TAK (Borel)

• wskazać liczbę, która jest
normalna przy każdej podstawie d .

PROBLEM OTWARTY

Tw. 8.8 (Borel) Prawie wszystkie liczby
(względem miary Lebesgue'a) \approx przedziału
 $[0, 1]$ są normalne względem każdej podstawy.

D-5. Niech

$$A_d = \{x \in [0, 1] : x \text{ normalny przy pods. } d\}$$

$$A = \bigcap_{d=2}^{\infty} A_d$$

Rozważamy przestrzeń prob. $(\Omega, \mathcal{F}, P) = ([0, 1], \text{Bor}([0, 1]), \lambda)$. Wystarczy pokazać, że $P[A_d] = 1$. Ustalmy d . Każdą $x \in [0, 1]$

można zapisać w postaci

$$x = \sum_{n=1}^{\infty} \frac{\epsilon_n(x)}{d^n},$$

dla $\epsilon_n(x) \in \{0, \dots, d-1\}$. Wtedy $\epsilon_n(x)$

jest ciągiem zm. los. o rozkładzie jednostajnym

na $\{0, 1, \dots, d-1\}$. Ustalmy $k \in \{0, \dots, d-1\}$.

Niech $\chi_n(x) \begin{cases} 1 \\ 0 \end{cases}$ gdy $\epsilon_n(x) = k$
w p.w.

Wówczas $E[X_n] = P[X_n=1] = \frac{1}{d}$ oraz z MPWL

$$\frac{\#\{i \leq n : \varepsilon_i(x) = k\}}{n} = \frac{X_1 + \dots + X_n}{n} \xrightarrow{p.n.} EX_1 = \frac{1}{d}$$

a zatem $P[A_d] = 1$ oraz $P[A] = 1$. ■

Tw. 8.9 (Kotmogorowa o 3 szeregach)

Ustalmy $c > 0$. Szereg $\sum_{n=1}^{\infty} X_n$

jest zbieżny p.n. wtedy i tylko wtedy,
gdy następujące 3 szeregi

$$\sum_{n=1}^{\infty} EX_n^{(c)}, \quad \sum_{n=1}^{\infty} \text{Var} X_n^{(c)}, \quad \sum_{n=1}^{\infty} P[|X_n| > c]$$

są zbieżne.

$$\text{Dla } c > 0 \quad X^{(c)} = \begin{cases} X & \text{dla } |X| \leq c \\ 0 & \text{dla } |X| > c \end{cases}$$

D-d. "⇐" Łat. że te 3 szeregi są

zbieżne.

1. że zbieżności $\sum EX_n^{(c)}$ i $\sum \text{Var} X_n^{(c)}$

i tw. Kotmogorowa o dwóch

szeregu otrzymujemy, że $\sum X_n^{(c)}$ jest zbieżny.

2. Korzystamy z lematu Borela-Canteliego.

Skoro $\sum P[|X_n| > c] < \infty$, to

$P[|X_n| > c \text{ i.o.}] = 0$, zatem

z p-stwem 1 $|X_n| < c$ dla

dużych n .

Tw. 9.1 (de Moivre'a - Laplace'a) [Centralne tw. graniczne]

Niech $X_n = \pm 1$ z p-stwem $\frac{1}{2}$ - niezależne zm. los.

z MPWL. $S_n = X_1 + X_2 + \dots + X_n$,

$$\frac{S_n}{n} \rightarrow 0 \text{ p.n.}$$

W szczególności: $\forall \varepsilon > 0 \exists n_0$ dla dużych n $|S_n| < \varepsilon \cdot n$

• Jaka jest typowa odl. S_n od 0 dla dużych n ?

• Jak należy znormalizować S_n , aby otrzymać coś miływielnego?

$$\frac{S_n}{a_n} \rightarrow \text{coś} \neq 0$$

Chcielibyśmy policzyć $E|S_n|$ - to jest
zmiudne, łatwiej policzyć $E S_n^2 = \text{Var} S_n$
 $= \text{Var}(X_1 + \dots + X_n) = \text{Var} X_1 + \dots + \text{Var} X_n$
 $= 1 + \dots + 1 = n.$

$$S_n^2 \approx n \rightarrow |S_n| \approx \sqrt{n}. \text{ Typowa}$$

odl. S_n od zera jest rzędu \sqrt{n}

Chcemy opisać $\frac{S_n}{\sqrt{n}}$. Czy ten ciąg
ma jakąś granicę? Strukturę?

Treść TW. 3.1

Niech $\{X_n\}$ będzie

ciągiem niezal. zm. los. t.ze $P[X_n = 1] =$

$$= P[X = -1] = \frac{1}{2} \text{ i niech } S_n = X_1 + \dots + X_n.$$

Wówczas, dla dowolnych $a < b$

$$P\left[a \leq \frac{S_n}{\sqrt{n}} \leq b\right] \xrightarrow{n \rightarrow \infty} \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{x^2}{2}} dx = \Phi(b) - \Phi(a)$$

$\Phi(b) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^b e^{-\frac{x^2}{2}} dx$ jest dystrybucją rozkładu normalnego.

P-d. Przypomnienie: formuła Stirlinga:

$$n! \sim \sqrt{2\pi n} \cdot \frac{n^n}{e^n} \quad \text{gdyn} \quad n \rightarrow \infty$$

Zet. że $n = 2m$ (głównie po a puszysta).

Wtedy $P[S_{2m} = 2k + 1] = 0$.

$$P[S_{2m} = 2k] = \binom{2m}{m+k} \frac{1}{2^{2m}} = \frac{(2m)!}{(m+k)!(m-k)! 2^{2m}}$$

Stirling $\sim \frac{e^{m+k} e^{m-k} (2m)^{2m}}{e^{2m} (m+k)^{m+k} (m-k)^{m-k}} \cdot \frac{\sqrt{4\pi m}}{(\sqrt{2\pi(m+k)} \sqrt{2\pi(m-k)})} \cdot \frac{1}{2^{2m}}$

$$= \left(\frac{m}{m+k}\right)^{m+k} \left(\frac{m}{m-k}\right)^{m-k} \frac{m}{(m+k)(m-k)} \cdot \frac{1}{\sqrt{\pi}}$$

$$= \left(1 + \frac{k}{m}\right)^{-(m+k)} \left(1 - \frac{k}{m}\right)^{-(m-k)} \cdot \frac{1}{\sqrt{\pi m}} \cdot \frac{1}{\sqrt{1 + \frac{k}{m}} \sqrt{1 - \frac{k}{m}}}$$

$$= \left(1 - \frac{k^2}{m^2}\right)^{-m} \left(1 + \frac{k}{m}\right)^{-k} \left(1 - \frac{k}{m}\right)^k \frac{1}{\sqrt{m\pi}} \cdot \frac{1}{\sqrt{1 + \frac{k}{m}} \sqrt{1 - \frac{k}{m}}}$$

Ustalony $x \in \mathbb{R}$. Jeżeli $2m \rightarrow \infty$,
 a $2k = x\sqrt{2m}$, to $\frac{k^2}{m} = \frac{x^2}{2}$, zatem

$$\left(1 - \frac{k^2}{m^2}\right)^{-m} \rightarrow e^{\frac{x^2}{2}}$$

$$\left(1 + \frac{k}{m}\right)^{-k} \rightarrow e^{-x^2}$$

$$\left(1 - \frac{k}{m}\right)^k \rightarrow e^{-\frac{x^2}{2}}$$

Stąd wynika

$$P[S_{2m} = 2k] \sim e^{-\frac{x^2}{2}} \frac{1}{\sqrt{\pi m}}$$

Dalej

$$P\left[a \leq \frac{S_{2m}}{\sqrt{2m}} \leq b\right] = \sum_{x \in [a, b] \cap \frac{2\mathbb{Z}}{\sqrt{2m}}} P[S_{2m} = x\sqrt{2m}]$$

$$\sim \sum_{x \in [a, b] \cap \frac{2\mathbb{Z}}{\sqrt{2m}}} \frac{1}{\sqrt{2\pi}} \sqrt{\frac{2}{m}} e^{-\frac{x^2}{2}} \sim \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$$

Zadanie: Jakie jest p-stwo, że w 100 rzutach kostką otrzymamy co najmniej 100 orłów? Rozwiązanie:

Niech $X_i = 1$ gdy w i -tym rzucie wypadł orzeł i $X_i = -1$ w p.p.

$$S_{100} = X_1 + \dots + X_{100}, \quad \text{Chcemy } S_{100} = 20.$$

Z tw. 3.1

$$\begin{aligned} P[S_{100} \geq 20] &= P\left[\frac{S_{100}}{10} \geq 2\right] \approx 1 - \Phi(2) \\ &\approx 0,02. \end{aligned}$$

Cel: Chcemy sformalizować zb. wg rozkładu.

Co znaczy ciąg miar μ_n zbieżny do miary μ ?

Zbieżność wg rozkładu definiuje się na funkcjach ciągłych. Oznaczmy

$$C(\mathbb{R}) = \{f: \mathbb{R} \rightarrow \mathbb{R} \text{ ciągłe i ogr.}\}$$

Definicja 9.2 Niech μ_n będzie ciągiem miar prob. na $\mathcal{B}_0(\mathbb{R})$. Mówimy, że μ_n zbiegają słabo do miary prob. μ ($\mu_n \Rightarrow \mu$) jeżeli dla każdej funkcji $f \in C(\mathbb{R})$

$$\int_{\mathbb{R}} f(x) \mu_n(dx) \longrightarrow \int_{\mathbb{R}} f(x) \mu(dx)$$

$$(f, \mu_n) \longrightarrow (f, \mu)$$

Przykład. $a_n \rightarrow a \in \mathbb{R}$, wtedy $\delta_{a_n} \Rightarrow \delta_a$.

Niech $f \in C(\mathbb{R})$.

$$\int_{\mathbb{R}} f d\delta_{a_n} = f(a_n) \xrightarrow{n \rightarrow \infty} f(a) = \int_{\mathbb{R}} f d\delta_a$$

Przykład $\mu_n(\{\frac{k}{n}\}) = \frac{1}{n}, k \in \{1, \dots, n\}$

Niech $f \in C(\mathbb{R})$.

$$\int_{\mathbb{R}} f d\mu_n = \sum_{k=1}^n f\left(\frac{k}{n}\right) \frac{1}{n} \xrightarrow{n \rightarrow \infty} \int_{[0,1]} f d\lambda$$

TW. 9.3 Niech μ_n, μ będą miar. prob. na $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$. NWSR

1° $\mu_n \Rightarrow \mu$

2° Dla $f \in C(\mathbb{R})$ i jedn. ciągłej

$$\int_{\mathbb{R}} f d\mu_n \xrightarrow{n \rightarrow \infty} \int_{\mathbb{R}} f d\mu$$

3° Dla każdego domkniętego $F \subset \mathbb{R}$

$$\limsup_{n \rightarrow \infty} \mu_n(F) \leq \mu(F)$$

4° Dla każdego otwartego $G \subset \mathbb{R}$

$$\liminf_{n \rightarrow \infty} \mu_n(G) \geq \mu(G)$$

5° Dla każdego $A \in \mathcal{B}(\mathbb{R})$ t. ze $\mu(\partial A) = 0$

$$\lim_{n \rightarrow \infty} \mu_n(A_n) = \mu(A)$$

↑
breg A

19.05.2021

D-d. tw. 9.3

• "2 \Rightarrow 3" Ustalmy zbiór domknięty F .

Dla $\varepsilon > 0$ oznaczymy przez

$$F_\varepsilon = \{x \in \mathbb{R} : d(x, F) < \varepsilon\}$$

ε -otoczkę zbioru F . Ustalmy $\delta > 0$

i weźmy $\varepsilon > 0$ taki, że

$$\mu(F_\varepsilon) < \mu(F) + \delta.$$

Taki ε istnieje, gdyż z domkniętości

$$F : F = \bigcap_{n=1}^{\infty} F_{1/n}, \quad \text{a z lematu}$$

o ciągłości miary $\mu(F_{1/n}) \rightarrow \mu(F)$. Niech

f będzie jedostajnie ciągłą funkcją

taką, że

$$\mathbb{1}_F \leq f \leq \mathbb{1}_{F_\varepsilon}$$

(można np. przyjąć $f(x) = \phi(d(x, F)/\varepsilon)$,

dla $\phi(t) = 1$, $1-t$, 0 dla $t \leq 0$, $t \in (0, 1)$,
 $t \geq 1$)

Wówczas

$$\limsup \mu_n(F) \leq \limsup \int f d\mu_n = \int f d\mu \leq \mu(F_\varepsilon) \leq \mu(F) + \delta$$

z dowolności δ mamy
tezę.

• "4 \Rightarrow 1" Załóżmy, że $g \in C(\mathbb{R})$ oraz $g \geq 0$.

Wówczas korzystając kolejno z:

tw. Fubiniego, lematu Fatou oraz pkt. 4:

$$\liminf \int_{\mathbb{R}} g(x) \mu_n(dx) = \liminf \int_{\mathbb{R}} \int_0^{g(x)} dt \mu_n(dx)$$

$$\stackrel{\text{Fubini}}{=} \liminf \int_0^{\infty} \int_{\{x: g(x) > t\}} \mu_n(dx) dt$$

$$= \liminf \int_0^{\infty} \mu_n \{x: g(x) > t\} dt$$

$$\stackrel{\text{Fatou}}{\geq} \int_0^{\infty} \liminf \mu_n \{x: g(x) > t\} dt$$

$$\stackrel{\text{pkt. 4}}{\geq} \int_0^{\infty} \mu \{x: g(x) > t\} dt$$

$$= \dots = \int_{\mathbb{R}} g(x) \mu(dx)$$

g ciągła,
więc
 $\{x: g(x) > t\}$
otwarty

• "3, 4 \Rightarrow 5" Bierzemy A t. i. e. $\mu(\partial A) = 0$.

$$0 = \mu(\partial A) = \mu(\bar{A}) - \mu(\text{Int} A) \Rightarrow \mu(\bar{A}) = \mu(\text{Int} A)$$

$$\begin{aligned} \mu(\bar{A}) &\stackrel{3)}{\geq} \limsup \mu_n(\bar{A}) \stackrel{A \subseteq \bar{A}}{\geq} \limsup \mu_n(A) \\ &\geq \liminf \mu_n(A) \stackrel{A \supseteq \text{Int} A}{\geq} \liminf \mu_n(\text{Int} A) \\ &\geq \mu(\text{Int} A) \end{aligned}$$

Ale $\mu(\bar{A}) = \mu(\text{Int} A)$, zatem

$$\lim \mu_n A = \mu \bar{A} = \mu \text{Int} A = \mu A.$$

• "5 \Rightarrow 3" Ustawmy domknięty F . Definiujemy

F_ε . Patrzymy na ∂F_ε - są to zbiory

$(F_{\varepsilon_n} \cap F_{\varepsilon_m})^c \neq \emptyset$ rozłączne $\mu(\partial F_\varepsilon) > 0$ jedynie dla

przeliczalnie wielu ε : $F^c \supset \bigcup_{\varepsilon > 0} \partial F_\varepsilon$,

$$\mu\left(\bigcup_{\varepsilon > 0} \partial F_\varepsilon\right) \leq \mu(F^c) \leq 1,$$

$\sum_{\varepsilon > 0} \mu(\partial F_\varepsilon) \leftarrow$ nieprzeliczalnie wiele,
więc tylko przeliczalnie
wiele musi być > 0 .

Jest więc więc ciąg $\{E_k\}$ t.ż. $E_k \rightarrow \emptyset$

oraz $\mu(\partial F_{E_k}) = 0$. Wstawmy k .

$$\limsup \mu_n(F) \leq \limsup \mu_n(F_{E_k}) \stackrel{5.1}{=} \mu(F_{E_k})$$

Gody $k \rightarrow \infty$ z lematu o ciągłości

miary $\mu(F_{E_k}) \rightarrow \mu(F)$. ▀

Tw. 9.4 Jeżeli μ, ν są miarami prob.

na $(\mathbb{R}, \text{Bor}(\mathbb{R}))$ t.ż. dla każdej

funkcji $f \in C(\mathbb{R})$

$$\int_{\mathbb{R}} f d\mu = \int_{\mathbb{R}} f d\nu$$

to $\mu = \nu$, tj. $\mu(A) = \nu(A)$ dla

każdego $A \in \text{Bor}(\mathbb{R})$.

Wniosek Granica w def. stałej zbierności

jest jednoznacznie wyznaczona.

D-d. Z lematu Dynkina o Π - λ wtedy

wystarczy pokazać, że $\mu(F) = \nu(F)$

dla dow. dom. $F \in \text{Bor}(\mathbb{R})$. Istotnie,

niech \mathcal{L} będzie rodziną wszystkich

domkniętych zbiorów borelowskich, a

$$\mathcal{L} = \{A \in \text{Bor}(\mathbb{R}) : \mu(A) = \nu(A)\}.$$

\mathcal{L} jest Π -układem, \mathcal{L} jest λ -układem.

Niech $\mu_n = \mu$. Wtedy z zeb.

$\mu_n \Rightarrow \nu$, z tw. 9.3 pkt. 3 mamy

$$\mu(F) = \limsup \mu_n(F) \leq \nu(F)$$

Analogicznie pokazyjemy $\nu(F) \leq \mu(F)$

co daje równość obu miar

$$(\mathcal{L} \subset \mathcal{L} \Rightarrow \sigma(\mathcal{L}) \subset \mathcal{L})$$

" "
 $\text{Bor}(\mathbb{R})$



TW. 9.5 Niech $\{\mu_n\}_{n=1}^{\infty}$, μ będą

rozkładami na \mathbb{R} o dystrybuantach

$\{F_n\}_{n=1}^{\infty}$, F . Wtedy $\mu_n \Rightarrow \mu$ wtedy

i tylko wtedy, gdy $F_n(x) \rightarrow F(x)$ dla

każdego x , w którym F jest ciągła.

Wniosek Niech $\{X_n\}$ i.i.d., $X_n = \pm 1$ z $\text{pctwem } \frac{1}{2}$.

$S_n = X_1 + \dots + X_n$. Z tw. Moivre'a-Laplace'a

$$\mu_{\frac{S_n}{\sqrt{n}}} \Rightarrow \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$$

$$\left(\mu(dx), \mu(A) = \int_A \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \right)$$

$$\text{bo } \mathbb{P}\left[\frac{S_n}{\sqrt{n}} \leq b\right] \rightarrow \Phi(b)$$

D-d. TW 9.5

• " \Rightarrow " zał. $\mu_n \Rightarrow \mu$. Wybierzmy x -pkt. ciągłości F .

Wzimy $A = (-\infty, x]$, $\partial A = \{x\}$, $\mu(\{x\}) = 0$.

(bo x nie jest atomem).

$$F_n(x) = \mu_n(A) \xrightarrow{\text{z pop. tw.}} \mu(A) = F(x)$$

- " \Leftarrow " Załóżmy, że $F_n \rightarrow F$ dla x w których F ciągła. Pokażemy $\liminf \mu_n G \geq \mu(G)$ dla każdego otwartego $G \subset \mathbb{R}$.

Ustalmy $G \subset \mathbb{R}$, otwarty. Zbiór G możemy zapisać w postaci $G = \bigcup_{i=1}^N I_k$, gdzie

$I_k = (a_k, b_k)$ i są rozłączne. (może być $N = \infty$)

Ustalmy $\varepsilon > 0$. Wybieramy a'_k, b'_k :

- a'_k, b'_k były pkt. ciągłości F

- $F(b'_k) - F(a'_k) = \mu((a'_k, b'_k))$

$$\geq \mu(I_k) - \varepsilon/2^k$$

Ustalmy m .

$$\liminf \mu_n(G) \geq \liminf \mu_n\left(\bigcup_{i=1}^m I_k\right)$$

$$\geq \sum_{i=1}^m \liminf \mu_n((a'_k, b'_k))$$

$$= \sum_{i=1}^m \liminf (F_n(b'_k) - F_n(a'_k))$$

z zol. $= \sum_{i=1}^m F(b'_k) - F(a'_k)$

$$\geq \sum_{i=1}^m \mu(I_k) - \varepsilon/2^k \geq \mu\left(\bigcup_{i=1}^m I_k\right) - \varepsilon$$

Gdy przejdziemy z $n \rightarrow \infty$, to
z lematu o ciągłości miary

$$\liminf \mu_n(G) \geq \mu(G) - \varepsilon.$$

Z dowolnością ε , przy $\varepsilon \rightarrow 0$

$$\liminf \mu_n(G) \geq \mu(G). \text{ z popr. tw.}$$

$$\mu_n \Rightarrow \mu.$$



Przykład Niech $a_n \rightarrow a \in \mathbb{R}$. Wtedy $\delta_{a_n} \Rightarrow \delta_a$,

bo dystrybuanta F miary δ_a ma
tylko jeden punkt nieciągłości: a .

Dla każdego $x \neq a$ $F_n(x) \rightarrow F(x)$.

Przykład Niech $\mu(\frac{k}{n}) = \frac{1}{n}$ i $\mu = \int_{[0,1]} \delta(x) dx$.

Wówczas zbieżność $\mu_n \Rightarrow \mu$ wynika

z popr. tw.

Definicja 9.6 Mówimy, że ciąg zm. los. $\{X_n\}$ zbiega według rozkładu do zmiennej losowej X ($X_n \xrightarrow{d} X$), jeżeli $\mu_{X_n} \Rightarrow \mu_X$ lub równoważnie $F_n(x) \rightarrow F(x)$ dla punktów ciągłości F .

Często będziemy używać nieco innej notacji i np. pisać $X_n \xrightarrow{d} N(0,1)$ co oznacza, że X_n zbierają wg rozkładu do pewnej zmiennej losowej o rozkładzie $N(0,1)$.

Uwaga $X_n \xrightarrow{d} X \iff \mathbb{E}f(X_n) \rightarrow \mathbb{E}f(X)$
dla każdej $f \in C(\mathbb{R})$.

Przykład Niech $\{X_n\}$ będzie ciągiem niezależnych zm. los. t.je $P[X_n = \pm 1] = 1/2$ i niech $S_n = X_1 + \dots + X_n$. Wówczas $S_n/n \xrightarrow{d} N(0,1)$

24.02.2021

Ω - zbiór zdarzeń elementarnych
(czyli „wyników doświadczenia“)

$\omega \in \Omega$ - konkretny wynik, czyli
zdarzenie elementarne

$A \subset \Omega$ - zdarzenie (czyli podzbiór Ω)

$A \cap B, A^c, A \cup B$, różne
operacje na zdarzeniach.

Def. 1.1 Rodzina \mathcal{F} podzbiorów Ω

nazywamy σ -ciałem, jeżeli

(i) $\emptyset \in \mathcal{F}$

(ii) $A \in \mathcal{F}$, to $A^c \in \mathcal{F}$

(iii) $A_1, A_2, \dots \in \mathcal{F}$, to $\bigcup_{i=1}^{\infty} A_i \in \mathcal{F}$

Parę (Ω, \mathcal{F}) nazywamy przestrzenią
mierzenia.

Przykład

1. Rzut monetą. Możliwe dwa wyniki:
orzeł (O) oraz reszka (R). $\Omega = \{O, R\}$.

$$\mathcal{F} = 2^\Omega$$

2. Rzut kostką. $\Omega = \{1, \dots, 6\}^n$

3. n rzutów kostką: $\Omega = \{1, \dots, 6\}^n$.

Możemy wyróżnić konkretne zdarzenie,

np. A - suma wyrzuconych wyników

jest !. parzystą, wtedy

$$A = \{\omega = (\omega_1, \dots, \omega_n) \in \Omega : \omega_1 + \dots + \omega_n \equiv 0 \pmod{2}\}$$

4. Czas oczekiwania na pewne

zdarzenie (np. przyjazd tramwaju,

wzrost kursu akcji), $\Omega = [0, \infty)$

Def 1.2 Niech (Ω, \mathcal{F}) będzie p. miarowym.

Funkcję $P: \mathcal{F} \rightarrow [0, 1]$ nazywamy
prawdopodobieństwem (miarą prob.)

jeżeli:

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

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

parami rozłącznych zdarzeń

$$A_1, A_2, \dots \in \mathcal{F}$$

$$(\Omega, \mathcal{F}) \rightsquigarrow (\Omega, \mathcal{F}, P)$$

Przestrzeń probabilistyczna

~ provided by Kolmogorov, ok. 1930 r.

Przykład P-stwo klasyczne

Ω - skończ. zbiór. $\mathcal{F} = 2^{\Omega}$. Wówczas

wystarczy zdefiniować p-stwo na

zdarzeniach elementarnych: $P(\omega) = \frac{1}{|\Omega|}$

Wtedy dla $A \subset \Omega$ mamy $P(A) = \frac{|A|}{|\Omega|}$

Przykład Załóżmy, że $\Omega = \{\omega_1, \omega_2, \dots\}$

jest zbiorem przeliczalnym i niech

$p_1, p_2, \dots \geq 0$ sumują się do 1.

Wtedy $\mathcal{F} = 2^\Omega$ oraz $P(\{\omega_i\}) = p_i$

dla $i \in \mathbb{N}$. Jednocześnie definiuje

to p. prob.

Tw. 1.4 (Ω, \mathcal{F}, P) — p. prob.

$A, B, A_1, A_2, \dots \in \mathcal{F}$.

1° $P(\emptyset) = 0$

2° A_1, \dots, A_n — parami rozłączne,

wtedy $P(\cup_i A_i) = \sum_i P(A_i)$

(dopuszczamy $n = \infty$)

3° $P[A^c] = 1 - P[A]$

4° $A \subset B \Rightarrow P[B \setminus A] = P[B] - P[A]$
 $P[B] \geq P[A]$

5° $P[A \cup B] = P[A] + P[B] - P[A \cap B]$

6° $P[\cup_i A_i] \leq \sum_i P[A_i]$

Tw. 1.5 Zasada włączeń i wyłączeń

$A_1, \dots, A_n \in \mathcal{F}$. Wtedy

$$\begin{aligned} P[A_1 \cup \dots \cup A_n] &= \\ &= \sum_i^n P[A_i] - \sum_{i < j} P[A_i \cap A_j] + \sum_{i < j < k} P[A_i \cap A_j \cap A_k] \\ &\quad + \dots + (-1)^{n+1} P[A_1 \cap \dots \cap A_n] \end{aligned}$$

Tw. 1.6 Tw. o ciągłości

$A_1, \dots \in \mathcal{F}$.

1° Jeżeli ciąg zdarzeń $\{A_n\}$ jest wstępujący (tzn. $A_1 \subset A_2 \subset \dots$) oraz
oraz $A = \bigcup_{i=1}^{\infty} A_i$, wtedy

$$P[A] = \lim_{n \rightarrow \infty} P[A_n]$$

2° Jeżeli ciąg zdarzeń $\{A_n\}$ jest zstępujący, to $(A_1 \supset A_2 \supset \dots)$ oraz
 $A = \bigcap_{i=1}^{\infty} A_i$, wtedy

$$P[A] = \lim_{n \rightarrow \infty} P[A_n]$$

Przykład Do urny wrzucamy nieskończenie wiele kul o numerach

1, 2, ... w następujący sposób:

- o godz. (12.00 - 1 min.) wrzucamy

kule 1, 2, ..., 10;

- o godz. (12.00 - $\frac{1}{2}$ min.) wyciągamy

a) kulę 10 b) kulę 1 c) losową kulę,

a następnie wrzucamy kule

11, 12, ..., 20;

- o godz. (12.00 - $\frac{1}{4}$ min.) wyciągamy

a) kulę 20 b) kulę 2 c) losową kulę

- ...

Ile kul będzie w urnie o

12:00?

a) ∞ wiele

b) 0

c) patrzamy na kulę 1.

A_n - po n krokach 1
jest w urnie, $A_n \supset A_{n+1}$

$A = \bigcap_{k=1}^{\infty} A_k$ - o 12.00 1 będzie
w urnie


Z tw. o ciągłości $P[A] = \lim_n P[A_n]$.

$$P[A] = \lim_n P[A_n] = \frac{9}{10} \cdot \frac{18}{19} \cdot \dots \cdot \frac{9n}{9n+1} \rightarrow 0$$

Uрна będzie pusta z pewnym 1.

Rozwiązanie: zestawów się jak wygląda
p. prob. dla powyższego
przykładu.

Przykład Romeo i Julia umówili się na spotkanie o północy. Każde z nich przybędzie z losowym opóźnieniem co najwyżej godziną (i opóźnienie to jest jedn. rozł. w czasie). Osoba która przyjdzie pierwsza może czekać co najwyżej 15 minut. Jakże jest prawdopodobieństwo że się spotkają?




$$\text{Spotkanie jest możliwe} \Leftrightarrow |R - J| < \frac{1}{4}$$

$$\Omega = [0, 1]^2, \quad \mathcal{F} = \text{Bor}([0, 1]^2), \quad \mathbb{P} = \text{Leb.}$$

Letno sprevidić, ie $P[\text{🎲}] = \frac{7}{16}$.

03.03.2021

Przypomnienie:



Zawsze powinniśmy mieć z tyłu
głowy jaką przestrzeń probabilistyczną
rozważamy.

P-stwo geometryczne

Pytanie: jak losować punkty z
odcinka $[0, 1]$?

Chcielibyśmy wziąć $x \in [0, 1]$, $P[x=y] > 0$.

żeby była jednostajna ($x \neq y \Rightarrow P[x=y] =$
 $= P[y=x]$)
 \Downarrow
 $P[x=y] = 0$.


Jeżeli miara nie musi być jednostajna,
to i tak się nie da tak zrobić, żeby
 $\forall x \in [0, 1] \quad P[\{x\}] > 0$, bo mielibyśmy

$$(*) \quad \sum_{x \in [0, 1]} P[\{x\}] = \infty$$

Szkieć dowodu (*):

Zdefiniujemy $A_n := \{x : P[x] \in (\frac{1}{n}, \frac{1}{n-1}]\}$

$A_1 := \{x : P[x] > 1\}$



$$\bigcup A_n = [0, 1]$$

A_1 (przeciwność)

↑
przeliczalna
suma

↑
nieprzeliczalne

∃ k t. że A_k nieprzeliczalne

$$\sum_{x \in A_k} P[\{x\}] = \infty$$

To nam mówi, że nie możemy
za bardzo zrobić sensownej
miary "na punktach".

Jeżeli zależy nam na sensownej
jednostajnej miarze, to bierzemy
miarę Lebesgue'a:


$([0, 1], \text{Box}[0, 1], \text{Leb})$

Przykład Paradox Bertranda

W okręgu o promieniu 1
wybrawo losowo cięciwę AB.


Jakie jest p-stwo, że będzie
ona dłuższa niż bok trójkąta
równobocznego wpisanego w ten
okrąg?

Cel: $P(|AB| > a)$



Rozw. 1

DT. cięciwy zależy jedynie od kąta, na którym jest rozwartą:



$$|AB| > a \Leftrightarrow \alpha > \frac{2}{3}\pi, \alpha \in [0, \pi]$$


Nasza P. Prob. to teraz:

$$([0, \pi], \mathcal{B}_\pi([0, \pi]), \frac{1}{\pi} \text{Leb})$$

$$P(|AB| > \frac{2}{3}\pi) = \frac{1}{3}$$

Rozw. 2

$|AB|$ jest jedn.
wyznaczona
przez długość $|SP|$.



$|AB| > a$ iff P leży wewnątrz
koła wpisanego w trójkąt.


Nasze przestrzeń:

$$\left(B(0,1), \text{Bor}(B(0,1)), \frac{1}{\pi} \text{Leb}_2 \right) \\ \mathbb{R}^2$$

$$\mathbb{P}[|AB| > a] = \frac{\left(\frac{1}{2}\right)^2 \pi}{\pi} = \frac{1}{4}$$

Rozw. 3

Wybór cięciwy jest
mierzniwcz na obroty.




Mozemy po prostu wylosować punkt z
promienia okręgu, wyznaczyć on cięciwę.

P. prob: $([0,1], \mathcal{P}([0,1]), \text{Leb})$

$$P(|AB| > a) = \frac{1}{2}$$

Model: wszystko zależy od
wyboru p. probabilistycznej:



P-stwa warunkowe.

Motywacja Powiadaćmy, że chcemy
liczyć średnie składki emerytalne.

Mezycyżni żyją średnio 70 lat,
jednakże jeśli facet dożyje wieku

emerytalnego, to dożyje średnio 83
roki życia.

Def. 2.1. (Ω, \mathcal{F}, P) - p. prob.

oraz A, B takie zdarzenia, że

$P[B] > 0$. P-stwo warunkowe

Zdarzenia A pod warunkiem B
nazywamy liczbę

$$P[A|B] = \frac{P[A \cap B]}{P[B]}$$

Wówczas przy ustalonym zbiorze B ,
miara $P[\cdot | B]$ jest miarą prob.
na (Ω, \mathcal{F}) .

Def. 2.2 Rodzina $\{B_k\}_{k=1}^n$ (dopuszczamy $n = \infty$)

jest rozbiciem zbiora Ω ,

gdy $\Omega = \bigcup_{k=1}^n B_k$



suma rozłączna.

(Wystarczyłoby $P[\Omega - \cup B_k] = 0$)

Tw. 2.3 Wzór na p-stwo całkowite

$\{B_k\}_k^n$ - rozbicie Ω takim,

że $P[B_k] > 0$, to dla $A \in \mathcal{F}$

$$P[A] = \sum_{k=1}^n P[A | B_k] \cdot P[B_k]$$

D-d.

$$P[A] = P[A \cap \bigcup_k^n B_k] = P[\bigcup_k^n \underbrace{A \cap B_k}_{\text{rozł.}}] =$$

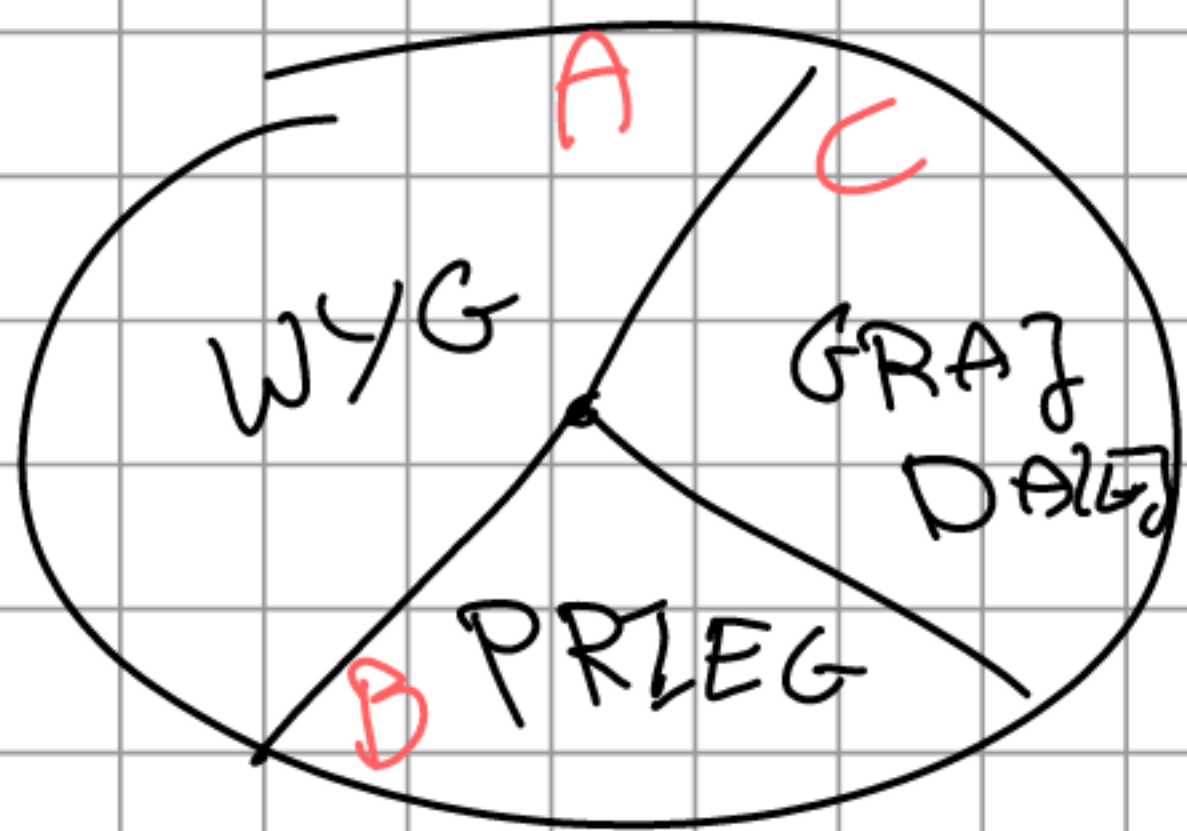
$$= \sum_k^n P[A \cap B_k] = \sum_k^n P[A | B_k] P[B_k]$$

■

Przykład Gry na loterii.

Wyciągamy los. Z p-stwem p wygrywamy,
z p-stwem q przegrywamy, z p-stwem
 r ciągniemy jeszcze raz (los "graj dalej").

Jakie jest p-stwo wygranej?



$$\begin{aligned}
 P[W] &= P[W|A] \cdot P[A] + \\
 &+ P[W|B] \cdot P[B] + \\
 &+ P[W|C] \cdot P[C] = \\
 &= p + P[W] \cdot r
 \end{aligned}$$

$$\Downarrow \\
 P[W] = \frac{p}{1-r} = \frac{p}{p+q}$$

Dywersja: z punktu widzenia
 probabilistyki zbiory miary \emptyset
 są „niewidoczne”, nie zmieniają
 ani nie wpływają na przebieg
 doświadczenia.

Tw. 2.4 Wzór Bayesa

Przy założeniach jak wyżej, jeżeli $P[A] > 0$, to dla każdego k

$$P[B_k | A] = \frac{P[A | B_k] \cdot P[B_k]}{\sum_i^n P[A | B_i] \cdot P[B_i]}$$

D-ł.

$$P[B_k | A] = \frac{P[B_k \cap A]}{P[A]} = \frac{P[B_k | A] \cdot P[A]}{\sum_i^n P[A | B_i] \cdot P[B_i]}$$

popr. tw.

def. prawd. warunk.

Przykład Mamy 100 monet, jedna

(ma orła po dwóch stronach) jest fałszywa i ma orła po obu

stronach. Wybieramy losową monetę

i rucamy nią 10 razy. Otrzymaliśmy

10 orłów. Jakie jest p-stwo, że

wylosowaliśmy fałszywą monetę?

Krok 1. Wybór monety

Krok 2. 10 raz rzucamy

Wynik: 10 orłów

czyli wamy
wyniku do analizy
poprzez dwóch kroków

B_1 - dobra moneta

B_2 - fałszywa moneta

A - 10 orłów

$$\Omega = B_1 \cup B_2$$

$$P[B_2 | A] = \frac{P[A|B_2]P[B_2]}{P[A|B_1]P[B_1] + P[A|B_2]P[B_2]} =$$

$$= \frac{1 \cdot \frac{1}{100}}{\frac{1}{2^{10}} \cdot \frac{99}{100} + 1 \cdot \frac{1}{100}} \approx 0.91$$

Przykład Pewna choroba zaraża

jedną na 1000 osób.

Test na tę chorobę wykrywa

ją z p-stwem 99%, a u

osób zdrowych działa poprawnie

z p-stwem 95%. Złożymy,

że u losowej osoby test wyszedł

pozytywny. Jakie jest p-stwo,

że naprawdę jest chora?

Zdorenia:


C - chora, Z - zdrowa. $\Omega = C \cup Z$

T - pozytywny test

$$P[C|T] = \frac{P[T|C] \cdot P[C]}{P[T|C] \cdot P[C] + P[T|Z] \cdot P[Z]}$$

$$= \frac{0.99 \cdot \frac{1}{1000}}{\frac{99}{100} \cdot \frac{1}{1000} + \frac{5}{100} \cdot \frac{999}{1000}} = 0.194 \dots$$

SZOK!



Lekarz do pacjenta:

"Niech będzie pan spokojny. Ze wzoru Bayesa wynika że jest tylko 19,4% szans, że jest pan chory!"

NIEZALEŻNOŚĆ ZDARZEŃ

Motywacja: jeżeli zdarzenie A nie zależy od zdarzenia B,

to chcielibyśmy mieć

$$\text{równość } P[A] = P[A|B] = \frac{P[A \cap B]}{P[B]}$$

Stąd definiujemy:

Def. 2.5. (Ω, \mathcal{F}, P) - p. prob.

Wtedy zdarzenia $A, B \in \mathcal{F}$ są

niezależne, gdy

$$P[A \cap B] = P[A] \cdot P[B]$$

Przykład Wybieramy losową dziewczynę

posiadającą n dzieci. Niech A

będzie zdarzeniem, że w wybranej

rodzinie jest co najwyżej jeden

dziewczyna, a B zdarzeniem, że

są dziewczyną i chłopcy.

Czy A jest niezależne $\rightarrow B$?

$\Omega = \{d, c\}^n$ - ptae' dni' wg
wieku


$$|A| = n+1, \quad |B| = 2^n - 2.$$

$$|A \cap B| = n$$

$$P[A] \cdot P[B] = \frac{n+1}{2^n} \cdot \frac{2^n - 2}{2^n}$$

$$P[A \cap B] = \frac{n}{2^n}$$

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



$$2^n = 2n + 2$$

$$n = 3$$

Morale: niezawetawo'ci' jest czysto
algebraicznym pojęciem.

Treba o tym myśleć w kategoriach
definicji, a nie intuicji.

Def. 2.6. Zdarzenia $A_1, \dots, A_n \in \mathcal{F}$
nazywamy niezależnymi, gdy

$$P[A_{i_1} \cap \dots \cap A_{i_k}] = P[A_{i_1}] \cdot \dots \cdot P[A_{i_k}]$$

dla każdego ciągu $1 \leq i_1 < \dots < i_k \leq n$,
 $k = 2, 3, \dots, n$.

Def. 2.7 Zdarzenia $A_1, \dots, A_n \in \mathcal{F}$
nazywamy niezależnymi parami,
gdy dla dowolnej pary $i \neq j$
 A_i jest niezależne z A_j

Przykład Rzucamy 2 razy kostką

- A - w pierwszym rzucie wypadła parzysta i oczek
- B - w drugim rzucie wypadła parzysta i liczbę oczek
- C - suma 1. oczek jest parzysta

Nówczas A, B, C są parami niezależne, ale $NI\bar{E}$ są niezależne.

Def. 2.8 Załóżmy, że $\{A_i\}_{i \in I}$ jest pewną rodziną zdarzeń.

Mówimy, że zdarzenia są **niezależne**, jeżeli wszystkie skończone podzbiory $\{A_i\}$ są niezależne.

Def. 2.9 (Ω, \mathcal{F}, P) - p. prob.,

$\mathcal{F}_1, \dots, \mathcal{F}_n$ będą σ -ciekami zawartymi

w \mathcal{F} . Mówimy, że te σ -ciekła

są **niezależne**, gdy dla dowolnych

$A_1 \in \mathcal{F}_1, \dots, A_n \in \mathcal{F}_n$ zachodzi

$$P[A_1 \cap \dots \cap A_n] = P[A_1] \cdot \dots \cdot P[A_n].$$

Dowolne rodzinę $\{\mathcal{F}_i\}_{i \in I}$ jest niezależną, gdy każdy \mathcal{F}_i skończony

Podzbiór jest niezależny

Tw. 2.10 σ -ciąta $\mathcal{F}_1, \dots, \mathcal{F}_n$

są niez. \Leftrightarrow dowolne zdarzenia

A_1, \dots, A_n są niezależne.

Przykład Rzucamy 2 razy kostkę.

Niech $\Omega = \{(i, j) : i, j \in \{1, \dots, 6\}\}$, \mathcal{F}

składa się ze wszystkich podzbiórów Ω ,

a \mathbb{P} jest miarą prob. Rozważmy dwa

σ -ciąta

$$\mathcal{F}_1 = \{A \times \{1, \dots, 6\} : A \subset \{1, \dots, 6\}\}$$

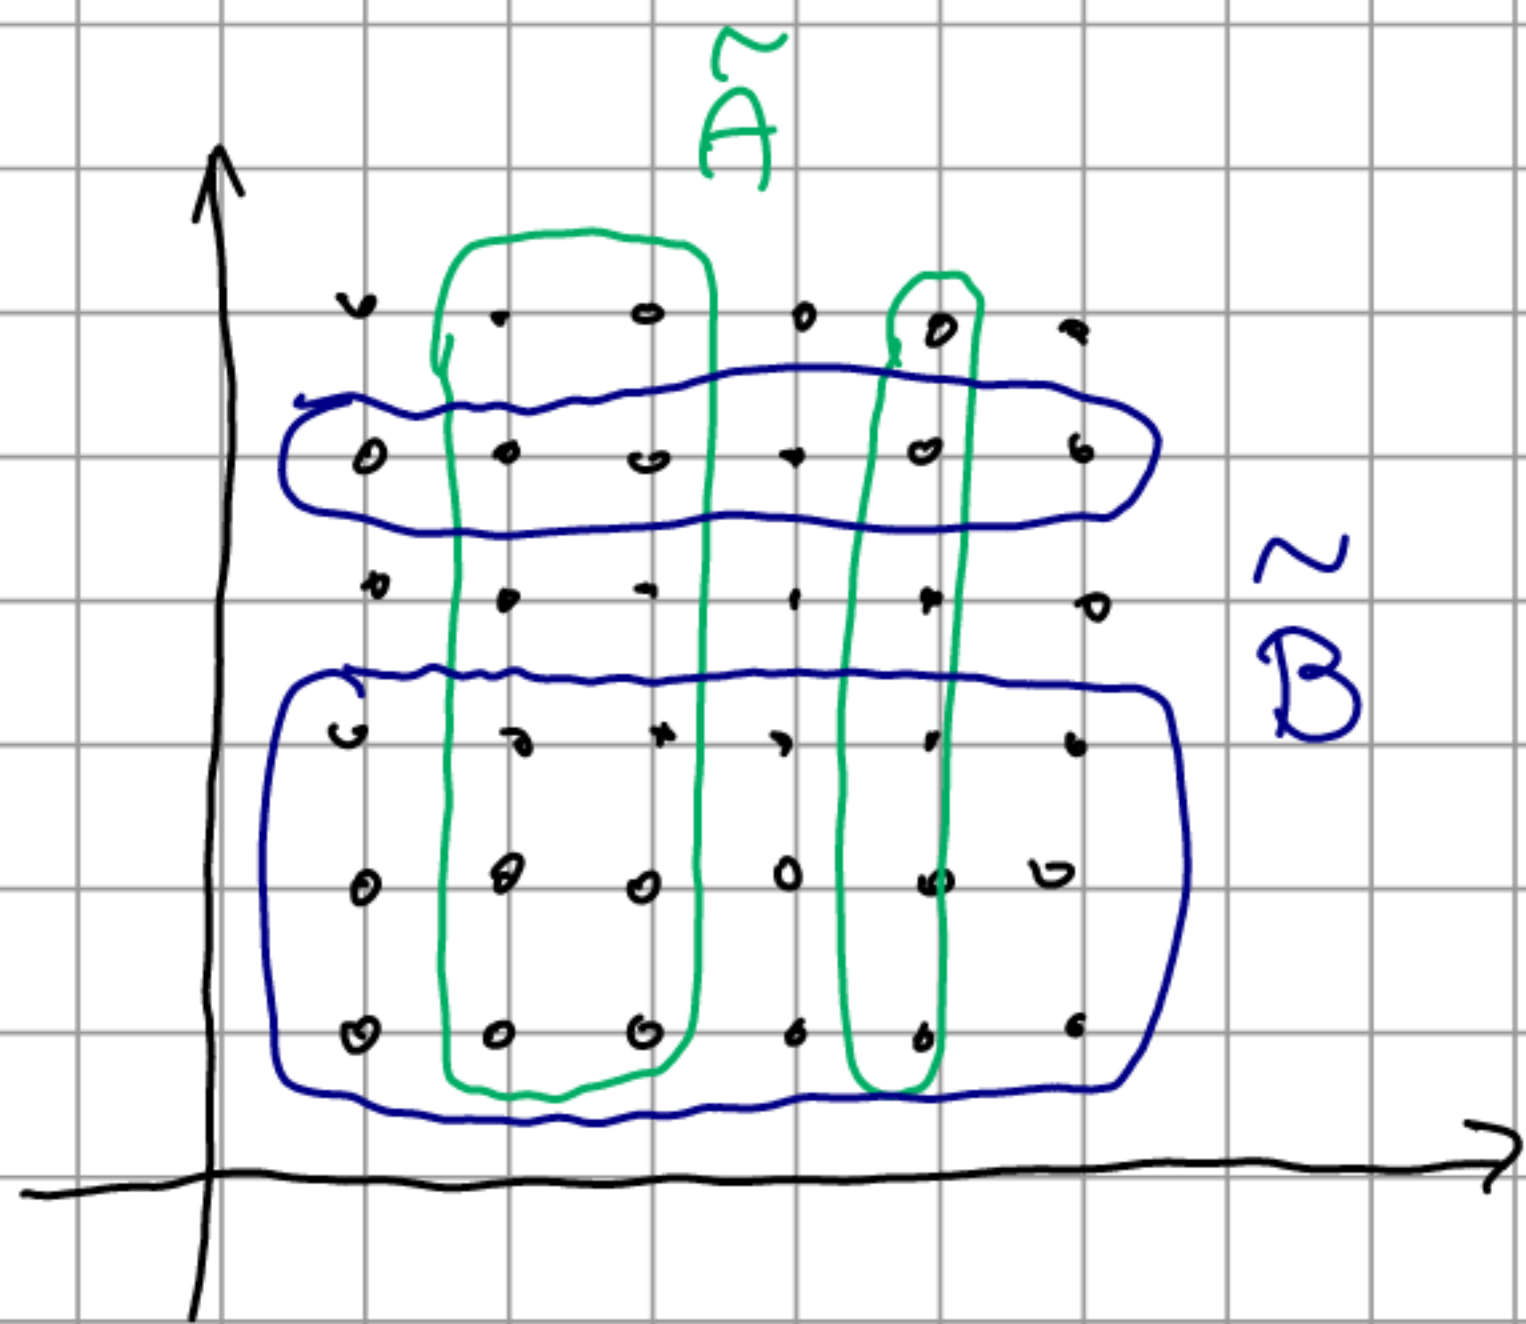
$$\mathcal{F}_2 = \{\{1, \dots, 6\} \times B : B \subset \{1, \dots, 6\}\}$$

Pokażać, że \mathcal{F}_1 i \mathcal{F}_2 są niezależne.

Rozw. $A \times \{1, \dots, 6\} \in \mathcal{F}_1$, $\{1, \dots, 6\} \times B \in \mathcal{F}_2$

$$\begin{array}{ccc} \parallel & & \parallel \\ A & & B \end{array}$$

$$P[\tilde{A} \cap \tilde{B}] = P[A \times B] = \frac{|A| \cdot |B|}{36} = P[\tilde{A}]P[\tilde{B}].$$



$$A = \{2, 3, 5\}$$

$$B = \{1, 2, 3, 5\}$$

\tilde{A}, \tilde{B} to sumy poziomych / pionowych prostokątów.

$$P[\tilde{A}] = \frac{6 \cdot |A|}{36} = \frac{|A|}{6}$$

$$P[\tilde{B}] = \frac{6 \cdot |B|}{36} = \frac{|B|}{6}$$

Co jest naszym celem?

Chcemy na tyle, na ile się da,

przenieść intuicje na formalny język.

RPis polega na tym że wykonujemy doświadczenie $n \rightarrow \infty$ razy. Potrzebujemy

jakąś przestrzeń, która pozwoli nam

np. zucić monetę wiele razy lub monety.

To są na razie pierwsze kroki
w ogólnieniu dyskretnej probabilistyki.

10.03.2021

lemmat 2.11 A_1, \dots, A_n - zdarzenia niezależne.

Wtedy σ -cieta $\sigma(A_1), \dots, \sigma(A_n)$

$(\sigma(A_i) = \{\emptyset, A_i, A_i^c, \Omega\})$ są niezawisłe

są niezależne.

Wniosek 2.12 Jeżeli A_1, \dots, A_n są niezależne, to

$$\begin{aligned} P\left[\bigcup_{i=1}^n A_i\right] &= 1 - P\left[\bigcap_{i=1}^n A_i^c\right] = \\ &= 1 - \prod_{i=1}^n (1 - P[A_i]) \end{aligned}$$

Problem Przeprowadzamy n doświadczeń.
Są one (tak czy owo, nie algebraicznie) niezależne. i -te jest

opisane przez $(\Omega_i, \mathcal{F}_i, P_i)$.

(np. x_1, \dots, x_{10} - wyniki 10 rzutów kostką)
ale problem, bo one są określone na różnych przestrzeniach. Jak to

Cel: Chcielibyśmy zdefiniować jedną
dużą przestrzeń i jeszcze jakąś
przemycić informację o niezależności
naszych doświadczeń.

Kolejny problem: Chcemy przejść z n
do nieskończoności, zrobić
jesień nieskończone ciągi doświadczeń.

Rozwiązanie celu: na razie n -skoneczne.

$$\Omega = \Omega_1 \times \Omega_2 \times \dots \times \Omega_n$$

$$\mathcal{F}_i' = \{ \Omega_1 \times \dots \times A \times \dots \times \Omega_n : A \in \mathcal{F}_i \}$$

\uparrow
 i -ta wsp.

$$\mathcal{F} = \sigma(\mathcal{F}_1', \dots, \mathcal{F}_n') = \mathcal{F}_1 \otimes \mathcal{F}_2 \otimes \dots \otimes \mathcal{F}_n$$

Szukamy P : powinna spełniać:

$$P[A_1 \times \dots \times A_n] = P[A_1] \cdot \dots \cdot P[A_n]$$

Wiemy, że miara produktowa
spełnia te warunki!

$$P = P_1 \otimes P_2 \otimes \dots \otimes P_n$$

Miara produktowa w końcu ma sens...

Przykład (Bernoulli)
Wykonesu n -krotnie

to samo doświadczenie, w którym

prawdopodobieństwo sukcesu wynosi p .

Kolejne próby są niezależne.

Więc prawdopodobieństwo sukcesu w k próbach

wynosi $\binom{n}{k} p^k (1-p)^{n-k}$.

D-d. $\Omega_i = \{0, 1\}$, \mathcal{F}_i , $P_i[\{1\}] = p$.

(Ω, \mathcal{F}, P) . Ustawiamy $\omega = (\omega_1, \dots, \omega_n) \in \Omega$

$$P_1[\{\omega_1\}] = p^{\omega_1} (1-p)^{1-\omega_1}$$

$$P[\omega] = \prod_{i=1}^n p^{\omega_i} (1-p)^{1-\omega_i} =$$

$$= p^{\sum \omega_i} (1-p)^{n - \sum \omega_i}$$

A_k — zdarzenie które mówi, że było k sukcesów.

$$A_k = \{ \omega : \sum \omega_i = k \}$$

$$P[A_k] = \sum_{\omega \in A_k} P[\omega] =$$

$$= \sum_{\omega \in A_k} p^k (1-p)^{n-k} =$$

$$= |A_k| p^k (1-p)^{n-k} =$$

$$= \binom{n}{k} p^k (1-p)^{n-k}$$

Pytanie: co gdy $n = \infty$? Chcemy zdefiniować p. prob. opisującą nieskończone ciągi niezależnych doświadczeń!

Tw. 2.13 (Kolmogorowa)

Załóżmy, że dany jest ciąg
miar \mathbb{P}_n na $(\mathbb{R}^n, \text{Bor}(\mathbb{R}^n))$

spełniający warunki zgodności

$$\mathbb{P}_{n+1}[A_1 \times \dots \times A_n \times \mathbb{R}] = \mathbb{P}_n[A_1 \times \dots \times A_n].$$

Wówczas istnieje jedyna miara proba-
bilistyczna \mathbb{P} na $(\mathbb{R}^{\mathbb{N}}, \text{Bor}(\mathbb{R}^{\mathbb{N}}))$

$(\text{Bor}(\mathbb{R}^{\mathbb{N}}))$ jest generowane przez
„skwońce wie” wymiarowych (ostkade) także,
że

$$\mathbb{P}[A_1 \times \dots \times A_n \times \mathbb{R} \times \mathbb{R} \times \dots] = \mathbb{P}_n[A_1 \times \dots \times A_n]$$

Przykład Zamierzamy skonstruować
przestrzeń prob. na której można
zdefiniować ciąg niezależnych zdarzeń
 $\{A_n\}_{n=1}^{\infty}$ takich, że $\mathbb{P}[A_n] = 1/2$

Szukamy p. prob. na ktorej
zdef. ∞ ciąg niezależnych rzutów
monety.


$$(\Omega, \mathcal{F}, \mathbb{P}) = ([0, 1], \mathcal{B}_\sigma([0, 1]), \text{Leb})$$

$$\omega \in [0, 1], \quad \omega = \sum_{i=1}^{\infty} \frac{\omega_i}{2^i} = 0, \omega_1, \omega_2, \dots$$

(nie jest jedn.: $\frac{1}{2} = \frac{1}{4} + \frac{1}{8} + \frac{1}{16} + \dots$)

(Ale takich liczb jest przeliczalnie)
(wiele więc mamy to gdaies)

$$A_n = \{\omega \in [0, 1] : \omega_n = 0\}$$



$$\lambda(A_n) = \frac{1}{2}. \quad \text{Zadanie: } \{A_n\}_{n=1}^{\infty} \rightarrow \infty$$

nie zaleine

Def. 3.1 $(\Omega, \mathcal{F}, \mathbb{P})$ - p. prob., $\{A_n\}_{n=1}^{\infty}$ - ciąg zdarzeń. Granicę górną ciągu $\{A_n\}_{n=1}^{\infty}$ nazywamy zdarzenie

$$\limsup_{n \in \mathbb{N}} A_n = \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n$$

Kiedy $\omega \in \bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} A_n$? gdy $\forall m \omega \in \bigcup_{n=m}^{\infty} A_n$, czyli ω należy do nieskończonej liczby zdarzeń.

Lemat 3.2. (Borele - Cantelliego)

$(\Omega, \mathcal{F}, \mathbb{P})$ - p. prob., $A_1, A_2, \dots \in \mathcal{F}$.

1. Jeżeli $\sum_{n=1}^{\infty} \mathbb{P} A_n < \infty$, to

$$\mathbb{P}[\limsup_n A_n] = 0$$

tzn. z pstwem 1 zachodzi tylko skończenie wiele z A_n .

2. Jeżeli A_1, \dots są niezależne oraz $\sum_{n=1}^{\infty} \mathbb{P} A_n = \infty$, to $\mathbb{P}[\limsup_n A_n] = 1$.

ten. z pstwem 1 zachodzi ∞ wiele
zdeżeń A_n .

D-d.

$$1. \mathbb{P} \left[\bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n \right] \leq \mathbb{P} \left[\bigcup_{n=M}^{\infty} A_n \right] \leq$$

$$\leq \sum_{n=M}^{\infty} \mathbb{P}[A_n] \xrightarrow{M \rightarrow \infty} 0$$

(z def. zbieżności szeregu)

2. Wystarczy, że

$$0 = \mathbb{P} \left[(\limsup A_n)^c \right] =$$

$$= \mathbb{P} \left[\left(\bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n \right)^c \right] = \mathbb{P} \left[\bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} A_n^c \right]$$

Wystarczy pokazać, że

$$\forall m \quad \mathbb{P} \left[\bigcap_{n=m}^{\infty} A_n^c \right] = 0$$

Korzystamy kolejno z tw. o ciągłości,
mierzalności zbiorów A_n oraz mierzalności

$$1 - x \leq e^{-x} :$$

$$\begin{aligned}
 P\left[\bigcap_{n=m}^{\infty} A_n^c\right] &= \lim_{k \rightarrow \infty} P\left[\bigcap_{n=m}^k A_n^c\right] = \\
 &= \lim_{k \rightarrow \infty} \prod_{n=m}^k P[A_n^c] = \lim_{k \rightarrow \infty} \prod_{n=m}^k (1 - P[A_n]) \\
 &\leq \lim_{k \rightarrow \infty} e^{-\sum_{n=m}^k P[A_n]} = e^{-\sum_{n=m}^{\infty} P[A_n]} = 0
 \end{aligned}$$

□

Przykład Ω , A_i - w i -tym rzucie 6.

$$P[A_i] = \frac{1}{6}. \quad \sum P[A_i] = \infty.$$

Z lematu B-C

$$P[A_n \text{ i.o.}] = 1$$

infinitely often

$$\left(P[\limsup_n A_n] = 1 \right)$$

(czyli w ciągu zdarzeń z prawdopodobieństwem 1 zachodzą nieskończenie wiele z nich)

Przykład Urządzenie, że jeżeli będziemy

rzucić odpowiednio długo kostką, to

z prawdopodobieństwem 1 wyrzucimy w kolejnych

punktach ciąg stworzony z kolejnych
10 jedynek i kolejnych 10 szóstek.

$$\Omega = \{1, \dots, 6\}^{\mathbb{N}}, \quad \mathcal{F} = 2^{\Omega}, \quad \mathbb{P}$$


$$A_n = \left\{ \omega : \begin{array}{l} \omega_n = \dots = \omega_{n+9} = 1 \\ \omega_{n+10} = \dots = \omega_{n+19} = 6 \end{array} \right\}$$

$$\mathbb{P}[A_n] = \frac{1}{6^{20}} \cdot \sum \mathbb{P}[A_n] = \infty.$$

Problem: A_n są zależne!

$\tilde{A}_n = A_{20n}$. Zdarzenia $\{\tilde{A}_n\}$ są
niezależne. $\mathbb{P}[\tilde{A}_n] = \frac{1}{6^{20}}$.

Z lem. B-C $\mathbb{P}[\tilde{A}_n \text{ i.o.}] = 1$




$$\rightarrow \mathbb{P}[A_n \cap A_2] = 0, \quad \mathbb{P}[A_n] \mathbb{P}[A_2] = \left(\frac{1}{6^{20}}\right)^2$$

Przykład Rzucamy ∞ wiele razy
niesymetryczną monetą. Niech

A_n oznacza zdarzenie, że w
pierwszych n rzutach wypadło
tyle samo orłów (w reszki)

Pokaż że $\mathbb{P}(A_n) = p^n$

zachodzi jedynie skończenie
wiele zdarzeń A_n .



Spacer losowy — z p prawdopodobieństwem

p idziemy w prawo, $1-p$

w lewo. Przykład mówi

o tym, że 0 odwiedimy skończenie

wiele razy.

Obs. 1: $P[A_{2n+1}] = 0$ (oczywiste)


Obs. 2: $P[A_{2n}] = \binom{2n}{n} p^n (1-p)^n$

(Wzór Stirlinga: $n! \sim \sqrt{2\pi n} \left(\frac{n}{e}\right)^n$)

$$\binom{2n}{n} = \frac{(2n)!}{n!n!} \sim \frac{1}{\sqrt{2\pi n}} \frac{\sqrt{2n}}{n} \frac{\left(\frac{2n}{e}\right)^{2n}}{\left(\frac{n}{e}\right)^{2n}} = \frac{2^{2n}}{\sqrt{\pi n}}$$

$$P[A_{2n}] \sim \frac{[4p(1-p)]^n}{\sqrt{\pi n}}$$

$$\sum_{n=1}^{\infty} \frac{(4p(1-p))^n}{\sqrt{\pi n}} < \infty$$



z Lem. B-C

dla $p \neq \frac{1}{2}$ $p(1-p) < \frac{1}{4}$

$$P[A_n \text{ i.o.}] = 0$$



A_n musi zejść skończenie wiele

razy.

Def. 3.3 $(\Omega, \mathcal{F}, \mathbb{P})$ - p. prob.

Zmienną losową nazywamy dowolną mierzalną funkcję $X: \Omega \rightarrow \mathbb{R}$.

(Czyli dla dowolnego $B \in \text{Bor}(\mathbb{R})$
mamy $X^{-1}(B) \in \mathcal{F}$)

Przykład

• Rzucamy 5 razy kostką i chcemy obliczyć sumę wyników (nie interesują nas konkretne wyniki, tylko suma). Wówczas $\Omega = \{(i_1, \dots, i_5),$

$i_j \in \{1, \dots, 6\}\}$, $\omega = (\omega_1, \dots, \omega_5)$

oraz $X(\omega) = \omega_1 + \dots + \omega_5$ jest

zmienną losową.

- X - wartość wygranej w totku
- X - cena ...

Mwagi:

• Ω : skończony, to dla $\mathcal{F} = 2^\Omega$

każde odwzorowanie $X: \Omega \rightarrow \mathbb{R}$

jest mierzalne

• X jest zmienną losową jeżeli

dla każdego t $X^{-1}((-\infty, t]) \in \mathcal{F}$

Tw. 3.4 Jeżeli X_1, X_2, \dots są

zmiennymi losowymi

1. $X_1 + X_2, X_1 - X_2, X_1 \cdot X_2, X_1 / X_2$ ($X_2 \neq 0$)

są zmiennymi losowymi

2. Jeżeli $f: \mathbb{R}^n \rightarrow \mathbb{R}$ jest mierzalne (czyli borelowskie tutaj) to $f(X_1, \dots, X_n)$ jest zmienną losową.

3. $\inf_n X_n, \sup_n X_n, \limsup_n X_n, \liminf_n X_n$

są zmiennymi losowymi.

Def. 3.5 Miara μ na $(\mathbb{R}, \mathcal{B}_\sigma(\mathbb{R}))$


zdefiniowana wzorem

$$\mu(B) := P[X \in B] =$$

$$= P[\{\omega \in \Omega : X(\omega) \in B\}] = P[X^{-1}(B)]$$

dla każdego $B \in \mathcal{B}_\sigma(\mathbb{R})$,

nazywamy rozkładem zmiennej losowej X .



$$(\Omega, \mathcal{F}, P) \xrightarrow{X} (\mathbb{R}, \mathcal{B}_\sigma(\mathbb{R}), \mu)$$

p. prob.

17.03.2021

Co byto do tej pracy?

(Ω, \mathcal{F}, P) - p. prob, nie zależność,

$X: (\Omega, \mathcal{F}, P) \rightsquigarrow (\mathbb{R}, \text{Bor}(\mathbb{R}), \mu)$

μ - rozkład X

$$\mu(B) = P[X \in B] = P[\omega: X(\omega) \in B]$$

Definicja 3.6 Dystybuanta

zmiennej losowej X mierzymy
funkcję $F: \mathbb{R} \rightarrow [0, 1]$ zachony
wzorem

$$F(t) = P[X \leq t] = \mu((-\infty, t])$$


Przykład

$$1) (\Omega = \{0, R\}, \mathcal{F}, P)$$

$$X(0) = 1, X(R) = -1$$

Jak wygląda dystrybucja?


$$F(t) = \begin{cases} 0 & t < -1 \\ \frac{1}{2} & t \in [-1, 1) \\ 1 & t \geq 1 \end{cases}$$



2) losujemy jednostajnie liczbę z przedziału $[0, 1]$. $([0, 1], \text{Bor}([0, 1]), \lambda)$, $X(\omega) = \omega$.

$$F(t) = \begin{cases} 0 & t < 0 \\ t & t \leq 1 \\ 1 & t > 1 \end{cases}$$

$$\mathbb{P}[X \leq t] = \lambda([0, t]) = t$$



Tw. 3.7 : Własności dystrybucyj

1. F jest niemalejąca
2. $\lim_{t \rightarrow -\infty} F(t) = 0$, $\lim_{t \rightarrow \infty} F(t) = 1$
3. F jest prawostronnie ciągła
4. Dla dowolnego $t \in \mathbb{R}$ istnieje lewostronna granica

$$F(t-) = \lim_{s \rightarrow t^-} F(s) = \mathbb{P}[X < t]$$

5. F jest nieciągła w punkcie t_0 iff $\mathbb{P}[X = t_0] > 0$. Wówczas $\mathbb{P}[X = t_0] = F(t_0) - F(t_0-)$.

Punkt t_0 nazywamy **atomem** rozkładu.

D-d.

2. Niech $t_n \nearrow \infty$. Wtedy $\{(-\infty, t_n]\}$ jest wstępującą rodziną zbiorów.

$$\bigcup_n (-\infty, t_n] = \mathbb{R}. \text{ Z lematu o ciągłości miary}$$
$$\lim_{n \rightarrow \infty} F(t_n) = \lim_{n \rightarrow \infty} \mu((-\infty, t_n]) = \mu(\mathbb{R}) = 1.$$

3. Niech $t \in \mathbb{R}$, $t_n \searrow t$.

Wtedy $(t, t_n]$ jest zstępującą rodziną zbiorów.

$$\lim_{n \rightarrow \infty} \mu((t, t_n]) = \mu(\emptyset) = 0$$

$$\lim_{n \rightarrow \infty} F(t_n) - F(t) \Rightarrow F(t) = \lim_{t_n \searrow t} F(t_n).$$

$$\mu((-\infty, t_n]) - \mu((-\infty, t])$$
$$\mu((t, t_n])$$


$$\begin{aligned}
& \bar{b}. \quad F(t_0) - F(t_0^-) = \mu((-\infty, t_0]) - \\
& - \lim_{t_n \rightarrow t_0^-} \mu((-\infty, t_n]) = \\
& = \lim_{t_n \rightarrow t_0^-} \mu((-\infty, t_0]) - \mu((-\infty, t_n]) = \\
& = \lim_{t_n \rightarrow t_0^-} \mu((t_n, t_0]) = \\
& = \lim_{t_n \rightarrow t_0^-} \mu((t_n, t_0)) + \mu(\{t_0\}) = \mu(\{t_0\}) = \\
& = \mathbb{P}[X = t_0].
\end{aligned}$$

Tw. 3.8 Jeżeli F jest funkcją na \mathbb{R} spełniającą warunki 1, 2 i 3 z poprzedniego twierdzenia, to F jest dystrybucją pewnego rozkładu.

D-d. Chcemy znaleźć p. prob.
 $(\Omega, \mathcal{F}, \mathbb{P})$ oraz $X: \Omega \rightarrow \mathbb{R}$ t.ż.
 $F = F_X$ (dystrybucja X).

$$(\Omega, \mathcal{F}, \mathbb{P}) := ([0,1], \text{Bor}([0,1]), \lambda)$$

I zotóžimy, że F jest funkcją odwracalną.



$$X(\omega) := F^{-1}(\omega)$$

Sprawdźmy: $F_X(t) = \mathbb{P}[X \leq t] =$

$$= \mathbb{P}[\{\omega : X(\omega) \leq t\}] = \mathbb{P}[\{\omega : F(X(\omega)) \leq F(t)\}]$$


↖ bo F niemalejąca ↗

$$= \mathbb{P}[\{\omega : \omega \leq F(t)\}] = \lambda([0, F(t)]) = F(t)$$

Problem : F nie musi być odwracalna.

II Przypadek ogólny. Dla funkcji
prawociągłej, niemalejącej można zdefiniować
ogólnioną funkcję odwrotną.

$$X(\omega) = F^{-1}(\omega) := \inf_{y \in \mathbb{R}} \{ F(y) \geq \omega \}$$



Potrzebujemy $\{ \omega : X(\omega) \leq t \} = \{ \omega : \omega \leq F(t) \}$.

1. $P \subseteq L$. Weźmy $\omega \in P$. Wtedy
 $\omega \leq F(t)$, czyli $t \in \{ y \in \mathbb{R} : F(y) \geq \omega \}$.
Zatem $X(\omega) \leq t$ (z def. X).
 $\Rightarrow \omega \in L$

2. $L \subseteq P$. Weźmy $\omega \in L$. Wtedy

$X(\omega) \leq t$, czyli $\inf_y \{ \omega \leq F(y) \} \leq t$,
a zatem $\omega \leq F(y) \leq F(t)$ (bo F niemalejąca i prawostronnie ciągła)
 $\Rightarrow \omega \in P$.

Pytanie Czy dystrybuenta jednoznacznie
wyznacza rozkład zmiennej losowej?
(zobaczmy, że zmienna losowa zależy
od p. prob. i to jest bardzo
elastyczne, rozkład jest już konkretny).

Tw. 3.9 (o jednoznaczności)

Dystrybucja zmiennej losowej X
wyznacza jednoznacznie jej rozkład.

Alt.: Dane są dystrybucje $F_x = F_y$.

Chcemy pokazać, że to implikuje

$$\mu_x = \mu_y.$$

(Z teorii miary wiemy, że

$$\mu_x((-\infty, t]) = \mu_y((-\infty, t]) \Rightarrow \mu_x = \mu_y)$$

Definicja 3.10 Niepusty rodzinę

\mathcal{A} podzbiorów Ω nazywamy

π -układem, jeżeli jest zamknięta

na operacje przecięcia, tzn. $A \cap B \in \mathcal{A}$

dla wszystkich $A, B \in \mathcal{A}$.

Np. $\mathcal{A} = \{(-\infty, t] : t \in \mathbb{R}\}$

Definicja 3.11

Niepustą rodzinę \mathcal{L} podzbiorów Ω nazywamy λ -układem, jeżeli:

- $\Omega \in \mathcal{L}$

- $A, B \in \mathcal{L} \wedge A \subset B \Rightarrow B \setminus A \in \mathcal{L}$

- $\{A_n\}_{n=1}^{\infty}$ wstępnicy, to $\bigcup_{n=1}^{\infty} A_n \in \mathcal{L}$

Lemma 3.12 (o π -układach) Tw. Dynkina

Jeżeli \mathcal{L} jest λ -układem zawierającym π -układ \mathcal{H} , to \mathcal{L} zawiera także $\sigma(\mathcal{H})$.

Throwback do MiC - tam było

tw. że jeśli pierścien $R \subset \mathcal{M}$,

to $\sigma(R) \subset \mathcal{M}$.

↑
klasa monotoniczna

D-d. tw. 3.9

Chcemy pokazać, że
 $F_x = F_y \Rightarrow \mu_x = \mu_y$, tzn $\forall B \in \text{Bor } \mathbb{R}$

$$\mu_x(B) = \mu_y(B). \quad (*)$$

wynika, że $*$ jest spełnione przez

zbiory postaci $B = (-\infty, t]$. Rodzina

$\mathcal{H} = \{(-\infty, t] \mid t \in \mathbb{R}\}$ tworzy π -układ.

Zdefiniujmy $\mathcal{L} = \{B \in \text{Bor}(\mathbb{R}) : \mu_x(B) = \mu_y(B)\}$.

\mathcal{L} jest λ -układem (zaobalenie).

Ponadto $\mathcal{H} \subseteq \mathcal{L}$, gdyż

$$\begin{array}{ccc} F_x(t) = F_y(t) & & \\ \parallel & & \parallel \\ \mu_x((-\infty, t]) & & \mu_y((-\infty, t]) \end{array}$$

Z Lematu 3.12 $\sigma(\mathcal{H}) \subseteq \mathcal{L} \subseteq \text{Bor}(\mathbb{R})$
 \parallel
 $\text{Bor}(\mathbb{R})$

Zatem $\mathcal{L} = \text{Bor}(\mathbb{R})$, więc $\mu_x = \mu_y$.

Definicja 3.13 Zmienna losowa X o

rozkładzie μ ma rozkład dyskretny,

jeżeli istnieje przeliczalny zbiór S

taki, że $\mu(S) = 1$. Wtedy

$$S = \{x : P[X=x] > 0\}$$

jest zbiorem atomów.

Przykład Rozkład skupiony w

punkcie $a \in \mathbb{R} : P[X=a] = 1$,

$$\mu = \delta_a, S = \{a\}.$$

Przykład Rozkład dwumianowy

(Bernoulliego) z parametrami

n, p ($n \in \mathbb{N}$, $p \in (0, 1)$)! X ma rozkład

$\text{Bin}(n, p)$, jeżeli

$$P[X=k] = \binom{n}{k} p^k (1-p)^{n-k}$$

Przykład Rozkład Poissona z

parametrem $\lambda > 0$. X ma

rozkład $\text{Pois}(\lambda)$, jeżeli

$$P[X = k] = \frac{\lambda^k}{k!} \cdot e^{-\lambda}, \quad k \in \mathbb{N}_0$$

Ten rozkład ma duży związek

z rozkładem dwumianowym. Przy

odpowiednim doborze parametrów dobrze

przybliża Bin, a Tetwiej go używać.

Przykład Ogólnie: jeżeli $S = \{s_1, s_2, \dots\}$


oraz $p_k > 0$ t. z. $\sum_k p_k = 1$,

to istnieje zmienna losowa spełniająca

$$P[X = s_k] = p_k$$

$([0, 1], \text{Bor}(0, 1), \lambda), X(\omega) = s_i$, gdy

$$p_1 + \dots + p_{i-1} < \omega \leq p_1 + \dots + p_i$$



Definicja 3.14 Zmienna losowa X

o rozkładzie μ ma rozkład

absolutnie ciągły (względem miary

Lebesgue'a), jeżeli istnieje

funkcja borelowska $f: \mathbb{R} \rightarrow [0, \infty)$

tak, że dla $B \in \mathcal{B}(\mathbb{R})$

$$P[X \in B] = \mu(B) = \int_B f \, d\lambda$$

Funkcja f nazywamy gęstością
rozkładu X .

(Funkcja f nie jest dowolna:

musimy założyć, że $\int_{-\infty}^{\infty} f(x) dx = 1$, $f \geq 0$

Wtedy $\mu([a, b]) = \int_a^b f(x) dx$ jest miarą
prob. na \mathbb{R})

Istnieje związek między dystrybucją,
a gęstością:

$$F(t) = \mu((-\infty, t]) = \int_{-\infty}^t f(x) dx.$$

Jeżeli f jest ciągła, to
 $F'(t) = f(t).$

Przykład Rozkład jednostajny
na $[0, 1]$: $X \sim U([0, 1]).$

$$f(x) = \mathbb{1}_{[0, 1]}(x)$$

X ma rozkład jednostajny
na odcinku $[0, 1]$
 $X \sim U([0, 1])$

Przykład Ogólniej, dla dowolnego
 $D \in \text{Bor}(\mathbb{R})$ o niezerowej mierze

możemy zdefiniować gęstość


$$f(x) = \frac{\mathbb{1}_D(x)}{\lambda(D)}$$

Wtedy, dla $B \in \text{Bor}(\mathbb{R})$

$$P[X \in B] = \int_B f(x) dx = \frac{\lambda(B \cap D)}{\lambda(D)}$$

Przykład Rozkład wykładniczy \geq
 parametrem λ ($\lambda > 0$): $X \sim \text{Exp}(\lambda)$


$$f(x) = \lambda e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x), \quad F(x) = \begin{cases} 0 & x < 0 \\ 1 - e^{-\lambda x} & x \geq 0 \end{cases}$$



Przykład Rozkład Gaussa (normalny):

$$X \sim N(0, 1)$$

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad F(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt$$



Rozkłady dyskretne i ciągłe
nie wyczerpują wszystkich możliwości.

Wiemy, że każdą miarę μ
można jednoznacznie zapisać w
postaci $\mu = \mu_{\text{abs}} + \mu_{\text{sing}}$

gdzie $\mu_{\text{abs}} \ll \lambda$ oraz $\mu_{\text{sing}} \perp \lambda$.

27.03.2024

Def. 4.1 (Ω, \mathcal{F}, P) -p.prob. Zmienną losową o wartościach w \mathbb{R}^d nazywamy dowolną funkcję mierzalną $X: \Omega \rightarrow \mathbb{R}^d$.

Jeżeli $d=1$, to powyższa definicja opisuje zmienną losową z poprzedniego wykładu.

Przykład Wylosowano 13 kart z 32.

Niech X_1 oznacza liczbę pików, a X_2 liczbę kierów. Wówczas $X = (X_1, X_2)$.

Podstawowe własności wielowymiarowych zmiennych losowych są analogiczne do zwykłych zmiennych losowych. Np.:

• jeżeli X_1, X_2 są d -wymiarowymi

zmiennymi losowymi, to $X_1 + X_2, X_1 - X_2$ też

• jeżeli $\phi: \mathbb{R}^d \rightarrow \mathbb{R}^k$ mierzalne, to $\phi(X)$ jest k -wymiarową zm. los.

Definicja 4.2 Rozkładem d -wymiarowej
zmiennnej losowej X nazywamy miarę prob.

$$\mu(B) = P[X \in B] = P[\omega : X(\omega) \in B].$$

Wówczas $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d), \mu)$ jest p. prob.

Definicja 4.3 Dystrybucją d -wymiarowej
zmiennnej losowej X nazywamy funkcję

$F: \mathbb{R}^d \rightarrow [0, 1]$ zadana wzorem

$$\begin{aligned} F(t_1, \dots, t_d) &= \mu((-\infty, t_1] \times (-\infty, t_2] \times \dots \times (-\infty, t_d]) \\ &= P[X_1 \leq t_1, \dots, X_d \leq t_d] \end{aligned}$$

T.W. 4.4 F - dystrybucja X . Wtedy

1. jeżeli $x_i \rightarrow -\infty$ dla pewnego i , to

$$F(x_1, \dots, x_d) \rightarrow 0$$

2. jeżeli $x_i \rightarrow \infty$ dla pewnego i , to

$$F(x_1, \dots, x_d) \rightarrow 1$$

3. dystrybucja X jedn. wyznacza rozkład.

Definicja 4.5 d -wym. zm. los. X ma rozkład dyskretny, jeżeli istnieje przeliczalny zbiór S taki, że $\mu(S) = 1$. Wtedy istnieje ciąg $p_1, p_2, \dots \in (0, 1]$, $s_1, \dots \in \mathbb{R}^d$ t. że

$$\sum p_i = 1, \quad P[X = s_i] = p_i$$

Definicja 4.6 d -wymiarowa zm. los. X ma rozkład absolutnie ciągły, jeżeli istnieje funkcja borelowska $f: \mathbb{R}^d \rightarrow [0, \infty)$ t. że

$$P[X \in B] = \mu(B) = \int_B f(x) dx, \quad B \in \mathcal{B}(\mathbb{R}^d).$$

Wówczas

$$F(t_1, \dots, t_d) = \int_{-\infty}^{t_1} \dots \int_{-\infty}^{t_d} f(x_1, \dots, x_d) dx_1 dx_2 \dots dx_d$$

Ponadto, jeżeli $F \in C^d(\mathbb{R}^d)$, to

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

Przykład. W urnie są 2 kule czerwone, 5 białych i 3 zielone. Wybieramy losowo 3 kule (jedn.). X_1 oznacza # białych kul, X_2 # kul czerwonych. Wówczas (X_1, X_2) jest 2-wymiarową zmienną losową i rozkład dyskretny:

$X_1 \setminus X_2$	0	1	2	$P[X_1 = x]$
0	$\frac{1}{120}$	$\frac{6}{120}$	$\frac{3}{120}$	$\frac{10}{120}$
1	$\frac{15}{120}$	$\frac{30}{120}$	$\frac{5}{120}$	$\frac{50}{120}$
2	$\frac{30}{120}$	$\frac{20}{120}$	0	$\frac{50}{120}$
3	$\frac{10}{120}$	0	6	$\frac{10}{120}$
$P[X_2 = y]$	$\frac{56}{120}$	$\frac{56}{120}$	$\frac{8}{120}$	1

$$P[X_1 \leq X_2] = \frac{45}{120} = \frac{3}{8}$$

$$P[X_1 = 1 | X_1 \leq X_2] = \frac{P[X_1 = 1 \text{ i } X_1 \leq X_2]}{P[X_1 \leq X_2]} = \frac{7}{9}$$

Wniosek: znajomość rozkładu X_1, X_2 nie daje nam jeszcze rozkładu (X_1, X_2) .

Przykład.

$(\mathbb{R}^2, \mathcal{B}(\mathbb{R}^2), \frac{1}{\lambda(S)} \lambda|_S)$

↑
p. prob.



$$P[(x_1, x_2) \in A] = \frac{\lambda(A \cap S)}{\lambda(S)}$$

zm. losowe
 $X(\omega) = \omega$

Rozkład tożsamości

to po prostu miara przestrzeni.

Przykład. Rozkład Gaussa (normalny) na \mathbb{R}^d ,

$N(m, A^{-1})$: m - ustalony wektor w \mathbb{R}^d ,

A - macierz $d \times d$, symetryczna,
dodatnio określona

(forma kw. określona przez A
jest ilocz. skalarnym)

gęstość: $f(x) = \frac{\sqrt{\det A}}{(2\pi)^{\frac{d}{2}}} \cdot e^{-\frac{1}{2} \langle (x-m), (x-m) \rangle}$
 iloczyn skalarny
 zdefiniowany przez A

Widocznie, że $f(x) \geq 0$.

Trzeba sprawdzić, że $\int_{\mathbb{R}^d} f(x) dx = 1$

Macierz $A = BDB^{-1}$
 \uparrow diagonalna \uparrow izometria

$$D = \begin{bmatrix} a_1 & & & \\ & a_2 & & \\ & & \ddots & \\ & & & a_d \end{bmatrix}, a_i > 0$$

Podstawiając $x-m = By$ otrzymujemy

$$\int_{\mathbb{R}^d} f(x) dx = \frac{\sqrt{\det A}}{(2\pi)^{\frac{d}{2}}} \int_{\mathbb{R}^d} e^{-\frac{1}{2} \langle By, By \rangle} |\det B| dy =$$

$$= C \int_{\mathbb{R}^d} e^{-\frac{1}{2} y^t D y} dy = C \int_{\mathbb{R}^d} e^{-\frac{1}{2} \sum_{i=1}^d a_i y_i^2} dy =$$

$$= C \prod_{i=1}^d \int_{\mathbb{R}} e^{-\frac{1}{2} a_i y_i^2} dy_i = \frac{1}{\sqrt{2\pi a_i}} \prod_{i=1}^d \int_{\mathbb{R}} e^{-\frac{z^2}{2}} dz = 1$$

Definicja 4.7 $X = (X_1, \dots, X_d)$. Wówczas dla $k \leq d$
rozkład X_k nazywamy rozkładem brzegowym

UWAGA: jeśli znamy wyłącznie rozkłady
brzegowe, to cały rozkład nie wynika
z nich jednocześnie.

Definicja 4.8 (Ω, \mathcal{F}, P) - p.p.rob., $\{X_i\}_{i \in I}$

rodzina zmiennych losowych. Zmiennie te

są niezależne, jeżeli $\sigma(X_i)$ (σ -cieta

generowane przez X_i) są niezależne.

$$\left[\sigma(X) = \sigma(\{X^{-1}[B]\}_{B \in \mathcal{B}(\mathbb{R})}) \subseteq \mathcal{F} \right]$$

Innymi słowy, $\{X_i\}_{i \in I}$ są niezależne,

gdy dla dowolnych, parami różnych

$i_1, i_2, \dots, i_n \in I$ oraz dowolnych $B_1, \dots, B_n \in \mathcal{B}(\mathbb{R})$

zachodzi

$$P[X_{i_1} \in B_1, \dots, X_{i_n} \in B_n] = P[X_{i_1} \in B_1] \cdot \dots \cdot P[X_{i_n} \in B_n]$$

Disclaimer: $\sigma(X)$ to najmniejsze σ -ciało
zawarte w \mathcal{F} , w którym X jest
mieralne: $X: (\Omega, \sigma(X)) \rightarrow (\mathbb{R}, \mathcal{P}(\mathbb{R}))$

Przykład. Rozważmy schemat Bernoulliego

zdefiniujemy

$$X_i(\omega) = X_i(\omega_1, \dots, \omega_n) = \begin{cases} 1 & \text{gdzi sukces w } i\text{-tej} \\ 0 & \text{ } \end{cases}$$

Wówczas X_1, \dots, X_n są niezależnymi zmiennymi
losowymi.

$$P[X_1=1, X_2=0] = P[\exists (\omega_1, \omega_2): X_1(\omega) = 1, X_2(\omega) = 0]$$

$$= P[X_1(\omega) = 1] \cdot P[X_2(\omega) = 0]$$

↑
wynika z tego, że
 X_1, X_2 są f. chw.
niezależnych zdarzeń.

Tw. 4.9 Niech X_1, \dots, X_n będą zmiennymi losowymi, $X = (X_1, \dots, X_n)$. NWSR:

1. X_1, \dots, X_n są niezależne.

2. dla dowolnych $B_1, \dots, B_n \in \mathcal{B}(\mathbb{R})$ zdarzenia $\{X_1 \in B_1\}, \dots, \{X_n \in B_n\}$ są niezależne.

$$3. \mu_X = \mu_{X_1} \otimes \mu_{X_2} \otimes \dots \otimes \mu_{X_n}$$

$$4. F_X(t_1, \dots, t_n) = F_{X_1}(t_1) \cdot \dots \cdot F_{X_n}(t_n)$$

D-d.

• $1 \Leftrightarrow 2$ z def.

• $2 \Rightarrow 4$ $B_i = (-\infty, t_i]$

$$F_X(t_1, \dots, t_n) = \mathbb{P}[X_1 \leq t_1, \dots, X_n \leq t_n] =$$

$$= \mathbb{P}[\{X_1 \in B_1\} \cap \dots \cap \{X_n \in B_n\}] \stackrel{2}{=} \mathbb{P}[X_1 \in B_1] \cdot \dots \cdot \mathbb{P}[X_n \in B_n]$$

• $4 \Rightarrow 3$ Niech X' - zm. los. o rozkładzie

$\mu_{X_1} \otimes \dots \otimes \mu_{X_n}$. Pokażemy $F_X = F_{X'}$.

$$(\Rightarrow \mu_X = \mu_{X'})$$

$$\begin{aligned}
 F_X(t_1, \dots, t_n) &= \mu_{X_1} \otimes \dots \otimes \mu_{X_n}([-\infty, t_1] \times \dots \times [-\infty, t_n]) = \\
 &= \mu_{X_1}([-\infty, t_1]) \cdot \dots \cdot \mu_{X_n}([-\infty, t_n]) = \\
 &= F_{X_1}(t_1) \cdot \dots \cdot F_{X_n}(t_n) \stackrel{4}{=} F_X(t_1, \dots, t_n)
 \end{aligned}$$

• 3 \Rightarrow 2

$$\begin{aligned}
 P[X_1 \in B_1, \dots, X_n \in B_n] &= \mu_X(B_1 \times \dots \times B_n) \stackrel{(3)}{=} \\
 &= \mu_{X_1}(B_1) \cdot \dots \cdot \mu_{X_n}(B_n) = \\
 &= P[X_1 \in B_1] \cdot \dots \cdot P[X_n \in B_n]
 \end{aligned}$$

■

Wniosek 4.10 Zmiennie losowe X_1, \dots, X_n

mające wartości dyskretne są niezależne

iff dla dowolnych $s_1 \in S_{X_1}, \dots, s_n \in S_{X_n}$

zachodzi

$$(*) \quad P[X_1 = s_1, \dots, X_n = s_n] = P[X_1 = s_1] \cdot \dots \cdot P[X_n = s_n]$$

Dowód. Jeżeli zmiennie losowe X_1, \dots, X_n są

niezależne to (*) jest prawdziwe.

Implikacja odwrotna (dla uproszczenia $n=2$):

Korzystając z (*) otrzymujemy dla dowolnych zbiorów borelowskich B_1, B_2 :

$$\begin{aligned} P[X_1 \in B_1, X_2 \in B_2] &= P[X_1 \in B_1 \cap S_{X_1}, X_2 \in S_2 \cap S_{X_2}] \\ &= \sum_{\substack{x_1 \in B_1 \cap S_{X_1} \\ x_2 \in B_2 \cap S_{X_2}}} P[X_1 = x_1, X_2 = x_2] = \\ &= \sum_{x_1 \in B_1 \cap S_{X_1}} \sum_{x_2 \in B_2 \cap S_{X_2}} P[X_1 = x_1] P[X_2 = x_2] = \\ &= P[X_1 \in B_1] \cdot P[X_2 \in B_2] \end{aligned}$$

Wniosek 4.11 Zmienne losowe X_1, \dots, X_n

o gęstościach f_1, \dots, f_n są niezależne iff

zmienne losowe $X = (X_1, \dots, X_n)$ ma

gęstość

$$f_X(x_1, \dots, x_n) = f_1(x_1) \cdot \dots \cdot f_n(x_n)$$


Przykład. Niech $X = (X_1, X_2)$ będzie losowym

punktem z kwadratu $[0,1] \times [0,1]$. Czy zmienne X_1, X_2 są niezależne?

$$(\Omega, \mathcal{F}, \mathbb{P}) = ([0, 1]^2, \mathcal{B}([0, 1]^2), \lambda)$$

$$f_X(x_1, x_2) =$$

$$= 1 \cdot \mathbb{1}_{[0, 1] \times [0, 1]}(x_1, x_2)$$



Jak wygląda gęstość X_1 ?

$$A \in \mathcal{B}([0, 1])$$

$$\mathbb{P}[X_1 \in A] = \lambda[(X_1, X_2) \in A \times [0, 1]] =$$

$$= \lambda[A] = \int_A 1 dx \Rightarrow f_{X_1}(x) = \mathbb{1}_{[0, 1]}(x)$$

Analogicznie $f_{X_2}(x) = \mathbb{1}_{[0, 1]}(x)$

Mamy $f_X = f_{X_1} f_{X_2} \Rightarrow X_1, X_2$ niezależne

Przykład. Niech $X = (X_1, X_2)$ będzie losowym punktem w trójkącie $d(x_1, x_2) : 0 \leq x_2 \leq x_1 \leq 1$.

Czy X_1, X_2 niezależne?

$$f_X(x_1, x_2) = \begin{cases} 2 & 0 \leq x_2 \leq x_1 \\ 0 & \text{poza} \end{cases}$$



+rodz niezależne
↓

$$\text{Dla } A \in [0,1] \quad P[X_1 \in A] = P[(X_1, X_2) \in A \times \mathbb{R}] =$$

$$= \int_{A \times \mathbb{R}} f_X(x_1, x_2) dx_1 dx_2 = \int_A \int_{\mathbb{R}} f_X(x_1, x_2) dx_2 dx_1 =$$

Tw. Fubiniego

$$= \int_A \int_0^{x_1} 2 dx_2 dx_1 = \int_A 2x_1 dx_1$$

\parallel
 $f_{X_1}(x_1)$

$$\text{Teraz } P[X_2 \in A] = \int_A \int_{\mathbb{R}} f_X(x_1, x_2) dx_1 dx_2 =$$

$$= \int_A \int_{x_2}^1 2 dx_1 dx_2 = \int_A 2(1-x_2) dx_2$$

\parallel
 $f_{X_2}(x_2)$

$$f_X\left(\frac{1}{2}, \frac{1}{2}\right) = 2$$

$$f_{X_1}\left(\frac{1}{2}\right) = 1, \quad f_{X_2}\left(\frac{1}{2}\right) = 1$$

$f_X \neq f_{X_1} \cdot f_{X_2} \Rightarrow X_1, X_2$ nie są niezależne.

Tw. 4.12 Załóżmy, że X_1, X_2 są nrl. zm. los.

o rozkładach ciągłych z gęstościami f_1, f_2 .

Wówczas zmienna losowa $X_1 + X_2$ ma rozkład z gęstością

$$f(x) = f_1 * f_2(x) = \int_{\mathbb{R}} f_1(x-y) f_2(y) dy$$

Funkcję f nazwemy splotem f_1, f_2 .

--- --- --- --- --- --- --- --- --- --- ---

$$\text{dane, } \text{dane}, f(x) = \sum_{n=0}^{\infty} a_n x^n, g(x) = \sum_{n=0}^{\infty} b_n x^n$$

$$f(x) \cdot g(x) = \sum_{n=0}^{\infty} c_n x^n, c_n = \sum_{k=0}^n a_k b_{n-k}$$

To jest splot

--- --- --- --- --- --- --- --- --- --- ---

31.03.2021

Tw. z poprzedniego wykładu:

TW.4.12 Załóżmy, że X_1, X_2 są niezależnymi zmiennymi losowymi.

O rozkładach ciągłych z gęstościami f_1, f_2 .

Wówczas zmienna losowa $X_1 + X_2$ ma

rozkład z gęstością

$$f(x) = f_1 * f_2(x) = \int_{\mathbb{R}} f_1(x-y) f_2(y) dy$$

D-od. Dla dowolnego $B \in \mathcal{B}(\mathbb{R})$:

$$P[X_1 + X_2 \in B] = \mu_{(X_1, X_2)}(\omega(x_1, x_2): x_1 + x_2 \in B)$$

$$= \int_{(x_1, x_2): x_1 + x_2 \in B} \mu_{(X_1, X_2)}(dx_1, dx_2)$$

niezależności

=

$$\iint f_1(x_1) f_2(x_2) dx_1 dx_2$$

tw. Fubiniego

▷

$$\int_{\mathbb{R}} \left(\int_{\mathbb{R}} \mathbb{1}_B(x_1 + x_2) f_1(x_1) f_2(x_2) dx_1 \right) dx_2$$

$z = x_1 + x_2$
=

$$\int_{\mathbb{R}} \left(\int_{\mathbb{R}} \mathbb{1}_B(z) f_1(z - x_2) dz \right) f_2(x_2) dx_2$$

$$\text{tw. Fubiniego} = \int_B \left(\int_{\mathbb{R}} f_1(z - x_2) f_2(x_2) dx_2 \right) dz =$$

$$= \int_B f_1 * f_2 dz$$

Przykład Niech X_1 i X_2 będą niezależnymi zmiennymi losowymi o rozkładzie jednostajnym na $[0, 1]$, czyli $U([0, 1])$.

Oblicz gęstość $X_1 + X_2$.

Rozwiązanie


$$f_1(x_1) = \mathbb{1}_{[0,1]}(x_1), \quad f_2(x_2) = \mathbb{1}_{[0,1]}(x_2).$$

Zatem $X_1 + X_2$ ma gęstość

$$f_1 * f_2(x) = \int_{\mathbb{R}} \mathbb{1}_{[0,1]}(x - y) \mathbb{1}_{[0,1]}(y) dy =$$

$$= \int_{\mathbb{R}} \mathbb{1}_{[x-1, x]}(y) \mathbb{1}_{[0,1]}(y) dy = |\{[x-1, x] \cap [0, 1]\}|$$

$$\begin{cases} 0 \leq x-y \leq 1 \\ x-1 \leq y \leq x \\ 0 \leq y \leq 1 \end{cases}$$



Przykład Zauważmy, że X_1, X_2 są niezależnymi zmiennymi losowymi o rozkładzie

$N(m_1, \sigma_1)$, $N(m_2, \sigma_2)$. Wówczas

$$f_i(x) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{(x-m_i)^2}{2\sigma_i^2}} \quad i=1,2$$

i można obliczyć spłot

$$f_1 * f_2(x) = \frac{1}{2\pi\sigma_1\sigma_2} \int_{\mathbb{R}} e^{-\frac{(x-y-m_1)^2}{2\sigma_1^2} - \frac{(y-m_2)^2}{2\sigma_2^2}} dy$$

$$\stackrel{\text{(Zadanie)}}{=} \frac{1}{\sqrt{2\pi(\sigma_1^2 + \sigma_2^2)}} e^{-\frac{(x-m_1-m_2)^2}{2(\sigma_1^2 + \sigma_2^2)}}$$

Zatem $X_1 + X_2$ ma rozkład $N(m_1 + m_2, \sigma_1^2 + \sigma_2^2)$

Definicja 5.1 Niech X będzie zmienną losową (o wartościach z \mathbb{R}) na p. prob (Ω, \mathcal{F}, P) . Mówimy, że X ma wartość oczekiwaną jeżeli

$$\int_{\Omega} |X| dP = \int_{\Omega} |X(\omega)| dP(\omega) < \infty$$

Wówczas wartość oczekiwaną zmienną losową X nazywamy liczbą

$$E X = \int_{\Omega} X dP$$

Jeżeli $\Omega = \{\omega_1, \dots, \omega_n\}$, $P[\{\omega_i\}] = p_i$,
wtedy $E X = \sum_{i=1}^n X(\omega_i) p_i$

Intuicja Rzucamy kostką. Jaki średnio otrzymamy wynik?

Wartość oczekiwana, to tak jakbyśmy wykonali doświadczenie wiele razy i obliczamy średnią wartość wyniku.

Historycznie: wartość losowa opisuje, czy gra losowa w którąś grę jest optycalna.

Przykład Dwie gracze A i B grają w grę: rzucają kostką, niech k będzie wynikiem rutu. Jeżeli k jest nieparzyste, to A wygra k zł. W p.w. B dostaje k zł. Czy gra jest uczciwa?

Rozwiązanie Załóżmy, że wykonano n ruzów. Wówczas oczekujemy, że gracz A wygra w przybliżeniu

$$\approx \frac{n}{6} + 3 \cdot \frac{n}{6} + 5 \cdot \frac{n}{6} - 2 \frac{n}{6} - 4 \frac{n}{6} - 6 \frac{n}{6} = -\frac{n}{2}$$


Formalnie: Niech X oznacza wygraną gracza A

podczas jednej rundy, wtedy:

$$EX = 1 \cdot P[X=1] - 2 \cdot P[X=2] + \dots - 6 \cdot P[X=6] = -\frac{1}{2}$$

Totolotek Mamy 49 liczb, skreślamy 6.




Jeśli skreśliśmy liczby wylosowane przez maszynę losującą, to dostajemy nagrody.



dzielone na osoby, które wylosowały "3", "4", "5"

Jeśli nikt nie wylosował "6", to
te 2 mln przechodzą na stopną
turę.

Jak było w
Ameryce?



okazało się,
że w tej puli
wartości odliczane stała
się dodatnie.

TW. 5.2 Załóżmy, że X, Y są zmiennymi losowymi i że $\mathbb{E}X, \mathbb{E}Y$ istnieją. Wtedy

1. Jeżeli $X \geq 0$, to $\mathbb{E}X \geq 0$

2. $|\mathbb{E}X| \leq \mathbb{E}|X|$

3. Dla dowolnych $a, b \in \mathbb{R}$

$$\mathbb{E}[aX + bY] = a\mathbb{E}X + b\mathbb{E}Y$$

TW. 5.3 Załóżmy, że $\{X_n\}$ jest ciągiem zm. los. t. je $\mathbb{E}X_n$ istnieją. Wtedy

1. (lemat Fatou) Jeżeli $X \geq 0$, to

$$\mathbb{E} \liminf_{n \rightarrow \infty} X_n \leq \liminf_{n \rightarrow \infty} \mathbb{E}X_n$$

2. (tw. o zbieżności monotonicznej) Jeżeli $X_n \geq 0$

oraz $\{X_n\}$ jest ciągiem monotonicznym

(tzn. $X_n \leq X_{n+1}$) to

$$\mathbb{E} \lim_{n \rightarrow \infty} X_n = \lim_{n \rightarrow \infty} \mathbb{E}X_n$$

3. (tw. Lebesgue'a o zbieżności zmejsorjzowanej)

Jeżeli $|X_n| \leq Y$ dla pewnej zmiennej losowej Y , t.ż. $E|Y| < \infty$ oraz istnieje

granica $\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$ dla P

prawie wszystkich ω , to

$$EX = E \lim_{n \rightarrow \infty} X_n = \lim_{n \rightarrow \infty} EX_n$$

Przykład Kupujemy k losów w loterii, w której

rej M losów jest przegranych, a N

wygranych (zakł. $k \leq M, N$). Niech X

będzie liczba wygranych wśród tych,

które kupiliśmy. Oblicz EX

I

$$X_i = \begin{cases} 1 & i\text{-ty wygrana} \\ 0 & i\text{-ty przegrana} \end{cases}$$

$$X = \sum_{i=1}^k X_i, \quad EX_i = P[X_i=0] \cdot 0 + P[X_i=1] \cdot 1 = \\ = P[X_i=1] = \frac{N}{M+N}$$

???

$$EX = \sum EX_i = \frac{KN}{M+N}.$$

$$\text{II} \quad EX = \sum_{j=0}^k j \cdot P[X=j] = \sum_{j=0}^k \frac{\binom{N}{j} \binom{M}{k-j}}{\binom{N+M}{k}} \cdot j = \dots$$

Masakra
do liczenia...

Przykład losujemy σ ze zbioru S_n .

Niech X oznacza l. punktów stałych.

Oblicz EX .

$$X_i = \begin{cases} 1 & \text{gdy } \sigma(i) = i \\ 0 & \text{inaczej} \end{cases}$$

$$EX = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n EX_i = 1,$$

$$\text{bo } EX_i = P[X_i = 1] = \frac{1}{n}.$$

Potęga liniowości E wynika z tego,
że nie wymaga niezależności.

Tw. 5.4 Niech $f: \mathbb{R}^d \rightarrow \mathbb{R}$ będzie f. borelowską
a X d -wymiarową zm. los. o rozkładzie μ .

Wówczas:

$$\int_{\Omega} f(X) dP = \mathbb{E} f(X) = \int_{\mathbb{R}^d} f d\mu \quad (*)$$

o ile jedna z tych statystyk istnieje

D-d. Przybliżemy f funkcjami prostymi.
(Zał. $d=1$, dla prostoty dowodu)

Krok 1. $f = \mathbb{1}_A$, dla $A \in \text{Bor}(\mathbb{R})$

$$\text{Wtedy } \mathbb{E} f(X) = \mathbb{P}[f(X) = 1] =$$

$$\mathbb{P}[X \in A] = \mu(A) = \int_A 1 d\mu =$$

$$= \int_{\mathbb{R}} \mathbb{1}_A d\mu = \int_{\mathbb{R}} f d\mu$$

Krok 2.

$$f = \sum_{i=1}^n a_i \mathbb{1}_{A_i} - f. \text{ prosta. Wtedy } (*)$$

wynik z kroku 1 i liniowości
wartości oczekiwanej.

Krok 3.

Załóżmy, że $f \geq 0$. Wtedy można

$\{f_n\}$ będzie ciągiem f . prostych t. że

$f_n \uparrow f$. Z tw. o zbieżności

monotonicznej i kroku 2.

$$\mathbb{E} f(X) = \mathbb{E} \lim_n f_n(X) \stackrel{\text{MCT}}{=} \lim_n \mathbb{E} f_n(X) \stackrel{**}{=}$$

$$= \lim_n \int f_n(X) d\mu \stackrel{\text{MCT}}{=} \int f(X) d\mu$$

Krok 4.

$$f = f^+ - f^-, \text{ znów z liniowości.}$$



Wniosek 5.5 Jeżeli zm. los. ma rozkład

dyskretny $P[X=x_i] = p_i$, to $E\Phi(X)$

istnieje iff $\sum |\Phi(x_i)| p_i < \infty$. Wówczas

$$E\Phi(X) = \sum \Phi(x_i) p_i$$

Wniosek 5.6

Jeżeli zm. los. ma rozkład absolutnie

ciągły o gęstości g (tzn. $\mu(dx) = g(x)dx$)

a $f: \mathbb{R} \rightarrow \mathbb{R}$, to

$$E f(X) = \int_{\mathbb{R}} f(x) g(x) dx$$

Tw. 5.7 Żet., że X i Y są niezależnymi

zmiennymi losowymi oraz obie posiadają wartości oczekiwane. Wówczas

$$E[XY] = EX \cdot EY$$

D-d. Niech $Z = (X, Y)$. Z niezależności

wynika, że $\mu_Z = \mu_X \otimes \mu_Y$.

Korzystając z tw. Fubniego oraz tw. 5.4
otrzymujemy

$$\mathbb{E}|XY| \stackrel{\text{TW.5.4}}{=} \int_{\mathbb{R}^2} |xy| \mu_z(dx, dy) = \int_{\mathbb{R}^2} |xy| \mu_x(dx) \mu_y(dy)$$

$$\stackrel{\text{Fubini}}{=} \int_{\mathbb{R}} \int_{\mathbb{R}} |xy| \mu_x(dx) \mu_y(dy) =$$

$$= \int_{\mathbb{R}} |x| \mu_x(dx) \cdot \int_{\mathbb{R}} |y| \mu_y(dy) \stackrel{\text{TW.5.4}}{=} \mathbb{E}|X| \cdot \mathbb{E}|Y|.$$

Powyższy rachunek pokazuje, że zmienne losowe X i Y mają wartość oczekiwaną.

Patząc na rachunki bez modułów
otrzymujemy też.

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 Trosnąjemy 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 , $X \sim \text{Bin}(n, p)$.

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

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

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

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

$$EX = \sum EX_i = np$$

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

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

Zmienne X_i są zależne!

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

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

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

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

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

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

21.04.2024

W poprzednim odcinku:

$$\mathbb{E} X = \int_{\mathbb{R}} x d\mu(x), \quad X \sim \mu$$

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

Jeżeli X, Y wzl., to $\mathbb{E} X \cdot Y = \mathbb{E} X \cdot \mathbb{E} Y$,

$$\text{Var} (X + Y) = \text{Var} (X) + \text{Var} (Y)$$

$$\begin{aligned} \text{Cov} (X, Y) &= \mathbb{E} [(X - \mathbb{E} X)(Y - \mathbb{E} Y)] \\ &= \mathbb{E} X Y - \mathbb{E} X \mathbb{E} Y \end{aligned}$$

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

Definicja 5.15 Niech $X = (X_1, \dots, X_n)$ będzie

n -wymiarową zmienną losową taką, że

$\mathbb{E} X_i < \infty$. Macierz

$$Q = \begin{bmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \dots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \dots & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_n, X_1) & \dots & \dots & \text{Cov}(X_n, X_n) \end{bmatrix}$$

nazywamy macierz kowariancji
zmiennej losowej X . Jest to wielowymiarowe
ogólnie wariancji.

Uwaga Jeżeli X_i są parami nie-
skorelowane, to Q diagonalne.

Tw. 5.16 Macierz kowariancji Q

zm. los. X jest symetryczna oraz
odwrotnie określona (tzn. dla każdego
 $t_1, \dots, t_n, \sum t_i t_j q_{ij} \geq 0$).

Dz Ustalmy $t_1, \dots, t_n \in \mathbb{R}$. Definiujemy

$$Y = \sum_{i=1}^n t_i X_i.$$

$$0 \leq \text{Var } Y = \mathbb{E}[(Y - \mathbb{E}Y)^2] =$$

$$= \mathbb{E}\left[\left(\sum t_j X_j - \sum t_j \mathbb{E}X_j\right)^2\right] =$$

$$= \mathbb{E}\left[\left(\sum t_j (X_j - \mathbb{E}X_j)\right)^2\right] =$$

$$\begin{aligned}
& \mathbb{E} \left[\sum_{i,j} t_i (X_i - \mathbb{E}X_i) t_j (X_j - \mathbb{E}X_j) \right] = \\
& = \sum_{i,j} t_i t_j \mathbb{E} \left[(X_i - \mathbb{E}X_i)(X_j - \mathbb{E}X_j) \right] = \\
& = \sum_{i,j} t_i t_j \text{Cov}(X_i, X_j) = \sum_{i,j} t_i t_j \sigma_{ij}
\end{aligned}$$

Zadanie X - wielowym. zm. los. $\sim \mathcal{N}(m, A^{-1})$,

gdzie $m \in \mathbb{R}^d$, A jest macierzą sym.

i niejemnie określona, tzn. gęstość


X jest dana wzorem

$$f(x) = \frac{\sqrt{\det A}}{(2\pi)^{\frac{d}{2}}} e^{-\frac{1}{2} \langle x-m, x-m \rangle}$$

• Pokaż, że $\mathbb{E}X = m$, a macierz kov. jest równa A^{-1}

• Pokaż, że jeżeli X ma rozkład normalny, to X_1, \dots, X_d są niezależne iff są nieskorelowane.

Przykład Regresja liniowa. Dane są
zm. los. X i Y , są skorelowane.



$$f(x) = y = \frac{\text{Cov}(X, Y)}{\text{Var } X} (x - \mathbb{E}X) + \mathbb{E}Y$$

Zał., że tutaj jest obserwowane jedną
z tych zm. los., np. X (tutaj jest
mierzyć przebieg samochodu, trudno liczyć
kosztu eksploatacji). Szukamy
funkcji f , które dobrze aproksymuje
 Y , to możemy przyjąć $Y = f(x)$.

Jak wyznaczyć ten wzór na f ?

Chcemy zminimalizować $\mathbb{E}[(Y - (aX + b))^2]$.

Szukamy a i b .

$g(a, b)$

$$\left. \begin{array}{l} \frac{\partial g}{\partial a} = 2a\mathbb{E}X^2 - 2\mathbb{E}XY + 2b\mathbb{E}X = 0 \\ \frac{\partial g}{\partial b} = 2b - 2\mathbb{E}Y + 2a\mathbb{E}X = 0 \end{array} \right\}$$

Stąd $a = \frac{\mathbb{E}XY - b\mathbb{E}X}{\mathbb{E}X^2}$

$b = \mathbb{E}Y - a\mathbb{E}X$

$$a\mathbb{E}X^2 - \mathbb{E}XY + \mathbb{E}Y\mathbb{E}X - a(\mathbb{E}X)^2 = 0$$

$$a\text{Var} X - \text{Cov}(X, Y) = 0$$

$$a = \frac{\text{Cov}(X, Y)}{\text{Var} X}$$

TW. 6.1 Jeżeli $\mathbb{E}X^2 < \infty$, $\mathbb{E}Y^2 < \infty$,
to

$$\mathbb{E}|XY| \leq (\mathbb{E}X^2)^{\frac{1}{2}} (\mathbb{E}Y^2)^{\frac{1}{2}}$$

TW. 6.2 Nierówność Höldera: Jeżeli

$\mathbb{E}|X|^p < \infty$ i $\mathbb{E}|Y|^q < \infty$, dla $p, q > 1$

t. że $\frac{1}{p} + \frac{1}{q} = 1$, to

$$\mathbb{E}|XY| \leq (\mathbb{E}|X|^p)^{\frac{1}{p}} (\mathbb{E}|Y|^q)^{\frac{1}{q}}$$

TW. 6.3 Nierówność Czebyszewa: Niech

X będzie zm. los. i niech $f: [0, \infty) \rightarrow [0, \infty)$

będzie niemalejąca funkcja taka, że

$f(x) > 0$ dla każdego $x > 0$. Wtedy

dla każdego $\lambda > 0$ zachodzi:

$$\mathbb{P}[|X| \geq \lambda] \leq \frac{\mathbb{E}f(|X|)}{f(\lambda)}$$

$$\text{D-o. } P[|X| \geq \lambda] = E \mathbb{1}_{\{|X| \geq \lambda\}} \leq$$

$$\leq E \left[\frac{f(|X|)}{f(\lambda)} \cdot \mathbb{1}_{\{|X| \geq \lambda\}} \right] \leq \frac{1}{f(\lambda)} E[f(|X|)]$$

Wniosek 8.4

- Nierówność Markowa ($f(x) = x^p$ dla $p > 0$):

$$P[|X| > \lambda] \leq \frac{E|X|^p}{\lambda^p}, \quad \forall \lambda > 0$$

- Nierówność Czebyszewa ($f(x) = x^2$,
zamiast X bierzemy $X - EX$):

$$P[|X - EX| \geq \lambda] \leq \frac{\text{Var } X}{\lambda^2}, \quad \forall \lambda > 0$$

- Wykładnicza nierówność Czebyszewa
($f(x) = e^{px}$): Jeżeli $E e^{pX} < \infty$, $p > 0$, to

$$P[X \geq \lambda] \leq \frac{E e^{pX}}{e^{p\lambda}}, \quad \forall \lambda > 0$$

Rodzaje zbieżności zmiennych losowych.

Definicja 6.5 Załóżmy, że X_n jest ciągiem zmi. losowych. Mówimy, że

1. X_n zbiega do X prawie na pewno,

jeżeli $P(\{\omega: X_n(\omega) \rightarrow X(\omega)\}) = 1$.

Piszemy wówczas $X_n \rightarrow X$ (lub $X_n \xrightarrow{p.n.} X$)

2. X_n zbiega do X według prawdopodobieństwa,

jeżeli dla każdego $\epsilon > 0$

$$\lim_{n \rightarrow \infty} P[\{\omega: |X_n(\omega) - X(\omega)| \geq \epsilon\}] =$$

$$\lim_{n \rightarrow \infty} P[|X_n - X| \geq \epsilon] = 0$$

Piszemy wówczas $X_n \xrightarrow{P} X$

3. X_n zbiega do X w L^p , jeżeli $X_n \in L^p$

(tzn. $\|X_n\|_p = (E|X_n|^p)^{1/p} < \infty$) oraz

$$\lim_{n \rightarrow \infty} \|X_n - X\|_p = \lim_{n \rightarrow \infty} (E|X_n - X|^p)^{1/p} = 0$$

Piszemy wówczas $X_n \xrightarrow{L^p} X$.

TW.6.6 Jeżeli $X_n \xrightarrow{P} X$, $Y_n \xrightarrow{P} Y$, to

1. $aX_n + bY_n \xrightarrow{P} aX + bY$

2. $X_n Y_n \xrightarrow{P} XY$

TW.6.7 Jeżeli $X_n \rightarrow X$, to $X_n \xrightarrow{P} X$. Impli-

kacja odwrotna nie jest prawdziwa.

\Rightarrow byto na teorii miary

$\Leftarrow (\Omega, \mathcal{F}, P) = ([0,1], \text{Bor}([0,1]), \lambda)$.

$X_1 = \mathbb{1}_{[0,1]}$, $X_2 = \mathbb{1}_{[0,1/2]}$, $X_3 = \mathbb{1}_{[1/2,1]}$,

$X_n = \mathbb{1}_{[0,1/n]}$, ..., $X_7 = \mathbb{1}_{[3/4,1]}$, ...

Wtedy $X_n \xrightarrow{P} 0$, ale nie $X \rightarrow 0$.

TW.6.8 Jeżeli $X_n \xrightarrow{L^p} X$, to $X_n \xrightarrow{P} X$. Implikacja

odwrotna nie jest prawdziwa.

D-d. Z nierówności Czebyszewa

\Rightarrow

$$P[|X_n - X| < \varepsilon] \leq \frac{E|X_n - X|^p}{\varepsilon^p} \rightarrow 0$$

$\Leftarrow X_n = n^{1/p} \cdot \mathbb{1}_{[0,1/n]}$, $X_n \xrightarrow{P} 0$, $X_n \not\xrightarrow{L^p} 0$

Tw. 6.9 Jeżeli $X_n \xrightarrow{P} X$, to istnieje podciąg
 $\{X_{n_k}\}_{k \in \mathbb{N}}$ taki, że $X_{n_k} \xrightarrow{P.n.} X$.

D-2 Ustalmy $\varepsilon = 2^{-k}$.

$$P[|X_n - X| \geq 2^{-k}] \leq 2^{-k} \quad (\text{dla dużych } n).$$

$n \geq n_k$

Mozemy założyć, że $\{n_k\}$ jest rosnący.

$$\text{Mamy } \sum_{k=1}^{\infty} P[|X_{n_k} - X| > 2^{-k}] \leq \sum_{k=1}^{\infty} 2^{-k} < \infty$$

* lematu Borela - Cantallego wynika,

$$\text{że } P[|X_{n_k} - X| \geq 2^{-k} \text{ i.o.}] = 0.$$

Stąd wynika, że $|X_{n_k} - X| \geq 2^{-k}$ tylko

dla skończonej liczby indeksów. Tzn. że

$$\text{od pewnego miejsca } |X_{n_k} - X| < 2^{-k}$$

$$\Rightarrow X_{n_k} \rightarrow X.$$

Stabe Prawo Wielkich Liczb (SPWL)

Tw. Dany jest ciąg niezależnych zmiennych losowych (X_n) o takiej samej wartości oczekiwanej i wariancji.

$$\text{Wówczas } \frac{X_1 + \dots + X_n}{n} \xrightarrow{\mathbb{P}} \mathbb{E}X_1.$$

Naszym celem będzie pokazanie Mocnego PWL, które mówi o zbieżności p.w.

Tw. 7.1 Jeżeli ciąg X_1, X_2, \dots spełnia $\mathbb{E}X_i^2 < \infty$, zmienne losowe są nieskorrelowane oraz mają wspólnie ograniczoną wariancję, to

$$\frac{X_1 + \dots + X_n - \mathbb{E}[X_1 + \dots + X_n]}{n} \xrightarrow{\mathbb{P}} 0$$

W szczególności, jeżeli wszystkie zmienne losowe X_i mają tę samą wartość oczekiwaną, to

$$\frac{X_1 + \dots + X_n}{n} \xrightarrow{\mathbb{P}} \mathbb{E}X_1.$$

D-đ. Z nierówności Czebyszewa, dla $\varepsilon > 0$

$$\mathbb{P} \left[\frac{X_1 + \dots + X_n - \mathbb{E}[X_1 + \dots + X_n]}{n} \geq \varepsilon \right] \leq$$

$$\frac{1}{\varepsilon^2} \cdot \text{Var} \left(\frac{X_1 + \dots + X_n}{n} \right) =$$

$$\frac{1}{(n\varepsilon)^2} \text{Var} (X_1 + \dots + X_n) \stackrel{\text{niezależność}}{=} =$$

$$\frac{1}{(n\varepsilon)^2} (\text{Var} X_1 + \dots + \text{Var} X_n) \leq$$

$$\frac{M \cdot n}{(n\varepsilon)^2} \xrightarrow{n \rightarrow \infty} 0$$

Przykład. Weźmy $\{X_k\}$ ciąg n.zl. zm. los.

oraz że $X_k \sim U([-1, 1])$. Wtedy

X_1^2, X_2^2, \dots są niezależne. Ponadto

$$\mathbb{E}X_1^2 = \int_{-1}^1 x^2 \frac{dx}{2} = \frac{1}{2} \cdot \frac{1}{3} x^3 \Big|_{-1}^1 = \frac{1}{3}.$$


$$\text{Var} X_1^2 \leq \mathbb{E}X_1^4 \leq 1.$$

Ze SPWL mamy

$$\frac{X_1^2 + \dots + X_n^2}{n} \xrightarrow{P} \frac{1}{3}$$

Ustalamy $\varepsilon \in (0, \frac{1}{2})$. Zdefiniujmy

$$A_{n,\varepsilon} = \left\{ x \in \mathbb{R}^n : (1-\varepsilon)\sqrt{\frac{n}{3}} \leq \|x\| \leq (1+\varepsilon)\sqrt{\frac{n}{3}} \right\}$$



Dla $n \geq 4$ będzie tak, że ten pierścien będzie trochę wychodził poza kostkę, a trochę jeszcze w nim będzie.

Teraz

$$\begin{aligned} & \frac{1}{2^n} \cdot \lambda(A_{n,\varepsilon} \cap [-1,1]^n) = \\ & = \mathbb{P}[(X_1, \dots, X_n) \in A_{n,\varepsilon}] = \\ & = \mathbb{P}\left[(1-\varepsilon)\sqrt{\frac{n}{3}} \leq \sqrt{X_1^2 + \dots + X_n^2} \leq (1+\varepsilon)\sqrt{\frac{n}{3}}\right] = \\ & = \mathbb{P}\left[\frac{1}{3}(1-\varepsilon)^2 \leq \frac{X_1^2 + \dots + X_n^2}{n} \leq \frac{1}{3}(1+\varepsilon)^2\right] \geq \\ & \geq \mathbb{P}\left[\left|\frac{1}{n} \sum_{i=1}^n X_i^2 - \frac{1}{3}\right| \leq \frac{1}{3}(2\varepsilon - \varepsilon^2)\right] \xrightarrow{\text{SPWL}} 1 \end{aligned}$$



28.04.2021

SPWL. $\{X_i\}$ - ciąg zm. los. o

takim samym rozkładzie i $\mathbb{E}X_i^2 < \infty$

Cel: $\frac{X_1 + \dots + X_n}{n}$ ~~P.W.~~ $\mathbb{E}X_1$

Chcemy badać sumy: $\frac{X_1 + \dots + X_n - a_n}{b_n}$

Przykład: Czy $\sum_{n=1}^{\infty} (\pm 1) \frac{1}{n}$ jest zbieżny?

Np. $\sum \frac{1}{n} = \infty$, $\sum (-1)^n \frac{1}{n} < \infty$

Tw. Riemanna: można tak

ustawić ± 1 , żeby szereg był zbieżny do dowolnej wartości

$x \in \mathbb{R} \cup \{-\infty, \infty\}$.

Definicja 7.2 Niech $(\Omega, \mathcal{F}, \mathbb{P})$ będzie

p. prob. i niech $\mathcal{F}_1, \mathcal{F}_2, \dots$ będzie

ciągami σ -ciał zawartych w \mathcal{F} . Zdefiniujemy

$$\mathcal{F}_{n,\infty} = \sigma(\mathcal{F}_n, \mathcal{F}_{n+1}, \dots)$$

Wtedy

$$\mathcal{F}_\infty = \bigcap_{n=1}^{\infty} \mathcal{F}_{n,\infty}$$

nazywamy σ -ciałem ogonowym.

Intuicja: Mamy ciąg doświadczeń
(zm. los. X_n). \mathcal{F}_n - wiedza o n -tym

doświadczeniu. $\mathcal{F}_{n,\infty}$ - wiedza o

dośw. od chwili n .

$$\mathcal{F}_{n,\infty} \supseteq \mathcal{F}_{n+1,\infty}$$

\mathcal{F}_∞ - wiedza o „nieskończenie

odległej” przyszłości.

Przykład. Rzucaamy kostką.

"6 wypadnie ∞ wiele razy"

Dla każdego n to zdarzenie

należy do $\mathcal{F}_{n, \infty}$

Przykład Niech X_1, X_2, \dots będzie ciągiem zmiennych losowych i niech $\mathcal{F}_n = \sigma(X_n)$ będzie σ -ciałem generowanym przez X_n .

Wtedy:

• jeżeli $A_i \in \sigma(X_i)$, to

$$A = \limsup A_n = \bigcap_{k \geq 1} \bigcup_{i \geq k} A_i \in \mathcal{F}_\infty$$

bo dla każdego n

$$A = \bigcap_{k > n} \bigcup_{i \geq k} A_i \in \mathcal{F}_{n, \infty}$$

($A_i = \{2\}$ w i -tym rzucie wypadła 6)
($\bigcup_{i \geq k} A_i = \{2\}$ w rzutach $k, k+1, k+2, \dots$ wypadła 6
co najmniej jedna 6)
($A = \{2\}$ wypadło ∞ wiele 6)

- zdarzenie

$A = \{\omega: \text{ciąg } \{X_n(\omega)\} \text{ jest zbieżny}\}$
 należy do σ -ciała ogólnego, bo

$$\{\omega: \{X_n(\omega)\} \text{ zbieżny}\} = \bigcap_{N=1}^{\infty} \bigcup_{k=N}^{\infty} \bigcap_{j,m \geq k} \{|X_j(\omega) - X_m(\omega)| < \frac{1}{N}\}$$

$$= \bigcap_{N=1}^{\infty} \bigcup_{k=N}^{\infty} \bigcap_{j,m \geq k} \{|X_j(\omega) - X_m(\omega)| < \frac{1}{N}\} \in \mathcal{F}_{n, \infty}$$

Pokazaliśmy, że dla każdego n

$\{\omega: \text{ciąg } \{X_n(\omega)\} \text{ jest zbieżny}\} \in \mathcal{F}_{n, \infty}$

a to daje nam

$\{\omega: \text{ciąg } \{X_n(\omega)\} \text{ jest zbieżny}\} \in \mathcal{F}_{\infty}$

- zdarzenie

$\{\sup_n |X_n| < \infty\}$ i $\{\sum_{n=1}^{\infty} X_n \text{ jest zbieżny}\}$

$\{\omega: \sup_n |X_n(\omega)| < \infty\}$

należy do σ -ciała ogólnego

• zdanie

$$\left\{ \limsup_{n \rightarrow \infty} (X_1 + \dots + X_n) > 0 \right\}$$

nie należy do σ -cieta

ogonowego, ponieważ pierwsze składniki mają wpływ na granicę.

Tw. 7.3 (Prawo 0-1 Kolmogorowa)

Jeżeli σ -cieta \mathcal{F}_n są niezależne,

to dla każdego zdarzenia $A \in \mathcal{F}_\infty$

zachodzi

$$P[A] = 0 \quad \text{lub} \quad P[A] = 1.$$

lemmat 7.4 Jeżeli rodziny zbiorów

A_1, A_2, \dots, A_n są niezależne i

każdy z nich tworzy π -aktua, to

σ -cieta przez nie generowane

$\sigma(A_1), \dots, \sigma(A_n)$ są niezależne.

D-d. Niezależny zbiory $A_2 \in \mathcal{A}_2, \dots, A_n \in \mathcal{A}_n$

oraz wtedy

$$\mathcal{L} = \{A \in \mathcal{F} : P[A \cap A_2 \cap \dots \cap A_n] = P[A] \cdot P[A_2] \cdot \dots \cdot P[A_n]\}$$

Oczywiście $A_1 \in \mathcal{L}$. Ponadto \mathcal{L} jest λ -układem

- $\Omega \in \mathcal{L}$

- jeżeli $A, B \in \mathcal{L}$ oraz $A \subset B$, to

$$P[(B \setminus A) \cap A_2 \cap \dots \cap A_n] =$$

$$P[B \cap A_2 \cap \dots \cap A_n] - P[A \cap A_2 \cap \dots \cap A_n] =$$

$$= P[B] \cdot P[A_2] \cdot \dots \cdot P[A_n] - P[A] \cdot P[A_2] \cdot \dots \cdot P[A_n]$$

$$= P[B \setminus A] \cdot P[A_2] \cdot \dots \cdot P[A_n].$$

- $\{B_k\}$ wst. rodz. zb. w \mathcal{L} , $B = \bigcup_{n=1}^{\infty} B_n$,

wtedy $P[B_n] \rightarrow P[B]$. Podobnie

$$P[B_k \cap A_2 \cap \dots \cap A_n]$$

$\downarrow k \rightarrow \infty$

$$P[B \cap A_2 \cap \dots \cap A_n]$$

Wynika stąd

$$P[B \cap A_2 \cap \dots \cap A_n] \stackrel{k \rightarrow \infty}{\leftarrow} P[B_k \cap A_2 \cap \dots \cap A_n] = \\ = P[B]P[A_2] \dots P[A_n] \stackrel{k \rightarrow \infty}{\rightarrow} P[B]P[A_2] \dots P[A_n]$$

a więc $B \in \mathcal{A}$.

Zatem $\sigma(A_1), A_2, \dots, A_n$ są

niezależne. Teraz ustalamy $A_1 \in \sigma(A_1)$,

$A_3 \in \mathcal{A}_3, \dots, A_n \in \mathcal{A}_n$ i definiujemy

$$\mathcal{A}_2 = \{A \in \mathcal{F} : P[A_1 \cap A \cap A_3 \cap \dots \cap A_n] = \\ = P[A_1]P[A]P[A_3] \dots P[A_n]\}.$$

Powtarzamy rozumowanie n razy
i dostajemy tezę. \square

Dł. tw. 7.3 Pokażemy że A jest

niezależny od samego siebie.

$$\text{Wtedy } P[A] = P[A \cap A] = P[A] \cdot P[A] = P[A]^2$$

Stąd $P[A] \in \{0, 1\}$.

Aby to uzasadnić opiszemy pewne rodziny zbiorów $\mathcal{G}_1, \mathcal{G}_2$ dla których zachodzi

$$P[B \cap C] = P[B]P[C]$$

dla $B \in \mathcal{G}_1, C \in \mathcal{G}_2$.

Krok 1. Weźmy dowolne k oraz

$$B \in \sigma(\mathcal{F}_1, \dots, \mathcal{F}_k), C \in \sigma(\mathcal{F}_{k+1}, \mathcal{F}_{k+2}, \dots)$$

$$\begin{aligned} \text{Zauważmy, że } \sigma(\mathcal{F}_{k+1}, \mathcal{F}_{k+2}, \dots) &= \\ &= \sigma\left(\bigcup_{j \geq 1} \sigma(\mathcal{F}_{k+1}, \mathcal{F}_{k+2}, \dots, \mathcal{F}_{k+j})\right) = (*) \end{aligned}$$

i powyższa suma jest π -układem.

Rodziny $\sigma(\mathcal{F}_1, \dots, \mathcal{F}_k)$ oraz

$$\bigcup_{j \geq 1} \sigma(\mathcal{F}_{k+1}, \dots, \mathcal{F}_{k+j}) \text{ są niezależne}$$

(z założenia t.w.), a zatem

$\sigma(\mathcal{F}_1, \dots, \mathcal{F}_k)$ oraz $(*) \stackrel{\text{z}}{=} \bigcup_{j \geq 1} \sigma(\mathcal{F}_{k+1}, \dots, \mathcal{F}_{k+j})$ są niezależne z lematu.

Zatem dla każdego k

$$\sigma(\mathcal{F}_1, \dots, \mathcal{F}_k), \sigma(\mathcal{F}_{k+1}, \mathcal{F}_{k+2}, \dots)$$

są niezależne.

Krok 2. Wzrost teraz

$$B \in \sigma(\mathcal{F}_1, \mathcal{F}_2, \dots), C \in \mathcal{F}_\infty$$

Zbiory $\sigma(\mathcal{F}_1, \dots, \mathcal{F}_k), \mathcal{F}_\infty$ są niezależne

z kroku 1. Zatem $\bigcup_{k \geq 1} \sigma(\mathcal{F}_1, \dots, \mathcal{F}_k), \mathcal{F}_\infty$

są niezależne. Są to π -układy,

więc z lematu niezależne są

$$\sigma\left(\bigcup_{k \geq 1} \sigma(\mathcal{F}_1, \dots, \mathcal{F}_k)\right), \mathcal{F}_\infty$$

$$= \sigma(\mathcal{F}_1, \mathcal{F}_2, \dots)$$

Ale $\mathcal{F}_\infty \subseteq \sigma(\mathcal{F}_1, \mathcal{F}_2, \dots)$, więc

dla dowolnego $A \in \mathcal{F}_\infty$ mamy

$$P[A] = P[A \cap A] = P[A]^2.$$



Wniosek 7.5 Jeżeli $\{X_n\}$ jest ciągiem

niezależnych zmiennych losowych, to

• granica $\lim_{n \rightarrow \infty} X_n$ istnieje z prawdopodobieństwem 0

lub 1

• szereg $\sum_{n=1}^{\infty} X_n$ jest zbieżny z prawdopodobieństwem

0 lub 1

• $\mathbb{P}[\limsup X_n = \infty] = 0$ lub 1

• $\mathbb{P}[\lim_{n \rightarrow \infty} (X_1 + \dots + X_n)/n < \infty] = 0$ lub 1.

Tw. 8.1 (Nierówność Kołmogorowa)

Niech X_1, \dots, X_n będą wzl. zm. los.


takimi, że $\mathbb{E}X_i = 0$ oraz $\mathbb{E}X_i^2 < \infty$.

Wtedy dla dowolnego $t > 0$

$$\mathbb{P}\left[\max_{1 \leq k \leq n} |X_1 + \dots + X_k| \geq t\right] \leq \frac{1}{t^2} \text{Var}(X_1 + \dots + X_n)$$

D-d. $S_0 = 0$, $S_k := S_{k-1} + X_k$. Zdefiniujmy

$$A_k = \{ |S_j| < t \text{ dla } j < k, |S_k| \geq t \}$$



A_k opisuje zdarzenia, które dopiero w k -tym kroku przekraczają t .

A_k są rozłączne, $\bigcup_{k=1}^n A_k = B = \{ \max_{1 \leq k \leq n} |S_k| \geq t \}$

$$A_k \in \sigma(\mathcal{F}_1, \mathcal{F}_2, \dots, \mathcal{F}_n) \quad (\sigma(X_i) = \mathcal{F}_i)$$

$$\text{Var } S_n = \mathbb{E} S_n^2 = \int_{\mathcal{B}} S_n^2 d\mathbb{P} \geq \int_{\mathcal{B}} S_n^2 d\mathbb{P}$$

$$= \sum_{k=1}^n \int_{\mathcal{A}_k} S_n^2 d\mathbb{P} = \sum_{k=1}^n \int_{\mathcal{A}_k} (S_k + S_n - S_k)^2 d\mathbb{P}$$

$$= \sum_{k=1}^n \left(\int_{\mathcal{A}_k} S_k^2 d\mathbb{P} + 2 \int_{\mathcal{A}_k} (S_n - S_k) S_k d\mathbb{P} + \int_{\mathcal{A}_k} (S_n - S_k)^2 d\mathbb{P} \right)$$

$$\geq \sum_{k=1}^n \left(\int_{A_k} S_k^2 dP + 2 \int (S_n - S_k) S_k \mathbb{1}_{A_k} dP \right)$$

Zmiennie losowe $S_n - S_k$ oraz $S_k \mathbb{1}_{A_k}$ są

wiezolne, bo $\sigma(S_k \mathbb{1}_{A_k}) \subseteq \sigma(X_1, \dots, X_k)$

$\sigma(S_n - S_k) \subseteq \sigma(X_{k+1}, \dots, X_n)$ ← niezolne

$$\int (S_n - S_k) \cdot S_k \mathbb{1}_{A_k} dP = \mathbb{E}[(S_n - S_k) S_k \mathbb{1}_{A_k}]$$

$$= \mathbb{E}[S_n - S_k] \mathbb{E}[S_k \mathbb{1}_{A_k}] =$$

$$= \sum_{j=k+1}^n \mathbb{E} \cdot \mathbb{E}[S_k \mathbb{1}_{A_k}] = 0$$

A stąd

$$\text{Var } S_n \geq \sum_{k=1}^n \int_{A_k} S_k^2 dP \geq \sum_{k=1}^n \int_{A_k} t^2 dP$$

$$= t^2 \int_B dP = t^2 P[B]$$



Tw. 8.2 (Kolmogorowa o dwóch szeregach)

Załóżmy, że X_1, X_2, \dots jest ciągiem niezależnych zmiennych losowych takich, że $\mathbb{E}X_i^2 < \infty$. Jeżeli

$$\sum_{k=1}^{\infty} \mathbb{E}X_k < \infty \quad \text{oraz} \quad \sum_{k=1}^{\infty} \text{Var} X_k < \infty,$$

to $\sum_{k=1}^{\infty} X_k < \infty$ p.n.

Przykład Czy szereg $\sum_{n=1}^{\infty} \frac{u_n}{n}$, gdzie

$$u_n = \begin{cases} 1 & \text{z prawdopodobieństwem } \frac{1}{2} \\ -1 & \text{z prawdopodobieństwem } \frac{1}{2} \end{cases}, \quad u_n \text{ niezależne,}$$

jest zbieżny?

Niech $X_n = \frac{u_n}{n}$, wtedy $\mathbb{E}X_n = 0$,

$$\text{Var} X_n = \frac{1}{n^2} \text{Var}(u_n) = \frac{1}{n^2}.$$

Zatem szereg $\sum X_n$ jest zbieżny p.n.

D-od. Tw. 8.2 Możemy założyć, że

$\mathbb{E}X_i = 0$, bo przy powyższych założeniach

$\sum X_i$ jest zbieżny p.n. $\Leftrightarrow \sum (X_i - \mathbb{E}X_i)$ jest zbieżny.

Niech $S_N = \sum_{n=1}^N X_n$. Chcemy pokazać, że $\{S_N\}$ jest ciągiem Cauchy'ego. Z nierówności Kołmogorowa

$$\mathbb{P}\left[\max_{M \leq m \leq N} |S_m - S_M| \geq \varepsilon\right] \leq \frac{1}{\varepsilon^2} \text{Var}(S_N - S_M)$$

$$= \frac{1}{\varepsilon^2} \sum_{n=M+1}^N \text{Var} X_n$$

Przechodząc z N do ∞ i korzystając z ciągłości miary oraz $\sum_{i=1}^{\infty} \text{Var} X_i < \infty$

$$\mathbb{P}\left[\sup_{m \geq M} |S_m - S_M| \geq \varepsilon\right] \leq \frac{1}{\varepsilon^2} \sum_{n=M+1}^{\infty} \text{Var} X_n \xrightarrow{M \rightarrow \infty} 0$$

Zatem dla każdego $\varepsilon > 0$

$$\mathbb{P}\left[\sup_{\substack{n, m \geq M}} |S_m - S_n| \geq 2\varepsilon\right] \xrightarrow{M \rightarrow \infty} 0$$

||
 W_M .

Zatem $W_n \xrightarrow{\mathbb{P}} 0$. Z tw. Rieszera

W_n ma podciąg W_{n_k} zbiegący do 0 p.n.

Ale zauważmy, że ciąg $W_n \xrightarrow{p.n.} 0$. To

pokażuje, że ciąg S_n jest ciągiem

Cauchy'ego p.n., a więc S_n jest

zbieżny p.n.

